

No Silver Bullet

*Exploring and comparing deep learning
for text classification with traditional
machine learning methods*

Aanund Nordskog



Thesis submitted for the degree of
Master in Programming and Network
60 credits

Department of Informatics
Faculty of mathematics and natural sciences

UNIVERSITY OF OSLO

Spring 2019

No Silver Bullet

*Exploring and comparing deep learning
for text classification with traditional
machine learning methods*

Aanund Nordskog

© 2019 Aanund Nordskog

No Silver Bullet

<http://www.duo.uio.no/>

Printed: Representralen, University of Oslo

Abstract

With all the data available today the need to label and categorise data is more important than ever. There are many machine learning and deep learning models well equipped to classify data. However, to find the best model for a specific task is not simple.

In this thesis, the goal is to compare deep learning and traditional machine learning on text classification. Deep learning is the new hype, and it seems to be the go-to solution for many problems. However, deep learning has its pitfalls and challenges the user might not be aware of. So, to see if deep learning is the silver bullet, a comparison will be made between the deep learning models, RNN and CNN, and the traditional machine learning models, SVM and Naive Bayes, on text classification. The comparison will be on classification performance, training time and setup complexity.

To make the comparison a dataset will be made from football articles in VG.no and TV2.no, and each model will learn to classify paragraphs in these articles. The optimised models will be tested in an application on new data, and the performance will be analysed and compared.

The conclusion is that with a limited dataset with few samples, the traditional machine learning models is the better alternative. The reason for this is that the classification performance is only slightly lower than the deep learning models, but the training time is much lower, the setup is more straightforward, and it is lower maintenance. However, for a larger dataset, the overhead with deep learning might be worth the extra performance.

Contents

1	Introduction	1
1.1	Motivation	1
1.2	Research Goals	2
1.3	Scope and Limitations	3
1.4	Contribution	3
1.5	Thesis Outline	4
2	Background	5
2.1	Machine Learning	5
2.1.1	Data Sampling	6
2.1.2	Supervised Learning	7
2.1.3	Unsupervised Learning	7
2.1.4	Classification	8
2.1.5	Regression	9
2.1.6	Overfitting and Underfitting	9
2.1.7	Normalisation	9
2.1.8	Neural Networks	10
2.1.9	Cross-validation	11
2.1.10	Vectoriser	12
2.2	Deep Learning	15
2.2.1	Word Embedding	16
2.2.2	Dropout	17
2.3	Deep Learning Algorithms	17
2.3.1	Recurrent Neural Networks	17
2.3.2	Convolutional Neural Networks	20
2.4	Machine Learning Algorithms	21
2.4.1	Naive Bayes	21
2.4.2	Support Vector Machine	22
2.5	Related Work	23
3	Methodology	27
3.1	Environment	27
3.1.1	Hardware	27
3.1.2	software	28
3.2	Arx	32
3.2.1	Backend	32
3.2.2	Frontend	32

3.3	Data	32
3.3.1	Retrieving Data	32
3.3.2	Labelling Data	33
3.3.3	The Dataset	34
3.4	Metrics	37
3.5	Training Implementation	38
3.5.1	Database API	40
3.5.2	Data handling	40
3.5.3	Metrics	40
3.5.4	Algorithm Setup	40
3.5.5	Machine learning model architecture and parameters	41
3.5.6	Deep learning model architecture and parameters . .	44
3.6	Application Implementation	46
4	Experiment	49
4.1	Traditional Machine Learning Experiment	49
4.1.1	Naive Bayes	49
4.1.2	Linear SVC	55
4.1.3	SVC RBF	60
4.1.4	SVC Poly with degree 2	65
4.1.5	Summary of the Traditional Machine Learning Ex- periments	70
4.2	Deep Learning Experiments	70
4.2.1	RNN	70
4.2.2	CNN	77
4.2.3	Summary of the Deep Learning Experiments	84
4.3	Discussion	84
4.3.1	Performance	84
4.3.2	Time Consumption	86
4.3.3	Setup	87
4.3.4	Pitfalls	88
4.3.5	Improvements	88
4.3.6	Future Outlook	89
5	Conclusion	91
5.1	Contributions	91
5.2	Future Work	92
	Appendices	99
A	Experiments	101
A.1	Naive Bayes	101
A.1.1	Application Experiments	101
A.2	Linear SVC	103
A.2.1	Application Experiments	103
A.3	SVC RBF	105
A.3.1	Training Experiments	105
A.3.2	Application Experiments	106

A.4	SVC Poly	108
A.4.1	Training Experiments	108
A.4.2	Application Experiments	110
A.5	RNN	112
A.5.1	Application Experiments	112
A.6	CNN	114
A.6.1	Training Experiments	114
A.6.2	Application Experiments	124
B	Complete Result Overview	127
B.1	Naive Bayes	127
B.1.1	Ful Tables from Training Experiments	127
B.1.2	All Application Results	132
B.2	Linear SVC	142
B.2.1	Ful Tables from Training Experiments	142
B.2.2	All Application Results	146
B.3	SVC RBF	156
B.3.1	Ful Tables from Training Experiments	156
B.3.2	All Application Results	161
B.4	SVC Poly	172
B.4.1	Ful Tables from Training Experiments	172
B.4.2	All Application Results	179
B.5	RNN	190
B.5.1	Ful Tables from Training Experiments	190
B.5.2	All Application Results	198
B.6	CNN	208
B.6.1	Ful Tables from Training Experiments	208
B.6.2	All Application Results	236
C	Submitted Paper	247

List of Figures

2.1	Machine learning process	6
2.2	Classification and Regression	8
2.3	Overfitting and Underfitting	10
2.4	Neural network	11
2.5	Artificial Neuron	12
2.6	Dropout example	17
2.7	Unfolded RNN	18
2.8	Unfolded bidirectional RNN	19
2.9	RNN cells	19
2.10	Convolution in CNN	20
2.11	Convolution and pooling on text	21
3.1	Example of how the labelling is done with Arx	34
3.2	Example of how to fetch articles and paragraphs with a keyword in Arx	35
3.3	Example of a confusion matrix	38
3.4	Metric database table	39
3.5	File Structure	39
4.1	Naive Bayes training experiments with Bernoulli distribu- tion on different alpha values, for two different vectorizers .	51
4.2	Naive Bayes training experiments with Multinomial distri- bution on different alpha values, for two different vectorizers	51
4.3	Naive Bayes Confusion Matrices	53
4.4	Naive Bayes application results for Lucas Moura	54
4.5	Linear SVC training experiments on different C values . . .	56
4.6	Linear SVC training experiments on different intercept scaling values, when $c = 0.052$	56
4.7	Linear SVC training experiments on different tolerance values, when $c = 0.052$	56
4.8	Linear SVC Confusion Matrices	58
4.9	Linear SVC application results for Lucas Moura	59
4.10	SVC RBF training experiments on different C values	61
4.11	SVC RBF training experiments on different gamma values, when $c = 2.0$	61
4.12	SVC RBF Confusion Matrices	63
4.13	SVC RBF application results for Lucas Moura	64

4.14	SVC Poly training experiments on different C values textwidththen shrinking = false	66
4.15	SVC Poly training experiments on different gamma values, when c = 0.96 and shrinking = false	66
4.16	SVC Poly training experiments on different coef0 values, when c = 0.96, gamma = 1.2 and shrinking = false	66
4.17	SVC Poly Confusion Matrices	68
4.18	SVC Poly application results for Lucas Moura	69
4.19	RNN training experiments on different embedding dimensions, for four different LSTM layers	72
4.20	RNN training experiments on different dropout rates, for two different placements of the dropout layer, when embedding dimension is 125 and LSTM neurons is 105	73
4.21	RNN training experiments on different LSTM layers when embedding dimension is 125	73
4.22	RNN Confusion Matrices	75
4.23	RNN application results for Lucas Moura	76
4.24	CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size is 6 and pooling size is 2	79
4.25	CNN training experiments on different dense layers, when embedding dimension is 210, filter size is 182, Kernel size is 6 and pooling size is 2	80
4.26	CNN training experiments on different dropout rates, when embedding dimension is 210, filter size is 182, dense layer is 178, Kernel size is 6 and pooling size is 2	80
4.27	CNN training experiments on different filter sizes, when embedding dimension is 210, Kernel size is 6 and pooling size is 2	80
4.28	CNN Confusion Matrices	82
4.29	CNN application results for Lucas Moura	83
A.1	Naive Bayes application results for Morata	102
A.2	Linear SVC application results for Morata	104
A.3	SVC RBF training experiments on different C values, when shrinking = flase	106
A.4	SVC RBF training experiments on different gamma values, when c = 2.0 and shrinking = flase	106
A.5	SVC RBF application results for Morata	107
A.6	SVC Poly training experiments on different C values textwidththen shrinking = true	109
A.7	SVC Poly training experiments on different gamma values, when c = 0.96 and shrinking = true	109
A.8	SVC Poly training experiments on different coef0 values, when c = 0.96, gamma = 1.2 and shrinking = true	109
A.9	SVC Poly application results for Morata	111
A.10	RNN application results for Morata	113

A.11 CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 2	115
A.12 CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 4	117
A.13 CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 4 and pooling size = 4	119
A.14 CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 2 and pooling size = 4	121
A.15 CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 8 and pooling size = 4	123
A.16 CNN application results for Morata	125
B.1 Naive Bayes application results on the "Goal/Assist" class, for Lucas Moura	133
B.2 Naive Bayes application results on the "Goal/Assist" class, for Lucas Moura	134
B.3 Naive Bayes application results on the "Quotes" class, for Lucas Moura	135
B.4 Naive Bayes application results on the "Irrelevant" class, for Lucas Moura	136
B.5 Naive Bayes application results on the "Ignore" class, for Lucas Moura	137
B.6 Naive Bayes application results on the "Goal/Assist" class, for Morata	138
B.7 Naive Bayes application results on the "Transfer" class, for Morata	139
B.8 Naive Bayes application results on the "Quotes" class, for Morata	140
B.9 Naive Bayes application results on the "Irrelevant" class, for Morata	141
B.10 Linear SVC application results on the "Goal/Assist" class, for Lucas Moura	147
B.11 Linear SVC application results on the "Goal/Assist" class, for Lucas Moura	148
B.12 Linear SVC application results on the "Quotes" class, for Lucas Moura	149
B.13 Linear SVC application results on the "Irrelevant" class, for Lucas Moura	150
B.14 Linear SVC application results on the "Ignore" class, for Lucas Moura	151
B.15 Linear SVC application results on the "Goal/Assist" class, for Morata	152

B.16	Linear SVC application results on the "Transfer" class, for Morata	153
B.17	Linear SVC application results on the "Quotes" class, for Morata	154
B.18	Linear SVC application results on the "Irrelevant" class, for Morata	155
B.19	SVC RBF application results on the "Goal/Assist" class, for Lucas Moura	162
B.20	SVC RBF application results on the "Goal/Assist" class, for Lucas Moura	163
B.21	SVC RBF application results on the "Quotes" class, for Lucas Moura	164
B.22	SVC RBF application results on the "Irrelevant" class, for Lucas Moura	165
B.23	SVC RBF application results on the "Irrelevant" class, for Lucas Moura	166
B.24	SVC RBF application results on the "Ignore" class, for Lucas Moura	167
B.25	SVC RBF application results on the "Goal/Assist" class, for Morata	168
B.26	SVC RBF application results on the "Transfer" class, for Morata	169
B.27	SVC RBF application results on the "Quotes" class, for Morata	170
B.28	SVC RBF application results on the "Irrelevant" class, for Morata	171
B.29	SVC Poly application results on the "Goal/Assist" class, for Lucas Moura	180
B.30	SVC Poly application results on the "Goal/Assist" class, for Lucas Moura	181
B.31	SVC Poly application results on the "Quotes" class, for Lucas Moura	182
B.32	SVC Poly application results on the "Irrelevant" class, for Lucas Moura	183
B.33	SVC Poly application results on the "Irrelevant" class, for Lucas Moura	184
B.34	SVC Poly application results on the "Ignore" class, for Lucas Moura	185
B.35	SVC Poly application results on the "Goal/Assist" class, for Morata	186
B.36	SVC Poly application results on the "Transfer" class, for Morata	187
B.37	SVC Poly application results on the "Quotes" class, for Morata	188
B.38	SVC Poly application results on the "Irrelevant" class, for Morata	189
B.39	RNN application results on the "Goal/Assist" class, for Lucas Moura	199
B.40	RNN application results on the "Goal/Assist" class, for Lucas Moura	200
B.41	RNN application results on the "Quotes" class, for Lucas Moura	201

B.42 RNN application results on the "Irrelevant" class, for Lucas Moura	202
B.43 RNN application results on the "Irrelevant" class, for Lucas Moura	203
B.44 RNN application results on the "Ignore" class, for Lucas Moura	203
B.45 RNN application results on the "Goal/Assist" class, for Morata	204
B.46 RNN application results on the "Transfer" class, for Morata .	205
B.47 RNN application results on the "Quotes" class, for Morata .	206
B.48 RNN application results on the "Irrelevant" class, for Morata	207
B.49 CNN application results on the "Goal/Assist" class, for Lucas Moura	237
B.50 CNN application results on the "Goal/Assist" class, for Lucas Moura	238
B.51 CNN application results on the "Quotes" class, for Lucas Moura	239
B.52 CNN application results on the "Irrelevant" class, for Lucas Moura	240
B.53 CNN application results on the "Irrelevant" class, for Lucas Moura	241
B.54 CNN application results on the "Ignore" class, for Lucas Moura	241
B.55 CNN application results on the "Goal/Assist" class, for Morata	242
B.56 CNN application results on the "Transfer" class, for Morata .	243
B.57 CNN application results on the "Quotes" class, for Morata .	244
B.58 CNN application results on the "Irrelevant" class, for Morata	245

List of Tables

2.1	Input-output pair	7
2.2	5-Fold Cross-validation	12
2.3	Summary of the dataset SST-1 and TREC	24
2.4	Accuracy score for the different models on the SST-1 and TREC dataset	24
3.1	Hardware specifications	28
3.2	Software specifications	28
3.3	View of how the data is stored in the database	33
3.4	Number of data samples per class in the training set	35
3.5	Number of data samples per class in the test set	35
4.1	Top MCC scores for Naive Bayes with Bernoulli distribution on different alpha values, for two different vectorizers	50
4.2	Top MCC scores for Naive Bayes with Multinomial distribution on different alpha values, for two different vectorizers	51
4.3	Metric scores from application experiments, with Naive Bayes as the classifier	53
4.4	Top MCC scores for linear SVC on different C values	55
4.5	Top MCC scores for linear SVC on different intercept scaling values, when $C = 0.052$	56
4.6	Top MCC scores for linear SVC on different tolerance values, when $C = 0.052$	56
4.7	Metric scores from application experiments, with Linear SVC as the classifier	57
4.8	Top MCC scores for SVC RBF on different C values when shrinking is true	60
4.9	Top MCC scores for SVC RBF on different gamma values, when $c = 2.0$ and shrinking is true	61
4.10	Metric scores from application experiments, with SVC RBF as the classifier	62
4.11	Top MCC scores for SVC Poly on different C values when shrinking = false	65
4.12	Top MCC scores for SVC Poly on different gamma values, when $c = 0.96$ and shrinking = false	66
4.13	Top MCC scores for SVC Poly on different coef0 values, when $c = 0.96$, $\gamma = 1.2$ and shrinking = false	66

4.14	Metric scores from application experiments, with SVC Poly as the classifier	67
4.15	Top MCC scores for RNN on different embedding dimensions, for four different LSTM layers	71
4.16	Top MCC scores for RNN on different LSTM layers when embedding dimension is 125	72
4.17	Top MCC scores for RNN on different dropout rates, for two different placements of the dropout layer, when embedding dimension is 125 and LSTM neurons is 105	72
4.18	Metric scores from application experiments, with RNN as the classifier	74
4.19	Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size is 6 and pooling size is 2	78
4.20	Top MCC scores for CNN on different filter sizes, when embedding dimension is 210, Kernel size is 6 and pooling size is 2	78
4.21	Top MCC scores for CNN on different dense layers, when embedding dimension is 210, filter size is 182, Kernel size is 6 and pooling size is 2	78
4.22	Top MCC scores for CNN on different dropout rates, when embedding dimension is 210, filter size is 182, dense layer is 178, Kernel size is 6 and pooling size is 2	78
4.23	Metric scores from application experiments, with CNN as the classifier	81
4.24	Shows the result of the training experiments	84
4.25	Shows the result of the application experiments	85
4.26	Summary of the SST-1, TREC and the dataset used in this research	85
4.27	Accuracy score for the different models tested on the SST-1, TREC and the dataset used in this research.	86
4.28	Show the total training time for each algorithm	86
A.1	Top MCC scores for SVC RBF on different C values, when shrinking = flase	105
A.2	Top MCC scores for SVC RBF on different gamma values, when c = 2.0 and shrinking = false	106
A.3	Top MCC scores for SVC Poly on different C values when shrinking = true	108
A.4	Top MCC scores for SVC Poly on different gamma values, when c = 0.96 and shrinking = true	109
A.5	Top MCC scores for SVC Poly on different coef0 values, when c = 0.96, gamma = 1.2 and shrinking = true	109
A.6	Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 2	116

A.7	Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 4	116
A.8	Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 4 and pooling size = 4	118
A.9	Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 2 and pooling size = 4	120
A.10	Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 8 and pooling size = 4	122
B.1	Performances and execution times for Naive Bayes on different alpha values when using Bernoulli distribution and count vectorization	128
B.2	Performances and execution times for Naive Bayes on different alpha values when using Bernoulli distribution and tfidf vectorization	129
B.3	Performances and execution times for Naive Bayes on different alpha values when using Multinomial distribution and count vectorization	130
B.4	Performances and execution times for Naive Bayes on different alpha values when using Multinomial distribution and tfidf vectorization	131
B.5	Performances and execution times for linear SVC on different C values when tolerance is set to 0.0001 and intercept scaling is 2	143
B.6	Performances and execution times for linear SVC on different intercept scaling values when tolerance is set to 0.0001 and c is 0.052	144
B.7	Performances and execution times for linear SVC on different tolerance values when c is set to 0.052 and intercept scaling is 2	145
B.8	Performances and execution times for SVC RBF on different c values when shrinking is false	157
B.9	Performances and execution times for SVC RBF on different gamma values when C is set to 2.0 and shrinking is false	158
B.10	Performances and execution times for SVC RBF on different c values when shrinking is true	159
B.11	Performances and execution times for SVC RBF on different gamma values when C is set to 2.0 and shrinking is true	160
B.12	Performances and execution times for SVC Poly on different C values when shrinking is false	173
B.13	Performances and execution times for SVC Poly on different gamma values when C is 0.96 and shrinking is false	174

B.14	Performances and execution times for SVC Poly on different Coef0 values when Gamma is 1.2, c is 0.96 and shrinking is false	175
B.15	Performances and execution times for SVC Poly on different C values when shrinking is true	176
B.16	Performances and execution times for SVC Poly on different gamma values when C is 0.96 and shrinking is true	177
B.17	Performances and execution times for SVC Poly on different Coef0 values when Gamma is 1.2, c is 0.96 and shrinking is true	178
B.18	Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 256	191
B.19	Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 128	192
B.20	Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 64	193
B.21	Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 32	194
B.22	Performances and execution times for RNN on different LSTM layers, when embedding dimension is 125	195
B.23	Performances and execution times for RNN on different dropout rates, when the dropout layer is before the LSTM layer, embedding dimension is 125 and LSTM neurons is 105	196
B.24	Performances and execution times for RNN on different dropout rates, when the dropout layer is after the LSTM layer, embedding dimension is 125 and LSTM neurons is 105	197
B.25	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 2 and pooling size = 4	209
B.26	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 2 and pooling size = 4	210
B.27	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 2 and pooling size = 4	211
B.28	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 2 and pooling size = 4	212
B.29	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 3 and pooling size = 2	213
B.30	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 3 and pooling size = 2	214
B.31	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 3 and pooling size = 2	215

B.32	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 3 and pooling size = 2	216
B.33	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 3 and pooling size = 4	217
B.34	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 3 and pooling size = 4	218
B.35	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 3 and pooling size = 4	219
B.36	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 3 and pooling size = 4	220
B.37	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 4 and pooling size = 4	221
B.38	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 4 and pooling size = 4	222
B.39	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 4 and pooling size = 4	223
B.40	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 4 and pooling size = 4	224
B.41	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 6 and pooling size = 2	225
B.42	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 6 and pooling size = 2	226
B.43	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 6 and pooling size = 2	227
B.44	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 6 and pooling size = 2	228
B.45	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 8 and pooling size = 4	229
B.46	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 8 and pooling size = 4	230
B.47	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 8 and pooling size = 4	231

B.48	Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 8 and pooling size = 4	232
B.49	Performances and execution times for CNN on different filter sizes, when embedding dimension is 210	233
B.50	Performances and execution times for CNN on different dense layers, when embedding dimension is 210 and filter size is 182	234
B.51	Performances and execution times for CNN on different dropout rates, when embedding dimension is 210, filter size is 182 and dense layer is 178	235

Acknowledgements

I want to thank my supervisors Michael Riegler and Pål Halvorsen for good guidance.

Chapter 1

Introduction

1.1 Motivation

The world wide web is almost an endless source of information, and a lot of this information comes in the form of text. From 2015 to 2018 the total number of websites have doubled, reaching 1.63 billion sites in 2018 [39] . It must be noted that around 75% of these sites are inactive, regardless, the trend is clear, the internet is exploding. With this amount of data available the need to categorize and label information is more important than ever.

Along with the increase in data the popularity of machine learning has also increased. The search term from google trends for machine learning and deep learning over the past five years shows that the popularity has grown significantly [12] [13]. Big tech-corporations such as Google and Microsoft have invested a lot of time and effort in deep learning. For example, Google has created Tensorflow, and Microsoft has created CNTK, which are both open source deep learning libraries. Even though this hype has come the last few years, the technology is not new. Deep learning has roots that go back decades [32]. However, the hardware power was too poor for deep learning to be used efficiently, but with today's powerful GPUs the training of deep neural networks is much faster than it used to be [32].

The popularity of deep learning is not without reason, for it has shown extraordinary results in many different application. In image classification CNN have shown state-of-the-art performance [19], Google translate is using RNN to translate from one language to another [21], and in NLP both RNN and CNN have seen a massive rise in popularity and state-of-the-art performance [42]. The mainstream media have also covered deep learning, the New York Times¹ had an article about the promise of deep learning on its front page, and Dagbladet² had a story about AlphaZero [35], the google

¹<https://www.nytimes.com/2012/11/24/science/scientists-see-advances-in-deep-learning-a-part-of-artificial-intelligence.html>

²<https://www.dagbladet.no/sport/68990539>

deep learning chess computer, when it beat Stockfish. With this popularity, it seems like deep learning is used to solve many problems. Nevertheless, deep learning cannot be used to solve all problems, and it is essential to know that deep learning comes with many pitfalls the user might not be aware of [23].

Even though machine learning and deep learning models have shown great promise and all the major tech companies are researching this area, there is still much research to be done in the field. There seems to be an endless number of different models to choose from, and finding the right model for a particular problem is not a simple task. Since no mathematical theorem states when to use a particular machine learning model for a problem, the only option is to do research, to find the optimal solutions for certain problems.

This thesis will further the research in the field by comparing deep learning and traditional machine learning on text classification. By seeing how different models perform on a specific text classification problem, the pros and cons of deep learning might come to light.

1.2 Research Goals

This thesis will look at how deep learning and traditional machine learning methods perform on text classification, more specifically how the methods perform when classifying paragraphs in football articles. The goal is to train a wide range of deep learning and traditional machine learning models and see how they perform. The models will be compared on classification performance, training time and setup complexity. Two methods will be used to determine the classification performance of the different models. The first method will compare the performance during training, i.e., metrics will be calculated during training and analysed. The second method will use the models created in method one and test how they perform in an application on new data. The application will present a visual result of how the models perform.

The data the models will use during training in method one have to be collected and labelled. Articles will be extracted from VG.no and TV2.no, and paragraphs from these articles will be labelled and stored in a database. An application will be created to make the labelling of the paragraphs easier.

The application that will determine the performance of the models in method two has to be created. It will display a visual representation of the paragraphs that have been classified by the different algorithms. New data will be collected and labelled for the application, and this data will be collected three months after the training set was created.

The research question then becomes: **How does deep learning compare to traditional machine learning on text classification when it comes to**

classification performance, training time and setup complexity?

Main Objective - Make a thorough comparison between deep learning and traditional machine learning algorithms on text classification. With a dataset created from football article from VG and TV2.

Sub-objective 1 - Create a dataset that will be used to train and test the deep learning and traditional machine learning algorithms.

Sub-objective 2 - Create an application that will (1) help to create the dataset and (2) show a visual representation of how the different models perform.

1.3 Scope and Limitations

There are many different models to choose from, but because it takes considerable time and effort to set up the different algorithms, a chosen few are selected. The traditional machine learning methods are SVM and Naive Bayes, and the deep learning models are CNN and RNN.

There are many ways to configure the CNN and RNN model, but due to the time it would take to test all the different configuration, only certain networks are tested. For example, RNN can be created with LSTM, GRU etc architecture, but in this thesis, only LSTM architecture will be tested.

The football articles are collected from Norwegian newspapers, and there are no libraries for pre-processing Norwegian text. As a result, there will be no pre-processing of the text in the dataset, except for removing special characters.

1.4 Contribution

The main contributions of the thesis are:

- Presented a thorough comparison between traditional machine learning and deep learning on classification performance, training time and setup complexity. Also, highlighted pitfall to be aware of when using deep learning.
- Created a dataset with 5500 training samples and 600 testing samples from the two Norwegian newspapers, TV2.no and VG.no.
- Made an application that can label paragraphs from articles, and classify paragraphs from articles with six different machine learning models.
- A paper about the research has been submitted to the CBMI³ 2019 conference. The paper is included in Appendix C.

³<http://cbmi2019.org/>

1.5 Thesis Outline

Chapter 2, Background - Presents the fundamental theory behind machine learning and deep learning, and describes the different models used in the thesis.

Chapter 3, Methodology - Describes the dataset, how it was created and gives a description of the different classes. There is a detailed description of the implementation of the training process, and a description of the implementation of the application.

Chapter 4, Experiment - Presents the result from the training experiments and shows how the different models performed in the application. The results are discussed and thoroughly explained.

Chapter 5, Conclusion - Summarises the findings, and explores how to further extend the thesis.

Chapter 2

Background

To get a general understanding of the research in this thesis, this chapter will explain the teori behind Machine learning and Deep learning. Furthermore, conventional techniques surrounding machine learning will be described, for example, converting words to numbers and cross-validation. Lastly, the machine learning models SVM, Naive Bayes, CNN and RNN will be explained in detail, and research done with these models on two different datasets will be examined.

2.1 Machine Learning

The field of machine learning is concerned with the question of how to construct computer programs that automatically improve with experience. [25]

Machine learning can solve problems that are too difficult to solve with conventional algorithms designed by programmers. [11] For example, we can't make an algorithm that can determine whether an email is spam or non-spam. However, we can construct a computer program that can learn the difference between spam and non-spam. [2] Making computer programs learn from past experiences can help solve many types of problems.

A computer program learns when it improves its performance P on a task T when given some experience E . [25] A task is the same as the problem we want to solve, e.g., determining if an email is spam or non-spam. The performance is how well the computer program does the task, e.g., how good the computer is at deciding what spam is. The experience is data the computer program gets to improve the performance, e.g., by giving the computer program a set of spam emails, it can look at the details of this set and help decide what a spam mail is. Next, we will look at a general overview of the machine learning process.

From figure 2.1 the machine learning process is divided into three phases; phase one pre-processing, phase two learning and phase three prediction.

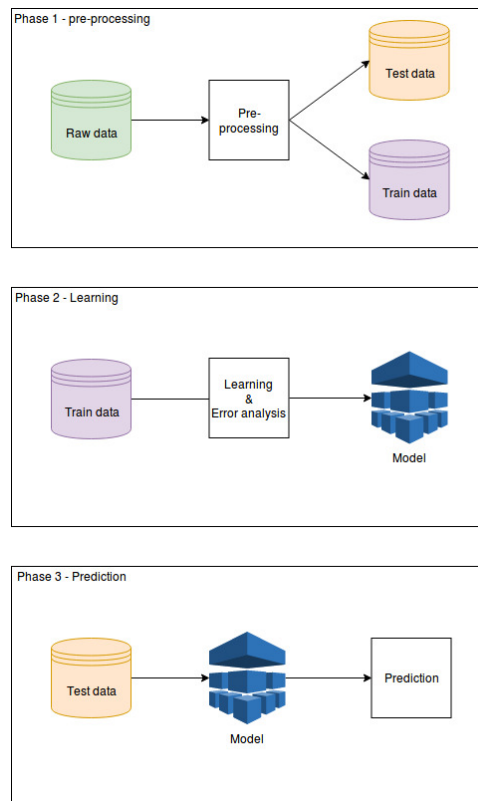


Figure 2.1: Machine learning process

Phase one (pre-processing), prepares the data and generates the features, for example, to remove non-informative words, or to stem certain words. The final step of this phase is splitting the data into a training set and a test set. Phase two (learning), makes the final model by using the training set from phase one. We also apply methods to avoid overfitting the model, such as cross-validation, model comparison or some other method. Lastly, the performance of the machine learning model is measured, there are several ways of doing this, for example by using accuracy, recall etc. Phase three (prediction), tests the test set on the model and checks if the performance is acceptable. If the performance is much lower than the training set, the model might be overfitted.

We divide most machine learning algorithms into two categories supervised learning and unsupervised learning. In this section, we will describe machine learning and focus primarily on supervised learning. But first, we will explain the process of sampling data from a dataset.

2.1.1 Data Sampling

To train a machine learning model we need to collect data samples. The programmer makes the data samples from the raw data available, for example, a large dataset of newspaper articles, twitter messages or some

	Training set					
Input	1	2	3	4	5	6
Output	1	4	9	16	25	?

Table 2.1: Input-output pair

other dataset relevant to the machine learning model. In supervised learning (section 2.1.2) the sample data is an input-output pair, i.e., standard input, along with a label to place this input. When there are enough data samples, the samples are divided into a training set and a test set. The training set is used to fit the model, and the test set is used to measure how accurate the model is.

The more training data the machine learning model gets, the more accurate it will be. However, gathering thousands of data samples can be a demanding task. The data gathered must be random, contain little noise and preferably be a uniform representation of the different labels, i.e., stratified sampling. For example, if we want our model to predict if a picture is of a cat, a dog or a pig. The training data must contain approximately the same number of samples for each animal.

2.1.2 Supervied Learning

In supervised learning, the primary goal is to approximate a function based on input-output pairs. The function is the machine learning model, the finished product that should be able to map new inputs to the correct output. The input-output pair is where the supervision comes in, we use normal input, but a 'supervisor' tells the computer where the input belongs. For example, in table 2.1 we have a set of input-output pairs, the goal is to use this data to make a model that can be generalised to new input. By giving the model a large enough training set, we hope that the function will approximate to X^2 . The hope is that by providing the trained model 6 as input it will generate 36 as output.

There are two subgroups of supervised learning, regression and classification. In regression the output is continuous, and In classification the output is discrete. Next, we will look at both of these subgroups.

2.1.3 Unsupervied Learning

In unsupervised learning, there are no input-output pairs like there is in supervised learning. Instead, there is only an input that maps to an undefined category. The goal of unsupervised learning is to find a structure in the input that belongs to a group of inputs with the same structure. For example, if the data is a tuple with hight and weight, we might get two clusters of points. One cluster might represent males, and the other cluster might represent females. In this thesis we will focus on supervised




Figure 2.2: Illustration of classification and regression. In classification, the line divides the classes, and in regression, the line represents the data points

learning, so we will not go into detail on the different unsupervised learning methods.

2.1.4 Classification

In classification problems, the goal is to approximate a function f that can map some input variable X to some discrete output variable Y . The output variable is discrete because there are only finite many categories to map the input variable X too, and the input should map to exactly one class. An example of classification would be assigning a car brand to a car, the input is a picture of a car, and the output is BMW, Opel, Audi etc. It is common to use a probability score to determine which class the input belongs too, for example, a picture of a car gets a score of 0.7 that it belongs to the class BMW.

If there are only two classes it is a binary classification problem, for example, the spam mail discussed earlier, class one is spam, and class two is non-spam. Or it can be many classes then it is called multi-class classification, for example, like the car example above, every car brand is a class. There are techniques to make a multi-class classifier from a binary classifier. Two popular methods to do this is called one-vs-rest and one-vs-all. In one-vs-one there are created $k(k - 1)/2$ (where k is the different number of classes) binary classifiers, and in one-vs-all there are created one binary classifier for each class.

Classifying an input to one distinct class is not always possible. For example, when an input maps to the 'border' of two classes or when it might not be possible to find an appropriate category for the input. All these factors can make the model less accurate, and prone to overfitting.

2.1.5 Regression

Regression models map the input variable to a continuous output variable, this is typically when the output is a number. [2] When predicting the price of a house we use regression. The input might be the size and the location of the house, and the output is a positive number representing the cost. However, if we want to predict if the house is expensive or cheap, then it would be a classification problem. There are different types of regression models, for example, linear regression, polynomial regression, non-linear regression etc..

2.1.6 Overfitting and Underfitting

It is essential for performance that the machine learning model is as general as possible. One data point should not weigh more or less than other data points. If it does, then the model will not be general over a set of data points, but will instead be more specific for certain types of inputs. Another factor that can cause the model to lose its generality is if there is a lot of noise in the training set, for example, bad samples or outliers. And lastly, if there are too few data samples it might be tough to make the machine learning model general.

Underfitting is when the model does not represent the data points precisely (figure 2.3 left). For example, if we have fitted the model to be a linear representation of the data points, but a polynomial model should represent the data samples. Underfitting happens typically when there is too little training data, or when the training set is a poor representation of the entire data set.

On the other hand, overfitting is when the model represents the data points too precisely (figure 2.3 right). For example, if we have fitted the model to touch every data point in the training set. Then the model will be very good at predicting the training set, but will not be able to predict new data points very well. When this happens, we say that the model is too complex.

The training set used to train the machine learning system can contain outliers, noise and other abnormal data points. These data points are a poor representation of the data model, and if there are too many of them, the model will not be able to fit the data points appropriately. It is therefore important to be thorough when making the training set and to have enough data samples. There are also some techniques to overcome overfitting, one popular choice is cross-validation.

2.1.7 Normalisation

Normalisation is a way of scaling all the data samples to the same scale. It is a problem when a large data sample is given more weight during training




Figure 2.3: Illustration of underfitting and overfitting. The left figure shows an example of underfitting, where the model is trying to use a linear function to fit a polynomial pattern. The centre figure shows a perfect fit, where the model approximates the data perfectly. The right figure shows overfitting, where the model is trying to fit the data to precisely. (figure taken from [40])

than a smaller sample, without describing the model in a better way. That's why we have to pre-process the data by using methods like normalisation to make the samples accurate.

In text processing, the normalisation is used to remove stop words, stem certain words and interpret slang. Stop words are common words that provide no information, words like "the", "is", "at" et cetera. Stemming words are important to reduce the word space, instead of having the words "going", "went" and "goes", the word "go" is used for all of them. The use of slang can be a problem for the machine learning model. The model doesn't now that "how r u?" is the same as "how are you?". The same problem goes for spelling mistakes.

2.1.8 Neural Networks

Artificial neural networks take its inspiration from how the brain works in humans and other animals. Our brain is a network of neurons that work together to interpret input we receive from our senses, and this is what we want to achieve in artificial neural networks. It is not possible to replicate the human brain, because of its enormous size, but it is instead an inspiration for how a machine learning algorithm can learn. [11]

There are typically three layers in an artificial neural network (see figure 2.4), the input layer, the hidden layer, and the output layer. The complexity of the network depends on the architecture, for example, a multilayer perceptron has three or more layers, one input layer, one output layer and one or more hidden layers. It is a feedforward neural network, i.e., the neurons can only send the output to the next layer in the network. There are no cycles or loop in the network. The multilayer perceptron is the oldest




Figure 2.4: A fully connected neural network. With an input layer, two hidden layers, and an output layer.

and simplest neural network. Two other architectures are the convolutional neural network and the recurrent neural networks, and we will look at these two in detail in the next section.

Each layer is built up of artificial neurons that communicate with each other and forms a link between the layers in the network. An artificial neuron is a function f that takes an input x . This input can either be the start input, from the input layer, or the output from another artificial neuron in the hidden layer. The function f is associated with an activation function ϕ , the purpose of the activation function is to determine if the neuron is on or off. The function converges to 0 if the input is a large negative number and converges to 1 if the number is a large positive number. The input is the expression $(wx + b)$, where x is the input from the function f , w is a weight that determines the significant of x , and b is a bias. So we get:

$$f_i(x) = \phi(w_i x + b_i)$$

Here are some popular activation functions:

The sigmoid function

$$\phi(x) = \frac{1}{(1 + e^{-x})}$$

The rectified linear unit (ReLU) function

$$\phi(x) = \max(0, x)$$

In the next section, we will look at deep learning in detail, and see how neural networks can learn using stochastic gradient descent and backpropagation.

2.1.9 Cross-validation

Cross-validation is a method that divides the training data into two parts, one part to train the model and another part to validate the model. By




Figure 2.5: The inside of a neuron. The input is multiplied with the weight matrix, then the bias matrix is added to the expression (not shown in the figure), and lastly, the activation function is applied

	Training set				Validation set
Model 1	f_1	f_2	f_3	f_4	f_5
Model 2	f_1	f_2	f_3	f_5	f_4
Model 3	f_1	f_2	f_4	f_5	f_3
Model 4	f_1	f_3	f_4	f_5	f_2
Model 5	f_2	f_3	f_4	f_5	f_1

Table 2.2: 5-Fold Cross-validation

separating the data this way, it is easier to determine how well the model will perform on unseen data.

One example of cross-validation is k-fold cross-validation, in this variant of cross-validation, we divide the training set into k equal parts. Where $K - 1$ of these parts train the model, and one part validates the model. Every subset will be the validation set one time. If we use 5-fold cross-validation the training set and test set will be as shown in table 2.2. The benefits of using k-fold cross-validation are that you create many models with the same dataset, and the average over the k models will say how well the model is doing. It is an excellent method to detect overfitting and underfitting. Using cross-validation will, of course, cost you more time, since you are performing the same operation k times.

One popular variant is stratified 10-fold cross-validation [18], stratified means that every fold should include the same amount of data samples. For example, if there are two classes, and both of those classes have an equal amount of data samples, then each fold should contain 50% of each class.

2.1.10 Vectoriser

Words can not be used directly by a machine learning algorithm because words are just characters, and a character is only a number. So if we use words as input, the algorithms wouldn't be able to distinguish between the word "was" and "saw", because they use the same characters. The solution is to represent every word with a unique number.

Bag of Words

There are different methods to represent words as numbers. One common approach is Bag of Words (BoW). This method constructs a vocabulary of the training set, where all the words in the training set get a unique position. Every data sample is a vector of the entire vocabulary, with ones where the words match and zero everywhere else. For example, if we have the following text from Charles Dickens "A Tale of Two Cities" (this example is taken from [7]):

It was the best of times,
it was the worst of times,
it was the age of wisdom,
it was the age of foolishness,

The vocabulary will look like this:

- it
- was
- the
- best
- of
- times
- wisdom
- age
- worst
- foolishness

There are ten unique words out of the 24 words that make up the entire text. If we use each sentence as a training sample the first sentence will look like this:

- it: 1
- was: 1
- the: 1
- best: 1
- of: 1
- times: 1
- wisdom: 0
- age: 0

- worst: 0
- foolishness: 0

Where one represents the presence of a word and zero the absence. The vectors that would be given to the machine learning algorithm for the four sentences would look like this:

$$\begin{aligned} \textit{sentence1} &= [1, 1, 1, 1, 1, 1, 0, 0, 0, 0] \\ \textit{sentence2} &= [1, 1, 1, 0, 1, 1, 0, 0, 1, 0] \\ \textit{sentence3} &= [1, 1, 1, 0, 1, 0, 1, 1, 0, 0] \\ \textit{sentence4} &= [1, 1, 1, 0, 1, 0, 0, 1, 0, 1] \end{aligned}$$

Three common ways to score the words in the document are, binary, count and Tf-idf. The example above uses binary word scoring, the words are either there or they are not. Another way to score the words are by counting the occurrence each word have in the documents. For example, in the case above, the word "the" would have a score of 4, because it appears four times in the text. However, this method gives a lot of weight to meaningless words like "the", "a" and "is", and little weight to interesting terms that seldom appears. Tf-idf solves this problem by rescaling the frequency of words by how often they appear in all documents. For example, the word "the" appears frequent in all documents and will, therefore, be given less weight.

There are some shortcomings with the bag of words technique. The first thing to note is that for large vocabularies the vector representation of the data samples will be huge. These vectors will consist of mostly zeros, these vectors are called sparse vector, and they require a lot of memory. The second limitation with Bag of Words is that the order of the words does not matter, and in most cases, that assumption is wrong.

Tokeniser

Another way to represent words as vectors is to give each word a unique id that the algorithm use during training. For example, if we use the vocabulary from above we get the following word to number representation:

- it: 0
- was: 1
- the: 2
- best: 3
- of: 4

- times: 5
- wisdom: 6
- age: 7
- worst: 8
- foolishness: 9

The vectors that would be given to the machine learning algorithm for the four sentences would look like this:

$$\text{sentence1} = [0, 1, 2, 3, 4, 5]$$

$$\text{sentence2} = [0, 1, 2, 8, 4, 5]$$

$$\text{sentence3} = [0, 1, 2, 7, 4, 6]$$

$$\text{sentence4} = [0, 1, 2, 7, 4, 9]$$

This method preserves the order of the words and is not so hard on memory compared to Bag of Words.

2.2 Deep Learning

Deep learning is a subset of machine learning that uses representation learning as a method to interpret real-world problems. The best approach to AI is by the use of machine learning, and some say it is the only viable option to make AI systems that can interpret and solve real-world problems [11] [s.8]. Deep learning's approach to represent real-world problems is by breaking the problem into abstraction levels, where the input is the lowest abstraction level, and the output is the highest abstraction level. We begin with basic input data, and as we go through the network, the system interprets the input into higher and higher abstractions. For example, if we want to identify an object in a picture. The input is the pixel values of the image, and every step will try to say something more concrete about what the image is. The first step seeks to identify edges based on the pixel values, the second step looks for corners based on the edges found in the first step, and so on, until the last step where the system can identify the object in the picture. The key aspect of deep learning is that people do not engineer these steps, they are learned from data using a general-purpose learning procedure. [20]

Say we want to make a system that can classify paragraphs in a football article to the classes quote, experts opinion, reporter question and goal description. The input to the system will be a paragraph transformed into a vector of numbers, and the output is a vector of probability scores. These scores determine to which class the input belongs. For example, if we have the paragraph "Cristiano Ronaldo scored a free kick against Napoli" we first

transform this into a vector of numbers (more on this transformation later), and then we feed this vector into the deep learning system. After multiple calculations in the hidden layer, we will get an output with different scores, if the model is accurate the score which corresponds to the class goal description will be the highest.

We must train the model with many data samples to achieve this accuracy. The approach to train a deep learning model is to look at the output scores and compare this value to the expected value. Typically if the output is a probability score that sums to one, the expected value for the different classes will be on the form $[0, 0, 1]$. We use a loss function to calculate the difference between the result and the expected value. Then we use this function to adjust the internal parameters of the model, such that the error becomes as small as possible. The internal parameters are numbers, and we refer to them as weights. In large deep learning systems, there can be millions of weights. The way we go about adjusting these weight vectors is by using a method called backpropagation and gradient descent. The gradient vector points in the direction of where the function increases, so we want to take the negative of the gradient vector and add this to the weight, this will bring us closer to the minimum value of the function which is where the output error is low on average. A conventional method to do this in deep learning is by using stochastic gradient descent.

Deep learning has been around since the 1960s and 1970s, but it wasn't before 1981 that backpropagations were used to train the networks. Because of several factors, among them, poor computational power and lack of data, deep learning never became a popular method. It wasn't before 2000 that deep learning attracted attention, mainly because of outperforming traditional machine learning methods in many essential applications. In 2009 deep learning won its first official competition using RNN, and it was around this time it was possible to train deep learning models using GPU instead of CPU, which made the training many times faster. And since then deep learning has achieved state-of-the-art performance in many fields, for example, superhuman visual pattern recognition using convolutional neural networks, and state-of-the-art performance in speech recognition [32]. Convolution neural networks have shown excellent performance in sentiment analysis and question categorisation [17].

2.2.1 Word Embedding

Some words are more closely related than other words. For example, "blue" and "red" are more related than "blue" and "horse". Word embedding is a method to connect words in a way that makes sense to the underlying data. Related words should be "placed" closer together.

Word embedding has become very popular in natural language processing and is a tool that is usually used in deep learning for text classification




Figure 2.6: Dropout in a neural network. The left figure shows a normal neural network with two hidden layers. The right figure shows the same network but with dropout applied.

tasks. The embedding layer is the first layer of the neural network and learns along with the rest of the network during training. It is also possible to use pre-trained embeddings, for example, Word2Vec and GloVe.

2.2.2 Dropout

Dropout [38] is a technique to help avoid overfitting deep neural networks. It works by dropping a per cent of the neurons in the network during training. The dropout rate determines how many neurons that should be ignored during training, for example, a dropout rate of 0.5 would ignore half the neurons in the network at random. The optimal dropout rate varies from network to network and is a parameter that must be tuned during training. An example of dropout is shown in figure 2.6.

2.3 Deep Learning Algorithms

2.3.1 Recurrent Neural Networks

Recurrent neural networks (RNN) [11] are designed to process sequential data on the form x_1, x_2, \dots, x_t . For example, a sentence or paragraph where each data point represents a word. The input sequences can be of varying length, and the RNN can produce an arbitrary number of outputs. This comes in handy when translating from one language to another language. For example, one sentence in English can be eight words and the same sentence in Norwegian can be ten words.

At each step in the RNN, the network inputs a data point x_t , does some computations in the hidden layer, and stores the results in the internal state H_t , as shown in figure 2.7. The U is the input matrix weight, W is the internal weight matrix, and V is the output weight matrix. These weights are shared between all the steps in the RNN.

One important feature with RNNs is that it is possible to share parameters across different parts of the model. This feature is especially useful when




Figure 2.7: An unfolded recurrent neural network. The x is the input to the RNN and y is the output. The H is the hidden layer of the network. The matrix U connects the input to the hidden layer, the matrix V connects the hidden layer to the output and the matrix W connects the hidden layer to the hidden layer.

one piece of information can occur at different places in the sequence. For example, if we look at the two sentences "I went to Nepal in 2009" and "In 2009, I went to Nepal.", if the relevant information is the year 2009, then we want to extract that information whether the information is at the beginning of the sentence or the end.

Bidirectional RNNs

The RNN mentioned above follow a casual structure, meaning that the state at step t can only use information from previous steps to predict the output. However, sometimes we need to know details about the whole sequence to make a prediction. When translating from one language to another, it might be necessary to have information about the entire sentence before making a prediction. For example, in German, the verb can be at the end of the sentence, while in English the verb can be at the beginning.

Bidirectional RNNs [11] are a solution to this problem. They have shown excellent results in handwriting recognition, speech recognition and bioinformatics. In bidirectional RNNs, there are one RNN that moves forward in the sequence, from left to right, and one RNN that moves backwards in the sequence, from right to left. Figure 2.8 shows a bidirectional RNN, where the H_t represents the sub-RNN that moves forward in the sequence, and G_t represents the sub-RNN that moves backwards in the sequence.

Long short-term memory

Inside the hidden layer in the RNN, i.e., inside the H in figure 2.7, there are calculations to store information about the sequence. In normal RNN there is a hyperbolic tangent (\tanh) layer as shown in figure 2.9a. However, one problem with the \tanh -function is that in long sequences the RNN struggle to connect information that is far apart [4]. This problem is called




Figure 2.8: An unfolded bidirectional recurrent neural network. The same as for figure 2.7 except here there is an additional RNN that propagates backwards in the sequence, i.e., from right to left.

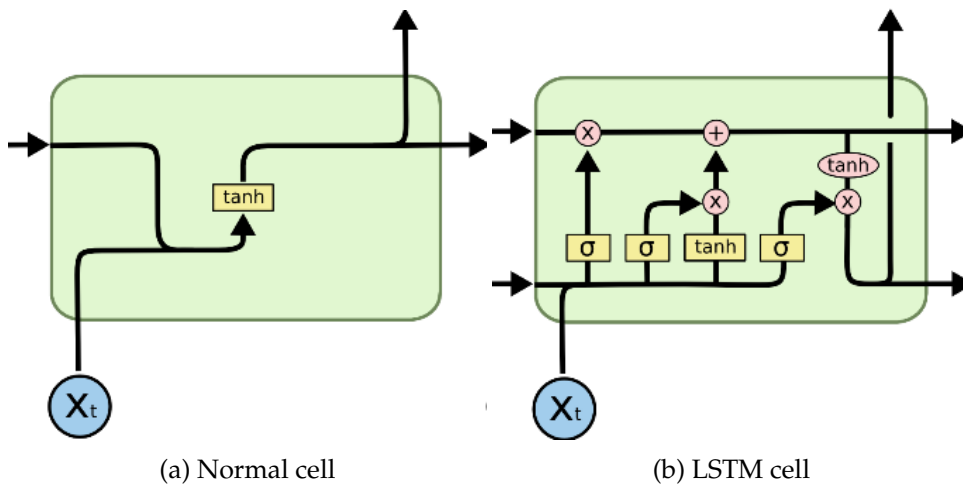


Figure 2.9: The figures show the inner workings of the RNN, for normal RNN and RNN with the LSTM architecture. (Figures from [27])

the problem of long-term dependencies and is caused because the gradient either vanishes or explodes.

One way to deal with the problem of long-term dependencies is the Long Short-Term Memory (LSTM) [14] architecture. Unlike cells in a normal RNN, the cells in LSTM are more complex. There are different versions of the LSTM architecture, but they all look similar to the one shown in figure 2.9b. The main idea to the LSTM is that the state goes through the entire chain, and each cell can add information to the state. In the figure the state is the top line, it goes through each cell, while the bottom line controls what should be added and to which extent it should be added to the state. There are three gates in an LSTM that control this process, the input gate, forget gate and output gate.




Figure 2.10: The kernel in yellow is multiplied elementwise and added together with the underlying picture, the result of the entire convolution is shown in the figure to the right. (figure is from [6])

2.3.2 Convolutional Neural Networks

Convolutional neural networks (CNN) [11] are specialised to process data that have a grid-like structure. For example, an image is a 2-dimensional grid of pixels, and text input, like sentences and paragraphs, is a 1-dimensional grid of words.

CNN consists of two primary operations, convolutions and pooling. The convolution operations map the input to the output with the use of a kernel. We can think of it as a sliding window function applied to the matrix. For example, in figure 2.10 the kernel is the 3x3 matrix in yellow, which is elementwise multiplied with the 5x5 picture matrix (green) at every location, to produce the 3x3 output matrix (pink). The kernel is usually much smaller than the input.

There are three benefits with using convolutions, sparse interactions, parameter sharing and equivariant representations. Sparse interactions mean that the network has to store fewer parameters and this reduces the memory requirement. Parameter sharing refers to the ability to use the same weights at every position of the input. For example, in image-recognition, the network can use the same kernel in every position of the image to detect edges. Equivariant representations are the networks ability to find features at different places in the input. For example, if we are trying to find a cat in an image, CNN can do this regardless of where in the image the cat is located.

The other operation is pooling, which is used to reduce the input space. It is usually performed after the convolution. There are different types of pooling, two conventional pooling methods are max-pooling and average-pooling. Max pooling finds the maximum value in the output from the convolution. Average pooling takes the average of the output from the convolution. The benefits of pooling are that it is possible to reduce the size of the input drastically without losing too much of the information. For example, an image can have an input of 1000x1000 pixels, this would

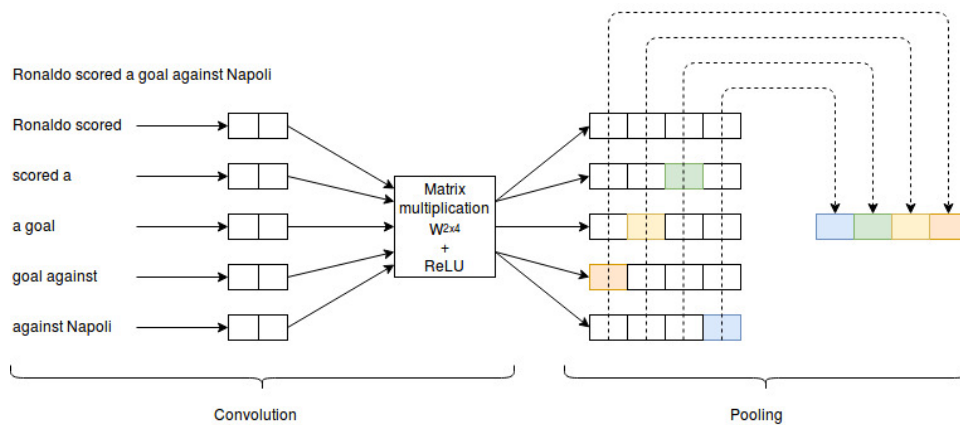


Figure 2.11: This figure shows how the convolution and pooling work on text data. The first part shows how the filter is "dragged" over the sentence. In this example, the filter size is two, and there are four filters. The pooling operation is then applied to the result, where the maximum value is found for each filter output (column). In this example, max pooling is used.

be very costly to compute in an MLP, but with pooling, it is possible to reduce the size without losing too much information. Another benefit to pooling is that it captures small variance in the features. For example, if the object in the image has rotated the CNN will still be able to recognise it.

In figure 2.11 there is an example of how convolution and pooling are done on text. In this example there is no embedding, so each word is only represented as a number. There are four kernels, and each kernel is of size two. The kernels are "dragged" over the sentence. First, the kernel is multiplied with "Ronaldo Scored", then it is multiplied with "scored a" and so on. After each multiplication, an activation function, in this case, ReLU, is applied to the output. The last step uses max-pooling over the result of each kernel.

2.4 Machine Learning Algorithms

2.4.1 Naive Bayes

Naive Bayes [44] is a supervised machine learning model that uses Bayes' theorem (2.1) to classify input to the correct output. Bayes' theorem states that for a class variable y and dependent features x_1 through x_n we have:

$$P(y|x_1, x_2, \dots, x_n) = \frac{P(x_1, x_2, \dots, x_n|y)P(y)}{P(x_1, x_2, \dots, x_n)} \quad (2.1)$$

However, the computation of function 2.1 is time-consuming with many features, so we have to assume that each feature is independent of each other to make the algorithm work in practice. The assumption is shown in equation 2.2 and the new function to calculate is shown in 2.3.

$$P(x_i|y, x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n) = P(x_i|y) \quad (2.2)$$

$$P(y|x_1, x_2, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i|y)}{P(x_1, x_2, \dots, x_n)} \quad (2.3)$$

An example of the assumption is that if we want to classify a sentence to a category, the model will look at each word independently, i.e., the order of the words does not matter. This assumption is incorrect, but naive Bayes performs well despite the assumption [31].

The next step is to find the distribution for $P(x_i|y)$. There are three common distributions to choose from Gaussian (2.4), Multinomial (2.5) and Bernoullie (2.6).

$$p(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} e^{-\frac{(x_i-\mu_y)^2}{2\sigma_y^2}} \quad (2.4)$$

Where σ_y and μ_y are estimated using maximum likelihood.

$$p(x_i|y) = \frac{N_{yi} + \alpha}{N_y + \alpha n} \quad (2.5)$$

Where $N_{yi} = \sum_{x \in T} x_i$ is the number of times feature i appears in a sample of class y in the training set T , and where $N_y = \sum_{i=1}^n N_{yi}$ is the total count of all features for class y .

$$p(x_i|y) = P(i|y)x_i + (1 - P(i|y))(1 - x_i) \quad (2.6)$$

The alpha value accounts for features that are not present in the learning samples and prevents zero probabilities in further computations. An alpha value of one is called Laplace smoothing, and alpha value that is less than one is called Lidstone smoothing.

2.4.2 Support Vector Machine

Support vector machine (SVM) [36] is a supervised machine learning algorithm that uses a hyperplane to separate two classes. This hyperplane can separate classes in the x,y plane with a line, or in the n -dimensional plane with a more complex separator. Two parameters adjust the

hyperplane, gamma and c. The gamma value determines which data points are used when forming the separator, low-value use data point far away from the line, while high-value use data points close to the line. The C value, also known as the regularisation parameter, determine how much the classifier should avoid miss-classification. High values will try to fit the separator with as many correct data points as possible, while low values are more generalised and do not care if some points are in the wrong class. High c value is prone to overfitting the model.

Kernels

Different kernels can separate the classes. They have different use cases, for example, SVM with a linear kernel is suitable to separate data points in the x y plane. For data points in higher dimensions, a different kernel is needed. Here are three different kernels:

- **Linear** SVMs have the simplest kernel; here a line separates the two classes and the kernel function is $\langle x, x' \rangle$.
- **Polynomial** SVMs have the following kernel function $(\gamma \langle x, x' \rangle + r)^d$ where d is the degree of the polynomial. and r is the coef0.
- **RBF** SVMs have the following kernel function $e^{-\gamma \|x-x'\|^2}$.

2.5 Related Work

Natural language processing has seen state-of-the-art performance in many application over the last few years [42]. Much research has been tested on different text-based datasets with different deep learning and traditional machine learning models. We will see how the models mentioned above have performed on the Stanford Sentiment Treebank dataset (SST-1) and the TREC question dataset (TREC). There is a summary of the two datasets in table 2.3.

The SST-1¹ dataset is a collection of movie reviews, and the objective of the classifier is to detect sentiment. There are five labels, very positive, positive, neutral, negative and very negative. One thing to note with this dataset is that the training set is provided at the parse-level, meaning that the training set consists of phrases and sentences. Therefore, the training set is an order of magnitude larger than what is shown in table 2.3. The test set, on the other hand, consists only of sentences. [37]

The TREC² dataset is a collection of questions, and the objective of the classifier is to classify the questions to different question types. For example, questions about location will classify to the location class. There

¹<http://nlp.stanford.edu/sentiment>

²<http://cogcomp.cs.illinois.edu/Data/QA/QC/>

Dataset	c	l	N	V	Test
SST-1	5	18	11855	17836	2210
TREC	6	10	5952	9592	500

Table 2.3: Summary of the dataset SST-1 and TREC. c: number of different classes. l: average number of word per sentence. N: Dataset size. |V|: Vocabulary size. Test: Test set size [17]

Model	SST-1	TREC
Naive Bayes	41.0	77.4
SVM	40.7	85.8
BiLSTM	47.8	93.0
CNN-rand	45.0	91.2

Table 2.4: Accuracy score for the different models on the SST-1 and TREC dataset

are six labels, Abbrev., Entity, Description, Human, Location and Numeric. [22]

Table 2.4 shows the accuracy the different models have on the SST-1 and TREC datasets. The results are collected from different research papers that have used Naive Bayes, SVM, CNN and RNN on the two datasets.

The CNN-rand model is from Yoon Kim paper [17] where he tests different CNN models on different text datasets among them SST-1 and TREC. The CNN-rand model is the only model that does not use pre-trained vectors with word2vec. The vectors are instead randomly initialised and modified during training. This model is chosen because word2vec is beyond the scope of this thesis.

The Bi-LSTM model is used as a comparison to C-LSTM neural networks presented in Chunting Zhou paper [45], and it is tested on the SST-1 and TREC dataset. The Bi-LSTM is a one layered bidirectional recurrent network with the LSTM architecture.

Socher presents the SVM and Naive Bayes model used on the SST-1 in the paper [37] where he presents the SST-1 dataset. They are both implemented with bag-of-words features. Zhang presents the SVM and Naive Bayes model used on the TREC dataset in the paper [43] where he tests SVM on question classification. Both models are implemented with bag-of-words features and default values for the parameters (e.g. C value in SVM). The SVM model that is shown in the table use a linear kernel, but there were the same results for the polynomial, RBF and sigmoid kernel. Another thing to mention is that Silva [34] managed to get 95% accuracy on the TREC dataset with SVM. However, that implementation of the SVM model had highly engineered features.

The results show that the deep learning models outperform the traditional machine learning models by a good margin. The bidirectional LSTM has

the highest performance closely followed by the CNN model; there is a small jump down to SVM and Naive Bayes. They perform about the same on the SST-1 dataset, but the SVM model has higher performance on the TREC dataset.

Chapter 3

Methodology

This chapter will describe the implementation of the project presented in this thesis. The first section will present the hardware used to train the different models, and the software used to help with the implementation of the different operations. Next, the implementation of the application (Arx) is described, followed by the details of the dataset and how it was made. After that, the different metrics used to determine the classification performance is presented. Lastly, the implementation of the training experiments, i.e. the optimisation of the different models, and the implementation of the application experiments are described in detail.

3.1 Environment

3.1.1 Hardware

In table 3.1 there is an overview of the hardware environment used to train the different machine learning algorithms. Training deep neural networks can be computationally heavy if it has many neurons and layers. Therefore it is essential to have adequate hardware so that the time it takes to train the network is reduced. GPUs are excellent at doing operations in parallel and is therefore excellent at training deep neural networks. Even though it is possible to run multiple GPUs on one computer, there is only used one here, and that should be enough for the training of the neural networks in this thesis.

¹<https://ark.intel.com/content/www/us/en/ark/products/126684/intel-core-i7-8700k-processor-12m-cache-up-to-4-70-ghz.html>

²<https://www.nvidia.com/en-us/geforce/products/10series/geforce-gtx-1070-ti/>

Component	Model	Description
CPU	Intel i7-8700K ¹	Cores: 6 Clock spees: 3.7-4.7GHz Catch: 12MB
GPU	Nvidia GTX1070 Ti ²	Memory: 8GB DDR5 Cuda cores: 2432 Boost clock: 1683 MHz
RAM	na	16 GB DDR4
OS	Ubuntu 18.04	na

Table 3.1: Hardware specifications

Usage	Software	Version	Source
Machine learning and deep learning model	Python	3.6	apt
	Keras	2.2.4	pip
	Tensorflow	1.12	pip
	cuDNN	7.4	Nvidia
	Cuda	10	Nvidia
	Scikit-learn	0.20.1	pip
Storing Dataset and Result	PostgreSQL	10.6	apt
	psycopg2	2.7.6.1	pip
Data Extraction	Requests	2.18.4	pip
	BeautifulSoup4	4.6.3	pip
Web application and labelling	React	16.4.2	NPM
	Django	2.1.3	pip

Table 3.2: Software specifications

3.1.2 software

The research project relies on numerous frameworks and libraries. There is a list in table 3.2 of the essential software in the thesis. The table shows the use case, the version and the source. Below is a brief description of the various libraries and frameworks.

Python

Python [41] is a high-level programming language that is suited for scientific research [24]. One reason for this is the thriving scientific community that use python for scientific research. Moreover, Python has a large number of libraries and frameworks such as Numpy [3], Scipy [15], Django and many more. Besides, Pythons have a clean syntax that makes reading and writing code easier. A combination of the reasons given above makes python a suitable programming language for the research in this thesis.

Keras

Keras [9] is a high-level neural network API written in python, that runs on top of Tensorflow [1], Theano [5] or CNTK [33]. The main idea behind Keras is for the user to have a user-friendly tool to make deep learning models. There are four guiding principles to Keras:

1. User-friendliness - the process of making a deep learning model in Keras should be fast and intuitive.
2. Modularity - the components in the neural network such as neural layers, cost functions, optimisers and so on are standalone components.
3. Easy extensibility - new modules are simple to add either as classes or functions.
4. Works with python.

There are two ways to create a model in Keras. The simplest way is to create a sequential model, which creates a linear stack of layers. The other alternative is to use Keras' functional API, which creates arbitrary graphs of layers. In listing 3.1 there is an example of a simple sequential model in Keras. It requires only a few lines of code to get a deep neural network ready for training . These facts make Keras a suitable tool for creating deep learning models for this thesis.

Listing 3.1: Sequential model in Keras

```
from keras.models import Sequential
from keras.layers import Dense

model = Sequential()
model.add(Dense(units=64, activation='relu', input_dim=100))
model.add(Dense(units=10, activation='softmax'))
model.compile(loss='categorical_crossentropy',
              optimizer='sgd',
              metrics=['accuracy'])
model.fit(x_train, y_train, epochs=5, batch_size=32)
classes = model.predict(x_test, batch_size=128)
```

Tensorflow

Tensorflow is an open-source library for high-performance numerical computation created by Google. Tensorflow uses dataflow graphs to represent the different operations. Where the vertices represent the mathematical operations, e.g., multiplication, addition and derivation, and the edges carry multi-dimensional arrays, also known as Tensors, between

the vertices. Furthermore, it can run operations in parallel on multiple CPUs and GPUs. [1]

Scikit-learn

Scikit-learn [8] is an easy to use machine learning package written in python. The package contains a wide array of well-known state-of-the-art machine learning algorithms. As well as functions to calculate different metrics, such as accuracy, F-measure, MCC and many more, and functions to divide the dataset into training data and test data or smaller parts with cross-validation. Combined with having high performance, proper documentation and a consistent API makes Scikit-learn an excellent tool to use for the master thesis. [28]

PostgreSQL

PostgreSQL is an open source object-relational database system, that can be used to store small and big datasets. With Psycopg2 it is possible to do SQL queries from python to the PostgreSQL database.

Requests

Requests is a python library used to send HTTP requests to a web page. The GET method is the most common, and it lets the user fetch data from any web page with one line of code. The Line in Listing 3.2 will fetch the entire HTML code of the URL given as parameter.

Listing 3.2: Request example

```
r = requests.get('www.vg.no/fotball')
```

Beautiful Soup

Beautiful soup [30] is a library to scrape web pages for information. It searches through HTML and XML pages for relevant information and fetches it. There are functions to search for different HTML tags, e.g., <div>, <p> and so on. For example, search for all the <p> tags and fetch the text inside the tags. Alternatively, fetch a <p> tag with a specific class or id name. In listing 3.3 there is an example of an HTML code of a football article, with beautiful soup you can fetch all the <p> tags, that will give you the entire article content, or if you only want the ingress you can get that with a search for <p> tags with the id name ingress.

Listing 3.3: Beautiful Soupe example

```
page_content =
"
<head>
  <div>
    <title id=header>
      Maalloes Higuain-debut
    </title>
  </div>
</head>
<body>
  <article class=article_content>
    <p id=ingress>
      Chelsea er oppskriftsmessig videre, mens Tottenham
      gikk pa en smell i FA-cupen sondag.
    </p>
    <p class=normal_content>
      Tidligere i uken mottes Chelsea og Tottenham pa
      Stamford Bridge, ...
    </p>
    <p class=normal_content> ... </p>
    <p class=normal_content> ... </p>
  </article>
</body>
"

soup = BeautifulSoup(page_content, 'html.parser')
article_content = soup.find_all('p')
```

React

React is a javascript library for building user interfaces, created by Facebook. It is a simple way to create a web page with many functionalities. It has a rich set of libraries that can help with everything from URL paths to the user interface.

Django

Django is a python web framework that follows model-view-template architecture. With the Django REST framework, it is possible to implement a RESTful web API that uses PostgreSQL as a database. In other words, it is possible to use HTTP requests to fetch data from the database with GET or to change it with POST, PUT and DELETE.

3.2 Arx

Arx is a web application with two functions. The first function is to help with labelling of paragraphs. This is done by presenting articles from VG and TV2, with an option to give the paragraphs a label. The second function is to present the classification result from different deep learning and traditional machine learning models.

Arx is a combination of two apps hosted by Django, a backend app and a frontend app. The backend app is an API to the database that contains the articles from VG and TV2, and the interface is HTTP. The frontend app use React to display a user interface.

3.2.1 Backend

The backend is a REST API that responds to the HTTP methods GET and PUT. The Django REST framework [10] handles the HTTP requests and responses. There are eight URL endpoints to the backend, here are the most important ones:

- **/API/article_info (GET)** - Fetches 50 random article headlines
- **/API/article_content/<article_id> (GET)** - Fetches all paragraphs in the article with the ID <article_id>.
- **/API/article_content/<article_id>/<paragraph_number> (PUT)** - Sets the label for the paragraph in the article with ID <article_id>, to the paragraph with number <paragraph_number>.
- **/API/player_classifier/<ml_model>/<name> (GET)** - Fetches all paragraphs from articles about <player_name>, classified with the machine learning model <ml_model>.

3.2.2 Frontend

Django loads the HTML template that runs the script created by Webpack and this script runs the ReactDOM. To navigate between different layouts React use the React Router library. To get the data from the backend React uses the fetch function.

3.3 Data

3.3.1 Retrieving Data

A python program was created to fetch and process the HTML code from VG and TV2. First, the program uses Request to fetch the HTML code of

Article_id	content_order	content	html_type	class
yvdVOJ	0	To mål av Espen Ruud - og Sarpsborg gikk på sitt fjerde strake tap	h1	
yvdVOJ	1	(Sarpsborg-Odd 1-2) Odd-backen Espen Ruud (34) har laget fem mål på de	p	
yvdVOJ	2	Mens østfoldingene presterer med bravur i Europa, går det alt annet	p	
yvdVOJ	3	Espen Ruud headet Odd i ledelsen, en annen back, Joachim Thomassen Ronaldo denne høsten).	p	

Table 3.3: View of how the data is stored in the database

all the football articles on 'www.vg.no/fotball' and 'www.tv2.no/fotball'. Next, the relevant information from the HTML code is extracted using beautiful soup and the result is stored in the database. There are four columns in the database table containing the extracted information and one containing the class label (see table 3.3):

- **article_id** - This is the id of the article given by TV2 and VG.
- **content_order** - This is the order of the paragraphs in the article. Zero is the headline, and the highest number is the last paragraph.
- **Content** - The content in the paragraph.
- **html_type** - The type of the HTML tag used by VG and TV2. For example p for paragraph and h1 for the headline.
- **class** - the label of the paragraph.

The database contains approximately 1000 articles and 20 000 paragraphs. The goal is to get 1000 labelled paragraphs from each class. How the labelling is done is explained in the next section.

3.3.2 Labelling Data

Arx was used to help with the labelling of the dataset. Arx displays the content of each article in a structured way with a labelling option for each paragraph (see figure 3.1). It is also possible to fetch all paragraphs or articles containing keywords (see figure 3.2). For example, It is possible to fetch all articles or paragraphs containing the word "målscorer", "overgang" or "vinnermålet". This option is beneficial since there are a lot of football articles that do not contain relevant paragraphs. Since Arx was always



Figure 3.1: Example of how the labelling is done with Arx. The first step is to click an article, the second step is to locate a paragraph, and the third step is to determine which label to give the chosen paragraph.

running on a computer, it made it possible to label on a phone, table, or any other device at any time.

There are in general only five labels, but to make the labelling easier there are several more options to choose from. For example, club detail, player detail and chances.

3.3.3 The Dataset

After the labelling, the training set contains 5526 data samples. In table 3.4 there is an overview of how many data samples there are of each class. There are eight classes, but only five will be used because the last three classes have too few samples. The dataset contains 11388 distinct words, the average length of each paragraph is 25 words, and the maximum length is 65 words.

The training set is split with stratified 10-fold cross-validation during training. Since the dataset is quite small, the cross-validation helps to get the maximum out of the entire dataset.

The test set contains 611 data samples. In table 3.5 there is an overview of how many data samples there are of each class. The dataset is unbalanced, and the reason for this is how the labelling was done. The labelling was done by finding all articles where the following players are mentioned, Martin Ødegaard, Lucas Moura, Morata, Rashford and Higuain, for so to classify all paragraphs in these articles.

The training set and test set can be found online here [26]. There is a description of the content of the five classes below.

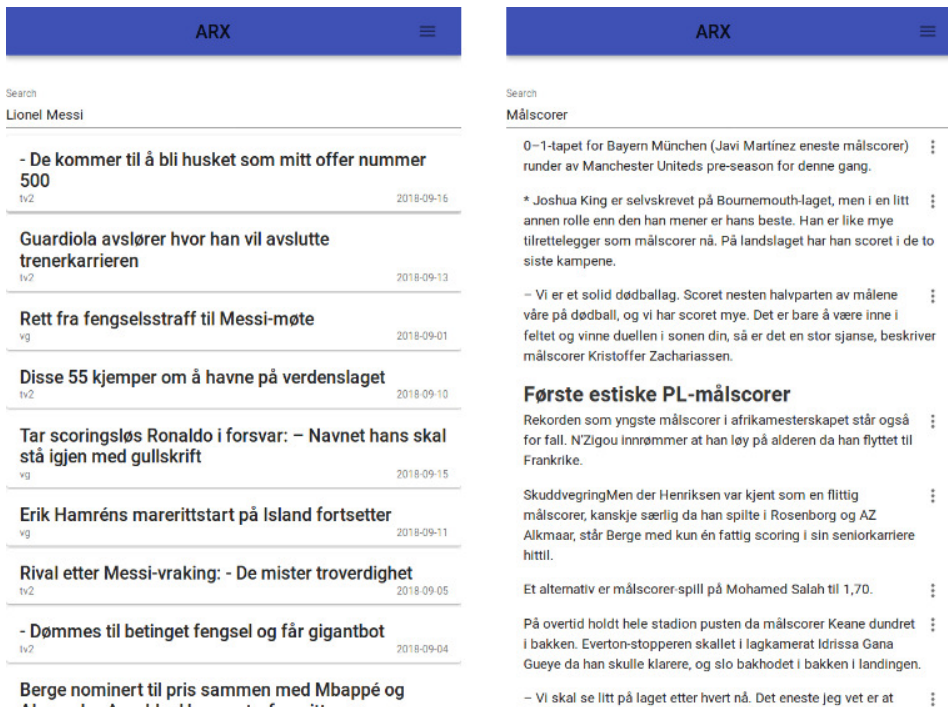


Figure 3.2: Example of how to fetch articles and paragraphs with a keyword in Arx. The left figure finds all articles that contain "Lionel Messi". The right figure finds all paragraphs that contain the word "Målscorer"

Class Label	Count
Goal/ Assist	1117
Quotes	975
Transfer	887
Irrelevant	812
Ignore	663
Player Detail	340
Club Detail	315
Chances	300

Table 3.4: Number of data samples per class in the training set

Class Label	Count
Goal/ Assist	69
Quotes	141
Transfer	60
Irrelevant	293
Ignore	48

Table 3.5: Number of data samples per class in the test set

Goal/Assist

This class contains paragraphs of who scored the goals or made the assists in a match. Also goal and assist descriptions are classified to this class. Typical examples are:

"Ti minutter før pause scoret Sam Johnson sitt første mål siden midten av mai da han dro seg fint inn fra venstre og curlet ballen i det lengste hjørnet via Hedenstad."

"Firmino scoret det andre målet i Liverpools 2-1-seier over Tottenham."

"Kampens beste spiller var nok likevel Ryan Fraser som scoret to mål og hadde én målgivende pasning."

Transfer

This class contains paragraphs about transfer rumours, transfers or loan deals for players. Typical examples are:

"Ronaldo gikk fra Real Madrid til Juventus i sommer. Pris: Snaut 950 millioner kroner. Han har skrevet en fireårskontrakt med en forventet årslønn på i underkant av 300 mill. kroner."

"Paulo Dybalas tidligere sjef i Palermo, Mauricio Zamparini, hevder at Juventus kommer til å selge sin stjernespiller i januar."

"28-åringen ble hentet til Liverpool fra Sunderland i 2011."

Quotes

This class contains quotes from football players, managers, exper commentators etc.. Typical examples are:

"– Helt korrekt. Så lenge det er holding, så er det ikke et ærlig forsøk, sier TV 2s fotballekspert Jesper Mathisen."

"– Jeg har bra selvtillit på de frisparkene!"

"– Vanskelig å konkludere på den, men jeg tror kypriotene puster lettet ut, sa Brede Hangeland."

Irrelevant

This class contains information that is not interesting for the reader. Filler paragraphs that is either an opinion from the author of the article or information about something trivial. Also, goal chances are classified here. This is the broadest class with many different types of paragraphs, but here are some examples:

"Før pause ble det ikke skapt en eneste ordentlig målsjanse i en kjedelig omgang."

"Borte mot Manchester City er trolig blant de vanskeligste kampene i en sesong, og klasseforskjellen ble raskt tydelig."

"Så fikk han en beskjed på øret."

Ignore

This class contains paragraphs about betting tips, match results and references to videos in the articles. Also, paragraphs that mention Sumo or Viplay are classified here. Typical examples are:

"Aserbajdsjan - Norge 1-3"

"Se scoringene fra kampen i videovinduet øverst på siden!"

"Vi går for at PSG vinner med to eller flere til 1,55 i odds. Spillestopp er 20.40, og kampen kan du se på Viaplay."

3.4 Metrics

Performance measurements are necessary to determine which classifier performs the best. There are many metrics to choose from, and in this thesis, the following will be used to determine the performance of a classifier: Accuracy, recall, precision, f-measure and MCC. To get the result of the classifiers as bias as possible the metrics will be average over 10-fold cross-validation. The metrics are stored in a database table after each training iteration. There is an overview of the metric database table in figure 3.4. Below is a brief explanation of each of the metrics.

True positive (TP): The number correctly identified samples. For example, when the umpire says the ball is in, and the ball is in.

False positive (FP): The number of wrongly identified negative samples. When the umpire says the ball is in, but the ball is out.

True negative (TN): The number of correctly identified negative samples. When the umpire says the ball is out, and the ball is out.

False negative (FN): The number of wrongly identified negative samples. When the umpire says the ball is out, but the ball is in.

Accuracy: The percentage of correctly identified true and false samples. [29]

$$\frac{TP + TN}{\text{Number of samples}} \quad (3.1)$$




Figure 3.3: Example of a confusion matrix

Recall: The ratio of samples that are correctly identified as positive among all existing positive samples. [29]

$$\frac{TP}{\text{Number of all positive samples}} = \frac{TP}{TP + FN} \quad (3.2)$$

Precision: The ratio of the samples that are correctly identified as positive among the returned samples. [29]

$$\frac{TP}{\text{Number of all returned samples}} = \frac{TP}{TP + FP} \quad (3.3)$$

F-measure: The harmonic mean of the precision and the recall. [29]

$$2 * \frac{\text{precision} * \text{recall}}{\text{precision} + \text{recall}} = \frac{2TP}{2TP + FP + FN} \quad (3.4)$$

MCC: MCC takes into account true and false positives and negatives and is a balanced measure even if the classes are very different in size. [29]

A confusion matrix will be generated for the different players tested in the application. The matrix shows how often each class was confused for another class, the rows represent the true labels, and the columns represent the predicted labels. There is an example of how it looks in figure 3.3.

3.5 Training Implementation

This section will describe the implementation of machine learning and deep learning algorithms. How the data is processed, the training process and how the metrics are calculated and stored. There is an overview of the file structure in figure 3.5, and the code for the implementation can be found on the github repository [26].

id	model	accuracy	recall	precision	f1	mcc	ignore_f1	goal_assist_f1	transfer_f1	quote_f1	irrelevant_f1	training_time	computation_time
2	cnn	0.839528	0.839528	0.84015	0.832852	0.798155	0.869679	0.822339	0.822339	0.870684	0.634682	13.7539	0.173524
3	cnn	0.857201	0.857201	0.858787	0.85412	0.820702	0.883657	0.857181	0.857181	0.971401	0.673768	19.4217	0.152808
4	cnn	0.868642	0.868642	0.863424	0.858826	0.825845	0.892838	0.862231	0.862231	0.970459	0.686431	17.9729	0.162582
5	cnn	0.823719	0.823719	0.825994	0.821695	0.778677	0.87806	0.841362	0.815823	0.964322	0.616368	10.2957	0.162038
6	svc	0.838864	0.838864	0.846637	0.835317	0.79593	0.878082	0.887959	0.87613	0.885291	0.654648	4.80935	0.201333
7	linear_svc	0.833987	0.833987	0.834184	0.828249	0.79169	0.859635	0.896478	0.857644	0.876582	0.659905	0.217362	0.0118999
8	linear_svc	0.829557	0.829557	0.828828	0.824833	0.786811	0.865922	0.888593	0.857732	0.88874	0.645568	0.401185	0.0118323
9	nb	0.752527	0.752527	0.782017	0.687688	0.712983	0.869955	0.782961	0.861751	0.838979	0.084794	0.116133	0.01317
10	nb	0.817594	0.817594	0.814318	0.809405	0.774107	0.834988	0.877459	0.865848	0.867469	0.556261	0.115283	0.0128889
11	nb	0.780994	0.780994	0.79888	0.737627	0.72759	0.874226	0.825923	0.85915	0.841322	0.287517	0.112845	0.0182738
12	nb	0.817572	0.817572	0.813689	0.808711	0.773956	0.840712	0.877462	0.862208	0.867383	0.555788	0.10952	0.0138012
13	linear_svc	0.243885	0.243885	0.248854	0.23312	0.044671	0.107166	0.308973	0.270119	0.234026	0.185316	0.642307	0.0111364
14	linear_svc	0.232923	0.232923	0.232373	0.224228	0.038924	0.137164	0.293298	0.266823	0.222357	0.188496	0.671559	0.0114294
15	linear_svc	0.245941	0.245941	0.244367	0.235728	0.0488941	0.159696	0.314883	0.282547	0.23324	0.189156	0.648121	0.01168
16	linear_svc	0.244817	0.244817	0.242244	0.233322	0.049767	0.14638	0.306465	0.278926	0.252489	0.188428	0.674139	0.0108469
17	linear_svc	0.246812	0.246812	0.244476	0.236362	0.0483642	0.151323	0.298334	0.28374	0.23993	0.208484	0.588939	0.0103797
18	linear_svc	0.233458	0.233458	0.232096	0.224652	0.0327938	0.155247	0.29229	0.269629	0.222889	0.184084	0.593872	0.0097487
19	linear_svc	0.261785	0.261785	0.260386	0.252775	0.068389	0.193111	0.314434	0.288563	0.232356	0.204109	0.753793	0.0107916
20	linear_svc	0.268743	0.268743	0.267492	0.259867	0.0775407	0.195109	0.334158	0.281456	0.237585	0.208826	0.772967	0.0108829
21	linear_svc	0.823746	0.823746	0.825332	0.819325	0.778934	0.8637	0.880358	0.847431	0.875649	0.629488	0.235185	0.0108721
22	linear_svc	0.826547	0.826547	0.828339	0.824337	0.786162	0.869951	0.889516	0.856939	0.871554	0.645627	0.458217	0.0113278
23	linear_svc	0.831406	0.831406	0.830724	0.825954	0.788215	0.868597	0.886552	0.855429	0.877586	0.641604	0.243922	0.0110577
24	linear_svc	0.824073	0.824073	0.826332	0.817933	0.779191	0.859277	0.869859	0.858939	0.873881	0.628788	0.472887	0.011516
25	nb	0.756532	0.756532	0.769592	0.68589	0.714433	0.866811	0.786128	0.866881	0.838616	0.0670143	0.119895	0.0119885
26	nb	0.81488	0.81488	0.810348	0.795519	0.778886	0.830224	0.875301	0.863439	0.869231	0.539398	0.118979	0.0139849
27	nb	0.788924	0.788924	0.80392	0.745769	0.747436	0.876975	0.834931	0.868012	0.84356	0.301667	0.117625	0.0115426
28	nb	0.816051	0.816051	0.809798	0.796681	0.77203	0.834059	0.878594	0.863019	0.871658	0.536703	0.116702	0.0134938
29	cnn	0.843084	0.843084	0.846562	0.839983	0.803042	0.869548	0.871532	0.831426	0.968524	0.658883	10.4185	0.152234
30	linear_svc	0.830276	0.830276	0.829785	0.825949	0.785728	0.855774	0.853189	0.845953	0.879335	0.645977	0.243894	0.0125355
31	linear_svc	0.826616	0.826616	0.826795	0.821267	0.782119	0.859511	0.887959	0.856226	0.869747	0.632892	0.487498	0.0110894

Figure 3.4: Overview of the metrics in the database table

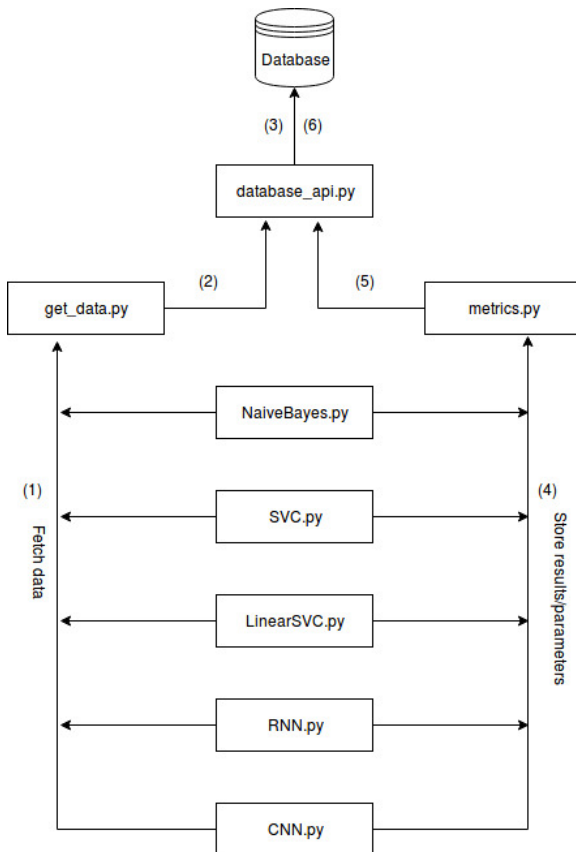


Figure 3.5: Overview of how the files interact with each other

3.5.1 Database API

The `database_api.py` talks to the database with the python library `Psycopg2`, with this library it is possible to store and fetch data in the database. The `metric.js` use the API to store all the metric values for the algorithms and the parameters used to train the algorithms. The `get_data.js` uses the API to fetch all the labelled data samples from the database.

3.5.2 Data handling

All the machine learning algorithms and the deep learning algorithms use the same input for the training data. The `get_data.py` divides the data the same way for all the algorithms. For cross-validation, the data samples are returned in two arrays one with the training data and one with the corresponding labels. The `get_data.py` also preprocesses the data to reduce the dimensionality, the preprocessing removes unnecessary spaces and excludes paragraphs with more than 65 words.

3.5.3 Metrics

The `metric.js` file contains the class `Metrics`. Each algorithm creates an instance of `Metrics` before the 10 fold cross-validation training. For each fold in the 10 fold cross-validation, the metrics are calculated and stored in the `Metrics` class, when the training is over, the mean of all the metrics are stored in the database along with the parameters used in the training. The metrics that are calculated are MCC, accuracy, f1 (for each class), recall and precision, these metrics are described in section 3.4. The python library `Scikit-learn` is used to calculate the metrics.

3.5.4 Algorithm Setup

All the algorithms use the same brute force approach to find the best hyperparameters. Listing 3.4 shows in general how the code looks for each algorithm. The training program takes a set of parameter values for each hyperparameter and then creates a model for each combination of the chosen parameters. For example, for SVM the program might get the `c` values 0.5, 1, 1.5 and 2 and the `gamma` values 1, 2 and 3. The program will then create a model for every combination of `gamma` and `c` values, in this case, there are 12 different combinations. It will then use 10 fold cross-validation to calculate the performance of each model. For lastly to store the parameters used to train the model and the metric values, in the database.

It is not possible to use a strict brute force approach to train the deep learning algorithms because of the high training time. Instead, it is a combination of brute force and checking the database for which parameters

give the best result. By using this process, it is possible to eliminate many parameter combinations, which in turn will reduce the time to find the best model.

Listing 3.4: Structure of the algorithm training process

```
class algorithm:
    def __init__():
        data = get_data()

    def create_model(parameters):
        #create model

    def train_model(parameters):
        metrics = Metrics()

        for each fold in crossvalidation(data):
            model = create_model(parameters)
            model.fit(fold_train)
            predicted = model.predict(fold_test)

            metrics.calculate_metrics(predicted, expected)

        metric.store_metrics()
        metric.store_parameters()

    def find_optimal_parameters(para1_array, para2_array, ...):
        for a in para1_array:
            for b in para2_array:
                .
                .
                .
                train_model((a,b,...))
```

3.5.5 Machine learning model architecture and parameters

The traditional machine learning algorithms Navie Bayes and SVM are all created with the Scikit-learn library. With Scikit-learn the algorithm is imported and initiated with the relevant hyperparameters, there is an example in listing 3.5 of how this is done with SVM.

All the algorithms choose between two vectorizers to transform the paragraphs into vectors of numbers. The first method is term frequency-inverse document frequency (Tfidf), and the other method is a count vectorizer.

Listing 3.5: Example of how to create model with scikit-learn

```
from sklearn.svm import SVC
```

```

        .
        .
def create_model(self, para):
    vectorizer = TfidfVectorizer()
    if para[0] == 'countVec':
        vectorizer = CountVectorizer()

    classifier = SVC(C=para[1], gamma=para[3], kernel=para[4],
                    coef0=para[6], degree=para[5], shrinking=para[7], tol=para[2])

    pipeline = Pipeline([
        ('vec', vectorizer),
        ('clf', classifier),
    ])

    return pipeline
        .
        .
        .

```

Naive Bayes

Three parameters will be optimised for Naive Bayes during training.

- **Distribution** - Can either be Bernoulli, Multinomial or Gaussian. Only Multinomial and Bernoulli will be tested during training.
- **Vectoriser** - Can either be Count or Tfidf. Both will be tested during training.
- **Alpha** - Can be any positive number. Different alpha values will be tested during training. The default value for alpha is 1.

To find the best Naive Bayes model all combination of distribution and vectoriser will be tested with different alpha values.

SVM

The SVM classifier is divided up into three separate models based on the kernel. The three models are Linear SVC, SVC poly and SVC RBF, each of these models use the linear, polynomial and RBF kernel respectively.

Linear SVC

Three parameters will be optimised for Linear SVC during training.

- **C** - Can be any positive number over 0. Different C values will be tested during training. The default value for C is 1.

- **Intercept Scaling** - Can be any positive number. Different intercept scaling values will be tested during training. The default value for intercept scaling is 2.
- **Tolerance** - Can be any positive number. Different tolerance values will be tested during training. The default tolerance value is 0.0001.

To find the optimal Linear SVC model three experiments will be executed. The first experiment will find the optimal C value, with intercept scaling and tolerance set to the default values. For the second experiment, the optimal C value will be used to find the optimal intercept scaling value, with tolerance set to the default value. And for the third experiment, the optimal C value and intercept scaling value will be used to find the optimal tolerance value.

SVC RBF

Three parameters will be optimised for SVC RBF during training.

- **C** - Can be any positive number over 0. Different C values will be tested during training. The default value for C is 1.
- **Gamma** - Can be any positive number greater than zero. Different gamma values will be tested during training. The default value for gamma is 0.5.
- **Shrinking** - Can be true or false. Both values will be tested during training. The default value is true.

To find the optimal SVC RBF model four experiments will be executed. The first experiment will find the optimal C value while the gamma value is the default value. For the second experiment, the optimal C value will be used to find the optimal gamma value. The experiments above are tested with shrinking set to true and false.

SVC Poly

Four parameters will be optimised for SVC Poly during training.

- **C** - Can be any positive number over 0. Different C values will be tested during training. The default value for C is 1.
- **Gamma** - Can be any positive number greater than zero. Different gamma values will be tested during training. The default value for gamma is 0.5.
- **Coef0** - Can be any positive number. Different Coef0 values will be tested during training. The default value for Coef0 is zero.
- **Shrinking** - Can be true or false. Both values will be tested during training. The default value is true.

To find the optimal SVC poly model six experiments will be executed. The first experiment will find the optimal C value while the other parameters use the default value. For the second experiment, the optimal C value will be used to find the optimal gamma value, with the other parameters set to the default value. For the third experiment, the optimal C and gamma value is used to find the optimal Coef0 value. The experiments above are tested for shrinking set du true and false.

3.5.6 Deep learning model architecture and parameters

The deep learning models RNN and CNN are both created with the python library Keras. They use the tokeniser from Keras to convert words to numbers. The input to the models is fixed, and the paragraph with the most words determine the input length. All other paragraphs are padded to match the max size.

RNN

The RNN model in listing 3.6 is bidirectional with the LSTM architecture, and it follows much of the same structure as the BiLSTM presented by Zhou in [45]. The first layer is the embedding layer, followed by the dropout layer, then comes the bidirectional LSTM layer, followed by a softmax classification layer. Four parameters will be optimised for the RNN during training.

- **Embedding dimension** - Can be any positive number greater than zero. Different embedding dimensions will be tested during training.
- **Number of LSTM neurons** - Can be any positive number greater than zero. Different sizes of the LSTM layer will be tested during training.
- **Dropout rate** - Can be any number between 0 and 1. Different dropout rates will be tested during training. The default dropout rate is 0.5.
- **Dropout location** - The dropout layer can be before or after the LSTM layer. Both positions will be tested during training. The default location is before the LSTM layer.

To find the optimal RNN model three experiments will be executed. The first experiment will find the optimal embedding dimension for four different LSTM layers, with the other parameters set to the default values. For the second experiment, the optimal embedding dimension will be used to find the optimal number of LSTM neurons in the LSTM layer, with the other parameters set to the default value. The third experiments will use the optimal embedding dimension and the optimal number of LSTM neurons, to find the optimal dropout rate when the dropout layer is before and after the LSTM layer.

Listing 3.6: Architecture of RNN

```
def create_model(self, para):
    model = Sequential()

    model.add(Embedding(self.vocab_size, para[0]))
    if para[3] == 'before':
        model.add(Dropout(para[2]))
    model.add(Bidirectional(CuDNNLSTM(para[1])))
    if para[3] == 'after':
        model.add(Dropout(para[2]))
    model.add(Dense(5, activation='softmax'))
    model.compile(loss='categorical_crossentropy',
                  optimizer=para[4], metrics=['accuracy'])

    return model
```

CNN

The CNN model in listing 3.7 follow much of the same structure as the Max-TDNN model presented by Kalchbrenner in [16]. The first layer is the embedding layer, followed by a convolution, then the dropout layer, followed by a pooling layer and a fully connected layer, and lastly a softmax classification layer. Six parameters will be optimised for CNN during training.

- **Embedding dimension** - Can be any positive number greater than zero. Different embedding dimensions will be tested during training.
- **Filter size** - Can be any positive number greater than zero. Different filter sizes will be tested during training.
- **Kernel size** - Can be any positive number greater than zero. Kernel size 2,3,4,6,8 will be tested during training.
- **Pooling size** - Can be any positive number greater than zero. Pool size 2 and 4 will be tested during training.
- **Dropout rate** - Can be any number between 0 and 1. Different dropout rates will be tested during training. The default dropout rate is 0.5.
- **Number of neurons in the last layer** - Can be any positive number greater than zero. Different numbers of neurons in the last layer will be tested during training.

To find the optimal CNN model four experiments will be executed. The first experiment will find the optimal embedding dimension with different filter sizes, pooling sizes and kernel sizes. The second experiment will use the optimal embedding dimension, kernel size and pooling size to find the optimal filter size. The third experiment will use the optimal values found

in experiment one and two to find the optimal number of neurons in the dense layer. The fourth experiment will find the optimal dropout rate when the optimal values are used for all parameters.

Listing 3.7: Architecture of CNN

```
def create_model(para):
    model = Sequential()

    model.add(Embedding(vocab_size, para[0], input_length=65))
    model.add(Conv1D(filters=para[1], kernel_size=para[2],
                    activation='relu'))
    model.add(Dropout(para[4]))
    model.add(MaxPooling1D(pool_size=para[3]))
    model.add(Flatten())
    model.add(Dense(para[6], activation='relu'))
    model.add(Dense(5, activation='softmax'))
    model.compile(loss='categorical_crossentropy',
                  optimizer=para[5], metrics=['accuracy'])

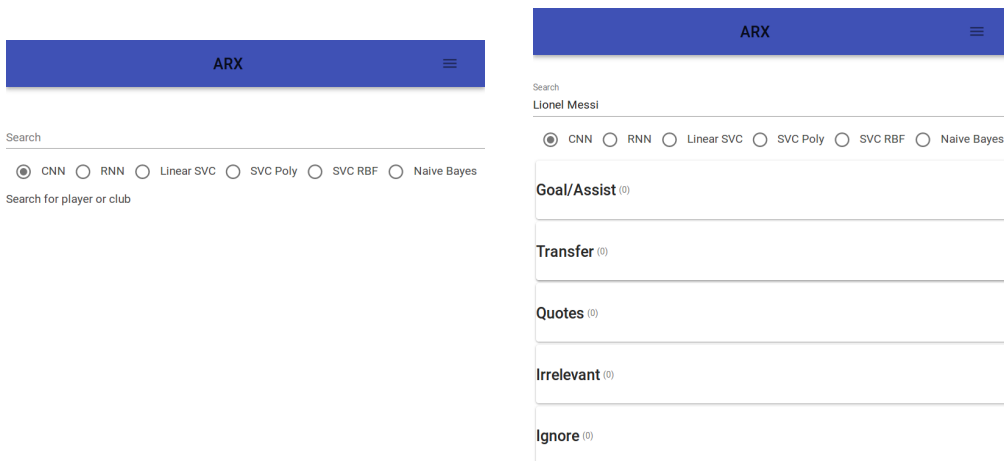
    return model
```

3.6 Application Implementation

After the training experiments, each model will use the optimal parameters and train on the entire dataset. The models will then be used in the application to classify articles about football players. The result from the models will be compared and analysed. The articles used in the application is collected in the period between December 2018 and February 2019, three months after the training set was made.

Figure 3.6a shows the user interface that will test the different models. The application takes a player name and a machine learning type as input. It then searches the database for all articles where that player is mentioned two times. The paragraphs in these articles are run through the machine learning algorithm, and the result is presented in five different tags shown in figure 3.6b.

Each model will classify articles for five players. Two players will test the models on how well they classify "Goal/Assist" paragraphs. The two players are Lucas Moura and Marcus Rashford, both of these players scored goals and performed well in the period from December 2018 to February 2019. Two players will test the models on how well they classify "Transfer" paragraphs. The two players are Higuain and Morata, these players were sold in the 2019 January transfer window. The last player to test the models is Martin Ødegaard, he performed well and was speculated in the transfer marked in the period December 2018 to February 2019.



(a) The figure shows the interface of the classification in the application. Search for a player and choose a machine learning model.

(b) The figure shows an example of the classification of Lionel Messi with the CNN model. Each paragraph in articles about Lione Messi will be classified in one of the five tabs.

Metric values and confusion matrix are calculated for each player on all the different models. In addition, for Lucas Moura and Morata the paragraphs will be shown and the result will be analysed. There are five articles from VG.no and TV2.no that will be about Lucas Moura ^{3 4 5 6 7} and Morata ^{8 9 10 11 12}.

³www.tv2.no/10358383
⁴www.tv2.no/10368905
⁵www.tv2.no/10388213
⁶www.vg.no/sport/fotball/i/Kvx5Q5
⁷www.vg.no/sport/fotball/i/qn9AJm
⁸www.tv2.no/10323549
⁹www.tv2.no/10360821
¹⁰www.tv2.no/10366951
¹¹www.tv2.no/10398386
¹²www.vg.no/sport/fotball/i/J1dx6m

Chapter 4

Experiment

This chapter presents the experiment from Naive Bayes, SVM, RNN and CNN on the dataset presented in section 3.3.3. Each model follows the same structure. First, the training experiments are presented with the best parameters, classification performance and training time. Second, the application experiments are presented with metrics, confusion metrics and a visual representation for each of the different players tested. Lastly, there is a discussion about the results of the experiments.

4.1 Traditional Machine Learning Experiment

4.1.1 Naive Bayes

Training Experiments

The experiments in figure 4.1 and 4.2 shows how the MCC and accuracy change for different parameters. A detailed overview of the experiments can be found in section B.1.1 in the appendix. The first experiment in figure 4.1 finds the optimal alpha value for the Bernoulli distribution with the Tfidf and count vectorisers. The figure shows that there is no noticeable difference in performance between the Tfidf and count vectorisers. The alpha value is best between 1.3 and 1.8, and when taking the average of the top results in table 4.1, the optimal alpha value is 1.74. The second experiment in figure 4.2 finds the optimal alpha value when the distribution is Multinomial for Tfidf and count vectorisers. For the count vectoriser, the best alpha value is between 0.25 and 0.5, and when taking the average of the top results in table 4.2a, the optimal alpha is 0.388. For the Tfidf vectoriser, the best alpha value is between 0.1 and 0.25, and when taking the average of the top results in table 4.2b, the optimal alpha is 0.172.

In table 4.1 and 4.2 there is an overview of the execution times and performance for the models with top MCC score. The performance

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
1.77	0.061	0.016	0.818	0.775	0.818	0.798	0.814	0.873	0.868	0.87	0.528	0.851
1.74	0.062	0.016	0.817	0.774	0.817	0.796	0.812	0.87	0.867	0.872	0.523	0.85
1.56	0.061	0.016	0.817	0.773	0.817	0.797	0.812	0.876	0.867	0.869	0.535	0.838
1.38	0.061	0.016	0.816	0.773	0.816	0.798	0.813	0.878	0.863	0.873	0.549	0.825
1.32	0.061	0.016	0.817	0.773	0.817	0.799	0.812	0.882	0.869	0.871	0.553	0.819

(a) Count vectorizer


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
1.8	0.063	0.016	0.818	0.775	0.818	0.798	0.813	0.87	0.868	0.872	0.521	0.857
1.41	0.063	0.016	0.817	0.774	0.817	0.799	0.814	0.883	0.86	0.872	0.556	0.826
1.5	0.062	0.016	0.816	0.773	0.816	0.797	0.812	0.875	0.867	0.868	0.542	0.833
1.26	0.063	0.017	0.816	0.773	0.816	0.798	0.814	0.883	0.868	0.873	0.557	0.808
1.77	0.063	0.017	0.816	0.773	0.816	0.796	0.812	0.87	0.869	0.869	0.521	0.852

(b) Tfidf vectorizer


Table 4.1: Top MCC scores for Naive Bayes with Bernoulli distribution on different alpha values, for two different vectorizers

of Naive Bayes is good, the models with Bernoulli distribution and Count vectorisation, Bernoulli distribution and Tfidf vectorisation and Multinomial distribution and Count vectorisation performs about the same, with an MCC score of 77.3% and an accuracy of 81.6%. The Naive Bayes model with Multinomial distribution and Tfidf vectorisation performs a bit lower, with an MCC score of 75.7% and an accuracy of 80%. The training time is 0.06 s, which is low. The prediction time is also low and takes 0.015 ms per paragraph. The f1 score for the "irrelevant" class is low for both distributions at 49% - 55%. A key difference between the Multinomial and Bernoulli distribution is that for Bernoulli the "Goal/Assist" class performs the best, while for Multinomial the "Ignore" class performs the best. The Bernoulli also have a higher f1 score for the "Irrelevant" class. The last two classes, "Transfer" and "Quote", f1 score is about the same for both distributions at 86%-87%.

To conclude, The performance is about the same for Bernoulli with either vectoriser and Multinomial with Count vectoriser, with an MCC score of 77.3% and an accuracy of 81.6%. However, the Bernoulli model is better to classify "Goal/Assist" paragraphs than Multinomial, which is an essential class to classify correctly. For that reason, the Naive Bayes classifier will use the Bernoulli distribution with count vectoriser and an alpha score of 1.74, in the application.



(a) Count vectorizer



(b) Tfidf vectorizer

Figure 4.1: Naive Bayes training experiments with Bernoulli distribution on different alpha values, for two different vectorizers


Parameter	Time		Metrics					f1 score for each class				
Alpha	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.46	0.063	0.015	0.818	0.776	0.818	0.797	0.815	0.862	0.876	0.866	0.491	0.89
0.28	0.064	0.015	0.818	0.775	0.818	0.798	0.814	0.864	0.871	0.867	0.5	0.889
0.25	0.065	0.015	0.817	0.774	0.817	0.799	0.812	0.86	0.873	0.868	0.5	0.895
0.55	0.064	0.014	0.815	0.774	0.815	0.791	0.816	0.861	0.871	0.859	0.472	0.891
0.4	0.063	0.015	0.816	0.773	0.816	0.796	0.812	0.86	0.872	0.866	0.495	0.89

(a) Count vectorizer


Parameter	Time		Metrics					f1 score for each class				
Alpha	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.13	0.064	0.015	0.806	0.762	0.806	0.782	0.805	0.851	0.865	0.853	0.457	0.882
0.16	0.065	0.015	0.804	0.76	0.804	0.777	0.804	0.85	0.865	0.852	0.434	0.883
0.22	0.063	0.015	0.801	0.759	0.801	0.77	0.808	0.844	0.872	0.849	0.403	0.881
0.1	0.064	0.015	0.802	0.757	0.802	0.78	0.799	0.847	0.864	0.852	0.452	0.883
0.25	0.064	0.015	0.799	0.757	0.799	0.767	0.807	0.839	0.869	0.85	0.392	0.886

(b) Tfidf vectorizer

Table 4.2: Top MCC scores for Naive Bayes with Multinomial distribution on different alpha values, for two different vectorizers



(a) Count vectorizer



(b) Tfidf vectorizer

Figure 4.2: Naive Bayes training experiments with Multinomial distribution on different alpha values, for two different vectorizers

Application Experiments

Table 4.3 shows the metric result from the classification of the different players in the application, with Naive Bayes as the classifier. The MCC and accuracy score from the application experiment is significantly lower than what it was during training, with a 20% drop in MCC and accuracy. The f1 score of the "Irrelevant" and "Quote" class is almost the same as what it was during training. However, "Ignore" and "Transfer" class have a 16 - 20% lower f1 score, and the "Goal/Assist" class f1 score is 35% lower than what it was during training.

In figure 4.3 there are confusion matrices of the classification of the different players. The confusion matrices show that the recall is high for all the classes except for the "Irrelevant" class, in fact, the recall for "Ignore", "Transfer" and "Goal/Assist" is the highest among all the different models. On the other hand, the recall of the "Irrelevant" class is extremely poor, and not far from random. The precision for the "Quotes" and "Irrelevant" class is good. Another thing to note from the confusion matrices is that many paragraphs that belong to the "Irrelevant" class get classified to "Goal/Assist" class instead. Moreover, The confusion matrix for the two players that test the models on the "Goal/Assist" class, Lucas Moura and Marcus Rashford, show that many paragraphs that belong to the "Irrelevant" class get classified to the "Ignore" class.

Figure 4.4 and A.1 shows the paragraphs that got classified for Lucas Moura and Morata, where green represents paragraphs that classified correctly, and red represents paragraphs that were classified wrongly. The full list of paragraphs can be found in section B.1.2 in the appendix. Paragraphs that classify to "Goal/Assist" class that belongs to the "Irrelevant" class are often goal chances. For example, paragraphs like these:

"Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren."

"Nytt stolpetreff Rondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frempå igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut."

Paragraphs that classify to "Ignore" class that belongs to the "Irrelevant" class are often team lineups. For example, paragraphs like these:

"Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente."

"Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon."

Parameter	Metrics					f1 score for each class				
	Player Name	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
Lucas Moura	0.681	0.643	0.681	0.669	0.8	0.634	0.5	0.93	0.456	0.825
Rashford	0.554	0.49	0.554	0.443	0.821	0.405	0	0.853	0.496	0.462
Morata	0.602	0.546	0.602	0.656	0.727	0.364	0.816	0.828	0.414	0.857
Higuain	0.667	0.589	0.667	0.567	0.814	0.522	0.81	0.941	0.563	0
Odegaard	0.576	0.466	0.576	0.53	0.632	0.621	0.455	0.786	0.423	0.364
All Players	0.613	0.564	0.613	0.645	0.738	0.515	0.711	0.855	0.467	0.677

Table 4.3: Metric scores from application experiments, with Naive Bayes as the classifier

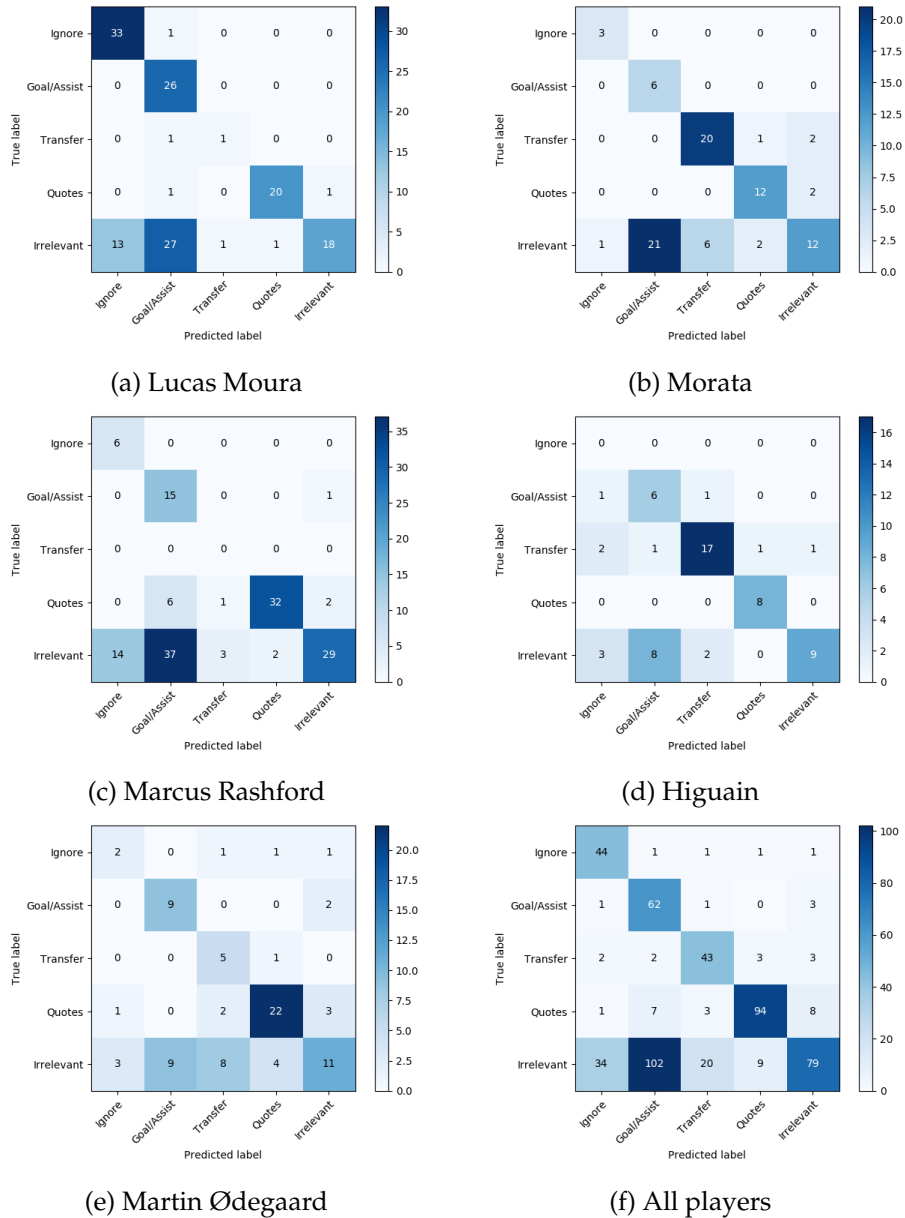


Figure 4.3: Confusion matrices for Naive Bayes on Lucas Moura and Morata

ARX
☰

Search

Lucas Moura

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽⁵⁶⁾

Transfer ⁽²⁾

Quotes ⁽²¹⁾

Irrelevant ⁽¹⁹⁾

Ignore ⁽⁴⁶⁾

Goal/Assist ⁽⁵⁶⁾

Tottenhams Harry Winks sørget for seier etter overtidsdrama.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikk set seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexandar Mitrovic dratt ned i feltet av Jan Vertonghen.

Claudio Ranieries menn fortsette å presse Tottenham, og etter nytt hjørnespark satte Harry Kanes erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

Quotes ⁽²¹⁾

– Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.

– Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.

– Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.

– Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.

Irrelevant ⁽¹⁹⁾

Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.

Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.

Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.

Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.

Transfer ⁽²⁾

Chelsea er klar for finalen i ligacupen etter å ha slått Tottenham 4-2 i straffesparkkonkurranse i returkampen på Stamford Bridge torsdag kveld.

Higuaín ikke spilleklarGonzalo Higuaín er klar for Chelsea og ble presentert før kampstart.

Figure 4.4: Naive Bayes application results for Lucas Moura. All classified paragraphs are in figure B.1 - B.5

4.1.2 Linear SVC

Training Experiments

The experiments in figure 4.5 - 4.7 shows how the MCC and accuracy change for different parameters. A detailed overview of the experiments can be found in section B.2.1 in the appendix. The first experiment in figure 4.5 finds the optimal C value. The best C value is between 0.03 and 0.06, and when taking the average of the top results in table 4.4, the optimal C value is 0.052. The second experiment in figure 4.6 finds the optimal intercept scaling value when the C value is 0.052. There is no effect on performance for different intercept scaling values. Therefore the intercept scaling value will be set to the default value. The final experiment in figure 4.7 finds the optimal tolerance value when the C value is 0.052. Same as for intercept scaling there is no change in performance for different tolerance values. Therefore the tolerance value will be set to the default value.

The top results for the Linear SVC model are in table 4.4. The Linear SVC model has an MCC score of 81.6% and an accuracy score of 85.2%, which is better than Naive Bayes. The training time is slightly higher than Naive Bayes at 0.084 s, and this is so low that it is almost neglectable. The main factor for the increase in training time is higher C value and intercept scaling value, but since both of these values are low the training time is also low. The prediction time is about the same as Naive Bayes at 0.016 ms per paragraph. The f1 score for the "Irrelevant" class is low at 68% but significantly higher than for Naive Bayes. The other classes f1 score is between 87%-90%.

To conclude, the performance of the Linear SVC model is high, with an MCC score of 81.6% and an accuracy of 85.2%. The C parameter was the only parameter to affect the MCC and accuracy for the Linear SVC model. Consequently, the linear SVC classifier will use the default values for all parameters except the C value which is optimal at 0.052, in the application.

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.085	0.093	0.014	0.853	0.815	0.853	0.848	0.854	0.907	0.877	0.893	0.68	0.883
0.0434	0.086	0.014	0.852	0.814	0.852	0.848	0.855	0.904	0.874	0.892	0.688	0.882
0.0434	0.087	0.014	0.852	0.814	0.852	0.848	0.855	0.903	0.874	0.9	0.687	0.875
0.053	0.087	0.014	0.85	0.812	0.85	0.847	0.854	0.904	0.877	0.893	0.681	0.882
0.037	0.086	0.014	0.85	0.812	0.85	0.846	0.853	0.907	0.876	0.896	0.677	0.872

Table 4.4: Top MCC scores for linear SVC on different C values

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Intersept												
6.8	0.103	0.014	0.853	0.816	0.853	0.85	0.857	0.906	0.879	0.895	0.691	0.877
4.4	0.093	0.014	0.853	0.816	0.853	0.85	0.857	0.903	0.876	0.897	0.691	0.884
6	0.099	0.014	0.853	0.816	0.853	0.85	0.857	0.903	0.879	0.896	0.69	0.883
9.6	0.128	0.014	0.852	0.815	0.852	0.848	0.855	0.907	0.872	0.898	0.681	0.883
9.8	0.129	0.014	0.853	0.815	0.853	0.849	0.857	0.911	0.874	0.895	0.691	0.873

Table 4.5: Top MCC scores for linear SVC on different intercept scaling values, when $C = 0.052$

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Tolerance												
0.00042	0.084	0.014	0.856	0.819	0.856	0.852	0.858	0.904	0.879	0.902	0.691	0.886
0.00044	0.084	0.014	0.853	0.816	0.853	0.849	0.856	0.908	0.875	0.899	0.686	0.876
0.00013	0.086	0.014	0.853	0.816	0.853	0.849	0.856	0.908	0.876	0.896	0.686	0.879
0.00089	0.082	0.014	0.853	0.816	0.853	0.85	0.857	0.906	0.878	0.894	0.69	0.881
0.00028	0.085	0.014	0.853	0.815	0.853	0.849	0.856	0.901	0.877	0.896	0.692	0.878

Table 4.6: Top MCC scores for linear SVC on different tolerance values, when $C = 0.052$




Figure 4.5: Linear SVC training experiments on different C values




Figure 4.6: Linear SVC training experiments on different intercept scaling values, when $c = 0.052$




Figure 4.7: Linear SVC training experiments on different tolerance values, when $c = 0.052$

Application Experiments


Table 4.7 shows the metric result from the classification of the different players in the application, with Linear SVC as the classifier. Same as for Naive Bayes the MCC and accuracy are significantly lower than what it was during training. With an MCC and accuracy that is 20% and 16% lower than what it was during training. However, the overall performance of the Linear SVC classifier is 6-8% better than the Naive Bayes classifier. The f1 score of the "Quote", "Irrelevant" and "Ignore" class is 2-6% lower than what it was during training. The f1 score of the "Goal/Assist" and "Transfer" class is poor with 34% and 24% drop in performance respectively.

In figure 4.8 there are confusion matrices of the classification of the different players. The confusion matrices show that the recall is good for the "Ignore", "Goal/Assist" and "Quotes" classes, and it shows that the precision is good for the "Ignore", "Quotes" and "Irrelevant" class. Same as for Naive Bayes many paragraphs that belong to the "Irrelevant" class are classified to the "Goal/Assist" class instead.

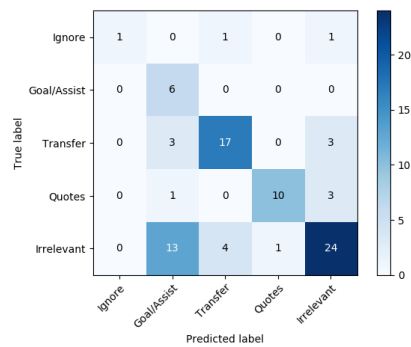
Figure 4.9 and A.2 shows the paragraphs that got classified for Lucas Moura and Morata, where green represents paragraphs that classified correctly, and red represents paragraphs that were classified wrongly. The full list of paragraphs can be found in section B.2.2 in the appendix. Same as for Naive Bayes, paragraphs that classify to "Goal/Assist" class that belongs to the "Irrelevant" class are often goal chances.

Parameter	Metrics					f1 score for each class				
	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Lucas Moura	0.771	0.712	0.771	0.735	0.833	0.686	0.444	0.927	0.693	0.925
Rashford	0.642	0.542	0.642	0.533	0.841	0.406	0	0.838	0.672	0.75
Morata	0.659	0.553	0.659	0.625	0.768	0.414	0.756	0.8	0.658	0.5
Higuain	0.717	0.625	0.717	0.601	0.776	0.737	0.789	0.842	0.634	0
Odegaard	0.647	0.535	0.647	0.563	0.719	0.667	0.4	0.836	0.576	0.333
All Players	0.69	0.609	0.69	0.704	0.758	0.566	0.633	0.85	0.657	0.813


Table 4.7: Metric scores from application experiments, with Linear SVC as the classifier




(a) Lucas Moura




(b) Morata




(c) Marcus Rashford



(d) Higuain



(e) Martin Ødegaard



(f) All players

Figure 4.8: Confusion matrices for Linear SVC on Lucas Moura and Morata

ARX
☰

Search: Lucas Moura

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽⁴⁴⁾

Transfer ⁽⁷⁾

Quotes ⁽¹⁹⁾

Irrelevant ⁽⁴¹⁾

Ignore ⁽³³⁾

Christian Eriksen scoret sikkert på Tottenhams første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenhams andre straffespark.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

På tampen ordnet Xherdan Shaqiri 3-0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4-0.

Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Quotes ⁽¹⁹⁾

– Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.

– Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.

– Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange trofæer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.

– Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på å de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betydde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.

Irrelevant ⁽⁴¹⁾

Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren. Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.

Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.

For få dager siden tapte de 2-3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.

Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.

Ignore ⁽³³⁾

21.484 tilskuere.

Se seiersmålet og høydepunktene i videovinduet øverst!

Mål: 1-0 Ryan Sessegnon (74), 1-1 Romain Saïss (85).

Manchester U. – Huddersfield 3-1 (1-0)

25.206 tilskuere

Mål: 0-1 Bernardo Silva (14), 1-1 Marc Albrighton (19), 2-1 Ricardo Pereira (81).

30.608 tilskuere

Mål: 0-1 Pierre-Emerick Aubameyang (7), 1-1 Jürgen Locadia (35).

Transfer ⁽⁷⁾

Chelsea er klar for finalen i ligacupen etter å ha slått Tottenham 4-2 i straffesparkkonkurranse i returkampen på Stamford Bridge torsdag kveld.

Drømmejul for Liverpool – ny gavepakke fra Manchester City

Chelsea hadde store sjanser på slutten, ved blant annet Giroud, men han viste hvorfor Chelsea har hentet inn Gonzalo Higuain, som ble presentert for Stamford Bridge-publikumet før kampen.

Men de to siste rundene har gjort Liverpool til storfavoritter når det gjelder ligagullet.

Higuain ikke spilleklarGonzalo Higuain er klar for Chelsea og ble presentert før kampstart.

Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.

Figure 4.9: Linear SVC application results for Lucas Moura. All classified paragraphs are in figure B.10 - B.14

59

4.1.3 SVC RBF

Training Experiments

The experiments in figure 4.10, 4.11, A.3 and A.4 shows how the MCC and accuracy change for different parameters. A detailed overview of the experiments can be found in section B.3.1 in the appendix. The first experiment in figure 4.10 finds the optimal C value when all other parameters are the default. There is no performance gain for C values above 1.2, and when taking the average of the top results in table 4.8, the optimal C value is 2. The second experiment in figure 4.11 finds the optimal gamma value when the C value is 2. The best gamma value is between 0.3 and 1, and when taking the average of the top results in table 4.9, the optimal gamma is 0.55. The last two experiments in figure A.3 and A.4 performs the same experiments as above, but with shrinking set to false. When set to false the training time decrease with 8%.

The top results for the SVC RBF model are in the last experiment, in table 4.9. The SVC RBF model has an MCC score of 82.2% and an accuracy score of 85.8%, this is marginally better than Linear SVC. The training time is 30 times higher for SVC RBF than it is for Linear SVC and Naive Bayes at about 2.7 seconds. The prediction time is 0.40 ms per paragraph, which is about 25 times longer than for Linear SVC. Same as for Naive Bayes and Linear SVC the f1 score of the "Irrelevant" class is low at 69%. The other classes f1 score is between 88% - 90%.

To conclude, the performance of SVC RBF is almost the same as Linear SVC, with an MCC score of 82.2% and an accuracy of 85.8%. The SVC RBF classifier will have a C value of 2, a gamma value 0.55 and shrinking set to false, in the application.

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
2.45	2.783	0.394	0.861	0.826	0.861	0.858	0.864	0.908	0.883	0.904	0.697	0.897
2.21	2.811	0.403	0.86	0.825	0.86	0.857	0.864	0.907	0.882	0.9	0.699	0.899
1.79	2.711	0.398	0.859	0.824	0.859	0.856	0.863	0.906	0.876	0.9	0.698	0.902
1.7	2.701	0.401	0.86	0.824	0.86	0.857	0.864	0.904	0.886	0.9	0.701	0.895
1.88	2.72	0.404	0.859	0.823	0.859	0.856	0.863	0.903	0.881	0.899	0.698	0.901

Table 4.8: Top MCC scores for SVC RBF on different C values when shrinking is true

Parameter	Time		Metrics					f1 score for each class				
	Gamma	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.295	2.135	0.373	0.859	0.823	0.859	0.857	0.864	0.903	0.876	0.903	0.701	0.9
0.68	3.043	0.408	0.859	0.823	0.859	0.856	0.864	0.906	0.881	0.902	0.698	0.894
0.505	2.712	0.394	0.859	0.822	0.859	0.856	0.862	0.906	0.881	0.898	0.694	0.9
0.365	2.4	0.377	0.858	0.821	0.858	0.854	0.861	0.904	0.879	0.9	0.692	0.897
0.855	3.306	0.429	0.857	0.821	0.857	0.854	0.861	0.904	0.877	0.9	0.689	0.903

Table 4.9: Top MCC scores for SVC RBF on different gamma values, when $c = 2.0$ and shrinking is true




Figure 4.10: SVC RBF training experiments on different C values




Figure 4.11: SVC RBF training experiments on different gamma values, when $c = 2.0$

Application Experiments

Table 4.10 shows the metric result from the classification of the different players in the application, with SVC RBF as the classifier. Much like Linear SVC the SVC RBF classifier has a lower MCC and accuracy than what it had during training. The overall performance is almost identical to Linear SVC. The f1 score of the "Quote" class is best among the traditional machine learning algorithms. However, it is very similar to Linear SVC and Naive Bayes, with a 2% better performance. The other classes are almost identical to Linear SVC in performance.

In figure 4.12 there are confusion matrices of the classification of the different players. The confusion matrices show that the recall is good for the "Goal/Assist" and "Quotes" class and that the precision is good for the "Ignore", "Quotes" and "Irrelevant" class. Same as for Naive Bayes and Linear SVC many paragraphs that belong to the "Irrelevant" class are classified to the "Goal/Assist" class instead.

Figure 4.13 and A.5 shows the paragraphs that got classified for Lucas Moura and Morata, where green represents paragraphs that classified correctly, and red represents paragraphs that were classified wrongly. The full list of paragraphs can be found in section B.3.2 in the appendix. Same as for Naive Bayes and Linear SVC paragraphs that classify to "Goal/Assist" class that belongs to the "Irrelevant" class are often goal chances. Paragraphs that contain a goal summary of a football match get classified wrongly to the "Irrelevant" class instead of to the "Ignore" class.


Parameter	Metrics					f1 score for each class				
Player Name	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Lucas Moura	0.771	0.706	0.771	0.744	0.823	0.714	0.5	0.927	0.705	0.875
Rashford	0.682	0.591	0.682	0.588	0.859	0.462	0	0.853	0.701	0.923
Morata	0.67	0.572	0.67	0.632	0.781	0.357	0.809	0.846	0.648	0.5
Higuain	0.7	0.593	0.7	0.572	0.735	0.632	0.737	0.842	0.651	0
Odegaard	0.624	0.52	0.624	0.529	0.694	0.581	0.381	0.877	0.519	0.286
All Players	0.697	0.618	0.697	0.711	0.767	0.563	0.65	0.872	0.663	0.809

Table 4.10: Metric scores from application experiments, with SVC RBF as the classifier


For example paragraphs like these:

"Mål: 1–0 Dejan Lovren (11), 2–0 Mohamed Salah (str. 48), 3–0 Xherdan Shaqiri (79), 4–0 Fabinho (85)."


"Mål: 0–1 Pierre-Emerick Aubameyang (7), 1–1 Jürgen Locadia (35)."




(a) Lucas Moura




(b) Morata




(c) Marcus Rashford



(d) Higuain



(e) Martin Ødegaard



(f) All players

Figure 4.12: Confusion matrices for SVC RBF on Lucas Moura and Morata

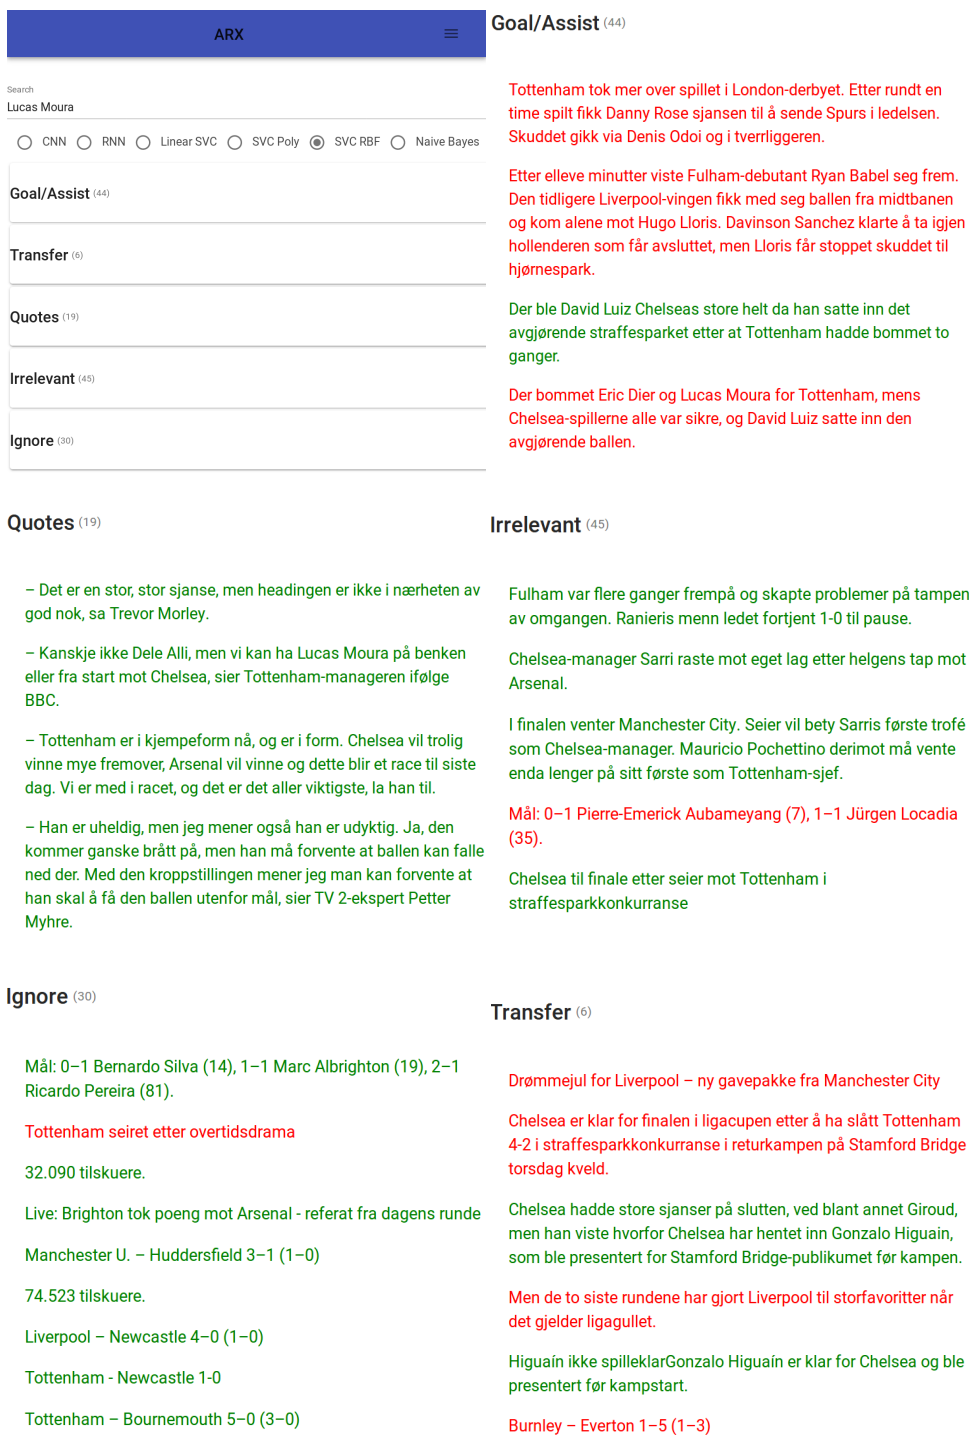


Figure 4.13: SVC RBF application results for Lucas Moura. All classified paragraphs are in figure B.19 - B.24

4.1.4 SVC Poly with degree 2

Training Experiments

The experiments in figure 4.14 - 4.16 and A.6 - A.8 shows how the MCC and accuracy change for different parameters. A detailed overview of the experiments can be found in section B.4.1 in the appendix. The first Experiment in figure 4.14 finds the optimal C value when all other parameters are the default. There is no performance gain for C values over 0.9, and when taking the average of the top results in table 4.11, the optimal C value is 1.32. The first Experiment in figure 4.15 finds the optimal gamma value when the C value is 1.32. The performance is the same for all gamma values above 1, and when taking the average of the top scores in table 4.12, the optimal gamma value is 1.2. The third experiment in figure 4.16 finds the optimal coef0 value when the C value is 1.32, and the gamma value is 1.2. The best Coef0 value is between 0.2 and 1.2, and when taking the average of the top results in table 4.13, the optimal Coef0 score is 0.63. The last three experiments in figure A.6 - A.8 are the same as the ones above, but with shrinking set to true. There is an 8% decrease in training time when shrinking is set to false.

The top results for the SVC poly model are in the last experiment, in table 4.16. The SVC poly model has an MCC score of 82% and an accuracy score of 85.7%, and this is almost identical to SVC RBF. The training time is 2.6 seconds, which is nearly the same as SVC RBF. The main factor for the increase in training time is a lower Coef0 value. There is an 32% drop in training time for coef0 values above 1.5 compared to 0. The prediction time is also the same as for SVC RBF with 0.43 ms per paragraph. Same as for the SVC RBF the f1 score of the "Irrelevant" class is 69.5%, and the other classes f1 score is between 88%-90%.

To conclude, the SVC poly is very similar to SVC RBF in performance, with an MCC score of 82% and an accuracy of 85.6%. The SVC poly classifier will have a C value of 1.32, a gamma value of 1.2, a Coef0 value of 0.63 and shrinking set to false, in the application.

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
C												
1.3875	3.402	0.478	0.84	0.8	0.84	0.838	0.849	0.893	0.872	0.885	0.656	0.882
1.1875	3.388	0.466	0.839	0.799	0.839	0.836	0.849	0.893	0.869	0.886	0.659	0.876
1.325	3.402	0.479	0.838	0.797	0.838	0.835	0.846	0.894	0.867	0.885	0.651	0.878
1.3375	3.393	0.474	0.838	0.797	0.838	0.835	0.848	0.894	0.867	0.879	0.657	0.879
1.375	3.402	0.48	0.838	0.797	0.838	0.835	0.847	0.891	0.868	0.882	0.657	0.878

Table 4.11: Top MCC scores for SVC Poly on different C values when shrinking = false

Parameter	Time		Metrics					f1 score for each class				
	Gamma	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
1.25	3.141	0.436	0.843	0.803	0.843	0.84	0.851	0.897	0.873	0.884	0.665	0.88
1.0875	3.383	0.473	0.84	0.8	0.84	0.836	0.849	0.893	0.873	0.887	0.659	0.87
1.1375	3.376	0.465	0.841	0.8	0.841	0.837	0.849	0.894	0.872	0.884	0.659	0.877
1.3625	3.155	0.441	0.84	0.799	0.84	0.837	0.848	0.891	0.869	0.885	0.658	0.883
1.175	3.395	0.473	0.839	0.798	0.839	0.836	0.849	0.891	0.867	0.886	0.656	0.882

Table 4.12: Top MCC scores for SVC Poly on different gamma values, when $c = 0.96$ and shrinking = false

Parameter	Time		Metrics					f1 score for each class				
	Coef0	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.4875	2.48	0.416	0.859	0.822	0.859	0.855	0.861	0.904	0.882	0.903	0.694	0.891
0.675	2.371	0.406	0.858	0.821	0.858	0.854	0.861	0.903	0.879	0.9	0.694	0.895
0.2625	2.714	0.432	0.857	0.821	0.857	0.855	0.862	0.901	0.88	0.899	0.7	0.895
0.4125	2.531	0.419	0.856	0.82	0.856	0.854	0.86	0.901	0.879	0.899	0.692	0.898
0.225	2.782	0.427	0.857	0.82	0.857	0.855	0.862	0.902	0.877	0.901	0.693	0.901

Table 4.13: Top MCC scores for SVC Poly on different coef0 values, when $c = 0.96$, gamma = 1.2 and shrinking = false




Figure 4.14: SVC Poly training experiments on different C values textwidthen shrinking = false




Figure 4.15: SVC Poly training experiments on different gamma values, when $c = 0.96$ and shrinking = false




Figure 4.16: SVC Poly training experiments on different coef0 values, when $c = 0.96$, gamma = 1.2 and shrinking = false

Application Experiments


Table 4.14 shows the metric result from the classification of the different players in the application, with SVC poly as the classifier. SVC poly has the best performance among the traditional machine learning algorithms, with an MCC of 62.4% and an accuracy of 70.3%. However, the performance is only slightly better than Linear SVC and SVC RBF, and it is significantly lower than what it was during training. The f1 score of the "Ignore" class is highest among all the models, with a 2-3% higher score than it is for Linear SVC and SVC RBF. The f1 score for the "Irrelevant" and "Goal/Assist" class are marginally higher than SVC RBF.

In figure 4.17 there are confusion matrices of the classification of the different players. The confusion matrices are almost identical to SVC RBF, with nearly the same recall and precision scores.

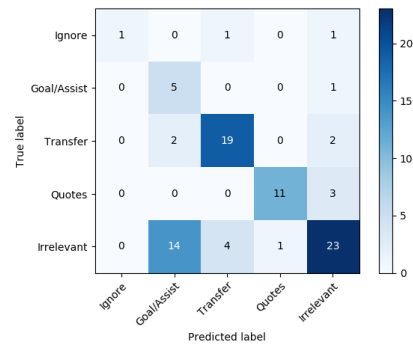
Figure 4.18 and A.9 shows the paragraphs that got classified for Lucas Moura and Morata, where green represents paragraphs that classified correctly, and red represents paragraphs that were classified wrongly. The full list of paragraphs can be found in section B.4.2 in the appendix. Same as for SVC RBF paragraphs that classify to "Goal/Assist" class that belongs to the "Irrelevant" class are often goal chances. Also, paragraphs that contain a goal summary of a football match get classified wrongly to the "Irrelevant" class instead of to the "Ignore" class.

Parameter	Metrics					f1 score for each class				
	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Lucas Moura	0.785	0.725	0.785	0.767	0.833	0.714	0.571	0.927	0.712	0.909
Rashford	0.682	0.587	0.682	0.584	0.85	0.438	0	0.857	0.701	0.923
Morata	0.67	0.567	0.67	0.633	0.769	0.37	0.809	0.846	0.639	0.5
Higuain	0.7	0.593	0.7	0.572	0.735	0.632	0.737	0.842	0.651	0
Odegaard	0.635	0.536	0.635	0.55	0.709	0.643	0.417	0.857	0.545	0.286
All Players	0.703	0.624	0.703	0.72	0.768	0.567	0.661	0.868	0.667	0.835


Table 4.14: Metric scores from application experiments, with SVC Poly as the classifier




(a) Lucas Moura




(b) Morata




(c) Marcus Rashford



(d) Higuain



(e) Martin Ødegaard



(f) All players

Figure 4.17: Confusion matrices for SVC Poly on Lucas Moura and Morata

ARX
☰

Search
Lucas Moura

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽⁴⁴⁾

Transfer ⁽⁵⁾

Quotes ⁽¹⁹⁾

Irrelevant ⁽⁴⁴⁾

Ignore ⁽³²⁾

Goal/Assist ⁽⁴⁴⁾

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

N'Golo Kanté banket inn 1–0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2–0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvspretten etter en corner som ble svakt halvklarert.

Quotes ⁽¹⁹⁾

- Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
- Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
- Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.
- Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.

Irrelevant ⁽⁴⁴⁾

Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.

Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.

Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.

(Liverpool-Newcastle 4–0, Leicester – Manchester City 2–1)
Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.

Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.

Ignore ⁽³²⁾

Brighton – Arsenal 1–1 (1–1)

Tottenham seiret etter overtidsdrama

Mål: 1–0 Ryan Sessegnon (74), 1–1 Romain Saïss (85).

74.523 tilskuere.

24.382 tilskuere.

Joshua King spilte 16 minutter som innbytter for Bournemouth.

Se seiersmålet og høydepunktene i videovinduet øverst!

32.090 tilskuere.

25.206 tilskuere

Transfer ⁽⁵⁾

Chelsea er klar for finalen i ligacupen etter å ha slått Tottenham 4-2 i straffesparkkonkurranse i returkampen på Stamford Bridge torsdag kveld.

Men de to siste rundene har gjort Liverpool til storfavoritter når det gjelder ligagullet.

Higuaín ikke spilleklarGonzalo Higuaín er klar for Chelsea og ble presentert før kampstart.

Chelsea hadde store sjanser på slutten, ved blant annet Giroud, men han viste hvorfor Chelsea har hentet inn Gonzalo Higuaín, som ble presentert for Stamford Bridge-publikumet før kampen.

Drømmejul for Liverpool – ny gavepakke fra Manchester City

Figure 4.18: SVC Poly application results for Lucas Moura. All classified paragraphs are in figure B.29 - B.34

69

4.1.5 Summary of the Traditional Machine Learning Experiments

To summarise, the performance of Linear SVC, SVC RBF and SVC poly are almost identical during training, with an MCC of 82% and an accuracy of 85.5%. The Naive Bayes model performs 4% lower than the others. All the algorithms have the same pattern, where the f1 score of the "Irrelevant" class has low performance, and the other classes have high performance. Especially for Naive Bayes the f1 score of the "Irrelevant" class is 17% lower than the other algorithms, but for the other four classes, the performance is only 2% lower. The training time for SVC poly and SVC RBF is 2.7 seconds, that is 30 times higher than what it is for Naive Bayes and Linear SVC. And the prediction time is 0.4 ms per paragraph, and that is 25 times higher than what it is for Linear SVC and Naive Bayes.

When running the optimal model for all the algorithms in the application, the results show a 20% drop in MCC for all the models. The SVC poly and SVC RBF have the best performance, with an MCC of 62%, beating Linear SVC with 2% and Naive Bayes with 6%. Then Naive Bayes classifier has a 5-7% higher f1 score on the "Transfer" class than the others. On the other hand, the f1 score of the "Ignore" class is 13-15% lower than the other models.

4.2 Deep Learning Experiments

4.2.1 RNN

Training Experiments

The experiments in figure 4.19 - 4.20 shows how the MCC and accuracy change for different parameters. A detailed overview of the experiments can be found in section B.5.1 in the appendix. The first experiment in figure 4.19 finds the optimal embedding dimension based on four different LSTM layers. There is no performance gain for embedding dimensions over 50, and after taking the average of the top results in table 4.15, the optimal embedding dimension is 125. The second experiment in figure 4.21 finds the optimal number of neurons in the LSTM layer when the embedding dimension is 125. The performance doesn't increase for LSTM layers with more than 50 neurons, and when taking the average of the top results in table 4.16, the optimal number of neurons in the LSTM layer is 105. The final experiment in figure 4.20 finds the optimal dropout rate for the dropout layer when the dropout layer is before and after the LSTM layer. When the dropout layer is after the LSTM layer, the result shows no improvements in performance for any dropout rate. However, when the dropout layer is before the LSTM layer, the results show a significant increase in performance. The optimal value for the dropout rate is between

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
157	15.444	0.493	0.876	0.845	0.876	0.873	0.881	0.893	0.886	0.977	0.732	0.879
169	15.839	0.496	0.875	0.844	0.875	0.873	0.881	0.899	0.873	0.977	0.729	0.885
79	12.073	0.464	0.875	0.844	0.875	0.873	0.882	0.896	0.872	0.98	0.721	0.897
55	12.788	0.485	0.876	0.844	0.876	0.873	0.879	0.9	0.875	0.979	0.715	0.894
109	15.115	0.49	0.874	0.843	0.874	0.872	0.879	0.892	0.878	0.98	0.73	0.88

(a) LSTM Neurons = 256

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
223	14.801	0.462	0.879	0.848	0.879	0.875	0.881	0.901	0.883	0.975	0.728	0.886
118	13.657	0.466	0.879	0.848	0.879	0.875	0.88	0.896	0.89	0.973	0.735	0.88
70	13.454	0.45	0.877	0.846	0.877	0.875	0.882	0.899	0.871	0.981	0.731	0.894
130	13.335	0.456	0.877	0.846	0.877	0.876	0.882	0.889	0.875	0.98	0.73	0.905
184	14.272	0.461	0.877	0.846	0.877	0.874	0.879	0.891	0.885	0.973	0.731	0.889

(b) LSTM Neurons = 128

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
124	9.726	0.529	0.878	0.847	0.878	0.876	0.881	0.895	0.877	0.973	0.736	0.898
169	9.086	0.409	0.876	0.845	0.876	0.874	0.879	0.894	0.874	0.973	0.731	0.899
91	13.145	0.442	0.876	0.845	0.876	0.875	0.88	0.894	0.872	0.975	0.734	0.897
64	13.034	0.423	0.876	0.845	0.876	0.875	0.88	0.895	0.87	0.976	0.728	0.905
184	9.213	0.405	0.875	0.844	0.875	0.873	0.88	0.893	0.875	0.974	0.728	0.895

(c) LSTM Neurons = 64

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
118	13.355	0.449	0.876	0.845	0.876	0.873	0.879	0.896	0.878	0.972	0.725	0.895
82	13.126	0.456	0.875	0.843	0.875	0.871	0.876	0.891	0.88	0.971	0.724	0.892
205	14.189	0.449	0.875	0.843	0.875	0.872	0.877	0.903	0.867	0.964	0.724	0.9
142	13.702	0.45	0.874	0.842	0.874	0.87	0.876	0.894	0.869	0.969	0.715	0.904
61	12.871	0.447	0.873	0.841	0.873	0.871	0.876	0.893	0.873	0.967	0.721	0.9


(d) LSTM Neurons = 32

Table 4.15: Top MCC scores for RNN on different embedding dimensions, for four different LSTM layers


0.8 and 0.93, and when taking the average of the top results in table 4.17a, the optimal dropout rate is 0.9.

The top results for the RNN model are in the last experiment, in table 4.17. The performance of the RNN model is high with an MCC score of 85.3% and an accuracy of 88.3%. The training time for RNN is high and varies from 7 seconds to 15 seconds. The main factor for the increase in training time is more neurons in the LSTM layer, although a higher embedding dimension increased the train time to some extent as well. The prediction time is 0.45 ms per paragraph. The "Quote" class has a very high f1 score of 98%, and the "Irrelevant" class has a low f1 score of 73%. The rest of the classes f1 score varies between 88% and 91%.


To conclude, the performance of the RNN model is high, with an MCC score of 85.3% and an accuracy of 88.3%. The RNN classifier will have an embedding dimension of 125, the LSTM layer will have 105 neurons, and the dropout layer will be before the LSTM layer with a dropout rate of 0.9, in the application.




(a) LSTM neurons = 256



(b) LSTM neurons = 128



(c) LSTM neurons = 64



(d) LSTM neurons = 32

Figure 4.19: RNN training experiments on different embedding dimensions, for four different LSTM layers

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
LSTM neurons												
130	9.768	0.435	0.875	0.843	0.875	0.872	0.878	0.889	0.891	0.976	0.72	0.884
154	10.289	0.441	0.874	0.842	0.874	0.871	0.878	0.897	0.878	0.974	0.717	0.887
112	8.986	0.425	0.873	0.841	0.873	0.871	0.877	0.892	0.874	0.973	0.722	0.892
34	7.844	0.434	0.873	0.841	0.873	0.872	0.878	0.892	0.869	0.973	0.728	0.895
97	8.997	0.421	0.873	0.841	0.873	0.872	0.879	0.889	0.875	0.977	0.726	0.891

Table 4.16: Top MCC scores for RNN on different LSTM layers when embedding dimension is 125


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Dropout Rate												
0.935	13.537	0.455	0.887	0.859	0.887	0.885	0.892	0.907	0.884	0.982	0.74	0.912
0.91	13.596	0.451	0.884	0.855	0.884	0.883	0.889	0.902	0.881	0.982	0.733	0.915
0.8725	13.604	0.456	0.883	0.853	0.883	0.881	0.887	0.891	0.891	0.981	0.737	0.906
0.9225	13.898	0.46	0.883	0.853	0.883	0.881	0.886	0.9	0.888	0.981	0.727	0.911
0.885	13.342	0.447	0.881	0.852	0.881	0.88	0.887	0.894	0.89	0.981	0.727	0.905

(a) Dropout layer is before LSTM layer


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Dropout Rate												
0.51	13.536	0.439	0.873	0.841	0.873	0.87	0.876	0.897	0.87	0.971	0.723	0.891
0.135	13.318	0.452	0.872	0.84	0.872	0.869	0.874	0.896	0.873	0.969	0.721	0.883
0.4475	13.37	0.439	0.87	0.836	0.87	0.867	0.872	0.889	0.868	0.978	0.714	0.885
0.6475	13.665	0.449	0.869	0.836	0.869	0.865	0.872	0.89	0.873	0.97	0.701	0.892
0.0725	12.865	0.447	0.869	0.835	0.869	0.867	0.872	0.89	0.865	0.968	0.713	0.897

(b) Dropout layer is after LSTM layer

Table 4.17: Top MCC scores for RNN on different dropout rates, for two different placements of the dropout layer, when embedding dimension is 125 and LSTM neurons is 105



(a) Dropout layer is before LSTM layer



(b) Dropout layer is after LSTM layer

Figure 4.20: RNN training experiments on different dropout rates, for two different placements of the dropout layer, when embedding dimension is 125 and LSTM neurons is 105




Figure 4.21: RNN training experiments on different LSTM layers when embedding dimension is 125

Application Experiments

Table 4.18 shows the metric result from the classification of the different players in the application, with RNN as the classifier. The MCC and accuracy score from the application experiment is significantly lower than what it was during training. However, the RNN classifier has the highest performance of all the algorithms with an MCC of 64.7% and an accuracy of 73.3%. The f1 score of the "Quote" and "Irrelevant" class is close to what it was during training, with a 2-4% drop in performance, and are the highest of all the algorithms. The f1 score of the "Goal/Assist" and "Ignore" class are 26-29% lower than what it was during training. Lastly, the f1 score of the "Transfer" class is 21% lower than what it was during training.

In figure 4.22 there are confusion matrices of the classification of the different players. The confusion matrices show that the recall is high for the "Goal/Assist" and "Quotes" class and that the precision is good for the "Ignore" and "Quotes" class. Another thing to note from the confusion matrices is that many paragraphs that belong to the "Irrelevant" class get classified to "Goal/Assist" class instead. Moreover, the confusion matrix for Lucas Moura shows that many paragraphs that belong to the "Ignore" class get classified to the "Goal/Assist" and "Irrelevant" class.

Figure 4.23 and A.10 shows the paragraphs that got classified for Lucas Moura and Morata, where green represents paragraphs that classified correctly, and red represents paragraphs that were classified wrongly. The full list of paragraphs can be found in section B.5.2 in the appendix. Paragraphs that classify to "Goal/Assist" class that belongs to the "Irrelevant" class are often goal chances. Paragraphs that contain a goal summary of a football match get classified wrongly to the "Goal/Assist" class instead of to the "Ignore" class. For example paragraphs like these:

"Mål: 1–0 Nemanja Matic (28), 2–0 Paul Pogba (64), 3–0 Pogba (78), 3–1 Mathias Jørgensen (88)."

"Mål: 1–0 Ryan Sessegnon (74), 1–1 Romain Saïss (85)."


Paragraphs about match results get classified to the "Irrelevant" class instead of to the "Ignore" class. For example paragraphs like these:

"Brighton – Arsenal 1–1 (1–1)"


"Burnley – Everton 1–5 (1–3)"

Parameter	Metrics					f1 score for each class				
Player Name	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Lucas Moura	0.729	0.642	0.729	0.712	0.79	0.704	0.571	0.927	0.729	0.627
Rashford	0.736	0.648	0.736	0.584	0.873	0.528	0	0.949	0.738	0.706
Morata	0.75	0.655	0.75	0.752	0.8	0.476	0.756	1	0.727	0.8
Higuain	0.783	0.691	0.783	0.788	0.787	0.588	0.818	1	0.744	0
Odegaard	0.682	0.576	0.682	0.626	0.743	0.643	0.421	0.873	0.623	0.571
All Players	0.733	0.647	0.733	0.717	0.778	0.611	0.672	0.936	0.718	0.65


Table 4.18: Metric scores from application experiments, with RNN as the classifier




(a) Lucas Moura




(b) Morata




(c) Marcus Rashford



(d) Higuain



(e) Martin Ødegaard



(f) All players

Figure 4.22: Confusion matrices for RNN on Lucas Moura and Morata

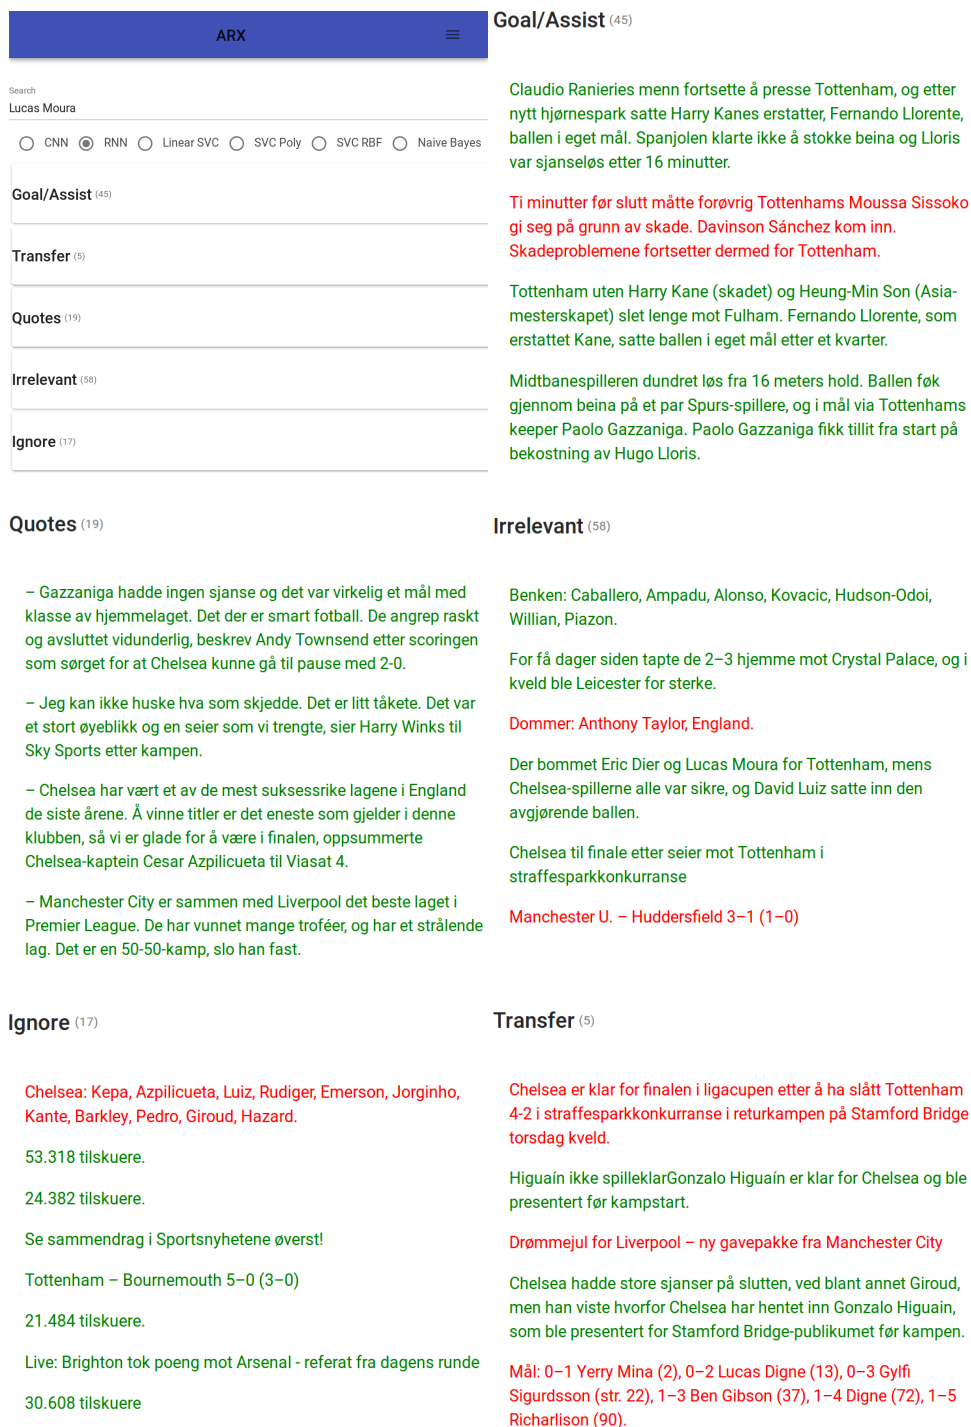


Figure 4.23: RNN application results for Lucas Moura. All classified paragraphs are in figure B.39 - B.44

4.2.2 CNN

Training Experiments

The experiments in figure 4.24 - 4.26 and A.11 - A.15 shows how the MCC and accuracy change for different parameters. A detailed overview of the experiments can be found in section B.6.1 in the appendix. The first experiment in figure 4.24 finds the optimal embedding dimension based on four different filter sizes when the kernel size is 6, and the pooling size is 2. There is no performance gain for embedding dimensions over 100, and when taking the average of the top results in table 4.19, the optimal embedding dimension is 210. In figure A.11 - A.15 the same experiment is done but with different kernel size and pooling size, however, the best configuration is when the kernel size is 6 and pooling size is 2 with a marginal margin. The second experiment in figure 4.27 finds the optimal filter size when the embedding dimension is 210, the kernel size is 6, and the pooling size is 2. The performance doesn't increase significantly after a filter size of 50, and when taking the average of the top results in table 4.20, the optimal filter size is 182. The third experiment in figure 4.25 finds the optimal number of neurons in the dense layer. There doesn't seem to be any performance gain after 50 neurons in the dense layer. When taking the average of the top results in table 4.21, the optimal number of neurons in the dense layer is 178. The final experiment in figure 4.26 finds the optimal dropout rate when the other parameters are as mentioned above. The dropout rate is best between 0.01 and 0.5, and when taking the average of the top scores in table 4.22, the optimal value is 0.09.

The top results for the CNN model are in the last experiment, in table 4.22. The CNN model has an MCC score of 84.5% and an accuracy of 87.5%, which is slightly lower than the RNN model. The training time is a bit lower than RNN and varies between 4 and 11 seconds. The main factor for the increase in training time is a higher embedding dimension. However, the filter size, dense layer and dropout rate increase the training time to some extent as well. The prediction time is 0.22 ms per paragraph, that is about half the prediction time of RNN. Same as for RNN the "Quote" class f1 score is very high at 98%, and the "Irrelevant" class f1 score is low at 72%. The rest of the classes f1 score varies between 88% and 90%.

To conclude, the performance of the CNN model is high, with an MCC score of 84.5% and an accuracy of 87.5%. The CNN classifier will have an embedding dimension of 210, a filter size of 182, a kernel size of 6, a pooling size of 2, 178 neurons in the dense layer and a dropout rate of 0.09, in the application.

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
232	11.38	0.256	0.872	0.84	0.872	0.869	0.873	0.889	0.87	0.975	0.716	0.893
223	11.215	0.258	0.873	0.84	0.873	0.868	0.873	0.896	0.87	0.978	0.706	0.889
184	10.404	0.258	0.87	0.836	0.87	0.866	0.871	0.893	0.86	0.979	0.704	0.896
169	10.078	0.249	0.869	0.836	0.869	0.867	0.873	0.883	0.873	0.978	0.703	0.898
196	10.517	0.252	0.868	0.834	0.868	0.864	0.87	0.89	0.865	0.976	0.7	0.89

(a) Filter size is 256

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
205	9.987	0.316	0.872	0.839	0.872	0.869	0.874	0.887	0.867	0.979	0.718	0.896
238	10.666	0.249	0.869	0.835	0.869	0.865	0.869	0.885	0.87	0.979	0.701	0.89
220	10.277	0.27	0.868	0.835	0.868	0.865	0.87	0.891	0.862	0.977	0.705	0.89
232	10.32	0.245	0.868	0.834	0.868	0.864	0.869	0.892	0.861	0.978	0.708	0.881
202	10.197	0.321	0.867	0.833	0.867	0.864	0.87	0.885	0.868	0.976	0.699	0.893

(b) Filter size is 128

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
229	8.9	0.281	0.868	0.834	0.868	0.863	0.867	0.89	0.865	0.972	0.704	0.885
238	8.958	0.3	0.867	0.833	0.867	0.862	0.867	0.887	0.867	0.971	0.695	0.891
244	9.513	0.275	0.867	0.833	0.867	0.864	0.869	0.884	0.866	0.975	0.699	0.896
226	8.866	0.278	0.864	0.829	0.864	0.86	0.864	0.883	0.868	0.967	0.697	0.884
210	9.844	0.282	0.863	0.828	0.863	0.859	0.862	0.884	0.864	0.975	0.683	0.886

(c) Filter size is 64

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
247	9	0.259	0.862	0.827	0.862	0.858	0.863	0.878	0.867	0.973	0.692	0.88
235	8.905	0.269	0.861	0.826	0.861	0.856	0.86	0.883	0.855	0.971	0.674	0.894
202	8.094	0.263	0.862	0.826	0.862	0.857	0.862	0.884	0.865	0.965	0.687	0.884
181	7.617	0.269	0.86	0.824	0.86	0.856	0.861	0.885	0.855	0.966	0.689	0.885
151	7.296	0.253	0.86	0.824	0.86	0.856	0.859	0.88	0.852	0.973	0.683	0.892

(d) Filter size is 32

Table 4.19: Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size is 6 and pooling size is 2

Parameter	Time		Metrics					f1 score for each class				
	Filter Size	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
199	10.424	0.249	0.872	0.839	0.872	0.867	0.871	0.888	0.875	0.976	0.71	0.888
70	9.901	0.284	0.867	0.833	0.867	0.862	0.867	0.883	0.871	0.974	0.696	0.887
172	10.492	0.25	0.867	0.833	0.867	0.865	0.87	0.881	0.867	0.979	0.701	0.896
217	10.685	0.254	0.867	0.833	0.867	0.863	0.868	0.884	0.87	0.977	0.697	0.887
250	11.049	0.255	0.867	0.833	0.867	0.864	0.868	0.882	0.871	0.979	0.695	0.892


Table 4.20: Top MCC scores for CNN on different filter sizes, when embedding dimension is 210, Kernel size is 6 and pooling size is 2

Parameter	Time		Metrics					f1 score for each class				
	Dense Layer	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
238	11.014	0.25	0.878	0.847	0.878	0.874	0.878	0.896	0.878	0.98	0.726	0.89
169	10.679	0.244	0.876	0.845	0.876	0.874	0.879	0.894	0.879	0.979	0.727	0.891
187	11.09	0.251	0.876	0.844	0.876	0.873	0.878	0.895	0.873	0.981	0.722	0.893
85	10.728	0.249	0.875	0.843	0.875	0.872	0.877	0.899	0.864	0.98	0.722	0.893
211	11.108	0.255	0.875	0.843	0.875	0.871	0.876	0.899	0.876	0.981	0.708	0.889


Table 4.21: Top MCC scores for CNN on different dense layers, when embedding dimension is 210, filter size is 182, Kernel size is 6 and pooling size is 2

Parameter	Time		Metrics					f1 score for each class				
	Dropout Rate	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.16	10.296	0.246	0.879	0.849	0.879	0.876	0.882	0.9	0.879	0.979	0.732	0.888
0.135	10.156	0.249	0.877	0.846	0.877	0.873	0.88	0.902	0.867	0.982	0.726	0.891
0.01	7.921	0.211	0.876	0.845	0.876	0.874	0.88	0.894	0.875	0.98	0.723	0.899
0.1225	10.098	0.249	0.876	0.844	0.876	0.872	0.878	0.892	0.88	0.981	0.721	0.889
0.0225	7.307	0.201	0.875	0.843	0.875	0.872	0.878	0.896	0.869	0.977	0.719	0.898


Table 4.22: Top MCC scores for CNN on different dropout rates, when embedding dimension is 210, filter size is 182, dense layer is 178, Kernel size is 6 and pooling size is 2




(a) Filter size = 256



(b) Filter size = 128



(c) Filter size = 64



(d) Filter size = 32

Figure 4.24: CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size is 6 and pooling size is 2




Figure 4.25: CNN training experiments on different dense layers, when embedding dimension is 210, filter size is 182, Kernel size is 6 and pooling size is 2




Figure 4.26: CNN training experiments on different dropout rates, when embedding dimension is 210, filter size is 182, dense layer is 178, Kernel size is 6 and pooling size is 2




Figure 4.27: CNN training experiments on different filter sizes, when embedding dimension is 210, Kernel size is 6 and pooling size is 2

Application Experiments

Table 4.23 shows the metric result from the classification of the different players in the application, with CNN as the classifier. Same as for RNN the MCC and accuracy are significantly lower than what it was during training. With an MCC and accuracy that is 20% and 16% lower than what it was during training. The RNN classifier has a 3% higher overall performance than the CNN classifier. The f1 score on the "Goal/Assist", "Irrelevant" and "Ignore" class are similar to RNN, and the "Goal/Assist" and "Quotes" class are 5% lower than RNN.

In figure 4.28 there are confusion matrices of the classification of the different players. Same as for RNN the recall is good for the "Goal/Assist" and "Quotes" class. The precision is good for the "Quotes" and "Irrelevant" class. Same as for RNN many paragraphs that belong to the "Irrelevant" class get classified to "Goal/Assist" class instead. Moreover, the confusion matrix for Lucas Moura shows that many paragraphs that belong to the "Ignore" class get classified to the "Goal/Assist", "Quotes" and "Irrelevant" class instead.


Figure 4.29 and A.16 shows the paragraphs that got classified for Lucas Moura and Morata, where green represents paragraphs that classified correctly, and red represents paragraphs that were classified wrongly. The full list of paragraphs can be found in section B.6.2 in the appendix. Same as for RNN paragraphs that classify to "Goal/Assist" class that belongs to the "Irrelevant" class are often goal chances. Paragraphs that contain a goal summary of a football match get classified wrongly to the "Goal/Assist" class instead of to the "Ignore" class. Paragraphs about match results get classified to the "Quotes" class instead of to the "Ignore" class. For example paragraphs like these:

"Brighton – Arsenal 1–1 (1–1)"


"Burnley – Everton 1–5 (1–3)"

Parameter	Metrics					f1 score for each class				
	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Lucas Moura	0.715	0.636	0.715	0.708	0.773	0.676	0.667	0.809	0.736	0.655
Rashford	0.662	0.568	0.662	0.538	0.859	0.431	0	0.861	0.691	0.706
Morata	0.716	0.657	0.716	0.705	0.843	0.429	0.766	0.966	0.697	0.667
Higuain	0.783	0.696	0.783	0.79	0.791	0.667	0.78	0.941	0.773	0
Odegaard	0.682	0.582	0.682	0.635	0.735	0.6	0.471	0.906	0.6	0.6
All Players	0.703	0.625	0.703	0.696	0.776	0.558	0.684	0.881	0.699	0.659


Table 4.23: Metric scores from application experiments, with CNN as the classifier




(a) Lucas Moura




(b) Morata




(c) Marcus Rashford



(d) Higuain



(e) Martin Ødegaard



(f) All players

Figure 4.28: Confusion matrices for CNN on Lucas Moura and Morata

ARX
☰

Search
Lucas Moura

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽⁴⁸⁾

Transfer ⁽⁴⁾

Quotes ⁽²⁵⁾

Irrelevant ⁽⁴⁶⁾

Ignore ⁽²¹⁾

Goal/Assist ⁽⁴⁸⁾

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikset seieren med scoring i siste minutt på overtid.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Sist Liverpool tapte en ligakamp på Anfield, var da Crystal Palace vant 2-1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seire. Denne sesongen har det blitt bare seire, med unntak av 0-0-kampen mot Manchester City.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Quotes ⁽²⁵⁾

Fulham – Wolverhampton 1-1 (0-0)

– Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.

– Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange troféer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.

– Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-managere ifølge BBC.

Brighton – Arsenal 1-1 (1-1)

Irrelevant ⁽⁴⁶⁾

Manchester U. – Huddersfield 3-1 (1-0)

For få dager siden tapte de 2-3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.

Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.

Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.

Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.

Slik startet lagene:

Ignore ⁽²¹⁾

21.484 tilskuere.

Se scoringen i videovinduet øverst!

Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.

Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.

Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):

Tottenham - Newcastle 1-0

Live: Brighton tok poeng mot Arsenal - referat fra dagens runde

Transfer ⁽⁴⁾

Dommer: Anthony Taylor, England.

Chelsea hadde store sjanser på slutten, ved blant annet Giroud, men han viste hvorfor Chelsea har hentet inn Gonzalo Higuain, som ble presentert for Stamford Bridge-publikumet før kampen.

Chelsea er klar for finalen i ligacupen etter å ha slått Tottenham 4-2 i straffesparkkonkurranse i returkampen på Stamford Bridge torsdag kveld.

Higuain ikke spilleklar Gonzalo Higuain er klar for Chelsea og ble presentert før kampstart.

Figure 4.29: CNN application results for Lucas Moura. All classified paragraphs are in figure B.49 - B.54

4.2.3 Summary of the Deep Learning Experiments

To summarise, the performance of the RNN and CNN classifier is very similar during training. The RNN model has an MCC of 85.3% and an accuracy of 88.3%, which is 1% better than CNN. The two models have the same pattern, where the f1 score of the "Irrelevant" class is low, and the other classes f1 score is high. The training time for CNN is between 4 and 11 seconds, and for RNN it is between 7 and 15 seconds. The predictions time for CNN is 0.22 ms per paragraphs, which is about half of what it is for RNN.

When running the optimal model for RNN and CNN in the application, the results show a 20% drop in MCC score. The RNN classifier has the best performance, with an MCC of 64.7%, which is 2% higher than what it is for CNN. The f1 score of the different classes is very similar between the two models.

4.3 Discussion

4.3.1 Performance

The performance of the algorithms during training was overall very high. There is an overview of the top results in table 4.24. Naive Bayes is at the low end with an MCC of 75% and RNN at the high end with an MCC of 85.3%. The MCC of the deep learning models was around 85%, while for the SVM models the MCC was around 82%. Thus, the performance is overall better for the deep learning algorithms, but not with a large margin.

After the training, each model was used in the application with the optimal parameters. The first thing to note from the results in the application is that all the algorithms suffered a $\sim 20\%$ drop in MCC. This drop might indicate that the models are overfitting, or that the training set does not represent the data good enough. Since all the algorithms are affected the same, the problem most likely lies with the training set.

The results from the application show that the deep learning models have a better performance than the traditional machine learning models; there is an overview of the results in table 4.25. Same as during training, RNN has the highest MCC with 64.7%, and Naive Bayes has the lowest MCC with

Parameter	Metrics					f1 score for each class				
Model	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
RNN	0.887	0.859	0.887	0.885	0.892	0.907	0.884	0.982	0.74	0.912
CNN	0.879	0.849	0.879	0.876	0.882	0.9	0.879	0.979	0.732	0.888
SVM RBF	0.859	0.823	0.859	0.857	0.864	0.903	0.876	0.903	0.701	0.9
SVM Poly	0.859	0.822	0.859	0.855	0.861	0.904	0.882	0.903	0.694	0.891
Linear SVM	0.853	0.815	0.853	0.848	0.854	0.907	0.877	0.893	0.68	0.883
Naive Bayes	0.818	0.775	0.818	0.798	0.814	0.873	0.868	0.87	0.528	0.851

Table 4.24: Shows the result of the training experiments

Parameter	Metrics					f1 score for each class				
Model	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
RNN	0.733	0.647	0.733	0.717	0.778	0.611	0.672	0.936	0.718	0.65
CNN	0.703	0.625	0.703	0.696	0.776	0.558	0.684	0.881	0.699	0.659
SVM Poly	0.703	0.624	0.703	0.72	0.768	0.567	0.661	0.868	0.667	0.835
SVM RBF	0.697	0.618	0.697	0.711	0.767	0.563	0.65	0.872	0.663	0.809
Linear SVM	0.69	0.609	0.69	0.704	0.758	0.566	0.633	0.85	0.657	0.813
Naive Bayes	0.613	0.564	0.613	0.645	0.738	0.515	0.711	0.855	0.467	0.677

Table 4.25: Shows the result of the application experiments

Dataset	c	l	N	V	Test
SST-1	5	18	11855	17836	2210
TREC	6	10	5952	9592	500
Football	5	25	5526	11388	611

Table 4.26: Summary of the SST-1, TREC and the dataset used in this research. c: number of different classes. l: average number of word per data sample. N: Dataset size. |V|: Vocabulary size. Test: Test set size

56.4%. The SVM model with polynomial kernel was closest with an MCC of 62.4%. The difference in performance is marginal, with RNN performing slightly better than SVM models.

It was hard to find related research to use as a comparison to the research done in this thesis. The most common problem is the dataset, for either is the dataset similar in the number of data samples and classes, but every data sample contains a lot fewer words per sample. Alternatively, if the number of words per data sample is similar, then there is usually just two classes (e.g. sentiment analysis) and a much larger dataset. However, two datasets with some similarities were found, the SST-1 and TREC dataset presented in section 2.5. In table 4.26 there is an overview of the different datasets.

The models that were chosen for the SST-1 and TREC dataset are not the best performing models. For example, the SVM model presented by Silva had an accuracy of 95% on the TREC dataset, and the best CNN model by Yoon Kim had an accuracy of 93% on the TREC dataset and 48% on the SST-1 dataset. However, these models are optimised in ways that are not possible in the research done here. The SVM model uses highly engineered features, and the CNN model is built on top of word2vec. So, to get the comparison as closely related to the models used in this research, the out-of-the-box models were chosen for comparison instead.

Table 4.27 shows the accuracy for each model on the three different datasets. The results the models have on the SST-1 and TREC dataset is presented in section 2.5, and the results from the Football dataset is taken from table 4.25. At first glance, it is clear that the performance of the models presented in this thesis is well below the TREC dataset and well above the SST-1 dataset. However, the pattern is similar for all three datasets, with the RNN model having the highest performance for the deep learning models, and SVM having the highest performance for the traditional machine learning models. The main difference is that in general,

Model	SST-1	TREC	Football
Naive Bayes	41.0	77.4	61.3
SVM	40.7	85.8	70.3
RNN	47.8	93.0	73.3
CNN	45.0	91.2	70.3

Table 4.27: Accuracy score for the different models tested on the SST-1, TREC and the dataset used in this research.

Model	$exp * ppe * att * fcv$	ttt
Naive Bayes	$4 * 80 * 0.063 * 10$	3 min
Linear SVM	$3 * 80 * 0.084 * 10$	3.36 min
SVM RBF	$4 * 80 * 2.7 * 10$	2.4 h
SVM Poly	$6 * 80 * 2.6 * 10$	3.46 h
RNN	$7 * 80 * 11 * 10$	17 h
CNN	$27 * 80 * 8 * 10$	48 h

Table 4.28: Show the total training time for each algorithm

the traditional machine learning models are closer in performance to the deep learning models on the football dataset than on the SST-1 and TREC datasets.

4.3.2 Time Consumption

The training time can be divided into three brackets, where Naive Bayes and linear SVM have a very low training time, SVM with polynomial and RBF kernel have a high training time, and RNN and CNN have a very high training time. In table 4.28 there is an overview of the approximate time for the different models. Where the time is calculated with the function 4.1 and where the different parameters are as follow:

- Experiments (exp) - Number of experiments that were executed.
- Parameters per experiment (ppe) - Number of values that were tested for each experiment.
- Average training time (att) - The average training time for each model.
- Number of folds in cross-validation (fcv) - Number of folds that were used during training.

$$Total\ training\ time\ (ttt) = exp * ppe * att * fcv \quad (4.1)$$

SVM with RBF and polynomial kernel have a lower training time then what is shown in table 4.28. The implementation from Sklearn does

not support multi-threading, so each of them only ran on one processor core. However, during training, the task was split up to use the six cores available. Therefore, the time shown in the table can roughly be divided by six.

The linear SVM model has a lower training time than the other SVM models because Sklearn uses a different multi-class implementation. For linear SVM Sklearn uses one-vs-rest, and for the other two, it uses one-vs-one, which is more computationally expensive.

The total training time is much higher for the deep learning algorithms than it is for the traditional machine learning models. One reason for the high training time is that there are more parameters to optimise for the deep learning models, combined with higher training time in general. Despite the high training time compared to the other models, it is not unreasonable high and still very manageable.

4.3.3 Setup

All the algorithms were set up on a clean machine with Ubuntu as the operating system. All the algorithms require python, a python library manager like PiP, and common libraries such as Numpy.

Sklearn was used to implement SVM and Naive Bayes. Sklearn can be installed with PiP and do not have any dependencies. Each algorithm comes pre-made and requires only the correct parameters and data to beginning training. The setup effort is very low.

Keras was used to implement RNN and CNN. Keras is installed with PiP, but unlike Sklearn it requires a backend like Tensorflow. Tensorflow can be installed with PiP as well, but if the algorithms are going to train on the GPU, which is essential to have a low training time, Cuda and CuDNN need to be installed first. Cuda and CuDNN are not trivial to install and requires time and effort to work correctly. When Cuda was installed during the implementation, a new version had come out (version 10), this version was not compatible with the Tensorflow version currently in PiP (version 1.11). So to make Tensorflow work with the latest version of Cuda, Tensorflow had to be recompiled from the Tensorflow git repository, and made into a PiP package using Bazel¹. When everything was installed and working, the algorithms had to be made from scratch with the Keras API.

There is a lot more overhead associated with deep learning algorithms than there is with traditional machine learning algorithms.

¹Bazel is a build tool, can be used to make PiP package

4.3.4 Pitfalls

There were some concerns and problems when implementing and training the deep learning algorithms for this thesis. Deep learning algorithms are more complex than traditional machine learning models when it comes to setup, implementation and optimising. With this complexity, there are some pitfalls to be aware of.

One thing that is evident after the research in this thesis is that it is essential to plan very carefully before starting the training. With Naive Bayes the training time is so low that if a mistake is made it is possible to train the algorithm again. However, for CNN and RNN one mistake that requires the algorithms to be trained again can cost much time. The mistake does not need to be that severe either for the training to be left invalid. For example, errors or inaccuracies in the training set, metrics that are not calculated or miscalculated, or parameters that use wrong values, are all small things that can cause the algorithms to be trained again. From table 4.28 there were executed 2160 experiments for CNN and 560 experiments for RNN. However, the database show that the total number of experiments that were executed are 5100 for CNN and 1750 for RNN, because of small mistakes, experiments had to be executed again.

Another thing to note is the uncertainty around deep learning algorithms. No mathematical theory says why CNN and RNN work, the networks are only black boxes that happen to work in practice, which means that the programmer is relying on research done by others with similar problems, or in the worst case, a try and fail approach. Since there are too many combinations of layers and parameters, it is impossible to do an exhaustive search for the best combination. For example, the RNN network in this thesis did not work without a bidirectional architecture, so if a bidirectional approach would never have been tried, either by the lack of knowledge or research, the RNN model would have been a waste of time.

As mentioned in the previous section the setup is time-consuming for deep learning algorithms. However, one can argue that this setup is a one-time thing and that the effort is worth it in the long run. This is not necessarily the case, for with more dependencies increases the probability for something to break. Moreover, to update one component might break another component that does not support that version. For example, Cuda is compiled with a specific kernel, so upgrading the kernel on Ubuntu can break Cuda and the support for GPU in Tensorflow.

4.3.5 Improvements

The algorithms have some common performance problems. The "Irrelevant" class have a low f1 score compared to the other classes. Moreover, paragraphs classify to the "Goal/Assist" class instead of the "Irrelevant"

class. There is also a significant drop in performance from the training results to the application results.

The "Irrelevant" class contains many different types of paragraphs, for example, goal chances, team lineups and general trivial information. In other words, the "Irrelevant" class is many classes put into one class, and this makes it difficult for the models to generalise what belongs to this class. One solution to increase the performance of the different models can be to change the "Irrelevant" class. For example, one of the main problems in the application is that paragraphs about goal chances get classified to the "Goal/Assist" class instead of to the "Irrelevant" class. Renaming the "Goal/Assist" class to "Situation" class, and changing the content from being about goals and assists to goals, assists and chances would simplify the "Irrelevant" class. Another problem in the application is that paragraphs about team line-ups get classified to the "Ignore" class instead of to the "Irrelevant" class. Moving these paragraphs to the "Ignore" class makes sense, maybe that is where they should have been from the start. These two measures would reduce the size of the "Irrelevant" class without complicating the "Goal/Assist" and "Ignore" class.

One possible reason for the big difference between the training experiment result and the application result can be the labelling method used on the training set and the test set. There are three ways to label data samples (1) label paragraphs in random articles, (2) label paragraphs in articles that contain a keyword, for example, articles that contain a certain player name, or (3) label paragraphs from a list of paragraphs containing a keyword, for example, a list of all paragraphs that contain the word "Målscorer". When making the training set, all three methods were used, but the third method was used the most. On the other hand, when making the test set, only the second method was used, which means that the training set has a less diverse set of paragraphs compared to the test set.

4.3.6 Future Outlook

RNN and CNN are data hungry algorithms compared to Naive Bayes and SVM, and the training set used in this research contains approximately 5500 data samples, which is considered to be few when it comes to deep learning. However, even with a limited training set, the deep learning algorithms outperformed the traditional machine learning algorithms, and if this dataset is a working progress, meaning that it will grow over time, it is reasonable to think that CNN and RNN will benefit more from this than SVM and Naive Bayes.

Another thing to be aware of when choosing a model is the future outlooks for that model. Deep learning is the new hype, and the tech giant like Google, Microsoft and Apple, are heavily investing in this technology. "Research into convolutional network architectures proceeds so rapidly that a new best architecture for a given benchmark is announced every

few weeks to months ..." [11]. It is hard to say what the future is bringing to RNN and CNN, maybe in a couple of months, there will be a breakthrough in RNN for text classification, that will make the performance of skyrocket.

Chapter 5

Conclusion

The research question raised in the thesis was: "**How does deep learning compare to traditional machine learning on text classification when it comes to classification performance, training time and setup complexity?**". To answer this question different machine learning and deep learning models were created, and then compared against each other.

There is no clear answer to whether deep learning or traditional machine learning algorithms are preferred on text classification, based on the research done in this thesis. On the one hand, the deep learning models did perform slightly better overall compared to the traditional machine learning algorithms. However, on the other hand, for the deep learning models, the training time is much higher, the setup is much harder, and there is more maintenance.

To conclude, if the dataset is limited as it is in this thesis with no more data added in the future, the traditional machine learning models is the better choice. The easy setup, low training time and limited maintenance outweigh the small performance gain given by deep learning. However, if the dataset is growing over time and have the potential to become much bigger than it is now, the deep learning models are the better choice. The overhead would then be worth the potential performance gain that is given by deep learning.

5.1 Contributions

Three objectives were set in the introduction of this thesis. (1) Make a thorough comparison between deep learning and traditional machine learning algorithms on text classification. With a dataset created from football article from VG and TV2. (2) Create a dataset that will be used to train and test the deep learning and traditional machine learning algorithms, and (3) Create an application that will, (1) help to create the dataset and (2) show a visual representation of how the different models

perform. Objective one has already been mentioned above, but here are the conclusion for objective two and three.

The dataset consists of a training set, which was used to train the different models, and a test set which was used in the application to test the performance of the various models. The training set was created in the period between July 2018 and September 2018, and the test set was created in the period between December 2018 and February 2019. The training set consist of about 5500 data samples (see table 3.4), and the test set consist of approximately 600 data samples (see table 3.5). Both the training set and the testing set can be found online in the git repository here [26].

The application was essential to classify all the data samples; without it, the task of labelling 6000 data samples would be too massive. The application also displayed a visual view of the classification from each of the different models. This visualisation helped to locate what kind of data samples the different models struggled to classify correctly.

The application in this research was used for football articles, but it could be used for other text classification problems that follow a similar pattern. For example, other news related articles such as finance articles, culture articles and so on. It is a great tool to help with labelling and to get a visual result from the classification. The code for the application can be found online in the git repository here [26].

Finally, a paper about the research has been submitted to the CBMI¹ 2019 conference. The paper can be seen in Appendix C.

5.2 Future Work

There was a lot of time-consuming tasks in the thesis, a dataset was created, an application was created, and each algorithm was optimized with optimal parameters. Consequently, some parts had to be ignored or limited to be able to finish everything. Three things can be improved further in the thesis.

First, to get a more thorough comparison between deep learning and traditional machine learning more algorithms can be tested. For example, add decision trees, k-nearest neighbours and other machine learning algorithms. Also, test different architectures for RNN and CNN. Furthermore, pre-processing of the dataset was almost non-existent in this research; only special characters were removed. So to get a better result, more advanced pre-processing could be tested on the dataset. One way to do this is to use the Google Translate API, and translate the dataset into English for so to apply pre-processing tools available in English. Alternatively, create a pre-processing tool from scratch for Norwegian.

¹<http://cbmi2019.org/>

Second, improve the dataset, by adding more data samples, and by adding the improvements suggested in section 4.3.5. See how the different models perform when given fewer data samples compared to more, and see if the statement in section 4.3.6, about RNN and CNN gaining more from a bigger dataset than Naive Bayes and SVM, is true.

Third, work on the application to make it more general. The application has the potential to be used in many other supervised machine learning problems. Make the application so general that the only thing it needs is an unlabeled dataset, and eventually machine learning models to classify data samples.

Bibliography

- [1] Martin Abadi et al. 'Tensorflow: a system for large-scale machine learning.' In: *OSDI*. Vol. 16. 2016, pp. 265–283.
- [2] Ethem Alpaydin. *Introduction to machine learning*. 2nd ed. Adaptive computation and machine learning. Cambridge, Mass: MIT Press, 2010. xl+537. ISBN: 978-0-262-01243-0.
- [3] David Ascher et al. *Numerical python*. 2001.
- [4] Yoshua Bengio, Patrice Simard, Paolo Frasconi et al. 'Learning long-term dependencies with gradient descent is difficult'. In: *IEEE transactions on neural networks* 5.2 (1994), pp. 157–166.
- [5] James Bergstra et al. 'Theano: A CPU and GPU math compiler in Python'. In: *Proc. 9th Python in Science Conf*. Vol. 1. 2010.
- [6] Denny Britz. *Understanding Convolutional Neural Networks for NLP*. WildML. 7th Nov. 2015. URL: <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/> (visited on 23/04/2019).
- [7] Jason Brownlee. *A Gentle Introduction to the Bag-of-Words Model*. Machine Learning Mastery. 8th Oct. 2017. URL: <https://machinelearningmastery.com/gentle-introduction-bag-words-model/> (visited on 24/04/2019).
- [8] Lars Buitinck et al. 'API design for machine learning software: experiences from the scikit-learn project'. In: *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*. 2013, pp. 108–122.
- [9] Francois Chollet et al. *Keras*. 2015. URL: <https://keras.io/>.
- [10] Tom Christie. 'Django REST framework'. In: *Home-Django REST Framework* (2011).
- [11] Ian Goodfellow. *Deep learning*. eng. Cambridge, Mass, 2016.
- [12] *Google Trends*. Google Trends. URL: <https://trends.google.com/trends/explore?date=today%205-y&q=Machine%20learning> (visited on 10/04/2019).
- [13] *Google Trends*. Google Trends. URL: <https://trends.google.com/trends/explore?date=today%205-y&q=Deep%20learning> (visited on 10/04/2019).
- [14] Sepp Hochreiter and Jürgen Schmidhuber. 'Long short-term memory'. In: *Neural computation* 9.8 (1997), pp. 1735–1780.

- [15] Eric Jones, Travis Oliphant and Pearu Peterson. 'SciPy: *opensourcescientifictoolsforPython*'. In: (2014).
- [16] Nal Kalchbrenner, Edward Grefenstette and Phil Blunsom. 'A convolutional neural network for modelling sentences'. In: *arXiv preprint arXiv:1404.2188* (2014).
- [17] Yoon Kim. 'Convolutional neural networks for sentence classification'. In: *arXiv preprint arXiv:1408.5882* (2014).
- [18] Ron Kohavi et al. 'A study of cross-validation and bootstrap for accuracy estimation and model selection'. In: *Ijcai*. Vol. 14. 2. Montreal, Canada. 1995, pp. 1137–1145.
- [19] Alex Krizhevsky, Ilya Sutskever and Geoffrey E Hinton. 'Imagenet classification with deep convolutional neural networks'. In: *Advances in neural information processing systems*. 2012, pp. 1097–1105.
- [20] Yann LeCun, Yoshua Bengio and Geoffrey Hinton. 'Deep learning'. In: *nature* 521.7553 (2015), p. 436.
- [21] Gideon Lewis-Kraus. 'The great AI awakening'. In: *The New York Times Magazine* 14 (2016).
- [22] Xin Li and Dan Roth. 'Learning question classifiers'. In: *Proceedings of the 19th international conference on Computational linguistics-Volume 1*. Association for Computational Linguistics. 2002, pp. 1–7.
- [23] Gary Marcus. 'Deep learning: A critical appraisal'. In: *arXiv preprint arXiv:1801.00631* (2018).
- [24] K Jarrod Millman and Michael Aivazis. 'Python for scientists and engineers'. In: *Computing in Science & Engineering* 13.2 (2011), pp. 9–12.
- [25] Tom M. Mitchell. *Machine Learning*. McGraw-Hill series in computer science. New York: McGraw-Hill, 1997. 414 pp. ISBN: 978-0-07-042807-2.
- [26] Aanund Nordskog. *Text Classification Project*. original-date: 2019-05-16T06:12:33Z. 16th May 2019. URL: <https://github.com/Halflingen/Text-Classification-Project> (visited on 16/05/2019).
- [27] Christopher Olah. *Understanding LSTM Networks – colah's blog*. URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (visited on 18/04/2019).
- [28] Fabian Pedregosa et al. 'Scikit-learn: Machine learning in Python'. In: *Journal of machine learning research* 12.Oct (2011), pp. 2825–2830.
- [29] Konstantin Pogorelov et al. 'Kvasir: A multi-class image dataset for computer aided gastrointestinal disease detection'. In: *Proceedings of the 8th ACM on Multimedia Systems Conference*. ACM. 2017, pp. 164–169.
- [30] Leonard Richardson. *Beautiful Soup*. URL: <https://www.crummy.com/software/BeautifulSoup/> (visited on 28/01/2019).

- [31] Irina Rish et al. 'An empirical study of the naive Bayes classifier'. In: *IJCAI 2001 workshop on empirical methods in artificial intelligence*. Vol. 3. 22. IBM New York. 2001, pp. 41–46.
- [32] Jurgen Schmidhuber. 'Deep learning in neural networks: An overview'. In: *Neural networks* 61 (2015), pp. 85–117.
- [33] Frank Seide and Amit Agarwal. 'CNTK: Microsoft's open-source deep-learning toolkit'. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM. 2016, pp. 2135–2135.
- [34] Joao Silva et al. 'From symbolic to sub-symbolic information in question classification'. In: *Artificial Intelligence Review* 35.2 (2011), pp. 137–154.
- [35] David Silver et al. 'Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm'. In: *arXiv:1712.01815 [cs]* (5th Dec. 2017). arXiv: 1712.01815. URL: <http://arxiv.org/abs/1712.01815> (visited on 31/05/2018).
- [36] Alex J Smola and Bernhard Schölkopf. 'A tutorial on support vector regression'. In: *Statistics and computing* 14.3 (2004), pp. 199–222.
- [37] Richard Socher et al. 'Recursive deep models for semantic compositionality over a sentiment treebank'. In: *Proceedings of the 2013 conference on empirical methods in natural language processing*. 2013, pp. 1631–1642.
- [38] Nitish Srivastava et al. 'Dropout: a simple way to prevent neural networks from overfitting'. In: *The Journal of Machine Learning Research* 15.1 (2014), pp. 1929–1958.
- [39] *Total number of Websites - Internet Live Stats*. URL: <http://www.internetlivestats.com/total-number-of-websites/> (visited on 19/04/2019).
- [40] *Underfitting vs. Overfitting — scikit-learn 0.15-git documentation*. URL: https://scikit-learn.org/0.15/auto_examples/plot_underfitting_overfitting.html (visited on 25/04/2019).
- [41] Guido Van Rossum and Fred L Drake Jr. *Python reference manual*. Centrum voor Wiskunde en Informatica Amsterdam, 1995.
- [42] Tom Young et al. 'Recent trends in deep learning based natural language processing'. In: *ieee Computational intelligence magazine* 13.3 (2018), pp. 55–75.
- [43] Dell Zhang and Wee Sun Lee. 'Question classification using support vector machines'. In: *Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval*. ACM. 2003, pp. 26–32.
- [44] Harry Zhang. 'The optimality of naive Bayes'. In: *AA* 1.2 (2004), p. 3.
- [45] Chunting Zhou et al. 'A C-LSTM neural network for text classification'. In: *arXiv preprint arXiv:1511.08630* (2015).

Appendices

Appendix A

Experiments

A.1 Naive Bayes

A.1.1 Application Experiments

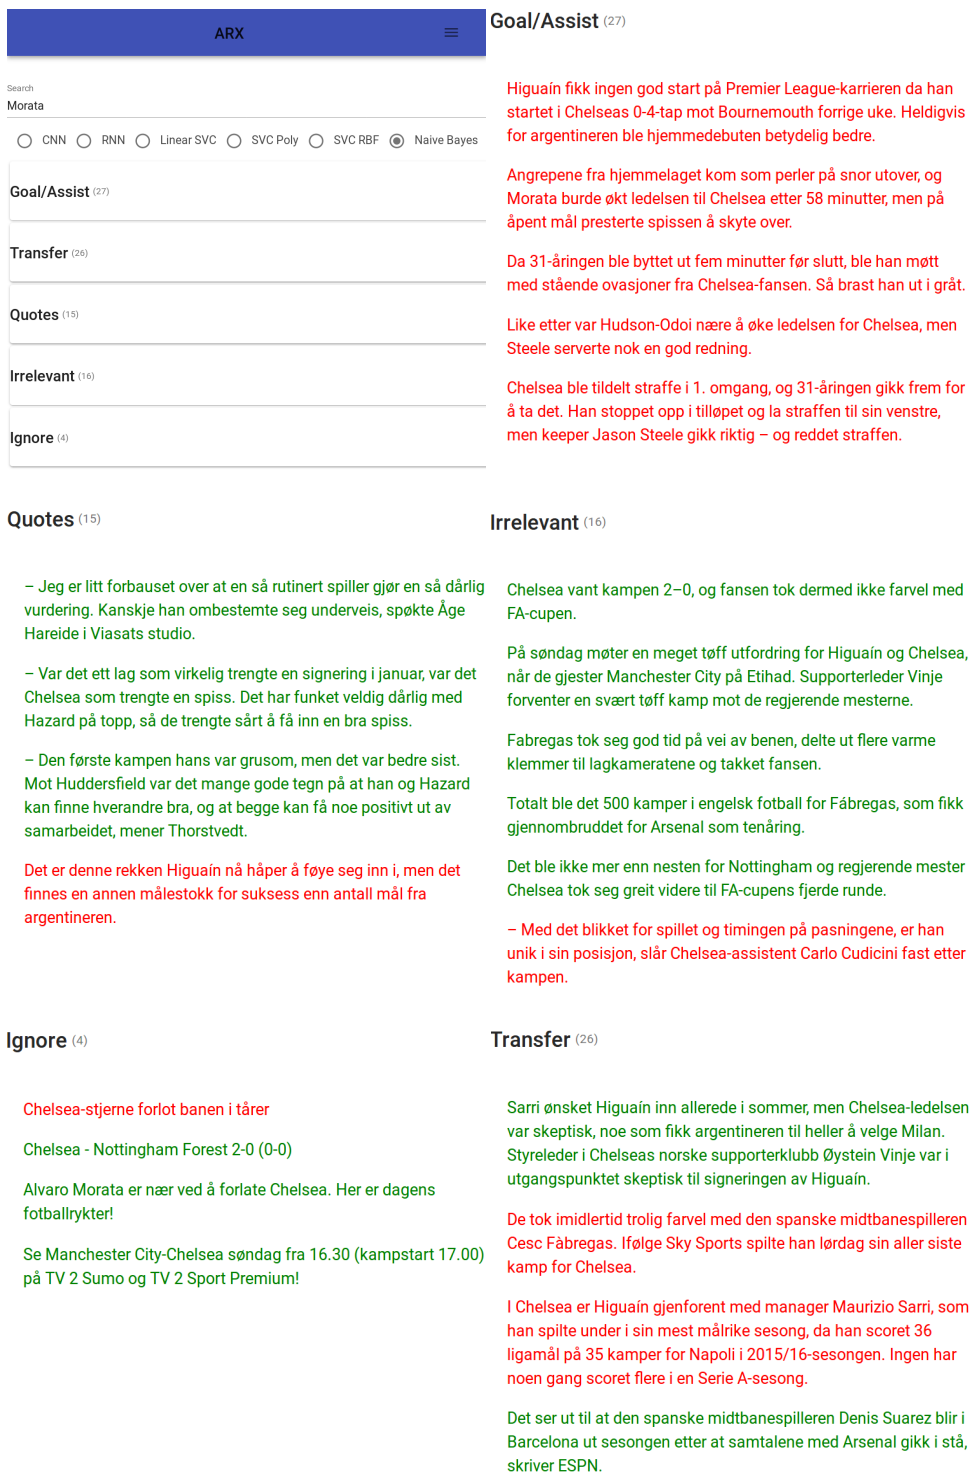


Figure A.1: Naive Bayes application results for Morata. All classified paragraphs are in figure B.6 - B.9

A.2 Linear SVC

A.2.1 Application Experiments

ARX
☰

Search
Morata

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽²³⁾

Transfer ⁽²²⁾

Quotes ⁽¹¹⁾

Irrelevant ⁽³¹⁾

Ignore ⁽¹⁾

Goal/Assist ⁽²³⁾

Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.

Sarri ønsket Higuain inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuain.

Morata misbrakte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.

Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene.

Quotes ⁽¹¹⁾

– Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.

– Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.

– Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.

Det er denne rekken Higuain nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.

Irrelevant ⁽³¹⁾

Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.

Spillere som Andrij Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Alvaro Morata, har ikledd seg den blå drakten uten nevneverdig suksess.

Chelsea vant kampen 2–0, og fansen tok dermed ikke farvel med FA-cupen.

Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.

Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.

Ignore ⁽¹⁾

Se Manchester City-Chelsea søndag fra 16.30 (kampstart 17.00) på TV 2 Sumo og TV 2 Sport Premium!

Transfer ⁽²²⁾

Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter walisersens landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasseklubb» som Juventus, skriver Sky Sports.

Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.

Figure A.2: Linear SVC application results for Morata. All classified paragraphs are in figure B.15 - B.18

A.3 SVC RBF

A.3.1 Training Experiments

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
2.45	2.283	0.402	0.86	0.824	0.86	0.857	0.862	0.902	0.884	0.903	0.697	0.897
2.33	2.31	0.406	0.86	0.824	0.86	0.857	0.862	0.909	0.88	0.898	0.69	0.905
1.94	2.267	0.399	0.86	0.824	0.86	0.857	0.864	0.903	0.883	0.904	0.699	0.897
2.42	2.284	0.401	0.859	0.823	0.859	0.855	0.862	0.908	0.881	0.898	0.692	0.899
2.09	2.28	0.399	0.859	0.823	0.859	0.856	0.862	0.906	0.879	0.903	0.696	0.896

Table A.1: Top MCC scores for SVC RBF on different C values, when shrinking = flase

Parameter	Time		Metrics					f1 score for each class				
	Gamma	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.82	2.602	0.427	0.858	0.821	0.858	0.855	0.861	0.907	0.875	0.9	0.696	0.897
0.575	2.315	0.4	0.857	0.821	0.857	0.854	0.861	0.901	0.884	0.901	0.687	0.898
0.365	2.074	0.377	0.858	0.821	0.858	0.855	0.861	0.902	0.88	0.903	0.692	0.898
0.785	2.564	0.424	0.858	0.821	0.858	0.855	0.862	0.904	0.881	0.899	0.694	0.899
0.26	1.997	0.373	0.857	0.82	0.857	0.855	0.862	0.9	0.879	0.906	0.69	0.897

Table A.2: Top MCC scores for SVC RBF on different gamma values, when $c = 2.0$ and shrinking = false




Figure A.3: SVC RBF training experiments on different C values, when shrinking = false




Figure A.4: SVC RBF training experiments on different gamma values, when $c = 2.0$ and shrinking = false

A.3.2 Application Experiments

ARX
☰

Search
Morata

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽²²⁾

Transfer ⁽²⁴⁾

Quotes ⁽¹²⁾

Irrelevant ⁽²⁹⁾

Ignore ⁽¹⁾

Goal/Assist ⁽²²⁾

Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.

Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøket angrep av samme duo som lagde 1-0 målet.

Huddersfield-kampen forrige helg, der Higuain scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

Men da en spanjol mislykkes, var det en annen som fikk det til – etter noen forsøk.

Quotes ⁽¹²⁾

– Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.

– Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.

– Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.

– Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.

Irrelevant ⁽²⁹⁾

Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.

Hudson-Odoi - som jaktes av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.

Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.

Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.

(Chelsea – Nottingham Forest 2–0) Cesc Fàbregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.

Ignore ⁽¹⁾

Se Manchester City-Chelsea søndag fra 16.30 (kampstart 17.00) på TV 2 Sumo og TV 2 Sport Premium!

Transfer ⁽²⁴⁾

Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Watford føler seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.

Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.

Figure A.5: SVC RBF application results for Morata. All classified paragraphs are in figure B.25 - B.28

A.4 SVC Poly

A.4.1 Training Experiments

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
1.3	3.715	0.472	0.84	0.8	0.84	0.837	0.85	0.895	0.874	0.882	0.661	0.873
1.4625	3.708	0.473	0.84	0.799	0.84	0.836	0.848	0.896	0.869	0.883	0.657	0.876
1.3375	3.715	0.472	0.839	0.798	0.839	0.835	0.847	0.895	0.867	0.884	0.658	0.874
1.225	3.703	0.471	0.839	0.798	0.839	0.836	0.848	0.891	0.868	0.883	0.66	0.879
1.2625	3.717	0.476	0.838	0.797	0.838	0.835	0.847	0.891	0.869	0.887	0.65	0.875

Table A.3: Top MCC scores for SVC Poly on different C values when shrinking = true

Parameter	Time		Metrics					f1 score for each class				
	Gamma	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
1.15	3.625	0.467	0.84	0.8	0.84	0.838	0.849	0.891	0.872	0.886	0.659	0.88
1.3125	3.443	0.44	0.839	0.799	0.839	0.836	0.849	0.891	0.87	0.886	0.658	0.878
1.2375	3.403	0.435	0.839	0.798	0.839	0.836	0.847	0.894	0.868	0.882	0.657	0.877
1.2	3.399	0.434	0.839	0.798	0.839	0.836	0.847	0.894	0.868	0.882	0.656	0.879
1.2125	3.411	0.436	0.839	0.798	0.839	0.836	0.847	0.891	0.868	0.886	0.655	0.88

Table A.4: Top MCC scores for SVC Poly on different gamma values, when $c = 0.96$ and $\text{shrinking} = \text{true}$

Parameter	Time		Metrics					f1 score for each class				
	Coef0	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.2625	3.396	0.431	0.861	0.825	0.861	0.858	0.864	0.908	0.875	0.903	0.7	0.902
1.5375	2.635	0.388	0.86	0.824	0.86	0.856	0.862	0.908	0.881	0.903	0.692	0.894
0.675	3.018	0.409	0.86	0.824	0.86	0.857	0.863	0.906	0.881	0.902	0.697	0.899
0.3	3.364	0.427	0.858	0.822	0.858	0.855	0.862	0.905	0.88	0.9	0.691	0.901
0.375	3.261	0.424	0.858	0.821	0.858	0.854	0.861	0.905	0.876	0.905	0.688	0.897

Table A.5: Top MCC scores for SVC Poly on different coef0 values, when $c = 0.96$, $\text{gamma} = 1.2$ and $\text{shrinking} = \text{true}$




Figure A.6: SVC Poly training experiments on different C values $\text{shrinking} = \text{true}$




Figure A.7: SVC Poly training experiments on different gamma values, when $c = 0.96$ and $\text{shrinking} = \text{true}$




Figure A.8: SVC Poly training experiments on different coef0 values, when $c = 0.96$, $\text{gamma} = 1.2$ and $\text{shrinking} = \text{true}$

A.4.2 Application Experiments

ARX
☰

Search
Morata

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽²¹⁾

Transfer ⁽²⁴⁾

Quotes ⁽¹²⁾

Irrelevant ⁽³⁰⁾

Ignore ⁽¹⁾

Goal/Assist ⁽²¹⁾

Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben.

Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene.

Men da en spanjol mislykkes, var det en annen som fikk det til – etter noen forsøk.

I Chelsea er Higuain gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong.

Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham.

Quotes ⁽¹²⁾

– Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:

– Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.

Det er denne rekken Higuain nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.

– Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.

Irrelevant ⁽³⁰⁾

Chelsea - Nottingham Forest 2-0 (0-0)

– I Jorginho og Higuain har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.

Higuain fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.

Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.

Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fábregas farvel med engelsk fotball.

Ignore ⁽¹⁾

Se Manchester City-Chelsea søndag fra 16.30 (kampstart 17.00) på TV 2 Sumo og TV 2 Sport Premium!

Transfer ⁽²⁴⁾

Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.

Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.

Chelsea har en lang tradisjon for å hente stjernespisser, men få har levd opp til forventningene på Stamford Bridge.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Siden Roman Abramovitsjs inntog i Chelsea har stjernespissene vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuain.

Figure A.9: SVC Poly application results for Morata. All classified paragraphs are in figure B.35 - B.38

A.5 RNN

A.5.1 Application Experiments

ARX

Goal/Assist ⁽¹⁵⁾

Search
Morata

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽¹⁵⁾

Transfer ⁽²²⁾

Quotes ⁽¹⁴⁾

Irrelevant ⁽³⁵⁾

Ignore ⁽²⁾

Huddersfield-kampen forrige helg, der Higuain scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

Morata misbrukte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.

Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt.

Men den siste sesongene har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjulte spissen scoret begge.

Quotes ⁽¹⁴⁾

- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- I Jorginho og Higuain har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.
- Med det blikket for spillet og timingen på pasningene, er han unik i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.
- Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.

Irrelevant ⁽³⁵⁾

Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.

Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.

Vondt ble til verre for Fabregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.

Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.

De tok imidlertid trolig farvel med den spanske midtbanespilleren Cesc Fábregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.

Ignore ⁽²⁾

Se Manchester City-Chelsea søndag fra 16.30 (kampstart 17.00) på TV 2 Sumo og TV 2 Sport Premium!

Chelsea - Nottingham Forest 2-0 (0-0)

Transfer ⁽²²⁾

Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.

Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.


Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.

Siden den gang har Higuain spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuain, og ikke den som mislykkes i Milano.


Figure A.10: RNN application results for Morata. All classified paragraphs are in figure B.45 - B.48

A.6 CNN


A.6.1 Training Experiments




(a) Filter size = 256



(b) Filter size = 128



(c) Filter size = 64



(d) Filter size = 32

Figure A.11: CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 2

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
223	10.313	0.248	0.869	0.836	0.869	0.865	0.87	0.89	0.869	0.976	0.699	0.893
247	10.979	0.254	0.87	0.836	0.87	0.867	0.87	0.888	0.867	0.978	0.701	0.9
244	10.701	0.245	0.867	0.833	0.867	0.863	0.868	0.885	0.872	0.978	0.69	0.891
238	10.69	0.248	0.867	0.833	0.867	0.863	0.868	0.885	0.871	0.973	0.698	0.889
136	9.325	0.247	0.866	0.832	0.866	0.864	0.868	0.881	0.865	0.977	0.693	0.903

(a) Filter size = 256

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
184	9.781	0.306	0.866	0.832	0.866	0.861	0.867	0.883	0.871	0.975	0.692	0.886
130	8.267	0.292	0.867	0.832	0.867	0.863	0.867	0.885	0.868	0.975	0.689	0.898
151	9.187	0.303	0.865	0.831	0.865	0.861	0.866	0.881	0.863	0.975	0.686	0.9
217	10.011	0.295	0.865	0.831	0.865	0.862	0.867	0.886	0.854	0.974	0.695	0.902
88	8.045	0.282	0.864	0.83	0.864	0.859	0.863	0.879	0.871	0.972	0.69	0.882

(b) Filter size = 128

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
187	5.701	0.25	0.867	0.833	0.867	0.863	0.868	0.885	0.875	0.972	0.693	0.891
193	5.209	0.25	0.866	0.832	0.866	0.862	0.866	0.882	0.867	0.975	0.69	0.896
220	8.31	0.273	0.865	0.83	0.865	0.861	0.865	0.883	0.866	0.974	0.684	0.901
184	5.286	0.244	0.864	0.829	0.864	0.86	0.864	0.877	0.866	0.974	0.685	0.898
211	5.51	0.254	0.864	0.829	0.864	0.859	0.864	0.884	0.863	0.975	0.682	0.894

(c) Filter size = 64

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
193	9.398	0.274	0.864	0.829	0.864	0.86	0.866	0.888	0.861	0.973	0.686	0.893
142	7.115	0.24	0.863	0.828	0.863	0.859	0.864	0.877	0.868	0.969	0.687	0.896
190	9.594	0.275	0.862	0.827	0.862	0.859	0.864	0.879	0.865	0.974	0.684	0.895
172	9.245	0.274	0.862	0.826	0.862	0.859	0.863	0.876	0.861	0.975	0.682	0.898
82	5.168	0.244	0.86	0.825	0.86	0.857	0.863	0.881	0.86	0.969	0.683	0.894

(d) Filter size = 32

Table A.6: Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 2

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
136	9.301	0.243	0.866	0.832	0.866	0.862	0.866	0.888	0.865	0.969	0.692	0.895
217	10.276	0.257	0.865	0.831	0.865	0.86	0.864	0.885	0.867	0.967	0.691	0.891
202	10.593	0.245	0.866	0.831	0.866	0.861	0.866	0.887	0.872	0.969	0.686	0.89
184	10.177	0.249	0.866	0.831	0.866	0.86	0.863	0.888	0.876	0.968	0.681	0.887
196	10.209	0.251	0.864	0.83	0.864	0.861	0.866	0.883	0.866	0.976	0.688	0.892

(a) Filter size = 256

Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
226	10.066	0.243	0.867	0.833	0.867	0.862	0.865	0.884	0.877	0.97	0.688	0.889
136	8.846	0.278	0.866	0.832	0.866	0.862	0.865	0.884	0.868	0.969	0.682	0.905
133	8.611	0.275	0.865	0.83	0.865	0.858	0.862	0.888	0.873	0.965	0.673	0.892
190	9.875	0.297	0.863	0.829	0.863	0.858	0.863	0.885	0.865	0.969	0.679	0.891
181	9.624	0.302	0.864	0.829	0.864	0.86	0.864	0.881	0.869	0.971	0.687	0.893

(b) Filter size = 128


Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
79	7.461	0.249	0.863	0.828	0.863	0.859	0.863	0.88	0.867	0.969	0.681	0.896
178	9.409	0.274	0.863	0.827	0.863	0.858	0.862	0.881	0.871	0.969	0.678	0.892
91	7.587	0.257	0.862	0.827	0.862	0.858	0.861	0.881	0.865	0.968	0.675	0.9
103	7.991	0.256	0.862	0.827	0.862	0.858	0.861	0.877	0.873	0.97	0.674	0.895
196	9.935	0.28	0.862	0.827	0.862	0.856	0.86	0.881	0.869	0.964	0.67	0.897

(c) Filter size = 64


Parameter	Time		Metrics					f1 score for each class				
	Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
247	10.432	0.276	0.862	0.828	0.862	0.856	0.861	0.886	0.865	0.966	0.672	0.893
100	8.037	0.249	0.863	0.828	0.863	0.858	0.863	0.888	0.868	0.963	0.678	0.893
190	9.483	0.271	0.862	0.827	0.862	0.856	0.861	0.883	0.87	0.958	0.675	0.892
157	9.019	0.253	0.862	0.826	0.862	0.857	0.861	0.886	0.873	0.96	0.673	0.893
196	9.627	0.258	0.861	0.826	0.861	0.856	0.86	0.881	0.869	0.961	0.676	0.893

(d) Filter size = 32


Table A.7: Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 4




(a) Filter size = 256



(b) Filter size = 128



(c) Filter size = 64



(d) Filter size = 32

Figure A.12: CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 3 and pooling size = 4

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Embedding dim												
226	10.79	0.25	0.868	0.834	0.868	0.862	0.866	0.894	0.873	0.972	0.69	0.882
235	10.811	0.249	0.867	0.834	0.867	0.864	0.87	0.885	0.873	0.973	0.694	0.897
244	11.227	0.245	0.867	0.832	0.867	0.862	0.865	0.883	0.877	0.974	0.688	0.887
199	10.42	0.255	0.866	0.832	0.866	0.861	0.865	0.893	0.865	0.967	0.689	0.89
130	9.452	0.252	0.865	0.831	0.865	0.861	0.866	0.883	0.87	0.969	0.696	0.889

(a) Filter size = 256

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Embedding dim												
214	5.876	0.275	0.87	0.837	0.87	0.865	0.87	0.894	0.871	0.97	0.698	0.894
244	8.341	0.236	0.87	0.836	0.87	0.863	0.868	0.893	0.877	0.971	0.695	0.881
145	6.035	0.261	0.868	0.834	0.868	0.864	0.867	0.884	0.878	0.967	0.692	0.897
124	7.059	0.272	0.867	0.833	0.867	0.861	0.865	0.888	0.874	0.97	0.69	0.886
148	7.683	0.273	0.865	0.831	0.865	0.861	0.867	0.885	0.873	0.97	0.697	0.88

(b) Filter size = 128


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Embedding dim												
244	10.57	0.288	0.866	0.832	0.866	0.86	0.864	0.887	0.88	0.964	0.683	0.886
238	10.399	0.287	0.866	0.831	0.866	0.86	0.864	0.889	0.868	0.967	0.684	0.89
235	10.115	0.29	0.864	0.829	0.864	0.859	0.864	0.889	0.863	0.964	0.693	0.888
142	8.645	0.261	0.864	0.829	0.864	0.86	0.864	0.887	0.864	0.966	0.688	0.896
214	10.339	0.28	0.864	0.829	0.864	0.86	0.864	0.885	0.868	0.968	0.683	0.893

(c) Filter size = 64


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
Embedding dim												
148	8.931	0.257	0.863	0.828	0.863	0.859	0.863	0.884	0.867	0.966	0.681	0.899
187	9.744	0.267	0.862	0.826	0.862	0.856	0.86	0.883	0.864	0.963	0.676	0.894
31	5.669	0.23	0.861	0.826	0.861	0.857	0.862	0.883	0.861	0.963	0.688	0.888
178	9.435	0.26	0.86	0.825	0.86	0.854	0.859	0.887	0.862	0.953	0.669	0.898
193	9.49	0.268	0.86	0.825	0.86	0.854	0.859	0.889	0.862	0.953	0.672	0.896

(d) Filter size = 32


Table A.8: Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 4 and pooling size = 4




(a) Filter size = 256



(b) Filter size = 128



(c) Filter size = 64



(d) Filter size = 32

Figure A.13: CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 4 and pooling size = 4

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
244	10.782	0.254	0.867	0.833	0.867	0.863	0.867	0.883	0.874	0.969	0.688	0.899
109	8.644	0.323	0.864	0.829	0.864	0.858	0.864	0.891	0.863	0.971	0.684	0.883
199	9.789	0.249	0.864	0.829	0.864	0.859	0.863	0.884	0.865	0.976	0.685	0.886
187	9.718	0.25	0.863	0.828	0.863	0.858	0.862	0.885	0.854	0.969	0.687	0.894
127	8.757	0.245	0.863	0.828	0.863	0.858	0.863	0.885	0.863	0.97	0.68	0.89

(a) Filter size = 256

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
226	9.838	0.238	0.869	0.836	0.869	0.865	0.868	0.886	0.872	0.974	0.693	0.897
127	8.378	0.28	0.865	0.83	0.865	0.859	0.864	0.888	0.864	0.972	0.679	0.895
166	8.908	0.291	0.864	0.829	0.864	0.861	0.864	0.883	0.869	0.97	0.683	0.899
100	7.94	0.269	0.863	0.829	0.863	0.858	0.863	0.883	0.865	0.967	0.681	0.892
190	9.682	0.294	0.863	0.829	0.863	0.858	0.862	0.883	0.865	0.969	0.681	0.892

(b) Filter size = 128


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
157	8.98	0.261	0.865	0.83	0.865	0.859	0.863	0.886	0.871	0.967	0.687	0.883
142	8.592	0.254	0.863	0.828	0.863	0.858	0.862	0.886	0.866	0.962	0.68	0.896
229	10.051	0.284	0.862	0.827	0.862	0.857	0.861	0.885	0.861	0.971	0.672	0.894
214	9.69	0.279	0.862	0.827	0.862	0.857	0.862	0.889	0.858	0.965	0.675	0.896
226	9.837	0.283	0.862	0.826	0.862	0.856	0.86	0.886	0.855	0.969	0.676	0.898

(c) Filter size = 64


Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
64	7.119	0.235	0.862	0.827	0.862	0.858	0.862	0.882	0.865	0.964	0.68	0.899
229	5.183	0.212	0.86	0.825	0.86	0.854	0.859	0.889	0.866	0.953	0.668	0.895
157	5.149	0.293	0.86	0.825	0.86	0.855	0.86	0.887	0.857	0.962	0.673	0.895
34	5.77	0.238	0.859	0.823	0.859	0.853	0.857	0.886	0.864	0.958	0.664	0.891
238	6.362	0.231	0.859	0.823	0.859	0.854	0.858	0.881	0.862	0.963	0.669	0.892

(d) Filter size = 32


Table A.9: Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 2 and pooling size = 4




(a) Filter size = 256



(b) Filter size = 128



(c) Filter size = 64



(d) Filter size = 32

Figure A.14: CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 2 and pooling size = 4

Parameter	Time		Metrics					f1 score for each class				
Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
238	11.182	0.251	0.869	0.835	0.869	0.864	0.869	0.892	0.871	0.972	0.7	0.886
247	11.362	0.253	0.867	0.833	0.867	0.864	0.868	0.889	0.866	0.97	0.698	0.896
136	9.249	0.246	0.867	0.833	0.867	0.862	0.866	0.889	0.869	0.972	0.692	0.889
115	8.592	0.313	0.867	0.833	0.867	0.863	0.868	0.889	0.869	0.969	0.7	0.889
190	10.358	0.255	0.866	0.832	0.866	0.863	0.868	0.887	0.863	0.972	0.703	0.889

(a) Filter size = 256

Parameter	Time		Metrics					f1 score for each class				
Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
232	10.125	0.245	0.868	0.834	0.868	0.864	0.868	0.891	0.862	0.976	0.697	0.892
217	9.856	0.29	0.868	0.834	0.868	0.864	0.868	0.892	0.864	0.968	0.702	0.893
154	8.715	0.279	0.868	0.834	0.868	0.863	0.869	0.892	0.867	0.971	0.702	0.885
82	6.588	0.258	0.868	0.834	0.868	0.864	0.868	0.892	0.864	0.967	0.698	0.897
220	10.091	0.255	0.867	0.833	0.867	0.862	0.867	0.888	0.873	0.973	0.701	0.876

(b) Filter size = 128


Parameter	Time		Metrics					f1 score for each class				
Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
232	9.914	0.28	0.867	0.833	0.867	0.864	0.869	0.891	0.861	0.97	0.704	0.892
235	9.872	0.279	0.864	0.83	0.864	0.861	0.866	0.891	0.857	0.972	0.693	0.892
220	9.017	0.269	0.864	0.83	0.864	0.861	0.865	0.886	0.862	0.967	0.695	0.895
199	9.361	0.266	0.864	0.829	0.864	0.86	0.865	0.891	0.86	0.966	0.695	0.89
187	8.905	0.27	0.864	0.829	0.864	0.86	0.864	0.89	0.863	0.96	0.692	0.894

(c) Filter size = 64


Parameter	Time		Metrics					f1 score for each class				
Embedding dim	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
244	9.426	0.266	0.864	0.829	0.864	0.86	0.863	0.887	0.861	0.965	0.682	0.903
196	9.12	0.253	0.861	0.826	0.861	0.856	0.861	0.879	0.865	0.962	0.682	0.894
235	9.512	0.268	0.861	0.825	0.861	0.855	0.859	0.88	0.866	0.962	0.678	0.889
184	8.74	0.263	0.859	0.824	0.859	0.855	0.86	0.886	0.867	0.958	0.679	0.882
82	6.649	0.239	0.86	0.824	0.86	0.855	0.86	0.887	0.863	0.962	0.68	0.883

(d) Filter size = 32


Table A.10: Top MCC scores for CNN on different embedding dimensions, for four different filter sizes. Kernel size = 8 and pooling size = 4




(a) Filter size = 256



(b) Filter size = 128



(c) Filter size = 64



(d) Filter size = 32

Figure A.15: CNN training experiments on different embedding dimensions, for four different filter sizes. Kernel size = 8 and pooling size = 4

A.6.2 Application Experiments

ARX

Goal/Assist ⁽²²⁾

Search
Morata

CNN
 RNN
 Linear SVC
 SVC Poly
 SVC RBF
 Naive Bayes

Goal/Assist ⁽²²⁾

Transfer ⁽²⁴⁾

Quotes ⁽¹⁵⁾

Irrelevant ⁽²⁴⁾

Ignore ⁽³⁾

Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham.

Sarri ønsket Higuain inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuain.

Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.

Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.

Quotes ⁽¹⁵⁾

- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Blir han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.
- Higuain kan ikke bare måles på antall scoringer
- Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.
- Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:

Irrelevant ⁽²⁴⁾

Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.

Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.

Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.

Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.

Chelsea vant kampen 2-0, og fansen tok dermed ikke farvel med FA-cupen.

Ignore ⁽³⁾

Chelsea - Nottingham Forest 2-0 (0-0)

Hans nye klubb ligger på andreplass i La Liga, fem poeng bak Barcelona. Som Sarri, har Atlético Madrid-manager Diego Simeone slitt med å få angrepsspillere til å score.

Se Manchester City-Chelsea søndag fra 16.30 (kampstart 17.00) på TV 2 Sumo og TV 2 Sport Premium!

Transfer ⁽²⁴⁾

Det ser ut til at den spanske midtbanespilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalen med Arsenal gikk i stå, skriver ESPN.

Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Chelsea har en lang tradisjon for å hente stjernespisser, men få har levd opp til forventningene på Stamford Bridge.

Figure A.16: CNN application results for Morata. All classified paragraphs are in figure B.55 - B.58

Appendix B

Complete Result Overview

B.1 Naive Bayes

B.1.1 Ful Tables from Training Experiments

Para	Time		Metrics					f1 score for each class				
Alpha	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.06	0.06	0.02	0.81	0.76	0.81	0.80	0.80	0.86	0.86	0.86	0.57	0.83
0.12	0.06	0.02	0.81	0.76	0.81	0.80	0.80	0.87	0.86	0.86	0.58	0.83
0.18	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.86	0.57	0.81
0.21	0.06	0.02	0.80	0.76	0.80	0.79	0.80	0.86	0.86	0.87	0.56	0.81
0.24	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.87	0.57	0.80
0.33	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.86	0.57	0.80
0.36	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.87	0.86	0.86	0.58	0.80
0.39	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.87	0.56	0.79
0.42	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.79
0.45	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.87	0.55	0.79
0.48	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.87	0.56	0.80
0.51	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.87	0.86	0.87	0.56	0.80
0.54	0.06	0.02	0.80	0.76	0.80	0.79	0.80	0.88	0.86	0.86	0.55	0.79
0.66	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.87	0.55	0.79
0.69	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.79
0.72	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
0.75	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.79
0.78	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.57	0.79
0.81	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.80
0.84	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.58	0.80
0.93	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
0.99	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.80
1.02	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
1.08	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
1.11	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.55	0.81
1.14	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.81
1.2	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.56	0.81
1.23	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.54	0.81
1.26	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.54	0.81
1.29	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.54	0.82
1.41	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.88	0.86	0.87	0.55	0.83
1.44	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.87	0.87	0.54	0.83
1.47	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.88	0.86	0.87	0.54	0.83
1.53	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.54	0.83
1.59	0.06	0.02	0.82	0.77	0.82	0.79	0.81	0.87	0.87	0.87	0.53	0.84
1.62	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.87	0.87	0.87	0.53	0.84
1.68	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.87	0.87	0.87	0.52	0.85
1.71	0.06	0.02	0.82	0.77	0.82	0.79	0.81	0.87	0.87	0.87	0.52	0.84
1.8	0.06	0.02	0.82	0.77	0.82	0.79	0.81	0.87	0.87	0.87	0.51	0.86
1.86	0.06	0.02	0.82	0.77	0.82	0.79	0.81	0.86	0.87	0.87	0.51	0.86
1.92	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.86	0.87	0.50	0.86
1.98	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.87	0.49	0.87
2.01	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.87	0.47	0.87
2.04	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.85	0.87	0.87	0.47	0.87
2.13	0.06	0.02	0.81	0.76	0.81	0.78	0.80	0.85	0.87	0.87	0.44	0.88
2.16	0.06	0.02	0.80	0.76	0.80	0.78	0.80	0.85	0.86	0.87	0.42	0.88
2.19	0.06	0.02	0.81	0.76	0.81	0.78	0.80	0.85	0.87	0.87	0.45	0.88
2.22	0.06	0.02	0.81	0.76	0.81	0.78	0.80	0.84	0.87	0.87	0.44	0.88
2.25	0.06	0.02	0.80	0.76	0.80	0.78	0.80	0.84	0.86	0.87	0.43	0.88
2.34	0.06	0.02	0.80	0.76	0.80	0.77	0.80	0.83	0.86	0.87	0.40	0.89
2.37	0.06	0.02	0.80	0.75	0.80	0.77	0.79	0.83	0.86	0.87	0.39	0.88
2.4	0.06	0.02	0.80	0.75	0.80	0.77	0.79	0.83	0.87	0.87	0.39	0.88
2.49	0.06	0.02	0.79	0.75	0.79	0.76	0.79	0.82	0.86	0.87	0.36	0.88
2.52	0.06	0.02	0.79	0.75	0.79	0.76	0.79	0.82	0.86	0.87	0.36	0.89
2.61	0.06	0.02	0.79	0.74	0.79	0.75	0.79	0.81	0.86	0.87	0.33	0.89
2.67	0.06	0.02	0.78	0.74	0.78	0.75	0.78	0.80	0.86	0.87	0.31	0.89
2.73	0.06	0.02	0.78	0.74	0.78	0.74	0.78	0.79	0.87	0.87	0.30	0.89
2.76	0.06	0.02	0.78	0.73	0.78	0.74	0.78	0.79	0.87	0.87	0.28	0.88
2.79	0.06	0.02	0.77	0.73	0.77	0.73	0.78	0.79	0.86	0.87	0.27	0.88
2.85	0.06	0.02	0.77	0.73	0.77	0.73	0.78	0.78	0.87	0.87	0.25	0.88
2.91	0.06	0.02	0.77	0.72	0.77	0.72	0.78	0.78	0.86	0.87	0.24	0.88
2.94	0.06	0.02	0.76	0.72	0.76	0.72	0.77	0.77	0.86	0.87	0.22	0.87
3	0.06	0.02	0.76	0.72	0.76	0.71	0.77	0.76	0.86	0.87	0.21	0.87
3.06	0.06	0.02	0.76	0.71	0.76	0.71	0.77	0.76	0.86	0.87	0.19	0.86
3.09	0.06	0.02	0.75	0.71	0.75	0.70	0.77	0.75	0.86	0.87	0.17	0.86
3.15	0.06	0.02	0.75	0.70	0.75	0.69	0.76	0.74	0.86	0.87	0.15	0.85
3.18	0.06	0.02	0.75	0.70	0.75	0.70	0.77	0.75	0.86	0.87	0.15	0.85
3.27	0.06	0.02	0.74	0.70	0.74	0.69	0.77	0.73	0.86	0.87	0.14	0.84
3.3	0.06	0.02	0.74	0.70	0.74	0.69	0.76	0.73	0.85	0.87	0.14	0.84
3.33	0.06	0.02	0.74	0.69	0.74	0.68	0.76	0.73	0.86	0.87	0.12	0.84
3.39	0.06	0.02	0.73	0.69	0.73	0.68	0.77	0.72	0.85	0.87	0.12	0.84
3.42	0.06	0.02	0.73	0.69	0.73	0.68	0.78	0.72	0.85	0.87	0.12	0.84
3.45	0.06	0.02	0.73	0.69	0.73	0.68	0.77	0.72	0.85	0.87	0.12	0.83
3.51	0.06	0.02	0.73	0.68	0.73	0.67	0.78	0.72	0.85	0.87	0.10	0.83
3.57	0.06	0.02	0.73	0.68	0.73	0.67	0.78	0.71	0.85	0.86	0.09	0.82
3.6	0.06	0.02	0.72	0.68	0.72	0.67	0.78	0.71	0.85	0.86	0.09	0.82
3.66	0.06	0.02	0.72	0.68	0.72	0.66	0.75	0.71	0.84	0.87	0.07	0.82
3.72	0.06	0.02	0.72	0.67	0.72	0.65	0.76	0.70	0.84	0.86	0.05	0.81
3.81	0.06	0.02	0.71	0.67	0.71	0.65	0.76	0.69	0.84	0.86	0.05	0.81
3.87	0.06	0.02	0.71	0.66	0.71	0.64	0.74	0.69	0.83	0.86	0.04	0.80
3.9	0.06	0.02	0.71	0.66	0.71	0.64	0.77	0.69	0.84	0.86	0.04	0.80
3.96	0.06	0.02	0.70	0.66	0.70	0.64	0.76	0.68	0.83	0.86	0.03	0.79

Table B.1: Performances and execution times for Naive Bayes on different alpha values when using Bernoulli distribution and count vectorization

Para	Time		Metrics					f1 score for each class				
Alpha	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.06	0.06	0.02	0.81	0.76	0.81	0.80	0.80	0.86	0.86	0.86	0.57	0.83
0.12	0.06	0.02	0.81	0.76	0.81	0.80	0.81	0.87	0.86	0.86	0.58	0.82
0.15	0.06	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.86	0.57	0.81
0.21	0.07	0.02	0.81	0.76	0.81	0.79	0.80	0.87	0.86	0.87	0.57	0.80
0.27	0.06	0.02	0.80	0.76	0.80	0.79	0.80	0.87	0.86	0.87	0.56	0.80
0.3	0.06	0.02	0.81	0.76	0.81	0.80	0.81	0.87	0.86	0.87	0.58	0.80
0.36	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.86	0.57	0.80
0.39	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.57	0.80
0.45	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.86	0.56	0.80
0.51	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.79
0.54	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.86	0.57	0.79
0.6	0.06	0.02	0.81	0.76	0.81	0.80	0.81	0.88	0.86	0.87	0.56	0.80
0.63	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.79
0.69	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.79
0.72	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.80
0.78	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
0.81	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.57	0.80
0.87	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
0.9	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.80
0.96	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
0.99	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.87	0.87	0.55	0.80
1.05	0.06	0.02	0.81	0.76	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.80
1.08	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.56	0.81
1.14	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.55	0.81
1.17	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.56	0.81
1.23	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.55	0.81
1.26	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.88	0.87	0.87	0.56	0.81
1.32	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.88	0.86	0.87	0.55	0.82
1.35	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.88	0.87	0.87	0.55	0.82
1.38	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.54	0.82
1.44	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.88	0.86	0.87	0.54	0.82
1.5	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.88	0.87	0.87	0.54	0.83
1.56	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.88	0.86	0.87	0.54	0.83
1.59	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.87	0.86	0.87	0.53	0.84
1.65	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.87	0.86	0.87	0.51	0.84
1.68	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.87	0.87	0.87	0.51	0.85
1.74	0.06	0.02	0.82	0.77	0.82	0.79	0.81	0.87	0.86	0.87	0.52	0.85
1.77	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.87	0.87	0.87	0.52	0.85
1.8	0.06	0.02	0.82	0.77	0.82	0.80	0.81	0.87	0.87	0.87	0.52	0.86
1.86	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.87	0.50	0.86
1.89	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.87	0.50	0.86
1.92	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.86	0.87	0.50	0.86
1.98	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.88	0.48	0.87
2.01	0.06	0.02	0.81	0.77	0.81	0.78	0.80	0.85	0.87	0.87	0.46	0.87
2.07	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.87	0.47	0.87
2.1	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.85	0.87	0.88	0.47	0.87
2.16	0.06	0.02	0.81	0.76	0.81	0.78	0.80	0.85	0.87	0.87	0.44	0.88
2.22	0.06	0.02	0.81	0.76	0.81	0.78	0.80	0.85	0.87	0.87	0.44	0.88
2.25	0.06	0.02	0.81	0.76	0.81	0.78	0.80	0.84	0.87	0.87	0.43	0.88
2.31	0.06	0.02	0.80	0.76	0.80	0.78	0.80	0.84	0.87	0.87	0.42	0.89
2.34	0.06	0.02	0.80	0.76	0.80	0.77	0.80	0.83	0.87	0.87	0.40	0.89
2.4	0.06	0.02	0.80	0.75	0.80	0.77	0.79	0.83	0.86	0.87	0.38	0.89
2.43	0.06	0.02	0.80	0.76	0.80	0.77	0.80	0.83	0.87	0.87	0.40	0.89
2.49	0.06	0.02	0.80	0.75	0.80	0.76	0.79	0.82	0.87	0.87	0.37	0.89
2.52	0.06	0.02	0.79	0.74	0.79	0.76	0.79	0.82	0.86	0.87	0.34	0.89
2.58	0.06	0.02	0.79	0.74	0.79	0.75	0.79	0.81	0.86	0.87	0.33	0.89
2.61	0.06	0.02	0.79	0.74	0.79	0.75	0.79	0.81	0.87	0.87	0.33	0.89
2.67	0.06	0.02	0.78	0.74	0.78	0.75	0.78	0.80	0.87	0.87	0.31	0.88
2.7	0.06	0.02	0.78	0.73	0.78	0.74	0.78	0.80	0.86	0.87	0.29	0.89
2.76	0.06	0.02	0.78	0.73	0.78	0.74	0.78	0.79	0.86	0.88	0.28	0.89
2.79	0.06	0.02	0.78	0.73	0.78	0.74	0.78	0.79	0.86	0.87	0.28	0.88
2.85	0.06	0.02	0.77	0.73	0.77	0.73	0.78	0.78	0.87	0.87	0.25	0.88
2.91	0.06	0.02	0.77	0.72	0.77	0.72	0.78	0.77	0.87	0.87	0.23	0.87
2.94	0.06	0.02	0.76	0.72	0.76	0.72	0.78	0.77	0.86	0.87	0.22	0.87
3.03	0.06	0.02	0.76	0.71	0.76	0.71	0.77	0.76	0.87	0.87	0.19	0.86
3.09	0.06	0.02	0.75	0.71	0.75	0.70	0.76	0.75	0.86	0.87	0.18	0.86
3.15	0.06	0.02	0.75	0.71	0.75	0.70	0.77	0.75	0.86	0.87	0.16	0.85
3.18	0.06	0.02	0.75	0.70	0.75	0.70	0.77	0.74	0.86	0.87	0.16	0.85
3.24	0.06	0.02	0.74	0.70	0.74	0.69	0.75	0.74	0.85	0.87	0.13	0.85
3.27	0.06	0.02	0.74	0.70	0.74	0.69	0.76	0.74	0.85	0.87	0.13	0.85
3.33	0.06	0.02	0.74	0.69	0.74	0.68	0.78	0.73	0.85	0.87	0.12	0.84
3.42	0.06	0.02	0.73	0.69	0.73	0.67	0.77	0.72	0.85	0.87	0.10	0.83
3.48	0.06	0.02	0.73	0.69	0.73	0.68	0.78	0.72	0.85	0.87	0.11	0.83
3.54	0.06	0.02	0.72	0.68	0.72	0.66	0.77	0.71	0.85	0.86	0.07	0.82
3.57	0.06	0.02	0.73	0.68	0.73	0.67	0.77	0.71	0.85	0.87	0.09	0.82
3.63	0.06	0.02	0.72	0.68	0.72	0.66	0.78	0.71	0.85	0.86	0.08	0.82
3.66	0.06	0.02	0.72	0.68	0.72	0.66	0.78	0.71	0.84	0.87	0.07	0.82
3.75	0.06	0.02	0.71	0.67	0.71	0.65	0.73	0.70	0.84	0.86	0.05	0.81
3.81	0.06	0.02	0.71	0.67	0.71	0.65	0.78	0.69	0.84	0.86	0.05	0.80
3.84	0.06	0.02	0.71	0.66	0.71	0.64	0.76	0.69	0.84	0.86	0.03	0.80
3.9	0.06	0.02	0.70	0.66	0.70	0.64	0.75	0.69	0.84	0.86	0.03	0.80
3.96	0.06	0.02	0.70	0.66	0.70	0.64	0.79	0.68	0.83	0.86	0.04	0.79

Table B.2: Performances and execution times for Naive Bayes on different alpha values when using Bernoulli distribution and tfidf vectorization

Para	Time		Metrics					f1 score for each class				
Alpha	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.04	0.06	0.01	0.80	0.76	0.80	0.79	0.80	0.85	0.86	0.85	0.49	0.89
0.1	0.06	0.01	0.81	0.76	0.81	0.79	0.80	0.85	0.86	0.86	0.50	0.89
0.13	0.06	0.01	0.81	0.76	0.81	0.79	0.80	0.85	0.86	0.86	0.49	0.89
0.22	0.06	0.02	0.81	0.77	0.81	0.80	0.81	0.86	0.87	0.87	0.50	0.89
0.25	0.06	0.01	0.82	0.77	0.82	0.80	0.81	0.86	0.87	0.87	0.50	0.89
0.28	0.06	0.01	0.82	0.78	0.82	0.80	0.81	0.86	0.87	0.87	0.50	0.89
0.37	0.06	0.01	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.86	0.48	0.89
0.4	0.06	0.01	0.82	0.77	0.82	0.80	0.81	0.86	0.87	0.87	0.49	0.89
0.49	0.06	0.01	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.86	0.46	0.89
0.52	0.06	0.02	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.86	0.46	0.89
0.55	0.06	0.01	0.81	0.77	0.81	0.79	0.82	0.86	0.87	0.86	0.47	0.89
0.61	0.06	0.01	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.86	0.46	0.89
0.64	0.06	0.01	0.81	0.77	0.81	0.79	0.81	0.86	0.87	0.86	0.46	0.89
0.67	0.06	0.01	0.81	0.77	0.81	0.78	0.81	0.86	0.87	0.86	0.46	0.88
0.7	0.06	0.01	0.81	0.77	0.81	0.78	0.81	0.85	0.87	0.86	0.45	0.88
0.73	0.06	0.01	0.81	0.77	0.81	0.78	0.81	0.85	0.87	0.86	0.45	0.89
0.79	0.06	0.01	0.81	0.77	0.81	0.78	0.81	0.85	0.87	0.85	0.43	0.89
0.85	0.06	0.01	0.81	0.77	0.81	0.78	0.81	0.85	0.88	0.86	0.43	0.89
0.91	0.06	0.01	0.81	0.77	0.81	0.77	0.81	0.85	0.87	0.86	0.41	0.88
0.94	0.06	0.01	0.80	0.76	0.80	0.77	0.81	0.85	0.87	0.85	0.39	0.88
0.97	0.06	0.01	0.81	0.77	0.81	0.78	0.82	0.85	0.88	0.86	0.41	0.89
1	0.06	0.01	0.80	0.76	0.80	0.77	0.81	0.85	0.87	0.86	0.40	0.88
1.03	0.06	0.01	0.80	0.76	0.80	0.77	0.81	0.85	0.87	0.85	0.39	0.88
1.12	0.06	0.01	0.80	0.76	0.80	0.77	0.81	0.85	0.87	0.85	0.38	0.88
1.15	0.06	0.01	0.80	0.76	0.80	0.76	0.81	0.84	0.87	0.85	0.36	0.88
1.18	0.06	0.01	0.80	0.76	0.80	0.76	0.81	0.84	0.87	0.85	0.36	0.88
1.21	0.06	0.01	0.80	0.76	0.80	0.76	0.81	0.84	0.87	0.85	0.36	0.88
1.24	0.06	0.01	0.80	0.76	0.80	0.76	0.81	0.84	0.87	0.85	0.36	0.88
1.27	0.06	0.01	0.79	0.75	0.79	0.76	0.81	0.84	0.87	0.84	0.35	0.88
1.36	0.06	0.01	0.79	0.75	0.79	0.76	0.81	0.84	0.87	0.84	0.34	0.88
1.39	0.06	0.01	0.79	0.75	0.79	0.75	0.81	0.84	0.87	0.84	0.34	0.88
1.42	0.06	0.01	0.79	0.75	0.79	0.75	0.80	0.84	0.87	0.85	0.31	0.88
1.48	0.06	0.01	0.79	0.75	0.79	0.75	0.80	0.83	0.87	0.84	0.31	0.87
1.51	0.06	0.01	0.79	0.75	0.79	0.75	0.81	0.84	0.87	0.85	0.32	0.88
1.54	0.06	0.01	0.79	0.74	0.79	0.74	0.80	0.83	0.87	0.84	0.29	0.87
1.57	0.06	0.01	0.79	0.74	0.79	0.74	0.80	0.83	0.87	0.84	0.30	0.87
1.6	0.06	0.01	0.79	0.74	0.79	0.74	0.80	0.84	0.86	0.84	0.30	0.87
1.69	0.06	0.01	0.78	0.74	0.78	0.74	0.80	0.83	0.87	0.84	0.26	0.87
1.72	0.06	0.01	0.79	0.74	0.79	0.74	0.80	0.83	0.86	0.84	0.28	0.87
1.75	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.83	0.86	0.84	0.27	0.87
1.81	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.83	0.87	0.84	0.26	0.87
1.84	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.83	0.87	0.84	0.27	0.87
1.87	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.83	0.87	0.83	0.25	0.87
1.9	0.06	0.01	0.78	0.73	0.78	0.73	0.80	0.83	0.86	0.83	0.25	0.87
1.93	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.82	0.87	0.84	0.24	0.87
1.99	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.83	0.87	0.83	0.26	0.87
2.08	0.07	0.02	0.77	0.73	0.77	0.72	0.80	0.82	0.86	0.83	0.21	0.86
2.14	0.06	0.01	0.78	0.73	0.78	0.72	0.80	0.83	0.86	0.83	0.22	0.86
2.17	0.06	0.01	0.77	0.73	0.77	0.72	0.80	0.82	0.86	0.83	0.20	0.87
2.2	0.06	0.01	0.77	0.73	0.77	0.72	0.80	0.82	0.86	0.83	0.21	0.86
2.29	0.06	0.01	0.77	0.73	0.77	0.71	0.79	0.82	0.86	0.83	0.19	0.86
2.32	0.06	0.01	0.77	0.73	0.77	0.72	0.80	0.82	0.86	0.83	0.20	0.87
2.35	0.06	0.01	0.77	0.73	0.77	0.71	0.80	0.82	0.86	0.83	0.19	0.86
2.41	0.06	0.01	0.77	0.73	0.77	0.71	0.80	0.82	0.86	0.83	0.18	0.87
2.44	0.06	0.01	0.77	0.73	0.77	0.71	0.79	0.82	0.86	0.83	0.18	0.86
2.5	0.06	0.01	0.77	0.73	0.77	0.71	0.79	0.82	0.86	0.83	0.16	0.86
2.56	0.06	0.01	0.77	0.72	0.77	0.70	0.79	0.82	0.86	0.82	0.16	0.86
2.62	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.81	0.86	0.82	0.15	0.86
2.65	0.06	0.01	0.77	0.72	0.77	0.70	0.79	0.81	0.86	0.83	0.16	0.86
2.74	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.81	0.86	0.82	0.15	0.85
2.8	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.81	0.86	0.82	0.14	0.85
2.83	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.81	0.86	0.82	0.14	0.85
2.86	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.81	0.86	0.82	0.14	0.86
2.89	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.81	0.86	0.82	0.12	0.86
2.95	0.06	0.01	0.76	0.72	0.76	0.70	0.78	0.81	0.86	0.82	0.14	0.85
3.04	0.06	0.01	0.76	0.72	0.76	0.70	0.78	0.81	0.86	0.82	0.14	0.85
3.07	0.06	0.01	0.76	0.72	0.76	0.69	0.79	0.81	0.86	0.82	0.13	0.85
3.1	0.06	0.01	0.76	0.71	0.76	0.69	0.78	0.81	0.86	0.82	0.13	0.85
3.16	0.06	0.01	0.76	0.71	0.76	0.69	0.77	0.81	0.86	0.81	0.12	0.85
3.25	0.06	0.01	0.76	0.71	0.76	0.69	0.77	0.81	0.85	0.82	0.11	0.86
3.28	0.06	0.01	0.76	0.71	0.76	0.69	0.77	0.81	0.85	0.82	0.10	0.85
3.37	0.06	0.01	0.76	0.71	0.76	0.69	0.77	0.81	0.85	0.82	0.11	0.85
3.43	0.06	0.01	0.76	0.71	0.76	0.69	0.77	0.81	0.86	0.81	0.11	0.85
3.46	0.06	0.01	0.75	0.71	0.75	0.69	0.77	0.81	0.86	0.82	0.10	0.85
3.49	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.81	0.86	0.81	0.09	0.85
3.55	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.80	0.86	0.82	0.08	0.85
3.58	0.06	0.01	0.75	0.71	0.75	0.68	0.76	0.80	0.86	0.82	0.10	0.85
3.7	0.06	0.01	0.75	0.71	0.75	0.68	0.78	0.80	0.85	0.81	0.10	0.85
3.73	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.81	0.86	0.81	0.09	0.84
3.82	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.80	0.85	0.81	0.08	0.85
3.88	0.06	0.01	0.75	0.70	0.75	0.68	0.76	0.80	0.86	0.81	0.08	0.84
3.94	0.06	0.01	0.75	0.70	0.75	0.67	0.75	0.80	0.85	0.81	0.07	0.84

Table B.3: Performances and execution times for Naive Bayes on different alpha values when using Multinomial distribution and count vectorization

Para	Time		Metrics					f1 score for each class				
Alpha	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.07	0.06	0.02	0.80	0.75	0.80	0.78	0.79	0.85	0.86	0.85	0.45	0.88
0.1	0.06	0.01	0.80	0.76	0.80	0.78	0.80	0.85	0.86	0.85	0.45	0.88
0.16	0.07	0.01	0.80	0.76	0.80	0.78	0.80	0.85	0.86	0.85	0.43	0.88
0.22	0.06	0.01	0.80	0.76	0.80	0.77	0.81	0.84	0.87	0.85	0.40	0.88
0.25	0.06	0.02	0.80	0.76	0.80	0.77	0.81	0.84	0.87	0.85	0.39	0.89
0.31	0.06	0.02	0.80	0.75	0.80	0.76	0.81	0.84	0.87	0.85	0.37	0.88
0.37	0.07	0.02	0.79	0.75	0.79	0.76	0.81	0.84	0.87	0.85	0.34	0.89
0.4	0.06	0.02	0.79	0.75	0.79	0.75	0.80	0.83	0.87	0.85	0.32	0.88
0.46	0.06	0.02	0.79	0.74	0.79	0.74	0.80	0.83	0.87	0.84	0.28	0.89
0.49	0.06	0.01	0.79	0.75	0.79	0.74	0.81	0.82	0.87	0.85	0.29	0.88
0.55	0.06	0.01	0.78	0.74	0.78	0.73	0.80	0.82	0.87	0.84	0.25	0.88
0.58	0.06	0.02	0.78	0.74	0.78	0.73	0.81	0.82	0.87	0.84	0.25	0.88
0.64	0.07	0.02	0.78	0.74	0.78	0.73	0.81	0.82	0.87	0.84	0.23	0.87
0.67	0.06	0.02	0.78	0.74	0.78	0.72	0.80	0.81	0.87	0.84	0.21	0.88
0.7	0.07	0.02	0.77	0.73	0.77	0.72	0.80	0.81	0.87	0.84	0.20	0.88
0.76	0.06	0.01	0.77	0.73	0.77	0.72	0.80	0.81	0.87	0.84	0.20	0.88
0.79	0.06	0.01	0.78	0.73	0.78	0.72	0.80	0.81	0.87	0.85	0.19	0.88
0.85	0.06	0.01	0.77	0.73	0.77	0.71	0.80	0.80	0.87	0.84	0.17	0.87
0.88	0.06	0.01	0.77	0.73	0.77	0.71	0.79	0.81	0.87	0.83	0.16	0.87
0.94	0.06	0.01	0.77	0.72	0.77	0.70	0.79	0.80	0.87	0.84	0.15	0.87
0.97	0.06	0.02	0.76	0.72	0.76	0.70	0.78	0.80	0.87	0.84	0.12	0.87
1.03	0.06	0.01	0.77	0.72	0.77	0.70	0.78	0.80	0.87	0.84	0.13	0.87
1.09	0.06	0.01	0.77	0.72	0.77	0.70	0.79	0.80	0.87	0.84	0.12	0.87
1.15	0.06	0.01	0.76	0.72	0.76	0.70	0.79	0.79	0.86	0.84	0.11	0.87
1.18	0.06	0.02	0.76	0.72	0.76	0.70	0.80	0.79	0.87	0.84	0.11	0.87
1.24	0.06	0.01	0.76	0.72	0.76	0.69	0.79	0.79	0.87	0.84	0.10	0.87
1.27	0.06	0.01	0.76	0.72	0.76	0.69	0.78	0.79	0.87	0.84	0.09	0.87
1.33	0.06	0.02	0.76	0.72	0.76	0.69	0.79	0.79	0.87	0.84	0.10	0.87
1.36	0.06	0.01	0.76	0.72	0.76	0.69	0.77	0.79	0.87	0.84	0.09	0.87
1.42	0.06	0.01	0.76	0.72	0.76	0.69	0.78	0.79	0.87	0.84	0.09	0.86
1.45	0.06	0.01	0.76	0.72	0.76	0.69	0.78	0.79	0.87	0.84	0.07	0.86
1.51	0.06	0.02	0.76	0.72	0.76	0.69	0.78	0.79	0.86	0.84	0.07	0.87
1.54	0.06	0.01	0.76	0.71	0.76	0.69	0.78	0.79	0.87	0.84	0.08	0.87
1.6	0.06	0.01	0.76	0.71	0.76	0.68	0.76	0.79	0.86	0.84	0.06	0.87
1.63	0.06	0.01	0.75	0.71	0.75	0.68	0.78	0.78	0.86	0.84	0.06	0.87
1.69	0.06	0.02	0.75	0.71	0.75	0.68	0.76	0.78	0.86	0.84	0.05	0.87
1.72	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.78	0.86	0.83	0.05	0.87
1.78	0.06	0.01	0.75	0.71	0.75	0.68	0.78	0.78	0.87	0.83	0.05	0.86
1.84	0.06	0.01	0.75	0.71	0.75	0.68	0.76	0.78	0.86	0.84	0.05	0.86
1.87	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.79	0.86	0.83	0.05	0.86
1.93	0.06	0.01	0.75	0.71	0.75	0.68	0.77	0.78	0.86	0.83	0.04	0.86
1.96	0.07	0.01	0.75	0.71	0.75	0.68	0.75	0.78	0.86	0.84	0.04	0.86
2.02	0.06	0.01	0.75	0.71	0.75	0.67	0.75	0.78	0.86	0.83	0.03	0.86
2.05	0.06	0.01	0.75	0.71	0.75	0.68	0.76	0.78	0.86	0.84	0.04	0.86
2.11	0.06	0.02	0.75	0.71	0.75	0.67	0.76	0.78	0.86	0.83	0.04	0.86
2.17	0.06	0.01	0.75	0.71	0.75	0.67	0.76	0.78	0.86	0.83	0.04	0.86
2.23	0.06	0.01	0.75	0.70	0.75	0.67	0.75	0.78	0.86	0.83	0.03	0.86
2.26	0.06	0.02	0.75	0.70	0.75	0.67	0.73	0.78	0.86	0.83	0.03	0.86
2.32	0.06	0.02	0.75	0.70	0.75	0.67	0.75	0.77	0.86	0.83	0.04	0.86
2.35	0.06	0.02	0.75	0.70	0.75	0.67	0.71	0.77	0.86	0.83	0.03	0.86
2.41	0.06	0.01	0.75	0.70	0.75	0.67	0.75	0.77	0.86	0.84	0.03	0.86
2.44	0.06	0.02	0.75	0.70	0.75	0.67	0.72	0.77	0.86	0.83	0.02	0.86
2.5	0.06	0.02	0.75	0.70	0.75	0.67	0.75	0.77	0.86	0.84	0.03	0.86
2.53	0.06	0.02	0.75	0.70	0.75	0.67	0.71	0.77	0.86	0.83	0.02	0.86
2.59	0.06	0.01	0.74	0.70	0.74	0.67	0.73	0.77	0.86	0.83	0.03	0.86
2.62	0.06	0.01	0.75	0.70	0.75	0.67	0.73	0.77	0.86	0.83	0.03	0.86
2.68	0.06	0.01	0.74	0.70	0.74	0.67	0.74	0.77	0.86	0.84	0.02	0.86
2.74	0.06	0.01	0.74	0.70	0.74	0.67	0.71	0.77	0.86	0.83	0.02	0.86
2.77	0.06	0.01	0.74	0.70	0.74	0.67	0.71	0.77	0.86	0.83	0.02	0.85
2.83	0.06	0.01	0.74	0.70	0.74	0.67	0.69	0.77	0.86	0.83	0.01	0.86
2.86	0.06	0.01	0.74	0.70	0.74	0.67	0.75	0.77	0.86	0.83	0.02	0.85
2.92	0.06	0.01	0.74	0.70	0.74	0.67	0.68	0.77	0.86	0.83	0.02	0.86
2.95	0.06	0.01	0.74	0.70	0.74	0.67	0.72	0.77	0.86	0.83	0.02	0.86
3.01	0.06	0.01	0.74	0.70	0.74	0.67	0.70	0.77	0.86	0.83	0.01	0.86
3.04	0.06	0.01	0.74	0.70	0.74	0.67	0.70	0.77	0.86	0.83	0.02	0.85
3.1	0.06	0.02	0.74	0.70	0.74	0.67	0.72	0.76	0.86	0.83	0.02	0.85
3.13	0.06	0.02	0.74	0.70	0.74	0.67	0.70	0.76	0.86	0.84	0.01	0.85
3.19	0.06	0.01	0.74	0.70	0.74	0.67	0.70	0.76	0.86	0.83	0.02	0.85
3.22	0.07	0.02	0.74	0.70	0.74	0.66	0.71	0.76	0.86	0.83	0.02	0.85
3.28	0.06	0.02	0.74	0.70	0.74	0.66	0.68	0.76	0.86	0.83	0.01	0.85
3.31	0.06	0.02	0.74	0.70	0.74	0.66	0.71	0.76	0.86	0.83	0.01	0.85
3.37	0.06	0.01	0.74	0.70	0.74	0.67	0.69	0.76	0.86	0.84	0.01	0.85
3.43	0.06	0.01	0.74	0.70	0.74	0.66	0.73	0.76	0.86	0.83	0.01	0.85
3.46	0.06	0.01	0.74	0.69	0.74	0.66	0.70	0.76	0.86	0.83	0.01	0.84
3.58	0.06	0.01	0.74	0.69	0.74	0.66	0.65	0.76	0.86	0.83	0.01	0.85
3.64	0.06	0.02	0.74	0.69	0.74	0.66	0.68	0.76	0.86	0.83	0.01	0.85
3.67	0.06	0.01	0.74	0.69	0.74	0.66	0.67	0.76	0.86	0.83	0.01	0.85
3.73	0.06	0.02	0.74	0.69	0.74	0.66	0.66	0.76	0.86	0.83	0.00	0.85
3.76	0.06	0.01	0.74	0.69	0.74	0.66	0.68	0.76	0.86	0.83	0.01	0.85
3.82	0.06	0.01	0.74	0.69	0.74	0.66	0.67	0.76	0.85	0.83	0.01	0.85
3.88	0.06	0.01	0.74	0.69	0.74	0.66	0.68	0.75	0.86	0.83	0.01	0.85
3.94	0.06	0.01	0.74	0.69	0.74	0.66	0.65	0.75	0.86	0.83	0.00	0.85

Table B.4: Performances and execution times for Naive Bayes on different alpha values when using Multinomial distribution and tfidf vectorization

B.1.2 All Application Results

Tottenhams Harry Winks sørget for seier etter overtidsdrama.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikset seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexander Mitrovic dratt ned i feltet av Jan Verthongen.

Claudio Ranieris menn fortsatte å presse Tottenham, og etter nytt hjørnespark satte Harry Kane erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

I andreomgang slo Tottenham tilbake. Seks minutter ut i omgangen slo Christian Eriksen et perfekt innlegg til Dele Alli som headet ballen i mål fra kloss hold. 1-1 og kamp igjen på Craven Cottage.

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Etter 72 minutter kokte det over for Mitrovic og Sánchez. Begge kamphanene hadde ved flere anledninger hakket på hverandre, og i denne situasjonen dro de hverandre ned i bakken. Begge ble straffet med gult kort.

Minuttet senere skjedde det som Tottenham-fansen fryktet. Dele Alli jaget en ball ut mot sidelinjen og i forsøket på å nå ballen holdt 22-åringen seg til hamstringen og måtte legge seg ned utenfor banen. Engelskmannen klarte ikke å komme seg på beina igjen og ble byttet ut. Alli så tydelig preget ut på benken etter byttet.

Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Midtbanespilleren dundret løs fra 16 meters hold. Ballen føk gjennom beina på et par Spurs-spillere, og i mål via Tottenham keeper Paolo Gazzaniga. Paolo Gazzaniga fikk tillit fra start på bekostning av Hugo Lloris.

I det 38. minutt viste Chelsea frem vidunderlig fotball. Eden Hazard startet det vakre angrepet, og avsluttet selv i boksen. Plutselig stod det 2-0 og Chelsea stormet mot en ny cupfinale.

Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.

Tottenham styrte mye av banespillet, men slet med å komme til de store sjansene. Der var Fulham farligere. Ryan Babel var nær å doble ledelsen fem minutter før pause. Hodestøtet fra fem meter gikk over mål.

Fulham skapte enda mer. To minutter senere la Babel inn til Andre Schurrle som banket til på hel volley fra kort avstand. Lloris vartet opp med en mesterlig redning, men ballen endte hos Mitrovic som headet ballen i mål. Serberen var imidlertid i offside og scoringen ble annullert.

Fulham var flere ganger frempå og skapte problemer på tampen av omgangen. Ranieris menn ledet fortjent 1-0 til pause.

På overtid svingte innbytter Nkoudou ballen inn i feltet der Harry Winks headet ballen i mål i siste minutt av overtiden. Dermed vant Tottenham 2-1 på Craven Cottage.

Tottenham uten Harry Kane (skadet) og Heung-Min Son (Asiamesterskapet) slet lenge mot Fulham. Fernando Llorente, som erstattet Kane, satte ballen i eget mål etter et kvarter.

Fernando Llorente fikk den store sjansen til å bli helt igjen for Tottenham. Med ti minutter igjen slo Eriksen et frispark inn i feltet. Ballen skled av hodet til spanjolen og like utenfor mål. Til Llorente og Tottenham-fansens store fortvilelse.

Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren.

Dier bommet for Spurs N'golo Kanté og Eden Hazards scoret målene for Chelsea på Stamford Bridge, mens Tottenham reduseringsmål ble satt inn av Fernando Llorente.

Spurs løftet seg etter pause - kampen avgjort på straffesparkkonkurranse Like etter pause reduserte Tottenham. Harry Kane-erstatteren Fernando Llorente headet inn 1-2-reduseringen seks minutter ut i omgangen, og dermed trengte Tottenham kun ett mål for å ta seg videre til ligacupens finale.

Christian Eriksen scoret sikkert på Tottenham's første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenham's andre straffespark.

Azpilicueta satte 2-2 for Chelsea. Så blåste Eric Dier ballen over for Tottenham, og Chelsea var i førerretet. Jorginho satte arrogant inn 3-2-ledelse med et frekt straffespark.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

Figure B.1: Naive Bayes application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Ti minutter før slutt måtte forøvrig Tottenhams Moussa Sissoko gi seg på grunn av skade. Davinson Sánchez kom inn. Skadeproblemene fortsetter dermed for Tottenham.

Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.

– Gazzaniga hadde ingen sjanse og det var virkelig et mål med klasse av hjemmelaget. Det der er smart fotball. De angrep raskt og avsluttet vidunderlig, beskrev Andy Townsend etter scoringen som sørget for at Chelsea kunne gå til pause med 2-0.

Son, som også scoret i midtukekampen mot Watford, har nå scoret i begge kampene etter sin hjemkomst fra Asiamesterskapet.

Angriperen fyrte løs fra 18 meter. Skuddet gikk rett Martin Dubravka, men keeperen klarte ikke å stoppe skuddet. Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Først vant Llorente duellen, før Son dro seg fri og sendte i vei et skudd fra 18 meter. Skuddet gikk rett på Dubravka, men keeperen klarte likevel ikke å stoppe det.

Det var det som skulle til for at Spurs dro i land nok en seier på eget gress. Resultatet gjør at Tottenham nå har sneket seg forbi Manchester City, riktignok med én kamp mer spilt.

Heung-min Son sørget for tre Tottenham-poeng med sen scoring.

Newcastle var på vei mot nok et kuttsterkt resultat mot et topplag, men Heung-min Son ville det annerledes. Med åtte minutter igjen av ordinær tid scoret sørkoreaneren sitt tiende ligamål for sesongen. På tampen ordnet Xherdan Shaqiri 3–0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4–0.

Tottenham knuste Bournemouth 5–0, og tok over annenplassen på tabellen – seks poeng bak Liverpool. Mauricio Pochettino lag har scoret vanvittige 11 mål på få dager, etter 6–2-seieren borte mot Everton lille julaften.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

Joshua King spilte 16 minutter som innbytter for Bournemouth.

Sist Liverpool tapt en ligakamp på Anfield, var da Crystal Palace vant 2–1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seire. Denne sesongen har det blitt bare seire, med unntak av 0–0-kampen mot Manchester City.

I straffesparkkonkurransen scoret Willian, Azpilicueta, Jorginho og David Luiz, mens Eric Dier banket ballen langt opp på tribunen, og Lucas Moura rett i fanget på Kepa, dermed hjalp det lite at Christian Eriksen og Erik Lamela scoret på de to første forsøkene.

N'Golo Kanté banket inn 1–0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2–0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Scoringen gjorde at Spurs nok en gang dro i land en seier i sluttminuttene. Det betyr at Tottenham nå er oppe på en andreplass, men med én kamp mer spilt enn Manchester City.

Midtveis i omgangen var det Erik Lamela som fikk en sjanse. Innlegget fra Jan Vertonghen var av det presise slaget, men headingen fra Lamela var akkurat ikke god nok. Ballen smalt i tverrliggeren. Returen falt til Moura, men heller ikke denne gang traff angriperen mål.

Sissoko prøvde seg med et brukbar volleyforsøk kort tid før pause, men Dubravka stoppet skuddet. Dermed gikk lagene til pause på 0-0.

Nytt stolpetreff Rondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frempå igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut.

Slik var kampen Det var Tottenham som var nærmest scoring i den første omgangen. Lucas Moura fikk en enorm mulighet etter et kvarter, men brasilianerens heading gikk utenfor mål.

For øyeblikket bunnsolide Liverpool gikk sin 30. strake hjemmekamp i ligaen uten tap. Selv om farlig utsatte Newcastle hang med lenge, så ble det stygge sifre til slutt. Den antatt argeste gullrivalen, Manchester City, ligger nå syv poeng bak.

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvsprett etter en corner som ble svakt halvklarert.

Tidlig i andre omgang økte Mohamed Salah til 2–0 fra straffemerket etter at han selv ble dratt i armen av Paul Dummett. Straffen var likevel billig, og Salah blir fra flere holdt beskyldt for å filme. Uansett var det svakt av Dummett å bruke armen i duellen, og straffen satte Salah sikkert forbi keeper Martin Dubravka.

Bernardo Silva sendte Manchester City i ledelsen, men Marc Albrighton og Ricardo Pereira scoret i hver sin omgang og sørget for 2–1-seier til Leicester. Vinnermålet til Pereira var et herlig langskudd, og Fabian Delph pådro seg rødt kort på tampen av kampen.

Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.

Men etter pause hevet Tottenham seg, og Fernando Llorente utlignet den sammenlagte ledelsen rett etter pause med et kontant hodestøt.

Chelsea hadde store sjanser på slutten, ved blant annet Giroud, men han viste hvorfor Chelsea har hentet inn Gonzalo Higuain, som ble presentert for Stamford Bridge-publikumet før kampen.

Figure B.2: Naive Bayes application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.
 - Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.
 - Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.
 - Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.
 - Vi vant mot dem på Wembley. De slo oss her. Jeg foretrekker å tape på straffer fremfor etter fulltid. Gratulerer til Chelsea. Nå skal vi gjøre alt og være klar for FA-cupkampen mot Crystal Palace på søndag, sa Tottenhams suksessjef etter kampen.
 - Det er en fantastisk følelse. I den første omgangen kunne vi scoret tre eller fire. Vi kontrollerte kampen også etter pause. Spurs fikk sin mulighet, og scoret. Reaksjonen til spillerne og viljen vi viste gjør meg svært glad. For det var frustrerende at vi risikerte å tape på straffer etter å kontrollert kampen fullstendig. I straffesparkkonkurranser vet man aldri hva som skjer. Men laget gjorde det strålende. Vi skapte mange sjanser og presset Tottenham hele kampen, sa Chelseas straffehelt David Luiz til Sky Sports etter kampen.
 - Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
 - Tottenham er i kjempeform nå, og er i form. Chelsea vil trolig vinne mye fremover, Arsenal vil vinne og dette blir et race til siste dag. Vi er med i racet, og det er det aller viktigste, la han til.
 - Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange troféeer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.
 - Hazard: - Jeg bryr meg ikkeMaurizio Sarri kritiserte som kjent Chelsea-spillerne etter 0-2-tapet mot Arsenal i Premier League. Manageren sa blant annet at Hazard ikke var en leder på banen.
 - Jeg bryr meg ikke. Jeg spiller bare fotball. Det har ingenting å si hva manageren sier, jeg fokuserer bare på fotballen og vil gjøre det best mulig for laget, svarte Hazard på spørsmål om hva han mente om Sarris kritikk.
 - Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
 - Han har vært en av Newcastles beste spillere denne sesongen. Han har reddet laget så mange ganger. Det er brutalt, sier TV 2-kommentator Andre Olav Osnes.
 - Det er en stor, stor sjanse, men headingen er ikke i nærheten av god nok, sa Trevor Morley.
 - Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.
 - Både City og Liverpool sviktet i forrige runde. Nå starter Tottenham denne helgen med å vinne. Det er tre lag som kjemper om tittelen nå, sier Osnes.
 - Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på at de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betydde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.
- Men de to siste rundene har gjort Liverpool til storfavoritter når det gjelder ligagullet.**
- Chelsea har vært et av de mest suksessrike lagene i England de siste årene. Å vinne titler er det eneste som gjelder i denne klubben, så vi er glade for å være i finalen, oppsummerte Chelsea-kaptein Cesar Azpilicueta til Viasat 4.
 - Det er deilig å se spillere leke fotball på den måten, sa Ronny Deila om Jorginhos arrogante straffe, hvor midtbanespilleren ventet ut keeper og trillet ballen nonchalant i mål.
 - Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.

Figure B.3: Naive Bayes application results on the "Quotes" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.

Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.

Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.

Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.

Maurizio Sarri øyner sitt første trofé som manager for Chelsea etter at blåtrøyene slo Tottenham på straffer torsdag kveld.

(Liverpool-Newcastle 4-0, Leicester - Manchester City 2-1) Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.

For nå er det syv poeng ned til Manchester City, som snublet igjen.

For få dager siden tapte de 2-3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.

Det ble klart etter seier i straffesparkkonkurranse mot Tottenham torsdag kveld.

Tottenhams manager Mauricio Pochettino hevdet at han ikke var særlig skuffet etter nederlaget.

- Vidunderlig fotball av Chelsea Etter en tett og jevn start på kampen presenterte N'golo Kanté seg etter 27 minutters spill.

Tottenham skapte en rekke sjanser det siste kvarteret. Chelsea skapte også sine sjanser og hadde ingen planer om å parkere bussen.

Flere scoringer ble det imidlertid ikke i kampen, og kampen måtte avgjøres på straffer.

Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.

Chelsea til finale etter seier mot Tottenham i straffesparkkonkurranse

I returoppgjøret mot Tottenham i Ligacupen fikk han svar på tiltale.

I finalen venter Manchester City. Seier vil bety Sarris første trofé som Chelsea-manager. Mauricio Pochettino derimot må vente enda lenger på sitt første som Tottenham-sjef.

(Chelsea - Tottenham 2-1, 2-2 sammenlagt, 6-4 etter straffer) Kun Pep Guardiola og Manchester City står mellom Maurizio Sarri og hans første trofé som Chelsea-manager.

Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.

Figure B.4: Naive Bayes application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Tottenham seiret etter overtidsdrama

Se seiersmålet og høydepunktene i videovinduet øverst!

Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):

Se sammendrag i Sportsnyhetene øverst!

Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.

Slik startet lagene:

Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.

Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.

Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente.

Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.

Dommer: Martin Atkinson, West Yorkshire

Tottenham - Newcastle 1-0

Se scoringen i videovinduet øverst!

Hjemvendte Son reddet dagen for Spurs

Live: Brighton tok poeng mot Arsenal - referat fra dagens runde

PS! Førstkommende lørdag spiller Tottenham hjemme mot Wolverhampton, og Liverpool får besøk av Arsenal. Manchester City spiller borte mot Southampton søndag.

Burnley – Everton 1–5 (1–3)

Mål: 0–1 Yerry Mina (2), 0–2 Lucas Digne (13), 0–3 Gylfi Sigurdsson (str. 22), 1–3 Ben Gibson (37), 1–4 Digne (72), 1–5 Richarlison (90).

21.484 tilskuere.

Crystal Palace – Cardiff 0–0

25.206 tilskuere

Fulham – Wolverhampton 1–1 (0–0)

Mål: 1–0 Ryan Sessegnon (74), 1–1 Romain Saïss (85).

24.382 tilskuere.

74.523 tilskuere.

Tottenham – Bournemouth 5–0 (3–0)

Mål: 1–0 Christian Eriksen (16), 2–0 Son Heung-min (23), 3–0 Lucas Moura (35), 4–0 Harry Kane (61), 5–0 Son (70).

45.154 tilskuere.

Brighton – Arsenal 1–1 (1–1)

30.608 tilskuere

Dommer: Anthony Taylor, England.

Gult kort: Martín Montoya (45), Glenn Murray (58), Brighton, Sea Kolasinac (81), Arsenal.

Leicester – Manchester C. 2–1 (1–1)

Mål: 0–1 Bernardo Silva (14), 1–1 Marc Albrighton (19), 2–1 Ricardo Pereira (81).

32.090 tilskuere.

Rødt kort: Fabian Delph (89), Manchester C.

Liverpool – Newcastle 4–0 (1–0)

53.318 tilskuere.

Manchester U. – Huddersfield 3–1 (1–0)

Mål: 1–0 Nemanja Matic (28), 2–0 Paul Pogba (64), 3–0 Pogba (78), 3–1 Mathias Jørgensen (88).

Senere kampstart: Watford – Chelsea 20.30.

Drømmejul for Liverpool – ny gavepakke fra Manchester City

Mål: 1–0 Dejan Lovren (11), 2–0 Mohamed Salah (str. 48), 3–0 Xherdan Shaqiri (79), 4–0 Fabinho (85).

Mål: 0–1 Pierre-Emerick Aubameyang (7), 1–1 Jürgen Locadia (35).

Finalen spilles på Wembley siste helgen i februar.

Chelsea til ligacupfinale etter straffeseier

Figure B.5: Naive Bayes application results on the "Ignore" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt.</p> <p>Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.</p> <p>Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham.</p> <p>Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.</p> <p>Etter halvtimen spilt sendte Zappacosta ballen til Ruben Loftus-Cheek som ventet innenfor Nottinghams 16-meter. Chelsea-midtbanemann ble taklet så det sang av Danny Fox, og Chelsea ble tildelt et soleklart straffespark.</p>	<p>Mot slutten av omgangen viste Nottingham mer selvtillit og utfordret Chelsea. Noen helt store sjanser ble det ikke, men etter å ha tilbragt store deler av omgangen på egen banehalvdel, var det i hvert fall et steg i riktig retning for gjestene.</p> <p>Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene.</p> <p>Callum Hudson-Odoi la inn foran mål hvor Morata ventet. Etter flere forsøk satt den endelig for Chelsea-spissen, og hjemmelaget ledet 1-0.</p> <p>Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.</p> <p>Angrepene fra hjemmelaget kom som perler på snor utover, og Morata burde økt ledelsen til Chelsea etter 58 minutter, men på åpent mål presterte spissen å skyte over.</p>
<p>Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøkent angrep av samme duo som lagde 1-0 målet.</p> <p>Etter drøye timen spilt begynte sjansene å bli større for Nottingham. Nærmest redusering var Joe Lolley, men spissen måtte nøye seg med netveggen denne gang.</p> <p>Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.</p> <p>Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.</p> <p>Morata misbrukte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.</p> <p>Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.</p> <p>Sparket fra ellevemetersmerket burde nok blitt tatt opp igjen, da en hel haug av spillere fra både Nottingham Forest og Chelsea var innenfor 16-meteren før Fabregas' avslutning:</p> <p>Vondt ble til verre for Fabregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.</p> <p>Men da en spjøl mislykkes, var det en annen som fikk det til – etter noen forsøk.</p>	<p>Antoine Griezmann er storklubbens toppscorer med ti mål i serien. Bak ham har ingen scoret mer enn to. Blant dem som har slitt, er tidligere Chelsea-stjerne Diego Costa. Spansk-brasilianeren har bare funnet nettmaskene én gang i ligasammenheng.</p> <p>Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben.</p> <p>Men den siste sesongen har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjelte spissen scoret begge.</p> <p>Higuain fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.</p> <p>Hudson-Odoi - som jакtes av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.</p> <p>Utskjelte Morata sendte Chelsea videre da Fabregas tok farvel med Stamford Bridge</p> <p>(Chelsea – Nottingham Forest 2–0) Cesc Fàbregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.</p> <p>Bare når ettertraktede Callum Hudson-Odoi serverte fra høyre fikk Morata til å score. Først med en tap-in, deretter med et pent hodestøt, hvor han knuste Claudio Yacob i lufta.</p>

Figure B.6: Naive Bayes application results on the "Goal/Assist" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.

Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.

Chelsea-spiss klar for La Liga-gigant

Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.

Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.

Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.

Det ser ut til at den spanske midtbanespilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalen med Arsenal gikk i stå, skriver ESPN.

PSG har vært koblet til Evertons midtbanespiller Idrissa Gueye en stund. Ifølge Liverpool Echo har de imidlertid ikke lagt inn noe formelt bud enda.

Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.

Watford føler seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.

I Chelsea er Higuain gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong.

Siden den gang har Higuain spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuain, og ikke den som mislykkes i Milano.

Sarri ønsket Higuain inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuain.

Med sommerens signering av Jorginho, og Higuain inn i januarvinduet, har Sarri hentet inn to viktige brikker fra tiden sin i Napoli, som vet hvordan italieneren ønsker å spille.

Hans nye klubb ligger på andreplass i La Liga, fem poeng bak Barcelona. Som Sarri, har Atlético Madrid-manager Diego Simeone slitt med å få angrepsspillerne til å score.

Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.

Álvaro Morata (26) lånes ut fra Chelsea til Atlético Madrid.

Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.

Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Chelsea har lenge vært koblet til Zenits argentinske midtbanespiller Leandro Paredes, men nå har Paris Saint-Germain seilet opp som favoritt til å signere 24-åringen, skriver The Telegraph.

Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter walisersens landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasseklubb» som Juventus, skriver Sky Sports.

Chelsea har en lang tradisjon for å hente stjernespisser, men få har levd opp til forventningene på Stamford Bridge.

Siden Roman Abramovitsjs inntog i Chelsea har stjernespisserne vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuain.

De tok imidlertid trolig farvel med den spanske midtbanespilleren Cesc Fábregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.

Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.

Figure B.7: Naive Bayes application results on the "Transfer" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

– Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.

Det er denne rekken Higuain nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.

– Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Blir han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.

Higuain kommer til Chelsea med et rykte som en notorisk målscore. Kun fem spillere har scoret mer enn argentineren i topp fem-ligaene siden starten av 2006/07-sesongen.

– Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.

– Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.

– Det er en av de to-tre vanskeligste kampene som er. Men toppkamper lever sitt eget liv, og Chelsea har ofte vært bedre borte mot topplagene enn mot de antatt svakere lagene.

– Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.

– Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.

– Utfordringen er at Chelsea har vinger som liker å føre ballen langt inn i banen, og da har Higuain ofte allerede løpt i offside før pasningen kommer, sier Vinje.

Huddersfield-kampen forrige helg, der Higuain scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

– Jeg har mer troa etter kampen mot Huddersfield. Han er jo en målscore, men han har slitt denne sesongen. Spørsmålet er om Chelsea får den Higuain som scoret 36 ligamål på en sesong i Napoli, eller den som slet i Milan denne sesongen.

– Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:

– I Jorginho og Higuain har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.

– Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.

Figure B.8: Naive Bayes application results on the "Quotes" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.</p> <p>Chelsea hadde stort sett kontroll på Nottingham Forest i FA-cupens tredje runde. Men det var duoen Álvaro Morata og Callum Hudson-Odoi som utgjorde forskjellen i 2-0 seieren.</p> <p>Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.</p> <p>Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.</p> <p>Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fábregas farvel med engelsk fotball.</p> <p>– Med det blikket for spillet og timingen på pasningene, er han unj i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.</p> <p>Chelsea vant kampen 2–0, og fansen tok dermed ikke farvel med FA-cupen.</p> <p>Det var dermed passende at Maurizio Sarri ga Fabregas kapteinsbindet, men det ble ingen fantastisk avskjed for Fabregas – selv om det kunne blitt det.</p> <p>Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.</p> <p>Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.</p>	<p>Fotballryktene: – Morata bare timer unna overgang</p> <p>Spillere som Andrij Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Álvaro Morata, har ikledd seg den blå drakten uten nevneverdig suksess.</p> <p>Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.</p> <p>Thorstvedt mener likevel Higuain-overgangen var en sårt tiltrengt forsterkning i Chelsea-stallen.</p> <p>På søndag møter en meget tøff utfordring for Higuain og Chelsea, når de gjester Manchester City på Etihad. Supporterleder Vinje forventer en svært tøff kamp mot de regjerende mesterne.</p> <p>– Higuain kan ikke bare måles på antall scoringer</p>
--	---

Figure B.9: Naive Bayes application results on the "Irrelevant" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

B.2 Linear SVC

B.2.1 Full Tables from Training Experiments

Para	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.013	0.08	0.01	0.84	0.80	0.84	0.84	0.85	0.90	0.87	0.90	0.66	0.86
0.021	0.08	0.01	0.84	0.80	0.84	0.84	0.85	0.90	0.87	0.89	0.67	0.87
0.029	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.87
0.037	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.88	0.90	0.68	0.87
0.0434	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.87	0.90	0.69	0.88
0.045	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.68	0.88
0.053	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.68	0.88
0.061	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.89
0.069	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.077	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.085	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.88	0.89	0.68	0.88
0.093	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
0.101	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.88	0.90	0.67	0.88
0.109	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.89
0.117	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.125	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
0.133	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
0.141	0.10	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.87	0.89	0.67	0.87
0.149	0.10	0.01	0.84	0.80	0.84	0.84	0.84	0.89	0.87	0.89	0.67	0.88
0.157	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
0.165	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.173	0.10	0.01	0.84	0.80	0.84	0.84	0.85	0.90	0.87	0.89	0.67	0.87
0.181	0.10	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.86	0.88	0.67	0.87
0.197	0.11	0.01	0.84	0.80	0.84	0.84	0.85	0.90	0.86	0.88	0.68	0.88
0.205	0.11	0.01	0.84	0.80	0.84	0.83	0.84	0.90	0.86	0.88	0.66	0.88
0.213	0.11	0.01	0.84	0.80	0.84	0.84	0.85	0.90	0.87	0.89	0.67	0.87
0.221	0.11	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.87	0.89	0.66	0.88
0.229	0.11	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.86	0.88	0.67	0.87
0.237	0.11	0.01	0.84	0.80	0.84	0.83	0.84	0.90	0.86	0.88	0.66	0.87
0.245	0.11	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.87	0.88	0.66	0.87
0.25	0.11	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.87	0.88	0.66	0.87
0.27	0.11	0.01	0.84	0.80	0.84	0.84	0.84	0.90	0.86	0.89	0.67	0.87
0.29	0.11	0.01	0.84	0.80	0.84	0.83	0.84	0.90	0.86	0.88	0.66	0.87
0.31	0.12	0.01	0.84	0.80	0.84	0.83	0.84	0.89	0.86	0.88	0.66	0.87
0.33	0.12	0.01	0.84	0.80	0.84	0.84	0.84	0.89	0.87	0.88	0.67	0.87
0.39	0.12	0.01	0.84	0.79	0.84	0.83	0.84	0.89	0.87	0.87	0.65	0.87
0.41	0.12	0.01	0.83	0.79	0.83	0.83	0.84	0.89	0.86	0.88	0.65	0.87
0.43	0.13	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.88	0.63	0.86
0.45	0.13	0.01	0.83	0.79	0.83	0.83	0.83	0.90	0.85	0.87	0.65	0.87
0.47	0.13	0.01	0.84	0.80	0.84	0.83	0.84	0.89	0.86	0.88	0.65	0.87
0.49	0.13	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.87	0.87	0.65	0.86
0.51	0.13	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.88	0.65	0.86
0.53	0.13	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.88	0.63	0.87
0.55	0.14	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.87	0.65	0.87
0.57	0.14	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.63	0.86
0.61	0.14	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
0.63	0.14	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.88	0.64	0.87
0.67	0.14	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.85	0.87	0.63	0.86
0.69	0.14	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.87	0.64	0.87
0.71	0.15	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.85	0.88	0.65	0.86
0.73	0.15	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.85	0.89	0.65	0.86
0.75	0.15	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.85	0.88	0.65	0.86
0.77	0.15	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.88	0.65	0.86
0.79	0.15	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.63	0.86
0.81	0.15	0.01	0.83	0.78	0.83	0.82	0.83	0.88	0.85	0.87	0.64	0.86
0.83	0.16	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
0.85	0.16	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.85	0.87	0.64	0.86
0.89	0.16	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.87	0.65	0.86
0.91	0.16	0.01	0.83	0.78	0.83	0.82	0.83	0.88	0.86	0.87	0.64	0.86
0.93	0.16	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.63	0.86
0.95	0.16	0.01	0.82	0.78	0.82	0.82	0.82	0.89	0.85	0.86	0.63	0.85
0.97	0.17	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.85
1.01	0.17	0.01	0.83	0.79	0.83	0.83	0.83	0.89	0.86	0.87	0.65	0.86
1.03	0.17	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.85	0.87	0.63	0.86
1.05	0.17	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
1.07	0.18	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
1.09	0.17	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
1.11	0.17	0.01	0.82	0.78	0.82	0.82	0.83	0.88	0.85	0.87	0.64	0.86
1.13	0.17	0.01	0.83	0.78	0.83	0.82	0.82	0.88	0.86	0.87	0.63	0.86
1.15	0.18	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
1.17	0.18	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.64	0.86
1.19	0.18	0.01	0.82	0.78	0.82	0.82	0.82	0.88	0.85	0.86	0.63	0.86
1.21	0.18	0.01	0.82	0.77	0.82	0.81	0.82	0.88	0.85	0.86	0.62	0.85
1.23	0.18	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.63	0.87
1.25	0.18	0.01	0.83	0.78	0.83	0.82	0.83	0.88	0.86	0.87	0.64	0.86
1.27	0.17	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.85	0.87	0.63	0.86
1.29	0.19	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.86	0.87	0.63	0.86
1.33	0.19	0.01	0.83	0.79	0.83	0.82	0.83	0.89	0.86	0.87	0.65	0.85
1.35	0.20	0.01	0.83	0.78	0.83	0.82	0.83	0.89	0.85	0.87	0.64	0.86
1.37	0.20	0.01	0.82	0.78	0.82	0.82	0.82	0.88	0.85	0.87	0.63	0.86
1.39	0.19	0.01	0.82	0.78	0.82	0.82	0.82	0.88	0.85	0.87	0.63	0.85
1.41	0.19	0.01	0.82	0.78	0.82	0.82	0.82	0.89	0.85	0.86	0.63	0.86
1.43	0.20	0.01	0.82	0.78	0.82	0.82	0.82	0.88	0.85	0.87	0.63	0.86
1.45	0.18	0.01	0.83	0.78	0.83	0.82	0.82	0.89	0.84	0.87	0.63	0.86
1.47	0.20	0.01	0.82	0.77	0.82	0.81	0.82	0.88	0.84	0.87	0.62	0.85
1.49	0.19	0.01	0.82	0.77	0.82	0.81	0.82	0.88	0.85	0.86	0.62	0.85

Table B.5: Performances and execution times for linear SVC on different C values when tolerance is set to 0.0001 and intercept scaling is 2

Para	Time		Metrics					f1 score for each class				
Intersept Scaling	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
1.2	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
1.4	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
1.6	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.68	0.88
1.8	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
2	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.87	0.90	0.69	0.88
2	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.69	0.88
2.2	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
2.4	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.87
2.6	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.67	0.88
2.8	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.88	0.90	0.69	0.87
3	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
3.2	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.87	0.90	0.69	0.88
3.4	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.89	0.67	0.88
3.6	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.88	0.89	0.67	0.88
3.8	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.90	0.69	0.88
4	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
4.2	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.69	0.88
4.4	0.09	0.01	0.85	0.82	0.85	0.85	0.86	0.90	0.88	0.90	0.69	0.88
4.6	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
4.8	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.90	0.69	0.87
5	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.87
5.2	0.10	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
5.4	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.88
5.6	0.10	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.68	0.88
5.8	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.68	0.88
6	0.10	0.01	0.85	0.82	0.85	0.85	0.86	0.90	0.88	0.90	0.69	0.88
6.2	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.87
6.4	0.10	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
6.6	0.10	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.89	0.67	0.87
6.8	0.10	0.01	0.85	0.82	0.85	0.85	0.86	0.91	0.88	0.90	0.69	0.88
7	0.10	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.87
7.2	0.11	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.69	0.88
7.4	0.11	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.69	0.87
7.6	0.11	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.90	0.68	0.88
7.8	0.11	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.69	0.87
8	0.11	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
8.2	0.11	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
8.4	0.12	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
8.6	0.12	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.89	0.68	0.88
8.8	0.12	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
9	0.12	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.87
9.2	0.12	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.88	0.89	0.68	0.88
9.4	0.12	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.89	0.67	0.87
9.6	0.13	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.90	0.68	0.88
9.8	0.13	0.01	0.85	0.82	0.85	0.85	0.86	0.91	0.87	0.89	0.69	0.87

Table B.6: Performances and execution times for linear SVC on different intersept scaling values when tolerance is set to 0.0001 and c is 0.052

Para	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.00003	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00004	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00005	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.88
0.00006	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00007	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.88
0.00008	0.09	0.01	0.84	0.80	0.84	0.84	0.85	0.90	0.87	0.89	0.66	0.88
0.00009	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.0001	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.69	0.88
0.0001	0.09	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.87	0.90	0.69	0.88
0.00011	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.68	0.88
0.00013	0.09	0.01	0.85	0.82	0.85	0.85	0.86	0.91	0.88	0.90	0.69	0.88
0.00014	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.69	0.87
0.00015	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00016	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.89	0.68	0.88
0.00017	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.87
0.00018	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.88
0.0002	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
0.00021	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.00022	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.88
0.00023	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00024	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.89	0.68	0.88
0.00025	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.00026	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.68	0.87
0.00028	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.88	0.90	0.69	0.88
0.00029	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.89	0.68	0.87
0.0003	0.09	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.89	0.68	0.88
0.00031	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.90	0.69	0.88
0.00032	0.09	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00034	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00035	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00036	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.87
0.00037	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
0.00038	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.87
0.00039	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.67	0.88
0.0004	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00041	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.69	0.88
0.00042	0.08	0.01	0.86	0.82	0.86	0.85	0.86	0.90	0.88	0.90	0.69	0.89
0.00043	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
0.00044	0.08	0.01	0.85	0.82	0.85	0.85	0.86	0.91	0.87	0.90	0.69	0.88
0.00045	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.89	0.68	0.87
0.00046	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00047	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00048	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00049	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.88	0.90	0.68	0.87
0.00051	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00053	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
0.00054	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.69	0.88
0.00055	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.69	0.88
0.00057	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.86	0.90	0.67	0.87
0.00058	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.67	0.88
0.00059	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.88	0.89	0.69	0.88
0.0006	0.08	0.01	0.85	0.82	0.85	0.85	0.86	0.91	0.87	0.90	0.68	0.88
0.00061	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00062	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.67	0.87
0.00064	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.89	0.69	0.88
0.00065	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00066	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.90	0.68	0.88
0.00067	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00068	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.90	0.68	0.88
0.00069	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.0007	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.87
0.00071	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00073	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
0.00074	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.89	0.68	0.88
0.00075	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00076	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00077	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.87
0.00078	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.0008	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.87
0.00081	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.89	0.68	0.88
0.00082	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.67	0.87
0.00083	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00084	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88
0.00085	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.87	0.90	0.68	0.88
0.00086	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.90	0.68	0.88
0.00088	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.90	0.87	0.89	0.68	0.88
0.00089	0.08	0.01	0.85	0.82	0.85	0.85	0.86	0.91	0.88	0.89	0.69	0.88
0.0009	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00091	0.08	0.01	0.85	0.81	0.85	0.84	0.85	0.91	0.87	0.90	0.67	0.88
0.00092	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.87	0.90	0.68	0.88
0.00093	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.91	0.88	0.90	0.68	0.87
0.00094	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.90	0.68	0.88
0.00095	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.90	0.88	0.90	0.69	0.87
0.00096	0.08	0.01	0.85	0.81	0.85	0.85	0.86	0.91	0.87	0.89	0.68	0.89
0.00098	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.88	0.90	0.68	0.88
0.00099	0.08	0.01	0.85	0.81	0.85	0.85	0.85	0.90	0.87	0.89	0.68	0.88

Table B.7: Performances and execution times for linear SVC on different tolerance values when c is set to 0.052 and intercept scaling is 2

B.2.2 All Application Results

Tottenhams Harry Winks sørget for seier etter overtidsdrama.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikk set seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexander Mitrovic dratt ned i feltet av Jan Verthongen.

Claudio Ranieries menn fortsatte å presse Tottenham, og etter nytt hjørnespark satte Harry Kanes erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Etter 72 minutter kokte det over for Mitrovic og Sánchez. Begge kampanene hadde ved flere anledninger hakket på hverandre, og i denne situasjonen dro de hverandre ned i bakken. Begge ble straffet med gult kort.

På overtid svingte innbytter Nkoudou ballen inn i feltet der Harry Winks headet ballen i mål i siste minutt av overtiden. Dermed vant Tottenham 2-1 på Craven Cottage.

Tottenham uten Harry Kane (skadet) og Heung-Min Son (Asiamesterskapet) slet lenge mot Fulham. Fernando Llorente, som erstattet Kane, satte ballen i eget mål etter et kvarter.

Midtbanespilleren dundret løs fra 16 meters hold. Ballen føk gjennom beina på et par Spurs-spillere, og i mål via Tottenhams keeper Paolo Gazzaniga. Paolo Gazzaniga fikk tillit fra start på bekostning av Hugo Lloris.

Spurs løftet seg etter pause - kampen avgjort på straffesparkkonkurranse. Like etter pause reduserte Tottenham. Harry Kane-erstatteren Fernando Llorente headet inn 1-2-reduseringen seks minutter ut i omgangen, og dermed trengte Tottenham kun ett mål for å ta seg videre til ligacupens finale.

Christian Eriksen scoret sikkert på Tottenhams første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenhams andre straffespark.

Azpilicueta satte 2-2 for Chelsea. Så blåste Eric Dier ballen over for Tottenham, og Chelsea var i førerretet. Jorginho satte arrogant inn 3-2-ledelse med et frekt straffespark.

Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.

Tottenham styrte mye av banespillet, men slet med å komme til de store sjansene. Der var Fulham farligere. Ryan Babel var nær å doble ledelsen fem minutter før pause. Hodestøtet fra fem meter gikk over mål.

Fulham skapte enda mer. To minutter senere la Babel inn til Andre Schurrle som banket til på hel volley fra kort avstand. Lloris vartet opp med en mesterlig redning, men ballen endte hos Mitrovic som headet ballen i mål. Serberen var imidlertid i offside og scoringen ble annullert.

I andreomgang slo Tottenham tilbake. Seks minutter ut i omgangen slo Christian Eriksen et perfekt innlegg til Dele Alli som headet ballen i mål fra kloss hold. 1-1 og kamp igjen på Craven Cottage.

Fernando Llorente fikk den store sjansen til å bli helt igjen for Tottenham. Med ti minutt igjen slo Eriksen et frispark inn i feltet. Ballen skled av hodet til spanjolen og like utenfor mål. Til Llorente og Tottenham-fansens store fortvilelse.

Dier bommet for Spurs' golo Kanté og Eden Hazards scoret målene for Chelsea på Stamford Bridge, mens Tottenhams reduseringsmål ble satt inn av Fernando Llorente.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

Ti minutter før slutt måtte forøvrig Tottenhams Moussa Sissoko gi seg på grunn av skade. Davinson Sánchez kom inn. Skadeproblemene fortsetter dermed for Tottenham.

– Gazzaniga hadde ingen sjanse og det var virkelig et mål med klasse av hjemmelaget. Det der er smart fotball. De angrep raskt og avsluttet vidunderlig, beskrev Andy Townsend etter scoringen som sørget for at Chelsea kunne gå til pause med 2-0.

Son, som også scoret i midtukekampen mot Watford, har nå scoret i begge kampene etter sin hjemkomst fra Asiamesterskapet.

Figure B.10: Linear SVC application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Scoringen gjorde at Spurs nok en gang dro i land en seier i sluttminuttene. Det betyr at Tottenham nå er oppe på en andreplass, men med én kamp mer spilt enn Manchester City.

Midtveis i omgangen var det Erik Lamela som fikk en sjanse. Innlegget fra Jan Vertonghen var av det presise slaget, men headingen fra Lamela var akkurat ikke god nok. Ballen smalt i tverrliggeren. Returen falt til Moura, men heller ikke denne gang traff angriperen mål.

Nytt stolpetreff Rondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frem på igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut.

Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Tidlig i andre omgang økte Mohamed Salah til 2–0 fra straffemerket etter at han selv ble dratt i armen av Paul Dummett. Straffen var likevel billig, og Salah blir fra flere holdt beskyldt for å filme. Uansett var det svakt av Dummett å bruke armen i duellen, og straffen satte Salah sikkert forbi keeper Martin Dúbravka.

På tampen ordnet Xherdan Shaqiri 3–0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4–0.

Tottenham knuste Bournemouth 5–0, og tok over annenplassen på tabellen – seks poeng bak Liverpool. Mauricio Pochettinos lag har scoret vanvittige 11 mål på få dager, etter 6–2-seieren borte mot Everton lille julaften.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

I straffesparkkonkurransen scoret Willian, Azpilicueta, Jorginho og David Luiz, mens Eric Dier banket ballen langt opp på tribunen, og Lucas Moura rett i fanget på Kepa, dermed hjalp det lite at Christian Eriksen og Erik Lamela scoret på de to første forsøkene.

N'Golo Kanté banket inn 1–0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2–0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Først vant Llorente duellen, før Son dro seg fri og sendte i vei et skudd fra 18 meter. Skuddet gikk rett på Dúbravka, men keeperen klarte likevel ikke å stoppe det.

Heung-min Son sørget for tre Tottenham-poeng med sen scoring.

Newcastle var på vei mot nok et kruttsterkt resultat mot et topplag, men Heung-min Son ville det annerledes. Med åtte minutter igjen av ordinær tid scoret sørkoreaneren sitt tiende ligamål for sesongen.

Slik var kampen Det var Tottenham som var nærmest scoring i den første omgangen. Lucas Moura fikk en enorm mulighet etter et kvarter, men brasilianerens heading gikk utenfor mål.

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvspretten etter en corner som ble svakt halvklarert.

Sist Liverpool tapte en ligakamp på Anfield, var da Crystal Palace vant 2–1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seire. Denne sesongen har det blitt bare seire, med unntak av 0–0-kampen mot Manchester City.

Bernardo Silva sendte Manchester City i ledelsen, men Marc Albrighton og Ricardo Pereira scoret i hver sin omgang og sørget for 2–1-seier til Leicester. Vinnermålet til Pereira var et herlig langskudd, og Fabian Delph pådro seg rødt kort på tampen av kampen.

Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.

Men etter pause hevet Tottenham seg, og Fernando Llorente utlignet den sammenlagte ledelsen rett etter pause med et kontant hodestøt.

Figure B.11: Linear SVC application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.
- Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.
- Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.
- Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.
- Det er en fantastisk følelse. I den første omgangen kunne vi scoret tre eller fire. Vi kontrollerte kampen også etter pause. Spurs fikk sin mulighet, og scoret. Reaksjonen til spillerne og viljen vi viste gjør meg svært glad. For det var frustrerende at vi risikerte å tape på straffer etter å kontrollert kampen fullstendig. I straffesparkkonkurranser vet man aldri hva som skjer. Men laget gjorde det strålende. Vi skapte mange sjanser og presset Tottenham hele kampen, sa Chelseas straffehelt David Luiz til Sky Sports etter kampen.
- Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
- Han har vært en av Newcastles beste spillere denne sesongen. Han har reddet laget så mange ganger. Det er brutalt, sier TV 2-kommentator Endre Olav Osnes.
- Chelsea har vært et av de mest suksessrike lagene i England de siste årene. Å vinne titler er det eneste som gjelder i denne klubben, så vi er glade for å være i finalen, oppsummerte Chelsea-kaptein Cesar Azpilicueta til Viasat 4.
- Det er deilig å se spillere leke fotball på den måten, sa Ronny Deila om Jorginhos arrogante straffe, hvor midtbanespilleren ventet ut keeper og trillet ballen nonchalant i mål.
- Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.
- Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange troféer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.
- Jeg bryr meg ikke. Jeg spiller bare fotball. Det har ingenting å si hva manageren sier, jeg fokuserer bare på fotballen og vil gjøre det best mulig for laget, svarte Hazard på spørsmål om hva han mente om Sarris kritikk.
- Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
- Vi vant mot dem på Wembley. De slo oss her. Jeg foretrekker å tape på straffer fremfor etter fulltid. Gratulerer til Chelsea. Nå skal vi gjøre alt og være klar for FA-cupkampen mot Crystal Palace på søndag, sa Tottenhams suksessjef etter kampen.
- Det er en stor, stor sjanse, men headingen er ikke i nærheten av god nok, sa Trevor Morley.
- Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.
- Både City og Liverpool sviktet i forrige runde. Nå starter Tottenham denne helgen med å vinne. Det er tre lag som kjemper om tittelen nå, sier Osnes.
- Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på at de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betydde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.
- Tottenham er i kjempeform nå, og er i form. Chelsea vil trolig vinne mye fremover, Arsenal vil vinne og dette blir et race til siste dag. Vi er med i racet, og det er det aller viktigste, la han til.

Figure B.12: Linear SVC application results on the "Quotes" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Tottenham seiret etter overtidsdrama</p> <p>Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.</p> <p>Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.</p> <p>Fulham var flere ganger frempå og skapte problemer på tampen av omgangen. Ranieris menn ledet fortjent 1-0 til pause.</p> <p>Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.</p> <p>Tottenhams manager Mauricio Pochettino hevdet at han ikke var særlig skuffet etter nederlaget.</p> <p>Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.</p> <p>– Vidunderlig fotball av Chelsea Etter en tett og jevn start på kampen presenterte N'golo Kanté seg etter 27 minutters spill.</p> <p>I det 38. minutt viste Chelsea frem vidunderlig fotball. Eden Hazard startet det vakre angrepet, og avsluttet selv i boksen. Plutselig stod det 2-0 og Chelsea stormet mot en ny cupfinale.</p> <p>Tottenham skapte en rekke sjanser det siste kvarteret. Chelsea skapte også sine sjanser og hadde ingen planer om å parkere bussen.</p> <p>Maurizio Sarri øyner sitt første trofé som manager for Chelsea etter at blåtrøyene slo Tottenham på straffer torsdag kveld.</p> <p>Sissoko prøvde seg med et brukbar volleyforsøk kort tid før pause, men Dubravka stoppet skuddet. Dermed gikk lagene til pause på 0-0.</p> <p>Det var det som skulle til for at Spurs dro i land nok en sen seier på eget gress. Resultatet gjør at Tottenham nå har sneket seg forbi Manchester City, riktignok med én kamp mer spilt.</p> <p>Hjemvendte Son reddet dagen for Spurs</p> <p>For øyeblikket bunnsolide Liverpool gikk sin 30. strake hjemmekamp i ligaen uten tap. Selv om farlig utsatte Newcastle hang med lenge, så ble det stygge sifre til slutt. Den antatt argeste gullrivalen, Manchester City, ligger nå syv poeng bak.</p> <p>Burnley – Everton 1–5 (1–3)</p> <p>I returoppgjøret mot Tottenham i Ligacupen fikk han svar på tiltale.</p> <p>I finalen venter Manchester City. Seier vil bety Sarris første trofé som Chelsea-manager. Mauricio Pochettino derimot må vente enda lenger på sitt første som Tottenham-sjef.</p> <p>Finalen spilles på Wembley siste helgen i februar.</p> <p>Chelsea til ligacupfinale etter straffeseier</p> <p>(Chelsea - Tottenham 2–1, 2–2 sammenlagt, 6–4 etter straffer) Kun Pep Guardiola og Manchester City står mellom Mauricio Sarri og hans første trofé som Chelsea-manager.</p> <p>Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.</p>	<p>Minuttet senere skjedde det som Tottenham-fansen fryktet. Dele Alli jaget en ball ut mot sidelinjen og i forsøket på å nå ballen holdt 22-åringen seg til hamstringen og måtte legge seg ned utenfor banen. Engelskmannen klarte ikke å komme seg på beina igjen og ble byttet ut. Alli så tydelig preget ut på benken etter byttet.</p> <p>Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.</p> <p>Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.</p> <p>Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren.</p> <p>Hazard: – Jeg bryr meg ikke Maurizio Sarri kritiserte som kjent Chelsea-spillerne etter 0-2-tapet mot Arsenal i Premier League. Manageren sa blant annet at Hazard ikke var en leder på banen.</p> <p>Flere scoringer ble det imidlertid ikke i kampen, og kampen måtte avgjøres på straffer.</p> <p>Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.</p> <p>Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.</p> <p>Slik startet lagene:</p> <p>Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente.</p> <p>Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.</p> <p>Dommer: Martin Atkinson, West Yorkshire</p> <p>Chelsea til finale etter seier mot Tottenham i straffesparkkonkurranse</p> <p>Joshua King spilte 16 minutter som innbytter for Bournemouth.</p> <p>Dommer: Anthony Taylor, England.</p> <p>(Liverpool-Newcastle 4–0, Leicester – Manchester City 2–1) Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.</p> <p>For nå er det syv poeng ned til Manchester City, som snublet igjen.</p> <p>For få dager siden tapte de 2–3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.</p> <p>Det ble klart etter seier i straffesparkkonkurranse mot Tottenham torsdag kveld.</p>
---	--

Figure B.13: Linear SVC application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Se seiersmålet og høydepunktene i videovinduet øverst!	Mål: 0-1 Yerry Mina (2), 0-2 Lucas Digne (13), 0-3 Gylfi Sigurdsson (str. 22), 1-3 Ben Gibson (37), 1-4 Digne (72), 1-5 Richarlison (90).
Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):	21.484 tilskuere.
Se sammendrag i Sportsnyhetene øverst!	Crystal Palace – Cardiff 0-0
Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.	25.206 tilskuere
Tottenham - Newcastle 1-0	Fulham – Wolverhampton 1-1 (0-0)
Se scoringen i videovinduet øverst!	Mål: 1-0 Ryan Sessegnon (74), 1-1 Romain Saïss (85).
Live: Brighton tok poeng mot Arsenal - referat fra dagens runde	24.382 tilskuere.
PS! Førstkommende lørdag spiller Tottenham hjemme mot Wolverhampton, og Liverpool får besøk av Arsenal. Manchester City spiller borte mot Southampton søndag.	Leicester – Manchester C. 2-1 (1-1)
32.090 tilskuere.	Mål: 0-1 Bernardo Silva (14), 1-1 Marc Albrighton (19), 2-1 Ricardo Pereira (81).
Rødt kort: Fabian Delph (89), Manchester C.	45.154 tilskuere.
Liverpool – Newcastle 4-0 (1-0)	Brighton – Arsenal 1-1 (1-1)
53.318 tilskuere.	30.608 tilskuere
Manchester U. – Huddersfield 3-1 (1-0)	Gult kort: Martin Montoya (45), Glenn Murray (58), Brighton, Sead Kolasinac (81), Arsenal.
Mål: 1-0 Nemanja Matic (28), 2-0 Paul Pogba (64), 3-0 Pogba (78), 3-1 Mathias Jørgensen (88).	Senere kampstart: Watford – Chelsea 20.30.
74.523 tilskuere.	Mål: 1-0 Dejan Lovren (11), 2-0 Mohamed Salah (str. 48), 3-0 Xherdan Shaqiri (79), 4-0 Fabinho (85).
Tottenham – Bournemouth 5-0 (3-0)	Mål: 0-1 Pierre-Emerick Aubameyang (7), 1-1 Jürgen Locadia (35).
Mål: 1-0 Christian Eriksen (16), 2-0 Son Heung-min (23), 3-0 Lucas Moura (35), 4-0 Harry Kane (61), 5-0 Son (70).	

Figure B.14: Linear SVC application results on the "Ignore" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt. Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.

Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham. Angrepene fra hjemmelaget kom som perler på snor utover, og Morata burde økt ledelsen til Chelsea etter 58 minutter, men på åpent mål presterte spissen å skyte over.

Etter halvtimen spilt sendte Zappacosta ballen til Ruben Loftus-Cheek som ventet innenfor Nottinghams 16-meter. Chelsea-midtbanemann ble taklet så det sang av Danny Fox, og Chelsea ble tildelt et soleklart straffespark. Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøket angrep av samme duo som lagde 1-0 målet.

Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene. Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.

Callum Hudson-Odoi la inn foran mål hvor Morata ventet. Etter flere forsøk satt den endelig for Chelsea-spissen, og hjemmelaget ledet 1-0. Antoine Griezmann er storklubbens toppscorer med ti mål i serien. Bak ham har ingen scoret mer enn to. Blant dem som har slitt, er tidligere Chelsea-stjerne Diego Costa. Spansk-brasilianeren har bare funnet nettmaskene én gang i ligasammenheng.

Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben. Siden den gang har Higuaín spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuaín, og ikke den som mislykkes i Milano.

Men den siste sesongene har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjelte spissen scoret begge. Sarri ønsket Higuaín inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuaín.

Higuaín kommer til Chelsea med et rykte som en notorisk målscorer. Kun fem spillere har scoret mer enn argentineren i topp fem-ligaene siden starten av 2006/07-sesongen. Huddersfield-kampen forrige helg, der Higuaín scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

I Chelsea er Higuaín gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong. – Higuaín kan ikke bare måles på antall scoringer

Morata misbrakte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.

Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.

Sparket fra ellevemetersmerket burde nok blitt tatt opp igjen, da en hel haug av spillere fra både Nottingham Forest og Chelsea var innenfor 16-meteren før Fabregas' avslutning.

Hudson-Odoi - som jaktet av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.

Bare når ettertraktede Callum Hudson-Odoi serverte fra høyre fikk Morata til å score. Først med en tap-in, deretter med et pent hodestøt, hvor han knuste Claudio Yacob i luften.

Figure B.15: Linear SVC application results on the "Goal/Assist" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p style="color: red;">Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.</p> <p>Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.</p> <p style="color: red;">Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.</p> <p>Chelsea-spiss klar for La Liga-gigant</p> <p>Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.</p> <p>Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.</p> <p>PSG har vært koblet til Evertons midtbanespiller Idrissa Gueye en stund. Ifølge Liverpool Echo har de imidlertid ikke lagt inn noe formelt bud enda.</p> <p>Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.</p> <p>Watford følger seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.</p> <p>Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.</p> <p style="color: red;">Siden Roman Abramovitsjs inntog i Chelsea har stjernespissene vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuaín.</p> <p>Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.</p>	<p>Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.</p> <p style="color: red;">Alvaro Morata er nær ved å forlate Chelsea. Her er dagens fotballrykter!</p> <p>Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.</p> <p>Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.</p> <p>Det ser ut til at den spanske midtbanespilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalene med Arsenal gikk i stå, skriver ESPN.</p> <p>Fotballryktene: – Morata bare timer unna overgang</p> <p>Chelsea har lenge vært koblet til Zenits argentinske midtbanespiller Leandro Paredes, men nå har Paris Saint-Germain seilet opp som favoritt til å signere 24-åringen, skriver The Telegraph.</p> <p>Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter walisserens landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasseklubb» som Juventus, skriver Sky Sports.</p> <p style="color: red;">Chelsea har en lang tradisjon for å hente stjernespiss, men få har levd opp til forventningene på Stamford Bridge.</p> <p>Med sommerens signering av Jorginho, og Higuain inn i januarvinduet, har Sarri hentet inn to viktige brikker fra tiden sin i Napoli, som vet hvordan italieneren ønsker å spille.</p>
---	---

Figure B.16: Linear SVC application results on the "Transfer" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.
- Det er denne rekken Higuaín nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.
- Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Bli han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.
- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.
- Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:
- Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.
- Utfordringen er at Chelsea har vinger som liker å føre ballen langt inn i banen, og da har Higuaín ofte allerede løpt i offside før pasningen kommer, sier Vinje.
- Jeg har mer troa etter kampen mot Huddersfield. Han er jo en målscore, men han har slitt denne sesongen. Spørsmålet er om Chelsea får den Higuaín som scoret 36 ligamål på en sesong i Napoli, eller den som slet i Milan denne sesongen.
- Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.
- Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.

Figure B.17: Linear SVC application results on the "Quotes" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Chelsea-stjerne forlot banen i tårer	Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.
Chelsea - Nottingham Forest 2-0 (0-0)	
Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.	Etter drøye timen spilt begynte sjansene å bli større for Nottingham. Nærmest redusering var Joe Lolley, men spissen måtte nøye seg med nettveggen denne gang.
Chelsea hadde stort sett kontroll på Nottingham Forest i FA-cupens tredje runde. Men det var duoen Álvaro Morata og Callum Hudson-Odoi som utgjorde forskjellen i 2-0 seieren.	Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.
Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.	Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fábregas farvel med engelsk fotball.
Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.	– Med det blikket for spillet og timingen på pasningene, er han unik i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.
Mot slutten av omgangen viste Nottingham mer selvtillit og utfordret Chelsea. Noen helt store sjanser ble det ikke, men etter å ha tilbragt store deler av omgangen på egen banehalvdel, var det i hvert fall et steg i riktig retning for gjestene.	
Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.	Thorstvedt mener likevel Higuain-overgangen var en sårt tiltrengt forsterkning i Chelsea-stallen.
Hans nye klubb ligger på andreplass i La Liga, fem poeng bak Barcelona. Som Sarri, har Atlético Madrid-manager Diego Simeone slitt med å få angrepsspillerne til å score.	Higuain fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.
Álvaro Morata (26) lånes ut fra Chelsea til Atlético Madrid.	På søndag møter en meget tøff utfordring for Higuain og Chelsea, når de gjester Manchester City på Etihad. Supporterleder Vinje forventer en svært tøff kamp mot de regjerende mesterne.
Spillere som Andrij Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Alvaro Morata, har ikledd seg den blå drakten uten nevneverdig suksess.	– Det er en av de to-tre vanskeligste kampene som er. Men toppkamper lever sitt eget liv, og Chelsea har ofte vært bedre borte mot topplagene enn mot de antatt svakere lagene.
Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.	– I Jorginho og Higuain har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.
Chelsea vant kampen 2–0, og fansen tok dermed ikke farvel med FA-cupen.	Men da en spenjol mislykkes, var det en annen som fikk det til – etter noen forsøk.
De tok imidlertid trolig farvel med den spanske midtbanespilleren Cesc Fábregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.	Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.
Det var dermed passende at Maurizio Sarri ga Fabregas kapteinsbindet, men det ble ingen fantastisk avskjed for Fabregas – selv om det kunne blitt det.	Utskjelte Morata sendte Chelsea videre da Fabregas tok farvel med Stamford Bridge
Vondt ble til verre for Fabregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.	(Chelsea – Nottingham Forest 2–0) Cesc Fábregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.
Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.	

Figure B.18: Linear SVC application results on the "Irrelevant" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

B.3 SVC RBF

B.3.1 Ful Tables from Training Experiments

Para	Time		Metrics				f1 score for each class					
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.2	2.838	0.462	0.725	0.674	0.725	0.674	0.715	0.741	0.823	0.851	0.127	0.830
0.23	2.761	0.457	0.755	0.700	0.755	0.733	0.760	0.793	0.845	0.858	0.337	0.830
0.26	2.722	0.453	0.780	0.727	0.780	0.770	0.792	0.835	0.846	0.859	0.478	0.830
0.29	2.649	0.446	0.799	0.748	0.799	0.792	0.812	0.861	0.849	0.871	0.544	0.833
0.32	2.596	0.442	0.808	0.760	0.808	0.803	0.823	0.876	0.851	0.872	0.582	0.835
0.35	2.564	0.438	0.812	0.765	0.812	0.808	0.827	0.881	0.850	0.875	0.596	0.839
0.38	2.500	0.431	0.817	0.771	0.817	0.813	0.832	0.885	0.852	0.878	0.606	0.844
0.41	2.536	0.434	0.819	0.773	0.819	0.815	0.833	0.888	0.852	0.878	0.611	0.846
0.44	2.477	0.429	0.822	0.777	0.822	0.819	0.838	0.889	0.857	0.882	0.620	0.848
0.47	2.428	0.422	0.824	0.780	0.824	0.821	0.839	0.892	0.860	0.882	0.622	0.848
0.5	2.430	0.426	0.825	0.781	0.825	0.823	0.840	0.891	0.857	0.885	0.627	0.852
0.53	2.432	0.423	0.828	0.785	0.828	0.826	0.842	0.893	0.859	0.887	0.636	0.855
0.56	2.392	0.419	0.831	0.789	0.831	0.828	0.845	0.899	0.862	0.882	0.641	0.858
0.59	2.346	0.411	0.835	0.793	0.835	0.831	0.846	0.898	0.864	0.889	0.646	0.861
0.62	2.314	0.407	0.835	0.793	0.835	0.832	0.848	0.899	0.861	0.888	0.647	0.866
0.65	2.324	0.410	0.836	0.794	0.836	0.833	0.847	0.899	0.857	0.890	0.650	0.867
0.68	2.316	0.405	0.839	0.798	0.839	0.836	0.850	0.898	0.865	0.893	0.655	0.869
0.71	2.305	0.407	0.838	0.797	0.838	0.835	0.849	0.898	0.863	0.891	0.655	0.870
0.74	2.297	0.403	0.839	0.798	0.839	0.837	0.849	0.895	0.865	0.893	0.654	0.876
0.77	2.309	0.407	0.843	0.804	0.843	0.841	0.854	0.902	0.873	0.894	0.663	0.873
0.8	2.271	0.400	0.839	0.799	0.839	0.837	0.850	0.897	0.864	0.892	0.660	0.873
0.83	2.255	0.401	0.842	0.802	0.842	0.840	0.852	0.899	0.871	0.891	0.661	0.876
0.86	2.277	0.408	0.842	0.803	0.842	0.840	0.853	0.899	0.867	0.895	0.665	0.876
0.89	2.269	0.402	0.845	0.805	0.845	0.842	0.855	0.901	0.871	0.894	0.668	0.878
0.92	2.273	0.402	0.846	0.807	0.846	0.844	0.856	0.903	0.871	0.894	0.673	0.880
0.95	2.280	0.407	0.850	0.812	0.850	0.847	0.859	0.904	0.871	0.895	0.684	0.882
0.98	2.323	0.413	0.849	0.810	0.849	0.846	0.856	0.904	0.873	0.898	0.674	0.882
1.01	2.285	0.407	0.848	0.809	0.848	0.845	0.857	0.903	0.869	0.897	0.677	0.881
1.04	2.236	0.395	0.849	0.811	0.849	0.846	0.857	0.901	0.872	0.898	0.677	0.884
1.07	2.238	0.398	0.851	0.814	0.851	0.849	0.859	0.903	0.879	0.898	0.680	0.884
1.1	2.262	0.401	0.851	0.814	0.851	0.849	0.859	0.901	0.875	0.899	0.682	0.887
1.13	2.279	0.400	0.852	0.815	0.852	0.850	0.861	0.902	0.879	0.897	0.688	0.886
1.16	2.267	0.399	0.854	0.817	0.854	0.852	0.861	0.905	0.877	0.901	0.683	0.892
1.19	2.243	0.397	0.851	0.813	0.851	0.849	0.858	0.902	0.872	0.900	0.681	0.888
1.22	2.231	0.397	0.848	0.810	0.848	0.846	0.854	0.898	0.870	0.897	0.672	0.892
1.25	2.276	0.400	0.854	0.817	0.854	0.851	0.860	0.901	0.881	0.902	0.685	0.888
1.28	2.281	0.402	0.852	0.814	0.852	0.849	0.858	0.905	0.872	0.897	0.680	0.889
1.31	2.280	0.406	0.854	0.817	0.854	0.851	0.861	0.902	0.880	0.899	0.687	0.890
1.34	2.273	0.402	0.853	0.816	0.853	0.851	0.859	0.902	0.870	0.903	0.685	0.895
1.37	2.219	0.392	0.855	0.818	0.855	0.852	0.862	0.903	0.876	0.903	0.687	0.893
1.4	2.286	0.406	0.857	0.821	0.857	0.855	0.862	0.904	0.878	0.902	0.692	0.897
1.43	2.252	0.400	0.853	0.815	0.853	0.850	0.858	0.900	0.875	0.897	0.684	0.893
1.46	2.286	0.403	0.856	0.819	0.856	0.853	0.861	0.902	0.879	0.901	0.688	0.897
1.49	2.243	0.399	0.855	0.818	0.855	0.853	0.860	0.904	0.875	0.896	0.685	0.902
1.52	2.245	0.397	0.852	0.814	0.852	0.849	0.857	0.899	0.875	0.898	0.678	0.894
1.55	2.297	0.408	0.853	0.815	0.853	0.851	0.858	0.898	0.878	0.894	0.681	0.902
1.58	2.297	0.405	0.854	0.817	0.854	0.851	0.858	0.906	0.870	0.898	0.684	0.897
1.61	2.280	0.402	0.856	0.820	0.856	0.854	0.861	0.902	0.880	0.898	0.691	0.897
1.64	2.269	0.399	0.858	0.822	0.858	0.855	0.862	0.904	0.879	0.900	0.693	0.901
1.67	2.277	0.399	0.857	0.821	0.857	0.854	0.862	0.905	0.881	0.899	0.689	0.898
1.7	2.275	0.403	0.855	0.818	0.855	0.853	0.860	0.900	0.876	0.898	0.690	0.899
1.73	2.293	0.407	0.855	0.818	0.855	0.852	0.859	0.902	0.877	0.899	0.687	0.897
1.76	2.263	0.401	0.856	0.819	0.856	0.853	0.860	0.904	0.874	0.899	0.690	0.899
1.79	2.289	0.401	0.854	0.816	0.854	0.851	0.858	0.898	0.874	0.901	0.683	0.900
1.82	2.265	0.396	0.856	0.819	0.856	0.853	0.860	0.905	0.874	0.902	0.687	0.895
1.85	2.269	0.399	0.855	0.818	0.855	0.852	0.860	0.903	0.882	0.899	0.685	0.890
1.88	2.276	0.399	0.856	0.819	0.856	0.853	0.860	0.905	0.877	0.899	0.689	0.896
1.91	2.271	0.399	0.856	0.818	0.856	0.852	0.858	0.902	0.878	0.897	0.684	0.898
1.94	2.267	0.399	0.860	0.824	0.860	0.857	0.864	0.903	0.883	0.904	0.699	0.897
1.97	2.277	0.400	0.856	0.818	0.856	0.852	0.859	0.902	0.880	0.905	0.682	0.891
2	2.289	0.400	0.856	0.818	0.856	0.853	0.860	0.901	0.878	0.898	0.690	0.899
2.03	2.269	0.399	0.856	0.820	0.856	0.854	0.861	0.903	0.877	0.897	0.698	0.895
2.06	2.284	0.399	0.856	0.819	0.856	0.852	0.859	0.904	0.874	0.899	0.687	0.899
2.09	2.280	0.399	0.859	0.823	0.859	0.856	0.862	0.906	0.879	0.903	0.696	0.896
2.12	2.271	0.399	0.857	0.820	0.857	0.854	0.861	0.904	0.879	0.897	0.692	0.900
2.15	2.272	0.400	0.859	0.822	0.859	0.856	0.861	0.902	0.882	0.903	0.690	0.901
2.18	2.286	0.401	0.855	0.818	0.855	0.852	0.859	0.900	0.878	0.903	0.683	0.898
2.21	2.266	0.396	0.857	0.821	0.857	0.854	0.861	0.908	0.874	0.900	0.694	0.895
2.24	2.296	0.401	0.856	0.819	0.856	0.853	0.859	0.904	0.878	0.899	0.686	0.897
2.27	2.258	0.396	0.858	0.822	0.858	0.855	0.861	0.901	0.879	0.901	0.693	0.903
2.3	2.298	0.405	0.856	0.819	0.856	0.853	0.859	0.904	0.878	0.897	0.687	0.898
2.33	2.310	0.406	0.860	0.824	0.860	0.857	0.862	0.909	0.880	0.898	0.690	0.905
2.36	2.288	0.399	0.858	0.821	0.858	0.854	0.860	0.906	0.876	0.901	0.686	0.902
2.39	2.283	0.402	0.857	0.820	0.857	0.854	0.860	0.902	0.877	0.902	0.686	0.902
2.42	2.284	0.401	0.859	0.823	0.859	0.855	0.862	0.908	0.881	0.898	0.692	0.899
2.45	2.283	0.402	0.860	0.824	0.860	0.857	0.862	0.902	0.884	0.903	0.697	0.897
2.48	2.296	0.402	0.857	0.820	0.857	0.854	0.860	0.906	0.879	0.896	0.690	0.898

Table B.8: Performances and execution times for SVC RBF on different c values when shrinking is false

Para	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.085	2.059	0.383	0.833	0.791	0.833	0.831	0.846	0.894	0.863	0.887	0.649	0.863
0.12	1.992	0.377	0.845	0.805	0.845	0.842	0.853	0.899	0.869	0.898	0.666	0.879
0.155	1.96	0.37	0.848	0.81	0.848	0.846	0.856	0.902	0.87	0.899	0.675	0.884
0.19	1.958	0.37	0.852	0.814	0.852	0.849	0.859	0.903	0.875	0.899	0.683	0.886
0.225	1.982	0.37	0.854	0.817	0.854	0.851	0.86	0.904	0.876	0.9	0.684	0.89
0.26	1.997	0.373	0.857	0.82	0.857	0.855	0.862	0.9	0.879	0.906	0.69	0.897
0.295	2.022	0.374	0.852	0.814	0.852	0.849	0.856	0.903	0.871	0.897	0.68	0.894
0.33	2.054	0.374	0.856	0.819	0.856	0.853	0.859	0.899	0.878	0.899	0.693	0.899
0.365	2.074	0.377	0.858	0.821	0.858	0.855	0.861	0.902	0.88	0.903	0.692	0.898
0.4	2.107	0.379	0.854	0.817	0.854	0.851	0.858	0.901	0.875	0.898	0.682	0.9
0.435	2.14	0.382	0.857	0.82	0.857	0.854	0.861	0.901	0.879	0.901	0.691	0.899
0.47	2.176	0.386	0.856	0.819	0.856	0.853	0.86	0.903	0.877	0.9	0.69	0.897
0.5	2.289	0.4	0.856	0.818	0.856	0.853	0.86	0.901	0.878	0.898	0.69	0.899
0.505	2.215	0.389	0.854	0.817	0.854	0.851	0.857	0.902	0.876	0.899	0.682	0.896
0.54	2.313	0.4	0.856	0.819	0.856	0.853	0.86	0.902	0.882	0.9	0.691	0.888
0.575	2.315	0.4	0.857	0.821	0.857	0.854	0.861	0.901	0.884	0.901	0.687	0.898
0.61	2.324	0.4	0.854	0.817	0.854	0.851	0.857	0.899	0.876	0.9	0.68	0.901
0.645	2.343	0.4	0.855	0.818	0.855	0.852	0.859	0.903	0.874	0.898	0.688	0.897
0.68	2.374	0.403	0.855	0.818	0.855	0.853	0.86	0.905	0.873	0.901	0.686	0.898
0.715	2.427	0.408	0.852	0.815	0.852	0.849	0.856	0.9	0.877	0.894	0.682	0.894
0.75	2.515	0.416	0.855	0.818	0.855	0.853	0.859	0.9	0.879	0.9	0.687	0.899
0.785	2.564	0.424	0.858	0.821	0.858	0.855	0.862	0.904	0.881	0.899	0.694	0.899
0.82	2.602	0.427	0.858	0.821	0.858	0.855	0.861	0.907	0.875	0.9	0.696	0.897
0.855	2.617	0.426	0.853	0.815	0.853	0.85	0.857	0.9	0.873	0.897	0.682	0.897
0.89	2.667	0.432	0.855	0.818	0.855	0.853	0.86	0.901	0.878	0.902	0.688	0.896
0.925	2.721	0.444	0.852	0.815	0.852	0.85	0.857	0.901	0.869	0.899	0.68	0.899
0.96	2.746	0.437	0.857	0.82	0.857	0.854	0.86	0.905	0.877	0.898	0.691	0.896
0.995	2.77	0.44	0.855	0.818	0.855	0.852	0.859	0.899	0.881	0.899	0.684	0.898
1.03	2.726	0.431	0.856	0.819	0.856	0.853	0.86	0.904	0.878	0.897	0.689	0.898
1.065	2.752	0.431	0.851	0.812	0.851	0.848	0.855	0.899	0.874	0.896	0.677	0.893
1.1	2.773	0.435	0.852	0.814	0.852	0.849	0.856	0.898	0.879	0.899	0.678	0.89
1.135	2.82	0.444	0.854	0.817	0.854	0.851	0.86	0.904	0.875	0.895	0.687	0.896
1.17	2.846	0.44	0.85	0.812	0.85	0.847	0.855	0.899	0.874	0.897	0.673	0.893
1.205	2.875	0.441	0.851	0.812	0.851	0.848	0.856	0.898	0.871	0.899	0.677	0.894
1.24	2.907	0.444	0.85	0.812	0.85	0.847	0.856	0.901	0.874	0.896	0.674	0.892
1.275	2.945	0.45	0.853	0.816	0.853	0.85	0.858	0.901	0.877	0.898	0.682	0.894
1.31	3.037	0.46	0.851	0.812	0.851	0.848	0.856	0.898	0.876	0.899	0.674	0.891
1.345	3.085	0.464	0.852	0.814	0.852	0.849	0.858	0.901	0.875	0.899	0.682	0.889
1.38	3.092	0.462	0.844	0.804	0.844	0.841	0.851	0.9	0.862	0.893	0.666	0.885
1.415	3.125	0.468	0.848	0.81	0.848	0.845	0.854	0.898	0.877	0.894	0.674	0.88
1.485	3.234	0.474	0.847	0.808	0.847	0.844	0.853	0.899	0.872	0.893	0.669	0.888
1.52	3.213	0.469	0.845	0.806	0.845	0.842	0.851	0.901	0.87	0.891	0.661	0.885
1.555	3.225	0.47	0.843	0.803	0.843	0.839	0.848	0.897	0.869	0.893	0.654	0.884
1.59	3.285	0.479	0.843	0.803	0.843	0.839	0.849	0.895	0.873	0.89	0.658	0.882
1.625	3.302	0.476	0.839	0.798	0.839	0.836	0.847	0.898	0.865	0.888	0.652	0.876
1.66	3.344	0.484	0.842	0.801	0.842	0.838	0.848	0.894	0.871	0.89	0.657	0.878
1.695	3.388	0.488	0.844	0.805	0.844	0.841	0.85	0.895	0.875	0.893	0.66	0.88
1.73	3.42	0.495	0.837	0.796	0.837	0.833	0.844	0.893	0.87	0.886	0.641	0.878
1.765	3.464	0.494	0.835	0.793	0.835	0.831	0.842	0.892	0.864	0.887	0.639	0.872
1.8	3.505	0.499	0.835	0.793	0.835	0.831	0.842	0.892	0.862	0.886	0.641	0.871
1.835	3.463	0.488	0.836	0.794	0.836	0.831	0.842	0.894	0.863	0.887	0.639	0.873
1.87	3.552	0.5	0.834	0.792	0.834	0.829	0.841	0.89	0.865	0.883	0.636	0.872
1.905	3.572	0.502	0.834	0.792	0.834	0.829	0.84	0.892	0.86	0.886	0.635	0.874
1.94	3.622	0.506	0.836	0.795	0.836	0.832	0.843	0.892	0.862	0.885	0.648	0.872
1.975	3.598	0.504	0.831	0.788	0.831	0.826	0.837	0.886	0.862	0.887	0.626	0.866
2.01	3.62	0.505	0.832	0.79	0.832	0.827	0.839	0.887	0.864	0.887	0.631	0.868
2.045	3.576	0.495	0.831	0.788	0.831	0.825	0.837	0.887	0.864	0.887	0.623	0.865
2.08	3.537	0.493	0.827	0.783	0.827	0.822	0.833	0.881	0.862	0.882	0.616	0.867
2.115	3.649	0.507	0.828	0.784	0.828	0.822	0.834	0.88	0.862	0.884	0.619	0.865
2.15	3.686	0.511	0.822	0.778	0.822	0.816	0.829	0.88	0.858	0.88	0.605	0.856
2.185	3.623	0.501	0.823	0.778	0.823	0.817	0.829	0.876	0.856	0.882	0.608	0.862
2.22	3.548	0.489	0.822	0.777	0.822	0.815	0.829	0.878	0.858	0.878	0.604	0.855
2.255	3.549	0.487	0.82	0.775	0.82	0.813	0.826	0.875	0.859	0.877	0.593	0.859
2.325	3.579	0.493	0.817	0.771	0.817	0.809	0.823	0.871	0.857	0.88	0.583	0.855
2.36	3.592	0.494	0.816	0.771	0.816	0.808	0.821	0.868	0.857	0.88	0.577	0.858
2.395	3.61	0.493	0.812	0.765	0.812	0.803	0.816	0.866	0.852	0.877	0.567	0.852
2.43	3.615	0.496	0.81	0.763	0.81	0.8	0.816	0.86	0.856	0.878	0.558	0.85
2.465	3.618	0.495	0.809	0.762	0.809	0.8	0.814	0.858	0.853	0.876	0.556	0.856
2.5	3.631	0.496	0.805	0.757	0.805	0.795	0.811	0.853	0.853	0.878	0.547	0.843
2.535	3.651	0.5	0.799	0.75	0.799	0.788	0.805	0.847	0.852	0.876	0.522	0.84
2.57	3.657	0.504	0.796	0.747	0.796	0.783	0.801	0.839	0.85	0.876	0.512	0.84
2.605	3.651	0.498	0.794	0.744	0.794	0.78	0.799	0.836	0.855	0.875	0.499	0.837
2.64	3.656	0.498	0.79	0.74	0.79	0.776	0.795	0.832	0.848	0.872	0.488	0.84
2.675	3.643	0.497	0.784	0.733	0.784	0.768	0.791	0.825	0.85	0.868	0.47	0.829
2.71	3.654	0.496	0.781	0.73	0.781	0.765	0.788	0.816	0.847	0.871	0.457	0.831
2.745	3.636	0.496	0.774	0.723	0.774	0.757	0.782	0.804	0.847	0.87	0.434	0.829
2.78	3.649	0.496	0.768	0.715	0.768	0.747	0.775	0.798	0.843	0.87	0.405	0.821
2.815	3.65	0.497	0.761	0.708	0.761	0.739	0.77	0.785	0.843	0.871	0.378	0.819
2.85	3.613	0.493	0.754	0.7	0.754	0.73	0.761	0.777	0.84	0.867	0.352	0.813
2.885	3.649	0.498	0.747	0.693	0.747	0.719	0.756	0.764	0.846	0.867	0.315	0.804
2.92	3.642	0.496	0.741	0.689	0.741	0.711	0.752	0.753	0.843	0.867	0.288	0.802
2.955	3.661	0.499	0.736	0.683	0.736	0.704	0.748	0.742	0.843	0.865	0.27	0.801

Table B.9: Performances and execution times for SVC RBF on different gamma values when C is set to 2.0 and shrinking is false

Para	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.2	2.827	0.457	0.729	0.680	0.729	0.681	0.729	0.744	0.826	0.855	0.146	0.833
0.23	2.755	0.457	0.756	0.701	0.756	0.735	0.762	0.789	0.847	0.856	0.350	0.832
0.26	2.731	0.456	0.782	0.729	0.782	0.772	0.793	0.836	0.848	0.862	0.481	0.831
0.29	2.642	0.444	0.797	0.746	0.797	0.789	0.810	0.863	0.844	0.868	0.540	0.832
0.32	2.605	0.441	0.809	0.761	0.809	0.804	0.824	0.875	0.849	0.873	0.586	0.838
0.35	2.558	0.435	0.815	0.768	0.815	0.811	0.830	0.883	0.849	0.880	0.602	0.841
0.38	2.497	0.427	0.817	0.772	0.817	0.813	0.833	0.886	0.852	0.879	0.610	0.840
0.41	2.542	0.436	0.817	0.771	0.817	0.813	0.833	0.888	0.847	0.876	0.609	0.847
0.44	2.475	0.427	0.819	0.773	0.819	0.816	0.834	0.885	0.856	0.878	0.612	0.848
0.47	2.443	0.419	0.828	0.784	0.828	0.825	0.843	0.892	0.860	0.883	0.637	0.852
0.5	2.437	0.423	0.826	0.782	0.826	0.824	0.842	0.893	0.858	0.882	0.634	0.852
0.53	2.448	0.425	0.828	0.785	0.828	0.825	0.842	0.894	0.859	0.885	0.634	0.854
0.56	2.415	0.419	0.829	0.786	0.829	0.826	0.842	0.894	0.861	0.884	0.636	0.856
0.59	2.357	0.407	0.832	0.789	0.832	0.829	0.845	0.895	0.866	0.887	0.640	0.857
0.62	2.325	0.405	0.836	0.794	0.836	0.833	0.848	0.898	0.866	0.890	0.649	0.862
0.65	2.332	0.407	0.836	0.795	0.836	0.834	0.848	0.898	0.862	0.885	0.655	0.871
0.68	2.334	0.410	0.836	0.795	0.836	0.834	0.849	0.900	0.862	0.888	0.652	0.867
0.71	2.322	0.410	0.837	0.795	0.837	0.834	0.849	0.897	0.863	0.890	0.655	0.866
0.74	2.337	0.412	0.841	0.801	0.841	0.839	0.852	0.899	0.867	0.892	0.662	0.872
0.77	2.323	0.406	0.840	0.800	0.840	0.838	0.851	0.896	0.869	0.891	0.660	0.875
0.8	2.282	0.403	0.841	0.800	0.841	0.838	0.852	0.900	0.870	0.890	0.659	0.873
0.83	2.261	0.398	0.843	0.804	0.843	0.841	0.853	0.899	0.867	0.897	0.665	0.878
0.86	2.282	0.404	0.844	0.804	0.844	0.841	0.854	0.901	0.871	0.896	0.663	0.873
0.89	2.273	0.400	0.845	0.806	0.845	0.843	0.854	0.902	0.866	0.895	0.671	0.880
0.92	2.284	0.402	0.846	0.807	0.846	0.844	0.855	0.901	0.872	0.898	0.669	0.877
0.95	2.294	0.404	0.845	0.805	0.845	0.843	0.853	0.899	0.869	0.894	0.669	0.882
0.98	2.337	0.410	0.847	0.808	0.847	0.845	0.856	0.898	0.874	0.897	0.674	0.879
1.01	2.299	0.405	0.848	0.809	0.848	0.845	0.857	0.902	0.872	0.896	0.676	0.880
1.04	2.238	0.393	0.851	0.813	0.851	0.848	0.858	0.903	0.875	0.901	0.680	0.883
1.07	2.252	0.396	0.847	0.808	0.847	0.844	0.855	0.902	0.869	0.894	0.672	0.884
1.1	2.329	0.401	0.850	0.812	0.850	0.847	0.857	0.901	0.873	0.894	0.681	0.887
1.13	2.385	0.399	0.856	0.819	0.856	0.853	0.863	0.904	0.880	0.902	0.687	0.893
1.16	2.464	0.403	0.852	0.814	0.852	0.849	0.859	0.899	0.882	0.894	0.684	0.887
1.19	2.479	0.395	0.854	0.817	0.854	0.851	0.860	0.906	0.875	0.900	0.682	0.890
1.22	2.539	0.403	0.853	0.815	0.853	0.850	0.859	0.900	0.878	0.900	0.684	0.887
1.25	2.561	0.400	0.853	0.816	0.853	0.851	0.860	0.901	0.876	0.900	0.688	0.890
1.28	2.577	0.402	0.855	0.818	0.855	0.852	0.861	0.904	0.882	0.901	0.684	0.890
1.31	2.589	0.404	0.855	0.818	0.855	0.852	0.861	0.905	0.875	0.902	0.687	0.893
1.34	2.529	0.393	0.853	0.815	0.853	0.851	0.858	0.900	0.876	0.900	0.683	0.895
1.37	2.583	0.401	0.855	0.817	0.855	0.852	0.861	0.904	0.875	0.900	0.685	0.897
1.4	2.591	0.395	0.855	0.818	0.855	0.852	0.860	0.902	0.878	0.897	0.688	0.894
1.43	2.659	0.401	0.856	0.819	0.856	0.854	0.861	0.900	0.883	0.901	0.686	0.899
1.46	2.648	0.399	0.857	0.820	0.857	0.854	0.862	0.903	0.883	0.899	0.689	0.897
1.49	2.668	0.397	0.856	0.819	0.856	0.853	0.860	0.902	0.880	0.895	0.690	0.900
1.52	2.733	0.409	0.856	0.819	0.856	0.853	0.860	0.903	0.876	0.900	0.686	0.901
1.55	2.690	0.405	0.856	0.819	0.856	0.853	0.861	0.903	0.880	0.897	0.690	0.894
1.58	2.687	0.398	0.853	0.815	0.853	0.850	0.858	0.901	0.874	0.900	0.683	0.891
1.61	2.702	0.400	0.855	0.818	0.855	0.852	0.859	0.902	0.877	0.901	0.683	0.899
1.64	2.714	0.402	0.857	0.821	0.857	0.855	0.862	0.904	0.882	0.899	0.693	0.895
1.67	2.712	0.396	0.854	0.817	0.854	0.852	0.858	0.901	0.874	0.901	0.683	0.900
1.7	2.701	0.401	0.860	0.824	0.860	0.857	0.864	0.904	0.886	0.900	0.701	0.895
1.73	2.682	0.398	0.858	0.821	0.858	0.855	0.862	0.904	0.880	0.903	0.690	0.896
1.76	2.705	0.399	0.857	0.821	0.857	0.855	0.862	0.904	0.878	0.901	0.692	0.899
1.79	2.711	0.398	0.859	0.824	0.859	0.856	0.863	0.906	0.876	0.900	0.698	0.902
1.82	2.706	0.402	0.854	0.817	0.854	0.852	0.859	0.902	0.877	0.896	0.687	0.896
1.85	2.714	0.398	0.853	0.815	0.853	0.850	0.857	0.901	0.877	0.896	0.681	0.896
1.88	2.720	0.404	0.859	0.823	0.859	0.856	0.863	0.903	0.881	0.899	0.698	0.901
1.91	2.714	0.398	0.855	0.818	0.855	0.852	0.859	0.901	0.877	0.898	0.689	0.896
1.94	2.733	0.403	0.854	0.817	0.854	0.851	0.859	0.905	0.876	0.896	0.687	0.893
1.97	2.709	0.397	0.855	0.818	0.855	0.853	0.859	0.900	0.875	0.902	0.686	0.901
2	2.747	0.402	0.855	0.818	0.855	0.852	0.858	0.901	0.878	0.902	0.684	0.896
2.03	2.730	0.397	0.855	0.818	0.855	0.853	0.859	0.902	0.874	0.899	0.685	0.903
2.06	2.711	0.395	0.855	0.818	0.855	0.852	0.858	0.905	0.869	0.901	0.689	0.897
2.09	2.756	0.404	0.857	0.820	0.857	0.854	0.860	0.903	0.876	0.901	0.688	0.900
2.12	2.754	0.399	0.857	0.820	0.857	0.854	0.860	0.901	0.879	0.900	0.689	0.899
2.15	2.770	0.399	0.856	0.819	0.856	0.853	0.859	0.902	0.878	0.894	0.689	0.900
2.18	2.785	0.406	0.857	0.820	0.857	0.854	0.860	0.901	0.881	0.903	0.686	0.899
2.21	2.811	0.403	0.860	0.825	0.860	0.857	0.864	0.907	0.882	0.900	0.699	0.899
2.24	2.767	0.400	0.858	0.822	0.858	0.855	0.861	0.902	0.879	0.899	0.695	0.900
2.27	2.792	0.401	0.854	0.816	0.854	0.851	0.857	0.904	0.877	0.893	0.683	0.896
2.3	2.774	0.399	0.858	0.821	0.858	0.855	0.861	0.903	0.879	0.901	0.694	0.899
2.33	2.726	0.395	0.857	0.821	0.857	0.854	0.860	0.906	0.876	0.903	0.687	0.898
2.36	2.746	0.398	0.854	0.817	0.854	0.852	0.858	0.897	0.878	0.899	0.683	0.900
2.39	2.806	0.399	0.850	0.812	0.850	0.847	0.854	0.901	0.871	0.898	0.675	0.891
2.42	2.718	0.391	0.856	0.819	0.856	0.852	0.859	0.907	0.875	0.898	0.685	0.898
2.45	2.783	0.394	0.861	0.826	0.861	0.858	0.864	0.908	0.883	0.904	0.697	0.897
2.48	2.720	0.391	0.853	0.815	0.853	0.850	0.856	0.902	0.872	0.899	0.677	0.899

Table B.10: Performances and execution times for SVC RBF on different c values when shrinking is true

Para	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.085	2.078	0.386	0.835	0.793	0.835	0.832	0.847	0.897	0.862	0.89	0.649	0.864
0.12	1.999	0.376	0.845	0.806	0.845	0.842	0.854	0.902	0.867	0.897	0.669	0.875
0.155	1.97	0.369	0.849	0.81	0.849	0.846	0.857	0.903	0.87	0.898	0.681	0.878
0.19	1.964	0.37	0.854	0.817	0.854	0.852	0.861	0.905	0.878	0.897	0.69	0.888
0.225	1.975	0.369	0.851	0.813	0.851	0.849	0.857	0.896	0.88	0.901	0.678	0.888
0.26	2.039	0.371	0.857	0.82	0.857	0.855	0.863	0.903	0.877	0.901	0.695	0.897
0.295	2.135	0.373	0.859	0.823	0.859	0.857	0.864	0.903	0.876	0.903	0.701	0.9
0.33	2.28	0.375	0.856	0.82	0.856	0.854	0.86	0.901	0.875	0.902	0.691	0.899
0.365	2.4	0.377	0.858	0.821	0.858	0.854	0.861	0.904	0.879	0.9	0.692	0.897
0.4	2.537	0.38	0.856	0.819	0.856	0.853	0.86	0.903	0.877	0.897	0.689	0.897
0.435	2.583	0.383	0.854	0.816	0.854	0.851	0.858	0.901	0.875	0.903	0.68	0.896
0.47	2.617	0.386	0.855	0.817	0.855	0.853	0.859	0.901	0.872	0.898	0.69	0.902
0.5	2.747	0.402	0.855	0.818	0.855	0.852	0.858	0.901	0.878	0.902	0.684	0.896
0.505	2.712	0.394	0.859	0.822	0.859	0.856	0.862	0.906	0.881	0.898	0.694	0.9
0.54	2.866	0.399	0.856	0.819	0.856	0.852	0.86	0.906	0.873	0.899	0.689	0.894
0.575	2.904	0.395	0.856	0.819	0.856	0.853	0.859	0.901	0.879	0.898	0.685	0.902
0.61	2.92	0.397	0.856	0.82	0.856	0.853	0.86	0.899	0.88	0.899	0.689	0.899
0.645	2.945	0.402	0.856	0.819	0.856	0.853	0.859	0.9	0.879	0.901	0.685	0.898
0.68	3.043	0.408	0.859	0.823	0.859	0.856	0.864	0.906	0.881	0.902	0.698	0.894
0.715	3.175	0.421	0.856	0.819	0.856	0.854	0.86	0.904	0.877	0.897	0.691	0.899
0.75	3.193	0.419	0.852	0.814	0.852	0.85	0.857	0.901	0.878	0.893	0.681	0.897
0.785	3.226	0.423	0.853	0.815	0.853	0.85	0.857	0.898	0.879	0.898	0.68	0.894
0.82	3.274	0.428	0.855	0.818	0.855	0.852	0.859	0.902	0.882	0.897	0.688	0.89
0.855	3.306	0.429	0.857	0.821	0.857	0.854	0.861	0.904	0.877	0.9	0.689	0.903
0.89	3.354	0.432	0.855	0.818	0.855	0.853	0.859	0.902	0.88	0.894	0.69	0.898
0.925	3.3	0.425	0.856	0.819	0.856	0.853	0.861	0.904	0.878	0.899	0.689	0.896
0.96	3.296	0.425	0.852	0.814	0.852	0.849	0.856	0.901	0.875	0.898	0.675	0.896
0.995	3.312	0.428	0.855	0.817	0.855	0.852	0.86	0.903	0.88	0.897	0.686	0.895
1.03	3.34	0.43	0.855	0.818	0.855	0.852	0.859	0.903	0.875	0.9	0.69	0.891
1.065	3.344	0.433	0.854	0.817	0.854	0.851	0.859	0.901	0.881	0.896	0.685	0.893
1.1	3.358	0.436	0.853	0.815	0.853	0.849	0.857	0.902	0.877	0.895	0.677	0.895
1.135	3.382	0.438	0.852	0.814	0.852	0.849	0.856	0.901	0.873	0.899	0.679	0.893
1.17	3.479	0.457	0.847	0.808	0.847	0.845	0.854	0.897	0.871	0.896	0.669	0.891
1.205	3.517	0.451	0.851	0.813	0.851	0.848	0.856	0.901	0.876	0.897	0.675	0.892
1.24	3.545	0.455	0.851	0.813	0.851	0.848	0.856	0.9	0.877	0.894	0.678	0.892
1.275	3.565	0.459	0.848	0.809	0.848	0.844	0.854	0.898	0.875	0.895	0.667	0.887
1.31	3.605	0.462	0.851	0.813	0.851	0.848	0.857	0.901	0.876	0.891	0.68	0.893
1.345	3.58	0.461	0.849	0.81	0.849	0.846	0.854	0.9	0.873	0.896	0.673	0.887
1.38	3.56	0.463	0.847	0.808	0.847	0.844	0.853	0.902	0.866	0.891	0.671	0.891
1.415	3.59	0.468	0.851	0.813	0.851	0.848	0.857	0.9	0.879	0.895	0.675	0.891
1.45	3.607	0.47	0.846	0.807	0.846	0.843	0.852	0.899	0.869	0.892	0.67	0.882
1.485	3.633	0.475	0.846	0.806	0.846	0.842	0.852	0.897	0.872	0.893	0.665	0.885
1.52	3.669	0.478	0.843	0.803	0.843	0.84	0.85	0.896	0.867	0.89	0.665	0.883
1.555	3.683	0.475	0.845	0.805	0.845	0.841	0.85	0.895	0.877	0.89	0.66	0.885
1.59	3.751	0.494	0.843	0.803	0.843	0.84	0.85	0.896	0.873	0.89	0.66	0.879
1.625	3.752	0.49	0.842	0.801	0.842	0.838	0.848	0.894	0.868	0.891	0.656	0.88
1.66	3.666	0.482	0.845	0.806	0.845	0.841	0.852	0.896	0.87	0.894	0.667	0.879
1.73	3.773	0.496	0.839	0.798	0.839	0.835	0.846	0.894	0.865	0.889	0.653	0.876
1.765	3.781	0.499	0.841	0.8	0.841	0.837	0.847	0.895	0.866	0.891	0.653	0.877
1.8	3.798	0.5	0.837	0.796	0.837	0.832	0.844	0.896	0.867	0.888	0.641	0.87
1.835	3.761	0.5	0.836	0.794	0.836	0.831	0.843	0.892	0.865	0.888	0.641	0.869
1.87	3.683	0.489	0.835	0.793	0.835	0.831	0.841	0.892	0.86	0.889	0.639	0.873
1.905	3.705	0.489	0.837	0.796	0.837	0.832	0.843	0.893	0.864	0.888	0.644	0.872
1.94	3.786	0.502	0.835	0.793	0.835	0.83	0.841	0.891	0.866	0.886	0.635	0.872
1.975	3.751	0.497	0.83	0.787	0.83	0.825	0.837	0.888	0.861	0.884	0.626	0.868
2.01	3.639	0.481	0.828	0.784	0.828	0.822	0.834	0.884	0.86	0.884	0.62	0.862
2.045	3.634	0.483	0.829	0.786	0.829	0.823	0.836	0.887	0.861	0.883	0.622	0.863
2.08	3.641	0.484	0.829	0.785	0.829	0.823	0.835	0.887	0.863	0.88	0.618	0.868
2.115	3.677	0.491	0.826	0.782	0.826	0.821	0.833	0.883	0.863	0.881	0.612	0.865
2.15	3.663	0.49	0.825	0.78	0.825	0.818	0.831	0.879	0.861	0.879	0.614	0.858
2.185	3.68	0.49	0.821	0.776	0.821	0.814	0.827	0.877	0.853	0.881	0.599	0.861
2.22	3.669	0.49	0.819	0.774	0.819	0.813	0.827	0.874	0.858	0.876	0.597	0.86
2.255	3.67	0.494	0.82	0.775	0.82	0.813	0.827	0.875	0.856	0.879	0.593	0.86
2.29	3.671	0.493	0.821	0.776	0.821	0.813	0.826	0.873	0.861	0.878	0.593	0.861
2.325	3.669	0.492	0.82	0.775	0.82	0.813	0.826	0.868	0.858	0.884	0.595	0.86
2.36	3.666	0.494	0.817	0.771	0.817	0.808	0.822	0.867	0.86	0.882	0.578	0.855
2.43	3.715	0.499	0.812	0.766	0.812	0.803	0.817	0.863	0.858	0.877	0.564	0.853
2.465	3.704	0.499	0.804	0.756	0.804	0.794	0.81	0.854	0.852	0.873	0.543	0.848
2.5	3.69	0.495	0.804	0.756	0.804	0.793	0.809	0.853	0.852	0.874	0.536	0.847
2.535	3.671	0.494	0.801	0.753	0.801	0.791	0.808	0.844	0.853	0.875	0.536	0.846
2.57	3.674	0.494	0.798	0.749	0.798	0.785	0.802	0.843	0.853	0.874	0.513	0.84
2.605	3.673	0.496	0.789	0.739	0.789	0.776	0.795	0.834	0.848	0.868	0.495	0.836
2.64	3.641	0.492	0.79	0.739	0.79	0.776	0.796	0.83	0.849	0.871	0.491	0.838
2.675	3.687	0.498	0.788	0.738	0.788	0.773	0.794	0.828	0.847	0.874	0.483	0.832
2.71	3.694	0.497	0.776	0.724	0.776	0.759	0.782	0.815	0.844	0.871	0.44	0.824
2.745	3.697	0.502	0.772	0.719	0.772	0.753	0.779	0.805	0.849	0.87	0.421	0.821
2.78	3.676	0.495	0.766	0.714	0.766	0.745	0.774	0.792	0.845	0.871	0.396	0.821
2.815	3.578	0.483	0.763	0.71	0.763	0.741	0.769	0.788	0.846	0.873	0.378	0.819
2.85	3.585	0.483	0.751	0.697	0.751	0.726	0.756	0.773	0.842	0.866	0.337	0.81
2.885	3.586	0.485	0.749	0.697	0.749	0.722	0.758	0.766	0.844	0.869	0.322	0.808
2.92	3.612	0.487	0.743	0.69	0.743	0.713	0.753	0.754	0.843	0.869	0.295	0.804
2.955	3.613	0.491	0.736	0.684	0.736	0.703	0.75	0.741	0.843	0.867	0.261	0.804

Table B.11: Performances and execution times for SVC RBF on different gamma values when C is set to 2.0 and shrinking is true

B.3.2 All Application Results

Tottenhams Harry Winks sørget for seier etter overtidsdrama.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikk seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexandar Mitrovic dratt ned i feltet av Jan Verthongen.

Claudio Ranieries menn fortsette å presse Tottenham, og etter nytt hjørnespark satte Harry Kanes erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Etter 72 minutter kokte det over for Mitrovic og Sánchez. Begge kamphanene hadde ved flere anledninger hakket på hverandre, og i denne situasjonen dro de hverandre ned i bakken. Begge ble straffet med gult kort.

På overtid svingte innbytter Nkoudou ballen inn i feltet der Harry Winks headet ballen i mål i siste minutt av overtiden. Dermed vant Tottenham 2-1 på Craven Cottage.

Tottenham uten Harry Kane (skadet) og Heung-Min Son (Asiamesterskapet) slet lenge mot Fulham. Fernando Llorente, som erstattet Kane, satte ballen i eget mål etter et kvarter.

Fernando Llorente fikk den store sjansen til å bli helten igjen for Tottenham. Med ti minutter igjen slo Eriksen et frispark inn i feltet. Ballen skled av hodet til spanjolen og like utenfor mål. Til Llorente og Tottenham-fansens store fortvilelse.

Spurs løftet seg etter pause - kampen avgjort på straffesparkkonkurransen. Like etter pause reduserte Tottenham. Harry Kane-erstatteren Fernando Llorente headet inn 1-2-reduseringen seks minutter ut i omgangen, og dermed trengte Tottenham kun ett mål for å ta seg videre til ligacupens finale.

Christian Eriksen scoret sikkert på Tottenhams første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenhams andre straffespark.

Azpilicueta satte 2-2 for Chelsea. Så blåste Eric Dier ballen over for Tottenham, og Chelsea var i førersetet. Jorginho satte arrogant inn 3-2-ledelse med et frekt straffespark.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.

Tottenham styrte mye av banespillet, men slet med å komme til de store sjansene. Der var Fulham farligere. Ryan Babel var nær å doble ledelsen fem minutter før pause. Hodestøtet fra fem meter gikk over mål.

Fulham skapte enda mer. To minutter senere la Babel inn til Andre Schurrle som banket til på hel volley fra kort avstand. Lloris vartet opp med en mesterlig redning, men ballen endte hos Mitrovic som headet ballen i mål. Serberen var imidlertid i offside og scoringen ble annullert.

I andreomgang slo Tottenham tilbake. Seks minutter ut i omgangen slo Christian Eriksen et perfekt innlegg til Dele Alli som headet ballen i mål fra kloss hold. 1-1 og kamp igjen på Craven Cottage.

Dier bommet for Spurs' golo Kanté og Eden Hazards scoret målene for Chelsea på Stamford Bridge, mens Tottenhams reduseringsmål ble satt inn av Fernando Llorente.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Midtbanespilleren dundret løs fra 16 meters hold. Ballen føk gjennom beina på et par Spurs-spillere, og i mål via Tottenhams keeper Paolo Gazzaniga. Paolo Gazzaniga fikk tillit fra start på bekostning av Hugo Lloris.

Figure B.19: SVC RBF application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

– Gazzaniga hadde ingen sjanse og det var virkelig et mål med klasse av hjemmelaget. Det der er smart fotball. De angrep raskt og avsluttet vidunderlig, beskrev Andy Townsend etter scoringen som sørget for at Chelsea kunne gå til pause med 2-0.

Son, som også scoret i midtukekampen mot Watford, har nå scoret i begge kampene etter sin hjemkomst fra Asiamesterskapet.

Angriperen fyrte løs fra 18 meter. Skuddet gikk rett Martin Dubravka, men keeperen klarte ikke å stoppe skuddet.

Scoringen gjorde at Spurs nok en gang dro i land en seier i sluttminuttene. Det betyr at Tottenham nå er oppe på en andreplass, men med én kamp mer spilt enn Manchester City.

Heung-min Son sørget for tre Tottenham-poeng med sen scoring.

Newcastle var på vei mot nok et kruttsterkt resultat mot et topplag, men Heung-min Son ville det annerledes. Med åtte minutter igjen av ordinær tid scoret sørkoreaneren sitt tiende ligamål for sesongen.

Slik var kampen Det var Tottenham som var nærmest scoring i den første omgangen. Lucas Moura fikk en enorm mulighet etter et kvarter, men brasilianerens heading gikk utenfor mål.

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvspretten etter en corner som ble svakt halvklarert.

Tidlig i andre omgang økte Mohamed Salah til 2-0 fra straffemerket etter at han selv ble dratt i armen av Paul Dummett. Straffen var likevel billig, og Salah blir fra flere holdt beskyldt for å filme. Uansett var det svakt av Dummett å bruke armen i duellen, og straffen satte Salah sikkert forbi keeper Martin Dubravka.

Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.

Men etter pause hevet Tottenham seg, og Fernando Llorente utlignet den sammenlagte ledelsen rett etter pause med et kontant hodestøt.

I straffesparkkonkurransen scoret Willian, Azpilicueta, Jorginho og David Luiz, mens Eric Dier banket ballen langt opp på tribunen, og Lucas Moura rett i fanget på Kepa, dermed hjalp det lite at Christian Eriksen og Erik Lamela scoret på de to første forsøkene.

Chelsea til ligacupfinale etter straffeseier

N'Golo Kanté banket inn 1-0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2-0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Midtveis i omgangen var det Erik Lamela som fikk en sjanse. Innlegget fra Jan Vertonghen var av det presise slaget, men headingen fra Lamela var akkurat ikke god nok. Ballen smalt i tverriggeren. Returen falt til Moura, men heller ikke denne gang traff angriperen mål.

Nytt stolpetreff Rondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frempå igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut.

Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Først vant Llorente duellen, før Son dro seg fri og sendte i vei et skudd fra 18 meter. Skuddet gikk rett på Dubravka, men keeperen klarte likevel ikke å stoppe det.

På tampen ordnet Xherdan Shaqiri 3-0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4-0.

Tottenham knuste Bournemouth 5-0, og tok over annenplassen på tabellen – seks poeng bak Liverpool. Mauricio Pochettinos lag har scoret vanvittige 11 mål på få dager, etter 6-2-seieren borte mot Everton lille julaften.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

Bernardo Silva sendte Manchester City i ledelsen, men Marc Albrighton og Ricardo Pereira scoret i hver sin omgang og sørget for 2-1-seier til Leicester. Vinnermålet til Pereira var et herlig langskudd, og Fabian Delph pådro seg rødt kort på tampen av kampen.

Figure B.20: SVC RBF application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.
- Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.
- Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.
- Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.
- Det er en fantastisk følelse. I den første omgangen kunne vi scoret tre eller fire. Vi kontrollerte kampen også etter pause. Spurs fikk sin mulighet, og scoret. Reaksjonen til spillerne og viljen vi viste gjør meg svært glad. For det var frustrerende at vi risikerte å tape på straffer etter å kontrollert kampen fullstendig. I straffesparkkonkurranser vet man aldri hva som skjer. Men laget gjorde det strålende. Vi skapte mange sjanser og presset Tottenham hele kampen, sa Chelseas straffehelt David Luiz til Sky Sports etter kampen.
- Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
- Han har vært en av Newcastles beste spillere denne sesongen. Han har reddet laget så mange ganger. Det er brutalt, sier TV 2-kommentator Endre Olav Osnes.
- Chelsea har vært et av de mest suksessrike lagene i England de siste årene. Å vinne titler er det eneste som gjelder i denne klubben, så vi er glade for å være i finalen, oppsummerte Chelsea-kaptein Cesar Azpilicueta til Viasat 4.
- Det er deilig å se spillere leke fotball på den måten, sa Ronny Deila om Jorginhos arrogante straffe, hvor midtbanespilleren ventet ut keeper og trillet ballen nonchalant i mål.
- Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.
- Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange trofæer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.
- Jeg bryr meg ikke. Jeg spiller bare fotball. Det har ingenting å si hva manageren sier, jeg fokuserer bare på fotballen og vil gjøre det best mulig for laget, svarte Hazard på spørsmål om hva han mente om Sarris kritikk.
- Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
- Vi vant mot dem på Wembley. De slo oss her. Jeg foretrekker å tape på straffer fremfor etter fulltid. Gratulerer til Chelsea. Nå skal vi gjøre alt og være klar for FA-cupkampen mot Crystal Palace på søndag, sa Tottenhams suksessjef etter kampen.
- Det er en stor, stor sjanse, men headingen er ikke i nærheten av god nok, sa Trevor Morley.
- Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.
- Både City og Liverpool sviktet i forrige runde. Nå starter Tottenham denne helgen med å vinne. Det er tre lag som kjemper om tittelen nå, sier Osnes.
- Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på at de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betyde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.
- Tottenham er i kjempeform nå, og er i form. Chelsea vil trolig vinne mye fremover, Arsenal vil vinne og dette blir et race til siste dag. Vi er med i racet, og det er det aller viktigste, la han til.

Figure B.21: SVC RBF application results on the "Quotes" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.</p> <p>Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.</p> <p>Fulham var flere ganger frempå og skapte problemer på tampen av omgangen. Ranieris menn ledet fortjent 1-0 til pause.</p> <p>Minuttet senere skjedde det som Tottenham-fansen fryktet. Dele Alli jaget en ball ut mot sidelinjen og i forsøket på å nå ballen holdt 22-åringen seg til hamstringen og måtte legge seg ned utenfor banen. Engelskmannen klarte ikke å komme seg på beina igjen og ble byttet ut. Alli så tydelig preget ut på benken etter byttet.</p> <p>Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.</p> <p>– Vidunderlig fotball av Chelsea Etter en tett og jevn start på kampen presenterte N'golo Kanté seg etter 27 minutters spill.</p> <p>I det 38. minutt viste Chelsea frem vidunderlig fotball. Eden Hazard startet det vakre angrepet, og avsluttet selv i boksen. Plutselig stod det 2-0 og Chelsea stormet mot en ny cupfinale.</p> <p>Tottenham skapte en rekke sjanser det siste kvarteret. Chelsea skapte også sine sjanser og hadde ingen planer om å parkere bussen.</p> <p>Flere scoringer ble det imidlertid ikke i kampen, og kampen måtte avgjøres på straffer.</p>	<p>Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.</p> <p>Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.</p> <p>Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren.</p> <p>Hazard: – Jeg bryr meg ikke Maurizio Sarri kritiserte som kjent Chelsea-spillerne etter 0-2-tapet mot Arsenal i Premier League. Manageren sa blant annet at Hazard ikke var en leder på banen.</p> <p>Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.</p> <p>Tottenhams manager Mauricio Pochettino hevdet at han ikke var særlig skuffet etter nederlaget.</p> <p>Ti minutter før slutt måtte forøvrig Tottenhams Moussa Sissoko gi seg på grunn av skade. Davinson Sánchez kom inn. Skadeproblemene fortsetter dermed for Tottenham.</p> <p>Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.</p> <p>Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.</p> <p>Slik startet lagene:</p> <p>Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.</p> <p>Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente.</p> <p>Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.</p>
--	--

Figure B.22: SVC RBF application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Dommer: Martin Atkinson, West Yorkshire</p> <p>Chelsea til finale etter seier mot Tottenham i straffesparkkonkurranse</p> <p>Maurizio Sarri øyner sitt første trofé som manager for Chelsea etter at blåtrøyene slo Tottenham på straffer torsdag kveld.</p> <p>Sissoko prøvde seg med et brukbar volleyforsøk kort tid før pause, men Dubravka stoppet skuddet. Dermed gikk lagene til pause på 0-0.</p> <p>Det var det som skulle til for at Spurs dro i land nok en sen seier på eget gress. Resultatet gjør at Tottenham nå har sneket seg forbi Manchester City, riktignok med én kamp mer spilt.</p> <p>Hjemvendte Son reddet dagen for Spurs</p> <p>(Liverpool-Newcastle 4-0, Leicester – Manchester City 2-1) Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.</p> <p>Sist Liverpool tapt en ligakamp på Anfield, var da Crystal Palace vant 2-1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seirer. Denne sesongen har det blitt bare seirer, med unntak av 0-0-kampen mot Manchester City.</p> <p>For nå er det syv poeng ned til Manchester City, som snublet igjen.</p> <p>For få dager siden tapte de 2-3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.</p> <p>Mål: 1-0 Dejan Lovren (11), 2-0 Mohamed Salah (str. 48), 3-0 Xherdan Shaqiri (79), 4-0 Fabinho (85).</p>	<p>For øyeblikket bunnsolide Liverpool gikk sin 30. strake hjemmekamp i ligaen uten tap. Selv om farlig utsatte Newcastle hang med lenge, så ble det stygge sifre til slutt. Den antatt argeste gullrivalen, Manchester City, ligger nå syv poeng bak.</p> <p>PS! Førstkommende lørdag spiller Tottenham hjemme mot Wolverhampton, og Liverpool får besøk av Arsenal. Manchester City spiller borte mot Southampton søndag.</p> <p>Mål: 1-0 Nemanja Matic (28), 2-0 Paul Pogba (64), 3-0 Pogba (78), 3-1 Mathias Jørgensen (88).</p> <p>Mål: 1-0 Christian Eriksen (16), 2-0 Son Heung-min (23), 3-0 Lucas Moura (35), 4-0 Harry Kane (61), 5-0 Son (70).</p> <p>Dommer: Anthony Taylor, England.</p> <p>Mål: 0-1 Pierre-Emerick Aubameyang (7), 1-1 Jürgen Locadia (35).</p> <p>Det ble klart etter seier i straffesparkkonkurranse mot Tottenham torsdag kveld.</p> <p>I returoppgjøret mot Tottenham i Ligacupen fikk han svar på tiltale.</p> <p>I finalen venter Manchester City. Seier vil bety Sarris første trofé som Chelsea-manager. Mauricio Pochettino derimot må vente enda lenger på sitt første som Tottenham-sjef.</p> <p>Finalen spilles på Wembley siste helgen i februar.</p> <p>(Chelsea - Tottenham 2-1, 2-2 sammenlagt, 6-4 etter straffer) Kun Pep Guardiola og Manchester City står mellom Maurizio Sarri og hans første trofé som Chelsea-manager.</p> <p>Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.</p>
---	--

Figure B.23: SVC RBF application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Tottenham seiret etter overtidsdrama	21.484 tilskuere.
Se seiersmålet og høydepunktene i videovinduet øverst!	Crystal Palace – Cardiff 0–0
Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):	25.206 tilskuere
Se sammendrag i Sportsnyhetene øverst!	Fulham – Wolverhampton 1–1 (0–0)
Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.	Mål: 1–0 Ryan Sessegnon (74), 1–1 Romain Saiss (85).
Tottenham - Newcastle 1-0	24.382 tilskuere.
Se scoringen i videovinduet øverst!	Leicester – Manchester C. 2–1 (1–1)
Live: Brighton tok poeng mot Arsenal - referat fra dagens runde	Mål: 0–1 Bernardo Silva (14), 1–1 Marc Albrighton (19), 2–1 Ricardo Pereira (81).
Mål: 0–1 Yerry Mina (2), 0–2 Lucas Digne (13), 0–3 Gylfi Sigurdsson (str. 22), 1–3 Ben Gibson (37), 1–4 Digne (72), 1–5 Richarlison (90).	32.090 tilskuere.
Rødt kort: Fabian Delph (89), Manchester C.	
Liverpool – Newcastle 4–0 (1–0)	
53.318 tilskuere.	
Manchester U. – Huddersfield 3–1 (1–0)	
74.523 tilskuere.	
Tottenham – Bournemouth 5–0 (3–0)	
45.154 tilskuere.	
Joshua King spilte 16 minutter som innbytter for Bournemouth.	
Brighton – Arsenal 1–1 (1–1)	
30.608 tilskuere	
Gult kort: Martín Montoya (45), Glenn Murray (58), Brighton, Sead Kolasinac (81), Arsenal.	
Senere kampstart: Watford – Chelsea 20.30.	

Figure B.24: SVC RBF application results on the "Ignore" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt. Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.

Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham. Angrepene fra hjemmelaget kom som perler på snor utover, og Morata burde økt ledelsen til Chelsea etter 58 minutter, men på åpent mål presterte spissen å skyte over.

Etter halvtimen spilt sendte Zappacosta ballen til Ruben Loftus-Cheek som ventet innenfor Nottinghams 16-meter. Chelsea-midtbanemann ble taklet så det sang av Danny Fox, og Chelsea ble tildelt et soleklart straffespark. Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøket angrep av samme duo som lagde 1-0 målet.

Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreamgang kom scoringen for vertene. Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.

Callum Hudson-Odoi la inn foran mål hvor Morata ventet. Etter flere forsøk satt den endelig for Chelsea-spissen, og hjemmelaget ledet 1-0. Antoine Griezmann er storklubbens toppscorer med ti mål i serien. Bak ham har ingen scoret mer enn to. Blant dem som har slitt, er tidligere Chelsea-stjerne Diego Costa. Spansk-brasilianeren har bare funnet nettmaskene én gang i ligasammenheng.

Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben. Sarri ønsket Higuain inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuain.

Men den siste sesongen har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjelte spissen scoret begge. Huddersfield-kampen forrige helg, der Higuain scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

Higuain kommer til Chelsea med et rykte som en notorisk målscorer. Kun fem spillere har scoret mer enn argentineren i topp fem-ligaene siden starten av 2006/07-sesongen. – Higuain kan ikke bare måles på antall scoringer

I Chelsea er Higuain gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong. Morata misbrukte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.

Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.

Sparket fra ellevemetersmerket burde nok blitt tatt opp igjen, da en hel haug av spillere fra både Nottingham Forest og Chelsea var innenfor 16-meteren før Fabregas' avslutning:

Men da en spanjol mislykkes, var det en annen som fikk det til – etter noen forsøk.

Bare når ettertraktede Callum Hudson-Odoi serverte fra høyre fikk Morata til å score. Først med en tap-in, deretter med et pent hodestøt, hvor han knuste Claudio Yacob i luften.

Figure B.25: SVC RBF application results on the "Goal/Assist" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.

Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.

Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.

Chelsea-spiss klar for La Liga-gigant

Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.

Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.

Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.

PSG har vært koblet til Evertons midtbanespiller Idrissa Gueye en stund. Ifølge Liverpool Echo har de imidlertid ikke lagt inn noe formelt bud enda.

Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.

Watford føler seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Siden den gang har Higuain spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuain, og ikke den som mislykkes i Milano.

Med sommerens signering av Jorginho, og Higuain inn i januarvinduet, har Sarri hentet inn to viktige brikker fra tiden sin i Napoli, som vet hvordan italieneren ønsker å spille.

Siden Roman Abramovitsjs inntog i Chelsea har stjernespissene vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuain.

Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.

Álvaro Morata (26) lånes ut fra Chelsea til Atlético Madrid.

Alvaro Morata er nær ved å forlate Chelsea. Her er dagens fotballrykter!

Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.

Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.

Det ser ut til at den spanske midtbanespilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalene med Arsenal gikk i stå, skriver ESPN.

Fotballryktene: – Morata bare timer unna overgang

Chelsea har lenge vært koblet til Zenits argentinske midtbanespiller Leandro Paredes, men nå har Paris Saint-Germain seilet opp som favoritt til å signere 24-åringen, skriver The Telegraph.

Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter waliserenes landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasseklubb» som Juventus, skriver Sky Sports.

Chelsea har en lang tradisjon for å hente stjernespiss, men få har levd opp til forventningene på Stamford Bridge.

Figure B.26: SVC RBF application results on the "Transfer" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.
- Utfordringen er at Chelsea har vinger som liker å føre ballen langt inn i banen, og da har Higuain ofte allerede løpt i offside før pasningen kommer, sier Vinje.
- Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Blir han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.
- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Jeg har mer troa etter kampen mot Huddersfield. Han er jo en målscore, men han har slitt denne sesongen. Spørsmålet er om Chelsea får den Higuain som scoret 36 ligamål på en sesong i Napoli, eller den som slet i Milan denne sesongen.
- Det er denne rekken Higuain nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.
- Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.
- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.
- Det er en av de to-tre vanskeligste kampene som er. Men toppkamper lever sitt eget liv, og Chelsea har ofte vært bedre borte mot topplagene enn mot de antatt svakere lagene.
- Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.
- Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:
- Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.

Figure B.27: SVC RBF application results on the "Quotes" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Chelsea-stjerne forlot banen i tårer	Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.
Chelsea - Nottingham Forest 2-0 (0-0)	
Chelsea hadde stort sett kontroll på Nottingham Forest i FA-cupens tredje runde. Men det var duoen Álvaro Morata og Callum Hudson-Odoi som utgjorde forskjellen i 2-0 seieren.	Etter drøye timen spilt begynte sjansene å bli større for Nottingham. Nærmest redusering var Joe Lolley, men spissen måtte nøye seg med nettveggen denne gang.
Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.	Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.
Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.	Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fàbregas farvel med engelsk fotball.
Mot slutten av omgangen viste Nottingham mer selvtillit og utfordret Chelsea. Noen helt store sjanser ble det ikke, men etter å ha tilbragt store deler av omgangen på egen banehalvdel, var det i hvert fall et steg i riktig retning for gjestene.	- Med det blikket for spillet og timingen på pasningene, er han unik i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.
Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.	Thorstvedt mener likevel Higuain-overgangen var en sårt tiltrent forsterkning i Chelsea-stallen.
Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.	Higuain fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.
Hans nye klubb ligger på andreplass i La Liga, fem poeng bak Barcelona. Som Sarri, har Atlético Madrid-manager Diego Simeone slitt med å få angrepsspillerne til å score.	På søndag møter en meget tøff utfordring for Higuain og Chelsea, når de gjester Manchester City på Etihad. Supporterleder Vinje forventer en svært tøff kamp mot de regjerende mesterne.
Spillere som Andrij Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Alvaro Morata, har ikkedd seg den blå drakten uten nevneverdig suksess.	- I Jorginho og Higuain har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.
Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.	Chelsea vant kampen 2-0, og fansen tok dermed ikke farvel med FA-cupen.
De tok imidlertid trolig farvel med den spanske midtbanespilleren Cesc Fàbregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.	Hudson-Odoi - som jaktes av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.
Det var dermed passende at Maurizio Sarri ga Fabregas kapteinsbindet, men det ble ingen fantastisk avskjed for Fabregas – selv om det kunne blitt det.	Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.
Vondt ble til verre for Fabregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.	Utskjelte Morata sendte Chelsea videre da Fabregas tok farvel med Stamford Bridge
Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.	(Chelsea – Nottingham Forest 2-0) Cesc Fàbregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.

Figure B.28: SVC RBF application results on the "Irrelevant" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

B.4 SVC Poly

B.4.1 Ful Tables from Training Experiments

Para	Time		Metrics					f1 score for each class				
	C	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.525	3.391	0.478	0.709	0.663	0.709	0.674	0.748	0.683	0.847	0.836	0.162	0.842
0.5375	3.394	0.478	0.711	0.663	0.711	0.679	0.747	0.687	0.845	0.834	0.184	0.841
0.55	3.397	0.474	0.719	0.668	0.719	0.693	0.750	0.702	0.845	0.840	0.237	0.841
0.5625	3.405	0.476	0.723	0.671	0.723	0.701	0.756	0.709	0.838	0.839	0.272	0.847
0.575	3.390	0.475	0.731	0.678	0.731	0.712	0.757	0.725	0.846	0.842	0.304	0.844
0.5875	3.383	0.476	0.738	0.684	0.738	0.722	0.763	0.739	0.846	0.842	0.343	0.843
0.6	3.403	0.475	0.748	0.693	0.748	0.735	0.770	0.757	0.847	0.848	0.381	0.843
0.6125	3.390	0.483	0.757	0.703	0.757	0.748	0.779	0.772	0.846	0.851	0.424	0.844
0.625	3.380	0.478	0.767	0.713	0.767	0.758	0.786	0.794	0.849	0.853	0.452	0.845
0.6375	3.392	0.477	0.772	0.718	0.772	0.764	0.790	0.806	0.848	0.847	0.476	0.844
0.65	3.389	0.480	0.778	0.725	0.778	0.772	0.797	0.817	0.850	0.850	0.498	0.842
0.6625	3.392	0.473	0.790	0.739	0.790	0.784	0.807	0.832	0.847	0.859	0.533	0.850
0.675	3.389	0.475	0.794	0.743	0.794	0.788	0.810	0.840	0.851	0.858	0.545	0.846
0.6875	3.392	0.471	0.795	0.745	0.795	0.791	0.813	0.846	0.848	0.854	0.558	0.847
0.7	3.396	0.470	0.802	0.753	0.802	0.798	0.818	0.857	0.848	0.860	0.577	0.846
0.7125	3.391	0.476	0.805	0.756	0.805	0.801	0.821	0.862	0.850	0.859	0.582	0.850
0.725	3.389	0.474	0.812	0.766	0.812	0.809	0.828	0.866	0.857	0.870	0.597	0.854
0.7375	3.390	0.477	0.811	0.764	0.811	0.809	0.829	0.868	0.852	0.865	0.602	0.856
0.75	3.391	0.472	0.814	0.768	0.814	0.812	0.831	0.872	0.857	0.862	0.611	0.856
0.7625	3.392	0.473	0.816	0.770	0.816	0.813	0.832	0.879	0.854	0.864	0.617	0.850
0.775	3.399	0.475	0.819	0.773	0.819	0.815	0.834	0.879	0.859	0.868	0.615	0.856
0.7875	3.400	0.474	0.818	0.773	0.818	0.815	0.833	0.879	0.858	0.865	0.617	0.855
0.8	3.406	0.473	0.818	0.773	0.818	0.815	0.833	0.880	0.855	0.869	0.616	0.858
0.8125	3.402	0.474	0.821	0.776	0.821	0.818	0.835	0.883	0.860	0.870	0.619	0.856
0.825	3.407	0.469	0.823	0.778	0.823	0.820	0.837	0.885	0.857	0.869	0.629	0.860
0.8375	3.407	0.476	0.823	0.778	0.823	0.820	0.836	0.880	0.865	0.866	0.629	0.858
0.85	3.402	0.478	0.826	0.782	0.826	0.823	0.839	0.885	0.865	0.866	0.636	0.862
0.8625	3.403	0.475	0.825	0.780	0.825	0.822	0.838	0.885	0.860	0.872	0.631	0.859
0.875	3.400	0.472	0.827	0.784	0.827	0.824	0.840	0.886	0.865	0.874	0.637	0.858
0.8875	3.392	0.475	0.828	0.785	0.828	0.825	0.842	0.891	0.862	0.873	0.640	0.859
0.9	3.405	0.471	0.828	0.785	0.828	0.824	0.840	0.889	0.862	0.875	0.635	0.860
0.9125	3.402	0.477	0.830	0.787	0.830	0.827	0.843	0.889	0.869	0.872	0.644	0.859
0.925	3.405	0.475	0.830	0.787	0.830	0.826	0.842	0.889	0.866	0.876	0.637	0.862
0.9375	3.414	0.472	0.833	0.791	0.833	0.830	0.844	0.890	0.871	0.877	0.644	0.866
0.95	3.413	0.480	0.830	0.787	0.830	0.826	0.841	0.887	0.864	0.877	0.639	0.865
0.96	3.397	0.473	0.833	0.791	0.833	0.830	0.844	0.890	0.870	0.879	0.647	0.864
0.9625	3.409	0.471	0.827	0.784	0.827	0.825	0.840	0.890	0.861	0.871	0.634	0.868
0.975	3.403	0.474	0.830	0.786	0.830	0.827	0.841	0.884	0.868	0.878	0.638	0.867
0.9875	3.396	0.473	0.834	0.792	0.834	0.831	0.846	0.893	0.868	0.878	0.649	0.867
1	3.402	0.474	0.833	0.791	0.833	0.830	0.844	0.892	0.866	0.879	0.644	0.867
1.0125	3.394	0.477	0.833	0.791	0.833	0.829	0.844	0.891	0.872	0.879	0.642	0.863
1.025	3.394	0.472	0.834	0.792	0.834	0.831	0.845	0.893	0.865	0.880	0.646	0.870
1.0375	3.404	0.475	0.833	0.791	0.833	0.830	0.843	0.888	0.866	0.885	0.643	0.868
1.05	3.401	0.473	0.833	0.791	0.833	0.830	0.844	0.889	0.865	0.880	0.648	0.869
1.0625	3.407	0.475	0.830	0.787	0.830	0.827	0.841	0.889	0.866	0.878	0.635	0.866
1.075	3.414	0.475	0.832	0.790	0.832	0.830	0.842	0.889	0.864	0.881	0.637	0.877
1.0875	3.397	0.471	0.836	0.794	0.836	0.832	0.846	0.889	0.872	0.881	0.650	0.869
1.1	3.411	0.472	0.833	0.790	0.833	0.829	0.843	0.891	0.865	0.879	0.642	0.870
1.1125	3.413	0.478	0.834	0.793	0.834	0.831	0.844	0.891	0.869	0.881	0.646	0.868
1.125	3.394	0.468	0.835	0.794	0.835	0.832	0.846	0.887	0.875	0.882	0.648	0.868
1.1375	3.401	0.478	0.835	0.793	0.835	0.831	0.844	0.891	0.866	0.882	0.644	0.873
1.15	3.418	0.475	0.832	0.790	0.832	0.829	0.842	0.891	0.860	0.879	0.644	0.869
1.1625	3.398	0.474	0.834	0.792	0.834	0.832	0.844	0.886	0.868	0.884	0.647	0.873
1.175	3.401	0.476	0.837	0.796	0.837	0.834	0.847	0.889	0.869	0.883	0.656	0.875
1.1875	3.388	0.466	0.839	0.799	0.839	0.836	0.849	0.893	0.869	0.886	0.659	0.876
1.2	3.408	0.472	0.836	0.795	0.836	0.833	0.846	0.894	0.872	0.876	0.652	0.869
1.2125	3.411	0.471	0.835	0.793	0.835	0.832	0.845	0.890	0.864	0.879	0.652	0.875
1.225	3.409	0.476	0.837	0.796	0.837	0.834	0.846	0.893	0.868	0.882	0.652	0.877
1.2375	3.403	0.478	0.836	0.794	0.836	0.832	0.845	0.896	0.864	0.882	0.646	0.871
1.25	3.400	0.472	0.834	0.792	0.834	0.831	0.843	0.893	0.860	0.883	0.647	0.871
1.2625	3.391	0.475	0.836	0.794	0.836	0.833	0.845	0.890	0.870	0.879	0.651	0.874
1.275	3.412	0.474	0.836	0.794	0.836	0.833	0.845	0.892	0.862	0.881	0.653	0.875
1.2875	3.392	0.471	0.836	0.794	0.836	0.833	0.846	0.892	0.866	0.884	0.648	0.875
1.3	3.399	0.475	0.834	0.792	0.834	0.830	0.843	0.894	0.864	0.879	0.641	0.874
1.3125	3.399	0.471	0.835	0.793	0.835	0.832	0.844	0.892	0.867	0.875	0.647	0.878
1.325	3.402	0.479	0.838	0.797	0.838	0.835	0.846	0.894	0.867	0.885	0.651	0.878
1.3375	3.393	0.474	0.838	0.797	0.838	0.835	0.848	0.894	0.867	0.879	0.657	0.879
1.35	3.401	0.477	0.833	0.791	0.833	0.830	0.843	0.889	0.861	0.882	0.647	0.873
1.3625	3.409	0.480	0.837	0.796	0.837	0.834	0.846	0.891	0.867	0.881	0.656	0.877
1.375	3.402	0.480	0.838	0.797	0.838	0.835	0.847	0.891	0.868	0.882	0.657	0.878
1.3875	3.402	0.478	0.840	0.800	0.840	0.838	0.849	0.893	0.872	0.885	0.656	0.882
1.4	3.418	0.484	0.837	0.796	0.837	0.834	0.846	0.891	0.873	0.879	0.653	0.874
1.4125	3.399	0.474	0.838	0.796	0.838	0.835	0.847	0.892	0.869	0.880	0.657	0.876
1.425	3.411	0.475	0.836	0.794	0.836	0.832	0.844	0.889	0.869	0.883	0.648	0.874
1.4375	3.405	0.477	0.835	0.793	0.835	0.832	0.844	0.890	0.868	0.882	0.647	0.872
1.45	3.413	0.470	0.834	0.792	0.834	0.832	0.844	0.890	0.863	0.880	0.650	0.875
1.4625	3.418	0.468	0.836	0.795	0.836	0.834	0.845	0.888	0.865	0.883	0.651	0.880
1.475	3.417	0.473	0.833	0.791	0.833	0.830	0.842	0.889	0.866	0.879	0.640	0.874
1.4875	3.404	0.474	0.839	0.797	0.839	0.835	0.846	0.893	0.866	0.882	0.655	0.882

Table B.12: Performances and execution times for SVC Poly on different C values when shrinking is false

Para	Time		Metrics					f1 score for each class				
	Gamma	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.525	3.473	0.494	0.542	0.502	0.542	0.505	0.635	0.531	0.466	0.766	0.000	0.763
0.5375	3.474	0.488	0.559	0.517	0.559	0.523	0.633	0.541	0.526	0.771	0.000	0.776
0.55	3.468	0.495	0.572	0.530	0.572	0.538	0.632	0.550	0.588	0.769	0.000	0.783
0.5625	3.468	0.488	0.590	0.549	0.590	0.555	0.635	0.562	0.652	0.774	0.000	0.787
0.575	3.458	0.492	0.602	0.560	0.602	0.566	0.632	0.573	0.696	0.767	0.000	0.793
0.5875	3.447	0.491	0.620	0.578	0.620	0.581	0.633	0.588	0.739	0.779	0.000	0.800
0.6	3.452	0.489	0.633	0.590	0.633	0.592	0.697	0.601	0.764	0.783	0.010	0.804
0.6125	3.441	0.484	0.646	0.603	0.646	0.601	0.672	0.612	0.792	0.789	0.005	0.809
0.625	3.443	0.484	0.656	0.612	0.656	0.609	0.670	0.624	0.803	0.792	0.005	0.820
0.6375	3.427	0.488	0.664	0.620	0.664	0.614	0.670	0.632	0.818	0.797	0.005	0.818
0.65	3.416	0.484	0.673	0.629	0.673	0.621	0.706	0.643	0.831	0.795	0.015	0.824
0.6625	3.406	0.479	0.678	0.634	0.678	0.624	0.685	0.651	0.833	0.798	0.012	0.824
0.675	3.408	0.486	0.685	0.640	0.685	0.632	0.745	0.659	0.832	0.808	0.029	0.831
0.6875	3.405	0.479	0.692	0.648	0.692	0.639	0.745	0.667	0.840	0.815	0.040	0.830
0.7	3.405	0.482	0.697	0.653	0.697	0.647	0.747	0.669	0.850	0.818	0.062	0.833
0.7125	3.404	0.479	0.701	0.657	0.701	0.652	0.749	0.674	0.845	0.828	0.076	0.838
0.725	3.398	0.478	0.704	0.660	0.704	0.662	0.750	0.676	0.850	0.830	0.111	0.840
0.7375	3.402	0.477	0.708	0.662	0.708	0.673	0.749	0.682	0.849	0.832	0.159	0.844
0.75	3.388	0.482	0.713	0.665	0.713	0.685	0.754	0.690	0.845	0.835	0.212	0.842
0.7625	3.388	0.480	0.726	0.675	0.726	0.704	0.757	0.711	0.845	0.839	0.277	0.847
0.775	3.390	0.471	0.731	0.678	0.731	0.714	0.759	0.725	0.849	0.837	0.315	0.842
0.7875	3.383	0.481	0.746	0.693	0.746	0.733	0.771	0.751	0.844	0.847	0.383	0.843
0.8	3.389	0.478	0.757	0.702	0.757	0.747	0.778	0.776	0.848	0.847	0.422	0.844
0.8125	3.394	0.477	0.773	0.719	0.773	0.766	0.791	0.806	0.847	0.852	0.475	0.851
0.825	3.388	0.473	0.780	0.728	0.780	0.774	0.799	0.824	0.847	0.852	0.506	0.843
0.8375	3.393	0.479	0.788	0.736	0.788	0.783	0.806	0.836	0.847	0.855	0.529	0.849
0.85	3.394	0.477	0.799	0.750	0.799	0.795	0.816	0.852	0.850	0.858	0.568	0.846
0.8625	3.395	0.474	0.805	0.756	0.805	0.801	0.821	0.862	0.852	0.860	0.582	0.850
0.875	3.384	0.471	0.815	0.769	0.815	0.811	0.830	0.873	0.858	0.866	0.607	0.849
0.8875	3.384	0.474	0.810	0.763	0.810	0.807	0.826	0.874	0.852	0.857	0.601	0.852
0.9	3.392	0.472	0.814	0.768	0.814	0.811	0.829	0.874	0.858	0.864	0.606	0.852
0.9125	3.398	0.470	0.819	0.774	0.819	0.816	0.834	0.882	0.857	0.870	0.618	0.854
0.925	3.394	0.473	0.824	0.780	0.824	0.820	0.838	0.888	0.861	0.869	0.630	0.855
0.9375	3.382	0.470	0.824	0.780	0.824	0.821	0.837	0.885	0.862	0.868	0.628	0.861
0.95	3.378	0.478	0.825	0.781	0.825	0.821	0.838	0.889	0.856	0.875	0.632	0.855
0.9625	3.402	0.473	0.831	0.789	0.831	0.828	0.843	0.884	0.865	0.881	0.648	0.864
0.975	3.399	0.473	0.831	0.788	0.831	0.828	0.844	0.888	0.867	0.878	0.643	0.864
0.9875	3.402	0.475	0.829	0.786	0.829	0.826	0.841	0.889	0.862	0.873	0.641	0.866
1	3.397	0.473	0.833	0.791	0.833	0.830	0.844	0.890	0.870	0.879	0.647	0.864
1.0125	3.401	0.480	0.829	0.786	0.829	0.825	0.840	0.887	0.865	0.876	0.636	0.864
1.025	3.393	0.473	0.832	0.789	0.832	0.829	0.842	0.888	0.863	0.881	0.641	0.870
1.0375	3.391	0.471	0.835	0.793	0.835	0.831	0.845	0.893	0.867	0.881	0.649	0.865
1.05	3.384	0.468	0.832	0.789	0.832	0.828	0.841	0.888	0.868	0.878	0.636	0.869
1.0625	3.392	0.470	0.834	0.792	0.834	0.831	0.845	0.891	0.866	0.882	0.646	0.871
1.075	3.390	0.479	0.835	0.794	0.835	0.832	0.844	0.889	0.872	0.881	0.646	0.871
1.0875	3.383	0.473	0.840	0.800	0.840	0.836	0.849	0.893	0.873	0.887	0.659	0.870
1.1	3.398	0.473	0.833	0.791	0.833	0.830	0.843	0.890	0.865	0.880	0.644	0.873
1.1125	3.391	0.470	0.835	0.793	0.835	0.832	0.844	0.889	0.867	0.883	0.649	0.870
1.125	3.386	0.473	0.835	0.793	0.835	0.831	0.843	0.890	0.869	0.879	0.645	0.874
1.1375	3.376	0.465	0.841	0.800	0.841	0.837	0.849	0.894	0.872	0.884	0.659	0.877
1.15	3.391	0.473	0.833	0.791	0.833	0.830	0.842	0.889	0.862	0.882	0.645	0.872
1.1625	3.396	0.478	0.838	0.797	0.838	0.834	0.846	0.892	0.870	0.882	0.654	0.875
1.175	3.395	0.473	0.839	0.798	0.839	0.836	0.849	0.891	0.867	0.886	0.656	0.882
1.1875	3.357	0.468	0.839	0.798	0.839	0.836	0.848	0.893	0.871	0.880	0.659	0.875
1.2	3.406	0.472	0.836	0.794	0.836	0.834	0.845	0.892	0.863	0.884	0.648	0.880
1.2	3.128	0.435	0.837	0.795	0.837	0.834	0.846	0.887	0.871	0.881	0.655	0.873
1.2125	3.131	0.434	0.837	0.796	0.837	0.834	0.846	0.895	0.867	0.884	0.653	0.870
1.225	3.132	0.434	0.835	0.794	0.835	0.832	0.844	0.889	0.868	0.883	0.646	0.876
1.2375	3.134	0.435	0.835	0.794	0.835	0.833	0.845	0.886	0.869	0.882	0.650	0.877
1.25	3.141	0.436	0.843	0.803	0.843	0.840	0.851	0.897	0.873	0.884	0.665	0.880
1.2625	3.136	0.438	0.835	0.793	0.835	0.832	0.843	0.887	0.867	0.882	0.648	0.876
1.275	3.128	0.436	0.836	0.794	0.836	0.833	0.845	0.889	0.864	0.880	0.656	0.876
1.2875	3.126	0.436	0.836	0.795	0.836	0.833	0.844	0.889	0.866	0.880	0.652	0.876
1.3	3.138	0.436	0.837	0.795	0.837	0.833	0.845	0.893	0.863	0.882	0.651	0.878
1.3125	3.144	0.436	0.836	0.794	0.836	0.833	0.844	0.890	0.865	0.881	0.648	0.881
1.325	3.149	0.438	0.837	0.796	0.837	0.835	0.846	0.893	0.862	0.884	0.653	0.882
1.3375	3.147	0.439	0.834	0.792	0.834	0.831	0.843	0.885	0.865	0.884	0.645	0.878
1.35	3.154	0.439	0.835	0.793	0.835	0.832	0.843	0.887	0.865	0.885	0.650	0.873
1.3625	3.155	0.441	0.840	0.799	0.840	0.837	0.848	0.891	0.869	0.885	0.658	0.883
1.375	3.147	0.440	0.838	0.797	0.838	0.835	0.846	0.890	0.869	0.885	0.652	0.879
1.3875	3.149	0.438	0.837	0.795	0.837	0.834	0.846	0.889	0.868	0.886	0.655	0.871
1.4	3.185	0.444	0.838	0.797	0.838	0.835	0.847	0.895	0.865	0.882	0.654	0.879
1.4125	3.158	0.440	0.835	0.793	0.835	0.832	0.844	0.890	0.866	0.881	0.646	0.875
1.425	3.155	0.441	0.836	0.794	0.836	0.832	0.844	0.888	0.867	0.885	0.646	0.876
1.4375	3.158	0.441	0.839	0.798	0.839	0.836	0.848	0.894	0.866	0.882	0.661	0.875
1.45	3.153	0.438	0.832	0.789	0.832	0.829	0.840	0.886	0.867	0.878	0.639	0.874
1.4625	3.163	0.442	0.839	0.798	0.839	0.836	0.847	0.891	0.867	0.888	0.653	0.881
1.475	3.160	0.440	0.833	0.791	0.833	0.830	0.842	0.887	0.864	0.884	0.641	0.875
1.4875	3.151	0.437	0.837	0.796	0.837	0.834	0.845	0.891	0.871	0.882	0.648	0.878

Table B.13: Performances and execution times for SVC Poly on different gamma values when C is 0.96 and shrinking is false

Para	Time		Metrics					f1 score for each class				
	Coef0	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0	3.406	0.472	0.836	0.794	0.836	0.834	0.845	0.892	0.863	0.884	0.648	0.880
0.0375	3.260	0.465	0.847	0.808	0.847	0.844	0.854	0.901	0.874	0.887	0.673	0.884
0.075	3.121	0.463	0.850	0.812	0.850	0.847	0.856	0.901	0.874	0.891	0.681	0.890
0.1125	3.018	0.447	0.851	0.813	0.851	0.848	0.856	0.900	0.875	0.896	0.680	0.891
0.15	2.910	0.450	0.854	0.817	0.854	0.851	0.859	0.904	0.876	0.896	0.687	0.894
0.1875	2.838	0.440	0.855	0.818	0.855	0.852	0.860	0.904	0.878	0.898	0.689	0.893
0.225	2.782	0.427	0.857	0.820	0.857	0.855	0.862	0.902	0.877	0.901	0.693	0.901
0.2625	2.714	0.432	0.857	0.821	0.857	0.855	0.862	0.901	0.880	0.899	0.700	0.895
0.3	2.659	0.424	0.855	0.818	0.855	0.852	0.858	0.903	0.877	0.898	0.686	0.895
0.3375	2.613	0.429	0.853	0.816	0.853	0.851	0.858	0.897	0.877	0.896	0.688	0.897
0.375	2.573	0.422	0.856	0.820	0.856	0.854	0.861	0.902	0.877	0.900	0.694	0.896
0.4125	2.531	0.419	0.856	0.820	0.856	0.854	0.860	0.901	0.879	0.899	0.692	0.898
0.45	2.496	0.416	0.856	0.820	0.856	0.854	0.860	0.902	0.881	0.896	0.690	0.901
0.4875	2.480	0.416	0.859	0.822	0.859	0.855	0.861	0.904	0.882	0.903	0.694	0.891
0.525	2.448	0.416	0.853	0.815	0.853	0.850	0.856	0.902	0.872	0.893	0.683	0.898
0.5625	2.421	0.409	0.857	0.820	0.857	0.853	0.859	0.904	0.877	0.898	0.692	0.897
0.6	2.405	0.408	0.856	0.819	0.856	0.852	0.860	0.903	0.876	0.898	0.693	0.892
0.6375	2.396	0.407	0.854	0.817	0.854	0.851	0.857	0.900	0.873	0.900	0.686	0.898
0.675	2.371	0.406	0.858	0.821	0.858	0.854	0.861	0.903	0.879	0.900	0.694	0.895
0.7125	2.353	0.403	0.854	0.817	0.854	0.851	0.858	0.901	0.876	0.897	0.684	0.898
0.75	2.343	0.406	0.857	0.820	0.857	0.853	0.860	0.903	0.878	0.904	0.690	0.892
0.7875	2.306	0.397	0.856	0.819	0.856	0.853	0.859	0.902	0.876	0.901	0.693	0.892
0.825	2.287	0.400	0.854	0.817	0.854	0.851	0.856	0.900	0.873	0.904	0.680	0.898
0.8625	2.294	0.398	0.855	0.818	0.855	0.852	0.858	0.903	0.878	0.899	0.688	0.890
0.9	2.278	0.397	0.854	0.817	0.854	0.851	0.856	0.903	0.875	0.897	0.684	0.894
0.9375	2.258	0.400	0.855	0.817	0.855	0.851	0.857	0.903	0.875	0.902	0.685	0.891
0.975	2.245	0.396	0.854	0.817	0.854	0.851	0.857	0.900	0.875	0.901	0.685	0.894
1.0125	2.234	0.396	0.853	0.816	0.853	0.850	0.857	0.902	0.869	0.899	0.686	0.895
1.05	2.230	0.398	0.853	0.815	0.853	0.850	0.856	0.902	0.872	0.900	0.683	0.892
1.0875	2.212	0.393	0.854	0.817	0.854	0.851	0.857	0.902	0.877	0.899	0.683	0.894
1.125	2.208	0.390	0.852	0.814	0.852	0.849	0.855	0.898	0.875	0.897	0.680	0.897
1.1625	2.202	0.395	0.856	0.819	0.856	0.852	0.859	0.903	0.881	0.900	0.683	0.895
1.2	2.184	0.393	0.851	0.812	0.851	0.848	0.854	0.899	0.871	0.894	0.681	0.893
1.2375	2.187	0.390	0.851	0.813	0.851	0.848	0.854	0.900	0.873	0.901	0.673	0.891
1.275	2.178	0.389	0.856	0.819	0.856	0.852	0.859	0.907	0.874	0.902	0.686	0.893
1.3125	2.177	0.387	0.851	0.813	0.851	0.848	0.854	0.898	0.874	0.897	0.678	0.894
1.35	2.165	0.386	0.855	0.818	0.855	0.853	0.858	0.900	0.875	0.900	0.689	0.899
1.3875	2.164	0.393	0.852	0.814	0.852	0.849	0.854	0.898	0.876	0.900	0.678	0.892
1.425	2.149	0.387	0.847	0.807	0.847	0.843	0.849	0.893	0.866	0.898	0.668	0.892
1.4625	2.153	0.388	0.850	0.812	0.850	0.847	0.853	0.900	0.867	0.899	0.678	0.892
1.5	2.140	0.391	0.851	0.813	0.851	0.847	0.853	0.899	0.873	0.899	0.674	0.891
1.5375	2.141	0.391	0.848	0.809	0.848	0.844	0.850	0.894	0.874	0.896	0.672	0.885
1.575	2.129	0.382	0.852	0.814	0.852	0.849	0.855	0.897	0.877	0.896	0.682	0.892
1.6125	2.139	0.391	0.848	0.810	0.848	0.845	0.851	0.898	0.872	0.897	0.669	0.890
1.65	2.123	0.384	0.851	0.812	0.851	0.846	0.852	0.903	0.870	0.898	0.671	0.892
1.6875	2.122	0.390	0.849	0.811	0.849	0.846	0.851	0.896	0.872	0.901	0.671	0.890
1.725	2.103	0.384	0.849	0.811	0.849	0.845	0.852	0.898	0.873	0.896	0.677	0.882
1.7625	2.101	0.384	0.851	0.812	0.851	0.847	0.852	0.901	0.872	0.897	0.670	0.892
1.8	2.102	0.380	0.852	0.814	0.852	0.848	0.853	0.898	0.877	0.899	0.676	0.888
1.8375	2.093	0.381	0.848	0.809	0.848	0.844	0.850	0.898	0.874	0.897	0.665	0.888
1.875	2.093	0.387	0.849	0.810	0.849	0.845	0.852	0.899	0.871	0.897	0.673	0.887
1.9125	2.088	0.379	0.849	0.810	0.849	0.845	0.852	0.900	0.874	0.896	0.668	0.888
1.95	2.079	0.380	0.852	0.813	0.852	0.848	0.853	0.898	0.879	0.901	0.673	0.887
1.9875	2.074	0.383	0.847	0.808	0.847	0.843	0.849	0.898	0.868	0.896	0.669	0.884
2.025	2.076	0.383	0.847	0.808	0.847	0.844	0.850	0.899	0.871	0.893	0.670	0.886
2.0625	2.077	0.383	0.849	0.811	0.849	0.845	0.851	0.897	0.874	0.895	0.674	0.888
2.1	2.061	0.386	0.852	0.814	0.852	0.849	0.854	0.897	0.878	0.896	0.678	0.893
2.1375	2.060	0.386	0.851	0.813	0.851	0.847	0.854	0.906	0.873	0.892	0.673	0.894
2.175	2.059	0.378	0.848	0.809	0.848	0.845	0.850	0.894	0.877	0.900	0.671	0.884
2.2125	2.062	0.382	0.849	0.811	0.849	0.845	0.850	0.903	0.867	0.893	0.675	0.888
2.25	2.068	0.378	0.845	0.805	0.845	0.841	0.846	0.896	0.868	0.896	0.656	0.887
2.2875	2.044	0.384	0.851	0.813	0.851	0.848	0.854	0.897	0.878	0.899	0.678	0.887
2.325	2.052	0.382	0.850	0.812	0.850	0.846	0.852	0.901	0.869	0.900	0.672	0.888
2.3625	2.033	0.377	0.848	0.809	0.848	0.844	0.850	0.902	0.865	0.897	0.668	0.887
2.4	2.043	0.378	0.847	0.808	0.847	0.843	0.849	0.899	0.869	0.898	0.664	0.886
2.4375	2.038	0.381	0.846	0.806	0.846	0.842	0.848	0.897	0.871	0.896	0.660	0.887
2.475	2.026	0.380	0.849	0.810	0.849	0.846	0.851	0.894	0.876	0.899	0.669	0.890
2.5125	2.027	0.386	0.845	0.805	0.845	0.841	0.847	0.894	0.865	0.896	0.661	0.888
2.55	2.032	0.376	0.850	0.811	0.850	0.847	0.852	0.894	0.882	0.897	0.671	0.890
2.5875	2.032	0.386	0.849	0.810	0.849	0.844	0.849	0.897	0.875	0.895	0.669	0.885
2.625	2.037	0.380	0.845	0.805	0.845	0.840	0.847	0.897	0.867	0.893	0.658	0.886
2.6625	2.030	0.383	0.849	0.811	0.849	0.846	0.851	0.899	0.870	0.892	0.674	0.893
2.7	2.024	0.383	0.850	0.811	0.850	0.846	0.852	0.897	0.881	0.893	0.674	0.886
2.7375	2.023	0.381	0.846	0.807	0.846	0.842	0.849	0.901	0.866	0.901	0.666	0.875
2.775	2.015	0.377	0.848	0.809	0.848	0.844	0.851	0.894	0.877	0.897	0.669	0.884
2.8125	2.022	0.378	0.846	0.806	0.846	0.842	0.846	0.897	0.867	0.898	0.661	0.886
2.85	2.011	0.377	0.846	0.806	0.846	0.842	0.848	0.893	0.867	0.896	0.668	0.885
2.8875	2.011	0.377	0.845	0.806	0.845	0.841	0.846	0.896	0.868	0.896	0.658	0.887
2.925	2.012	0.379	0.847	0.807	0.847	0.843	0.849	0.896	0.871	0.896	0.662	0.892
2.9625	2.011	0.375	0.848	0.809	0.848	0.844	0.849	0.900	0.868	0.897	0.669	0.883

Table B.14: Performances and execution times for SVC Poly on different Coef0 values when Gamma is 1.2, c is 0.96 and shrinking is false

Para	Time		Metrics					f1 score for each class				
	C	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.525	3.514	0.483	0.710	0.664	0.710	0.676	0.758	0.681	0.848	0.833	0.174	0.845
0.5375	3.562	0.486	0.712	0.664	0.712	0.682	0.749	0.690	0.843	0.837	0.198	0.844
0.55	3.578	0.477	0.715	0.664	0.715	0.688	0.743	0.699	0.842	0.833	0.221	0.844
0.5625	3.588	0.476	0.725	0.674	0.725	0.704	0.758	0.711	0.848	0.842	0.281	0.838
0.575	3.603	0.478	0.729	0.676	0.729	0.712	0.756	0.723	0.845	0.841	0.306	0.844
0.5875	3.612	0.476	0.740	0.687	0.740	0.726	0.767	0.741	0.843	0.844	0.355	0.849
0.6	3.609	0.480	0.749	0.695	0.749	0.738	0.774	0.757	0.844	0.845	0.399	0.846
0.6125	3.613	0.479	0.757	0.703	0.757	0.747	0.778	0.772	0.850	0.846	0.421	0.844
0.625	3.611	0.478	0.768	0.714	0.768	0.761	0.788	0.795	0.849	0.851	0.462	0.847
0.6375	3.619	0.475	0.775	0.722	0.775	0.768	0.793	0.811	0.846	0.853	0.486	0.844
0.65	3.616	0.475	0.784	0.732	0.784	0.777	0.801	0.824	0.851	0.856	0.506	0.849
0.6625	3.617	0.474	0.787	0.736	0.787	0.782	0.805	0.832	0.846	0.859	0.530	0.843
0.675	3.626	0.475	0.791	0.741	0.791	0.786	0.809	0.838	0.847	0.855	0.544	0.849
0.6875	3.636	0.475	0.801	0.752	0.801	0.796	0.817	0.849	0.853	0.864	0.567	0.848
0.7	3.640	0.476	0.800	0.750	0.800	0.796	0.816	0.854	0.848	0.858	0.569	0.849
0.7125	3.639	0.475	0.808	0.761	0.808	0.804	0.824	0.864	0.852	0.861	0.593	0.849
0.725	3.647	0.474	0.805	0.757	0.805	0.802	0.823	0.863	0.853	0.861	0.585	0.847
0.7375	3.671	0.477	0.813	0.766	0.813	0.809	0.828	0.868	0.859	0.867	0.600	0.850
0.75	3.662	0.471	0.810	0.763	0.810	0.807	0.825	0.871	0.846	0.862	0.602	0.855
0.7625	3.672	0.477	0.817	0.771	0.817	0.814	0.832	0.877	0.854	0.867	0.615	0.856
0.775	3.677	0.475	0.817	0.771	0.817	0.814	0.832	0.879	0.854	0.864	0.617	0.854
0.7875	3.688	0.471	0.819	0.774	0.819	0.816	0.834	0.877	0.858	0.872	0.618	0.853
0.8	3.683	0.472	0.821	0.776	0.821	0.818	0.836	0.878	0.863	0.873	0.624	0.852
0.8125	3.698	0.478	0.822	0.778	0.822	0.819	0.837	0.882	0.859	0.870	0.626	0.858
0.825	3.688	0.476	0.824	0.780	0.824	0.820	0.839	0.886	0.859	0.870	0.632	0.855
0.8375	3.683	0.472	0.823	0.779	0.823	0.820	0.838	0.885	0.861	0.869	0.628	0.858
0.85	3.695	0.474	0.824	0.780	0.824	0.821	0.838	0.887	0.861	0.869	0.628	0.858
0.8625	3.696	0.472	0.829	0.786	0.829	0.826	0.841	0.888	0.868	0.873	0.636	0.864
0.875	3.709	0.473	0.827	0.783	0.827	0.824	0.840	0.887	0.864	0.876	0.633	0.861
0.8875	3.705	0.471	0.828	0.785	0.828	0.825	0.841	0.885	0.863	0.873	0.643	0.864
0.9	3.700	0.473	0.831	0.788	0.831	0.827	0.842	0.887	0.864	0.880	0.639	0.866
0.9125	3.716	0.471	0.830	0.788	0.830	0.827	0.843	0.891	0.862	0.876	0.642	0.864
0.925	3.716	0.478	0.831	0.789	0.831	0.828	0.843	0.889	0.868	0.878	0.641	0.866
0.9375	3.718	0.478	0.828	0.785	0.828	0.825	0.840	0.889	0.863	0.874	0.639	0.861
0.95	3.708	0.474	0.831	0.788	0.831	0.827	0.841	0.888	0.866	0.876	0.640	0.866
0.96	3.713	0.470	0.830	0.787	0.830	0.826	0.841	0.888	0.863	0.879	0.639	0.861
0.9625	3.712	0.472	0.829	0.786	0.829	0.826	0.841	0.892	0.864	0.872	0.641	0.864
0.975	3.711	0.478	0.833	0.791	0.833	0.830	0.844	0.890	0.863	0.878	0.648	0.869
0.9875	3.709	0.475	0.831	0.788	0.831	0.828	0.842	0.890	0.867	0.875	0.639	0.868
1	3.717	0.481	0.833	0.791	0.833	0.830	0.844	0.891	0.867	0.880	0.646	0.867
1.0125	3.713	0.478	0.831	0.788	0.831	0.828	0.842	0.888	0.869	0.876	0.641	0.865
1.025	3.697	0.475	0.835	0.793	0.835	0.832	0.845	0.892	0.862	0.884	0.648	0.873
1.0375	3.702	0.478	0.830	0.786	0.830	0.826	0.841	0.886	0.866	0.883	0.637	0.859
1.05	3.694	0.475	0.833	0.791	0.833	0.830	0.844	0.889	0.870	0.878	0.642	0.871
1.0625	3.698	0.471	0.833	0.791	0.833	0.830	0.843	0.890	0.863	0.882	0.639	0.876
1.075	3.698	0.481	0.834	0.793	0.834	0.830	0.845	0.896	0.867	0.880	0.648	0.862
1.0875	3.704	0.476	0.834	0.792	0.834	0.831	0.844	0.892	0.867	0.879	0.644	0.873
1.1	3.719	0.479	0.834	0.792	0.834	0.830	0.844	0.892	0.867	0.876	0.645	0.871
1.1125	3.719	0.476	0.835	0.793	0.835	0.831	0.844	0.889	0.867	0.881	0.648	0.872
1.125	3.704	0.471	0.833	0.791	0.833	0.830	0.842	0.887	0.862	0.883	0.642	0.876
1.1375	3.710	0.473	0.835	0.793	0.835	0.832	0.845	0.892	0.865	0.880	0.648	0.874
1.15	3.698	0.478	0.838	0.797	0.838	0.835	0.848	0.892	0.867	0.884	0.658	0.872
1.1625	3.722	0.474	0.833	0.791	0.833	0.830	0.844	0.889	0.865	0.883	0.647	0.869
1.175	3.707	0.475	0.835	0.794	0.835	0.832	0.844	0.890	0.862	0.882	0.649	0.877
1.1875	3.704	0.469	0.836	0.794	0.836	0.832	0.845	0.890	0.860	0.879	0.647	0.875
1.2	3.718	0.475	0.836	0.794	0.836	0.832	0.844	0.890	0.864	0.884	0.649	0.873
1.2125	3.701	0.475	0.833	0.791	0.833	0.830	0.842	0.885	0.869	0.878	0.646	0.873
1.225	3.703	0.471	0.839	0.798	0.839	0.836	0.848	0.891	0.868	0.883	0.660	0.879
1.2375	3.701	0.478	0.835	0.793	0.835	0.832	0.844	0.892	0.864	0.880	0.647	0.875
1.25	3.692	0.472	0.838	0.797	0.838	0.834	0.847	0.891	0.869	0.882	0.660	0.869
1.2625	3.717	0.476	0.838	0.797	0.838	0.835	0.847	0.891	0.869	0.887	0.650	0.875
1.275	3.722	0.471	0.838	0.797	0.838	0.836	0.847	0.890	0.869	0.881	0.657	0.881
1.2875	3.708	0.473	0.838	0.797	0.838	0.834	0.846	0.891	0.871	0.884	0.652	0.873
1.3	3.715	0.472	0.840	0.800	0.840	0.837	0.850	0.895	0.874	0.882	0.661	0.873
1.3125	3.730	0.474	0.837	0.795	0.837	0.833	0.845	0.891	0.866	0.884	0.655	0.867
1.325	3.726	0.475	0.836	0.795	0.836	0.833	0.845	0.892	0.860	0.886	0.653	0.874
1.3375	3.715	0.472	0.839	0.798	0.839	0.835	0.847	0.895	0.867	0.884	0.658	0.874
1.35	3.710	0.475	0.834	0.792	0.834	0.831	0.843	0.892	0.859	0.886	0.645	0.875
1.3625	3.706	0.474	0.836	0.795	0.836	0.833	0.844	0.891	0.868	0.883	0.646	0.878
1.375	3.701	0.473	0.838	0.797	0.838	0.836	0.847	0.888	0.865	0.884	0.659	0.881
1.3875	3.702	0.473	0.836	0.794	0.836	0.833	0.845	0.890	0.867	0.883	0.646	0.876
1.4	3.710	0.474	0.838	0.796	0.838	0.835	0.847	0.890	0.870	0.884	0.656	0.875
1.4125	3.701	0.475	0.838	0.797	0.838	0.835	0.846	0.894	0.867	0.881	0.655	0.876
1.425	3.706	0.473	0.834	0.792	0.834	0.831	0.844	0.891	0.862	0.883	0.647	0.874
1.4375	3.698	0.470	0.838	0.797	0.838	0.834	0.845	0.889	0.869	0.883	0.652	0.878
1.45	3.708	0.477	0.835	0.794	0.835	0.832	0.844	0.896	0.867	0.872	0.647	0.880
1.4625	3.708	0.473	0.840	0.799	0.840	0.836	0.848	0.896	0.869	0.883	0.657	0.876
1.475	3.708	0.472	0.838	0.797	0.838	0.835	0.846	0.892	0.866	0.886	0.656	0.875
1.4875	3.693	0.475	0.836	0.794	0.836	0.833	0.844	0.890	0.867	0.882	0.649	0.879

Table B.15: Performances and execution times for SVC Poly on different C values when shrinking is true

Para	Time		Metrics					f1 score for each class				
	Gamma	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0.525	3.519	0.486	0.541	0.500	0.541	0.504	0.631	0.531	0.457	0.763	0.000	0.767
0.5375	3.525	0.502	0.559	0.518	0.559	0.522	0.632	0.541	0.526	0.774	0.000	0.771
0.55	3.532	0.496	0.573	0.532	0.573	0.539	0.632	0.551	0.587	0.771	0.000	0.785
0.5625	3.518	0.487	0.588	0.546	0.588	0.554	0.632	0.562	0.645	0.768	0.000	0.792
0.575	3.516	0.487	0.602	0.560	0.602	0.567	0.651	0.573	0.692	0.773	0.002	0.792
0.5875	3.508	0.490	0.620	0.577	0.620	0.581	0.649	0.589	0.728	0.780	0.002	0.803
0.6	3.508	0.490	0.633	0.590	0.633	0.592	0.695	0.600	0.757	0.786	0.010	0.808
0.6125	3.497	0.484	0.647	0.604	0.647	0.603	0.681	0.613	0.790	0.788	0.010	0.815
0.625	3.506	0.486	0.655	0.611	0.655	0.608	0.690	0.621	0.807	0.790	0.010	0.813
0.6375	3.507	0.488	0.661	0.617	0.661	0.611	0.662	0.630	0.819	0.794	0.005	0.809
0.65	3.505	0.485	0.671	0.627	0.671	0.620	0.699	0.642	0.827	0.794	0.017	0.821
0.6625	3.522	0.485	0.679	0.634	0.679	0.626	0.711	0.653	0.829	0.799	0.022	0.827
0.675	3.520	0.487	0.685	0.640	0.685	0.631	0.701	0.658	0.833	0.808	0.028	0.828
0.6875	3.506	0.484	0.689	0.644	0.689	0.635	0.736	0.665	0.836	0.806	0.036	0.833
0.7	3.492	0.478	0.697	0.654	0.697	0.647	0.739	0.669	0.849	0.822	0.062	0.833
0.7125	3.520	0.481	0.700	0.655	0.700	0.654	0.753	0.671	0.849	0.825	0.086	0.839
0.725	3.507	0.481	0.702	0.657	0.702	0.661	0.754	0.673	0.848	0.828	0.121	0.834
0.7375	3.522	0.479	0.706	0.660	0.706	0.669	0.750	0.681	0.841	0.833	0.143	0.848
0.75	3.532	0.478	0.714	0.666	0.714	0.685	0.754	0.690	0.844	0.840	0.212	0.841
0.7625	3.565	0.474	0.726	0.675	0.726	0.703	0.756	0.712	0.851	0.837	0.273	0.844
0.775	3.581	0.475	0.734	0.682	0.734	0.717	0.764	0.726	0.849	0.842	0.323	0.846
0.7875	3.599	0.479	0.746	0.693	0.746	0.734	0.771	0.752	0.847	0.845	0.382	0.844
0.8	3.591	0.475	0.765	0.712	0.765	0.756	0.785	0.783	0.851	0.853	0.445	0.847
0.8125	3.596	0.473	0.771	0.717	0.771	0.764	0.790	0.805	0.847	0.847	0.476	0.844
0.825	3.601	0.479	0.781	0.728	0.781	0.775	0.799	0.820	0.852	0.857	0.504	0.840
0.8375	3.627	0.478	0.790	0.738	0.790	0.784	0.806	0.838	0.843	0.858	0.537	0.844
0.85	3.638	0.477	0.803	0.755	0.803	0.799	0.818	0.855	0.853	0.860	0.572	0.854
0.8625	3.633	0.478	0.806	0.758	0.806	0.802	0.821	0.863	0.851	0.858	0.584	0.854
0.875	3.659	0.472	0.812	0.765	0.812	0.808	0.828	0.867	0.852	0.868	0.599	0.856
0.8875	3.660	0.472	0.819	0.774	0.819	0.816	0.834	0.879	0.857	0.865	0.621	0.858
0.9	3.668	0.476	0.818	0.773	0.818	0.816	0.834	0.876	0.859	0.870	0.620	0.855
0.9125	3.688	0.475	0.818	0.772	0.818	0.816	0.833	0.880	0.848	0.867	0.623	0.860
0.925	3.685	0.472	0.821	0.776	0.821	0.818	0.835	0.881	0.852	0.869	0.627	0.862
0.9375	3.697	0.474	0.828	0.784	0.828	0.824	0.841	0.888	0.865	0.875	0.635	0.859
0.95	3.699	0.477	0.827	0.783	0.827	0.823	0.839	0.886	0.862	0.872	0.638	0.860
0.9625	3.693	0.477	0.830	0.787	0.830	0.827	0.843	0.886	0.864	0.878	0.644	0.864
0.975	3.694	0.474	0.831	0.789	0.831	0.828	0.843	0.888	0.862	0.881	0.644	0.867
0.9875	3.706	0.475	0.831	0.789	0.831	0.828	0.842	0.887	0.865	0.881	0.641	0.865
1	3.713	0.470	0.830	0.787	0.830	0.826	0.841	0.888	0.863	0.879	0.639	0.861
1.0125	3.700	0.474	0.830	0.787	0.830	0.827	0.840	0.888	0.861	0.877	0.637	0.870
1.025	3.692	0.474	0.832	0.790	0.832	0.829	0.843	0.888	0.866	0.879	0.643	0.871
1.0375	3.702	0.471	0.832	0.790	0.832	0.829	0.842	0.888	0.863	0.881	0.643	0.868
1.05	3.697	0.475	0.831	0.789	0.831	0.828	0.843	0.890	0.866	0.876	0.644	0.866
1.0625	3.689	0.470	0.831	0.788	0.831	0.828	0.840	0.888	0.860	0.877	0.643	0.870
1.075	3.684	0.471	0.829	0.786	0.829	0.826	0.840	0.887	0.868	0.876	0.636	0.862
1.0875	3.700	0.472	0.834	0.792	0.834	0.831	0.845	0.894	0.863	0.882	0.647	0.871
1.1	3.693	0.473	0.837	0.796	0.837	0.834	0.847	0.893	0.864	0.886	0.653	0.874
1.1125	3.692	0.475	0.837	0.796	0.837	0.834	0.846	0.891	0.869	0.885	0.651	0.876
1.125	3.696	0.481	0.833	0.790	0.833	0.830	0.842	0.890	0.862	0.880	0.647	0.869
1.1375	3.712	0.475	0.834	0.792	0.834	0.831	0.843	0.891	0.865	0.879	0.644	0.874
1.15	3.625	0.467	0.840	0.800	0.840	0.838	0.849	0.891	0.872	0.886	0.659	0.880
1.1625	3.403	0.434	0.837	0.796	0.837	0.834	0.846	0.888	0.869	0.886	0.652	0.874
1.175	3.401	0.433	0.834	0.792	0.834	0.832	0.844	0.890	0.866	0.880	0.645	0.877
1.1875	3.400	0.435	0.838	0.796	0.838	0.835	0.846	0.891	0.868	0.884	0.656	0.875
1.2	3.697	0.474	0.839	0.798	0.839	0.835	0.848	0.892	0.875	0.883	0.654	0.872
1.2	3.399	0.434	0.839	0.798	0.839	0.836	0.847	0.894	0.868	0.882	0.656	0.879
1.2125	3.411	0.436	0.839	0.798	0.839	0.836	0.847	0.891	0.868	0.886	0.655	0.880
1.225	3.407	0.437	0.837	0.796	0.837	0.834	0.846	0.892	0.867	0.881	0.653	0.876
1.2375	3.403	0.435	0.839	0.798	0.839	0.836	0.847	0.894	0.868	0.882	0.657	0.877
1.25	3.415	0.436	0.837	0.796	0.837	0.834	0.846	0.890	0.870	0.884	0.650	0.877
1.2625	3.430	0.437	0.835	0.792	0.835	0.831	0.842	0.890	0.859	0.884	0.645	0.877
1.275	3.444	0.441	0.839	0.798	0.839	0.836	0.847	0.891	0.871	0.884	0.655	0.881
1.2875	3.442	0.440	0.837	0.796	0.837	0.834	0.846	0.893	0.868	0.880	0.650	0.881
1.3	3.450	0.441	0.836	0.795	0.836	0.833	0.845	0.889	0.869	0.886	0.648	0.873
1.3125	3.443	0.440	0.839	0.799	0.839	0.836	0.849	0.891	0.870	0.886	0.658	0.878
1.325	3.448	0.442	0.831	0.788	0.831	0.828	0.839	0.886	0.861	0.878	0.635	0.878
1.3375	3.447	0.441	0.838	0.797	0.838	0.835	0.847	0.890	0.871	0.883	0.649	0.883
1.35	3.460	0.445	0.838	0.797	0.838	0.835	0.846	0.893	0.866	0.883	0.654	0.877
1.3625	3.444	0.441	0.835	0.793	0.835	0.832	0.844	0.886	0.866	0.884	0.651	0.875
1.375	3.438	0.438	0.839	0.798	0.839	0.836	0.848	0.892	0.869	0.884	0.655	0.880
1.3875	3.451	0.442	0.838	0.796	0.838	0.835	0.846	0.889	0.871	0.885	0.650	0.880
1.4	3.455	0.442	0.836	0.794	0.836	0.833	0.845	0.892	0.863	0.879	0.651	0.879
1.4125	3.437	0.439	0.836	0.794	0.836	0.833	0.844	0.889	0.864	0.883	0.653	0.875
1.425	3.440	0.438	0.837	0.795	0.837	0.834	0.846	0.892	0.862	0.882	0.657	0.877
1.4375	3.347	0.430	0.835	0.793	0.835	0.832	0.843	0.890	0.863	0.885	0.646	0.875
1.45	3.343	0.432	0.839	0.798	0.839	0.836	0.847	0.893	0.864	0.885	0.657	0.880
1.4625	3.345	0.429	0.834	0.792	0.834	0.831	0.843	0.888	0.866	0.881	0.644	0.874
1.475	3.343	0.428	0.837	0.796	0.837	0.834	0.846	0.892	0.864	0.883	0.654	0.879
1.4875	3.341	0.427	0.836	0.794	0.836	0.833	0.845	0.892	0.867	0.876	0.651	0.877

Table B.16: Performances and execution times for SVC Poly on different gamma values when C is 0.96 and shrinking is true

Para	Time		Metrics					f1 score for each class				
	Coef0	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
0	3.697	0.474	0.839	0.798	0.839	0.835	0.848	0.892	0.875	0.883	0.654	0.872
0.0375	3.661	0.466	0.845	0.806	0.845	0.842	0.852	0.900	0.871	0.890	0.667	0.885
0.075	3.610	0.457	0.850	0.811	0.850	0.847	0.856	0.903	0.870	0.893	0.676	0.893
0.1125	3.563	0.449	0.854	0.817	0.854	0.852	0.859	0.902	0.879	0.895	0.685	0.898
0.15	3.496	0.445	0.856	0.819	0.856	0.853	0.861	0.904	0.878	0.896	0.695	0.893
0.1875	3.465	0.443	0.851	0.813	0.851	0.848	0.856	0.901	0.875	0.897	0.677	0.891
0.225	3.430	0.434	0.854	0.817	0.854	0.851	0.859	0.901	0.880	0.899	0.688	0.889
0.2625	3.396	0.431	0.861	0.825	0.861	0.858	0.864	0.908	0.875	0.903	0.700	0.902
0.3	3.364	0.427	0.858	0.822	0.858	0.855	0.862	0.905	0.880	0.900	0.691	0.901
0.3375	3.300	0.423	0.854	0.817	0.854	0.851	0.858	0.899	0.884	0.901	0.681	0.892
0.375	3.261	0.424	0.858	0.821	0.858	0.854	0.861	0.905	0.876	0.905	0.688	0.897
0.4125	3.237	0.420	0.856	0.819	0.856	0.853	0.860	0.901	0.882	0.897	0.689	0.896
0.45	3.199	0.414	0.856	0.820	0.856	0.853	0.860	0.904	0.880	0.900	0.687	0.894
0.4875	3.179	0.415	0.853	0.816	0.853	0.850	0.857	0.904	0.874	0.898	0.683	0.894
0.525	3.161	0.412	0.853	0.816	0.853	0.850	0.857	0.901	0.877	0.899	0.680	0.894
0.5625	3.110	0.412	0.854	0.817	0.854	0.851	0.858	0.904	0.875	0.896	0.685	0.893
0.6	3.082	0.405	0.856	0.819	0.856	0.853	0.860	0.907	0.875	0.900	0.685	0.898
0.6375	3.022	0.410	0.854	0.817	0.854	0.851	0.857	0.904	0.876	0.897	0.688	0.892
0.675	3.018	0.409	0.860	0.824	0.860	0.857	0.863	0.906	0.881	0.902	0.697	0.899
0.7125	3.001	0.407	0.857	0.820	0.857	0.854	0.860	0.903	0.875	0.903	0.692	0.897
0.75	2.939	0.407	0.853	0.816	0.853	0.850	0.856	0.900	0.879	0.899	0.680	0.892
0.7875	2.884	0.401	0.857	0.820	0.857	0.853	0.859	0.905	0.880	0.896	0.690	0.894
0.825	2.840	0.398	0.855	0.818	0.855	0.852	0.859	0.904	0.877	0.899	0.688	0.892
0.8625	2.815	0.404	0.848	0.810	0.848	0.845	0.852	0.899	0.863	0.902	0.674	0.887
0.9	2.804	0.397	0.856	0.818	0.856	0.853	0.859	0.900	0.878	0.900	0.687	0.900
0.9375	2.803	0.404	0.856	0.819	0.856	0.852	0.859	0.903	0.877	0.899	0.693	0.892
0.975	2.786	0.401	0.855	0.817	0.855	0.852	0.858	0.899	0.878	0.902	0.683	0.897
1.0125	2.767	0.391	0.854	0.816	0.854	0.850	0.856	0.901	0.873	0.900	0.682	0.894
1.05	2.755	0.399	0.854	0.816	0.854	0.850	0.856	0.904	0.871	0.898	0.684	0.893
1.0875	2.737	0.394	0.857	0.820	0.857	0.854	0.861	0.902	0.880	0.899	0.697	0.891
1.125	2.724	0.393	0.851	0.813	0.851	0.847	0.854	0.903	0.872	0.896	0.679	0.885
1.1625	2.712	0.400	0.853	0.815	0.853	0.849	0.855	0.899	0.874	0.898	0.679	0.896
1.2	2.698	0.392	0.853	0.816	0.853	0.850	0.856	0.898	0.878	0.901	0.682	0.892
1.2375	2.691	0.393	0.847	0.808	0.847	0.844	0.850	0.895	0.872	0.896	0.670	0.886
1.275	2.685	0.392	0.852	0.814	0.852	0.848	0.854	0.901	0.873	0.897	0.679	0.889
1.3125	2.674	0.392	0.850	0.811	0.850	0.846	0.852	0.898	0.871	0.899	0.674	0.891
1.35	2.668	0.391	0.850	0.811	0.850	0.846	0.852	0.901	0.874	0.896	0.671	0.889
1.3875	2.653	0.390	0.850	0.812	0.850	0.847	0.853	0.901	0.871	0.897	0.678	0.889
1.425	2.657	0.386	0.852	0.814	0.852	0.849	0.855	0.901	0.868	0.903	0.680	0.892
1.4625	2.664	0.389	0.850	0.812	0.850	0.846	0.852	0.896	0.879	0.898	0.673	0.884
1.5	2.636	0.385	0.851	0.813	0.851	0.848	0.854	0.897	0.871	0.901	0.678	0.890
1.5375	2.635	0.388	0.860	0.824	0.860	0.856	0.862	0.908	0.881	0.903	0.692	0.894
1.575	2.628	0.386	0.851	0.813	0.851	0.847	0.853	0.902	0.876	0.895	0.679	0.885
1.6125	2.624	0.385	0.851	0.813	0.851	0.847	0.853	0.897	0.876	0.899	0.673	0.891
1.65	2.621	0.387	0.852	0.814	0.852	0.849	0.855	0.899	0.873	0.899	0.682	0.891
1.6875	2.616	0.387	0.856	0.819	0.856	0.853	0.858	0.901	0.883	0.898	0.689	0.891
1.725	2.614	0.383	0.847	0.808	0.847	0.843	0.849	0.898	0.865	0.897	0.671	0.886
1.7625	2.603	0.385	0.851	0.813	0.851	0.847	0.852	0.900	0.872	0.897	0.676	0.889
1.8	2.616	0.383	0.850	0.811	0.850	0.847	0.852	0.896	0.873	0.896	0.671	0.898
1.8375	2.614	0.386	0.854	0.816	0.854	0.850	0.857	0.902	0.875	0.899	0.681	0.894
1.875	2.606	0.386	0.852	0.814	0.852	0.849	0.855	0.903	0.872	0.896	0.687	0.887
1.9125	2.594	0.385	0.848	0.809	0.848	0.844	0.850	0.897	0.866	0.899	0.671	0.889
1.95	2.541	0.385	0.854	0.816	0.854	0.850	0.855	0.902	0.876	0.904	0.683	0.885
1.9875	2.543	0.383	0.849	0.810	0.849	0.845	0.851	0.900	0.869	0.896	0.676	0.885
2.025	2.545	0.379	0.846	0.806	0.846	0.843	0.848	0.898	0.869	0.895	0.661	0.890
2.0625	2.524	0.379	0.853	0.816	0.853	0.850	0.856	0.898	0.881	0.900	0.681	0.890
2.1	2.490	0.383	0.849	0.810	0.849	0.845	0.851	0.901	0.870	0.894	0.671	0.888
2.1375	2.475	0.378	0.848	0.809	0.848	0.843	0.849	0.899	0.866	0.898	0.665	0.889
2.175	2.469	0.383	0.845	0.806	0.845	0.842	0.847	0.896	0.868	0.893	0.664	0.887
2.2125	2.472	0.389	0.853	0.816	0.853	0.850	0.855	0.897	0.878	0.904	0.683	0.885
2.25	2.455	0.382	0.850	0.811	0.850	0.846	0.851	0.903	0.870	0.893	0.672	0.891
2.2875	2.449	0.379	0.853	0.815	0.853	0.849	0.855	0.900	0.879	0.901	0.677	0.888
2.325	2.430	0.387	0.848	0.809	0.848	0.845	0.851	0.897	0.872	0.896	0.671	0.889
2.3625	2.426	0.384	0.849	0.810	0.849	0.845	0.851	0.898	0.873	0.896	0.670	0.889
2.4	2.426	0.379	0.844	0.805	0.844	0.840	0.848	0.898	0.865	0.889	0.663	0.887
2.4375	2.418	0.383	0.845	0.806	0.845	0.841	0.848	0.896	0.872	0.894	0.661	0.883
2.475	2.423	0.377	0.848	0.809	0.848	0.844	0.849	0.896	0.878	0.893	0.669	0.882
2.5125	2.395	0.384	0.848	0.809	0.848	0.844	0.850	0.899	0.871	0.896	0.667	0.888
2.55	2.411	0.380	0.845	0.805	0.845	0.842	0.848	0.893	0.874	0.896	0.661	0.885
2.5875	2.416	0.385	0.844	0.804	0.844	0.840	0.846	0.896	0.868	0.895	0.658	0.884
2.625	2.402	0.381	0.847	0.808	0.847	0.844	0.850	0.892	0.877	0.899	0.671	0.881
2.6625	2.395	0.379	0.847	0.808	0.847	0.844	0.850	0.898	0.872	0.892	0.675	0.882
2.7	2.396	0.377	0.849	0.810	0.849	0.845	0.850	0.900	0.874	0.896	0.670	0.883
2.7375	2.373	0.378	0.848	0.809	0.848	0.844	0.849	0.897	0.871	0.898	0.666	0.886
2.775	2.358	0.381	0.850	0.811	0.850	0.845	0.851	0.901	0.872	0.893	0.672	0.888
2.8125	2.342	0.378	0.851	0.813	0.851	0.847	0.852	0.900	0.877	0.895	0.676	0.886
2.85	2.353	0.377	0.848	0.809	0.848	0.844	0.850	0.895	0.869	0.899	0.674	0.884
2.8875	2.349	0.380	0.844	0.804	0.844	0.840	0.846	0.896	0.866	0.894	0.658	0.887
2.925	2.343	0.379	0.849	0.810	0.849	0.846	0.852	0.896	0.874	0.901	0.669	0.888
2.9625	2.321	0.374	0.846	0.807	0.846	0.842	0.848	0.897	0.872	0.893	0.663	0.885

Table B.17: Performances and execution times for SVC Poly on different Coef0 values when Gamma is 1.2, c is 0.96 and shrinking is true

B.4.2 All Application Results

Tottenhams Harry Winks sørget for seier etter overtidsdrama.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikk seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexander Mitrovic dratt ned i feltet av Jan Verthongen.

Claudio Ranieris menn fortsette å presse Tottenham, og etter nytt hjørnespark satte Harry Kanes erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Etter 72 minutter kokte det over for Mitrovic og Sánchez. Begge kamphanene hadde ved flere anledninger hakket på hverandre, og i denne situasjonen dro de hverandre ned i bakken. Begge ble straffet med gult kort.

På overtid svingte innbytter Nkoudou ballen inn i feltet der Harry Winks headet ballen i mål i siste minutt av overtiden. Dermed vant Tottenham 2-1 på Craven Cottage.

Tottenham uten Harry Kane (skadet) og Heung-Min Son (Asiamesterskapet) slet lenge mot Fulham. Fernando Llorente, som erstattet Kane, satte ballen i eget mål etter et kvarter.

Spurs løftet seg etter pause - kampen avgjort på straffesparkkonkurranse Like etter pause reduserte Tottenham. Harry Kane-erstatteren Fernando Llorente headet inn 1-2- reduseringen seks minutter ut i omgangen, og dermed trengte Tottenham kun ett mål for å ta seg videre til ligacupens finale.

Christian Eriksen scoret sikkert på Tottenhams første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenhams andre straffespark.

Azpilicueta satte 2-2 for Chelsea. Så blåste Eric Dier ballen over for Tottenham, og Chelsea var i førerretet. Jorginho satte arrogant inn 3-2-ledelse med et frekt straffespark.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.

Tottenham styrte mye av banespillet, men slet med å komme til de store sjansene. Der var Fulham farligere. Ryan Babel var nær å doble ledelsen fem minutter før pause. Hodestøtet fra fem meter gikk over mål.

Fulham skapte enda mer. To minutter senere la Babel inn til Andre Schurrle som banket til på hel volley fra kort avstand. Lloris vartet opp med en mesterlig redning, men ballen endte hos Mitrovic som headet ballen i mål. Serberen var imidlertid i offside og scoringen ble annullert.

I andreomgang slo Tottenham tilbake. Seks minutter ut i omgangen slo Christian Eriksen et perfekt innlegg til Dele Alli som headet ballen i mål fra kloss hold. 1-1 og kamp igjen på Craven Cottage.

Fernando Llorente fikk den store sjansen til å bli helten igjen for Tottenham. Med ti minutter igjen slo Eriksen et frispark inn i feltet. Ballen skled av hodet til spanjolen og like utenfor mål. Til Llorente og Tottenham-fansens store fortvilelse.

Dier bommet for Spurs N'golo Kanté og Eden Hazards scoret målene for Chelsea på Stamford Bridge, mens Tottenhams reduseringsmål ble satt inn av Fernando Llorente.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Midtbanespilleren dundret løs fra 16 meters hold. Ballen føk gjennom beina på et par Spurs-spillere, og i mål via Tottenhams keeper Paolo Gazzaniga. Paolo Gazzaniga fikk tillit fra start på bekostning av Hugo Lloris.

Figure B.29: SVC Poly application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

– Gazzaniga hadde ingen sjanse og det var virkelig et mål med klasse av hjemmelaget. Det der er smart fotball. De angrep raskt og avsluttet vidunderlig, beskrev Andy Townsend etter scoringen som sørget for at Chelsea kunne gå til pause med 2-0.

Son, som også scoret i midtukekampen mot Watford, har nå scoret i begge kampene etter sin hjemkomst fra Asiamesterskapet.

Angriperen fyrte løs fra 18 meter. Skuddet gikk rett Martin Dubravka, men keeperen klarte ikke å stoppe skuddet.

Scoringen gjorde at Spurs nok en gang dro i land en seier i sluttminuttene. Det betyr at Tottenham nå er oppe på en andreplass, men med én kamp mer spilt enn Manchester City.

Midtveis i omgangen var det Erik Lamela som fikk en sjanse. Innlegget fra Jan Vertonghen var av det presise slaget, men headingen fra Lamela var akkurat ikke god nok. Ballen smalt i tverliggeren. Returen falt til Moura, men heller ikke denne gang traff angriperen mål.

Slik var kampen Det var Tottenham som var nærmest scoring i den første omgangen. Lucas Moura fikk en enorm mulighet etter et kvarter, men brasilianerens heading gikk utenfor mål.

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvspretten etter en corner som ble svakt halvklarert.

Tidlig i andre omgang økte Mohamed Salah til 2-0 fra straffemerket etter at han selv ble dratt i armen av Paul Dummett. Straffen var likevel billig, og Salah blir fra flere holdt beskyldt for å filme. Uansett var det svakt av Dummett å bruke armen i duellen, og straffen satte Salah sikkert forbi keeper Martin Dúbravka.

På tampen ordnet Xherdan Shaqiri 3-0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4-0.

Men etter pause hevet Tottenham seg, og Fernando Llorente utlignet den sammenlagte ledelsen rett etter pause med et kontant hodestøt.

I straffesparkkonkurransen scoret Willian, Azpilicueta, Jorginho og David Luiz, mens Eric Dier banket ballen langt opp på tribunen, og Lucas Moura rett i fanget på Kepa, dermed hjalp det lite at Christian Eriksen og Erik Lamela scoret på de to første forsøkene.

Chelsea til ligacupfinale etter straffeseier

N'Golo Kanté banket inn 1-0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2-0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Nytt stolpetreff Rondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frempå igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut.

Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Først vant Llorente duellen, før Son dro seg fri og sendte i vei et skudd fra 18 meter. Skuddet gikk rett på Dubravka, men keeperen klarte likevel ikke å stoppe det.

Heung-min Son sørget for tre Tottenham-poeng med sen scoring.

Newcastle var på vei mot nok et knuttsterkt resultat mot et topplag, men Heung-min Son ville det annerledes. Med åtte minutter igjen av ordinær tid scoret sørkoreaneren sitt tiende ligamål for sesongen.

Tottenham knuste Bournemouth 5-0, og tok over annenplassen på tabellen – seks poeng bak Liverpool. Mauricio Pochettinos lag har scoret vanvittige 11 mål på få dager, etter 6-2-seieren borte mot Everton lille julaften.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

Bernardo Silva sendte Manchester City i ledelsen, men Marc Albrighton og Ricardo Pereira scoret i hver sin omgang og sørget for 2-1-seier til Leicester. Vinnermålet til Pereira var et herlig langskudd, og Fabian Delph pådro seg rødt kort på tampen av kampen.

Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.

Figure B.30: SVC Poly application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.
- Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.
- Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.
- Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.
- Det er en fantastisk følelse. I den første omgangen kunne vi scoret tre eller fire. Vi kontrollerte kampen også etter pause. Spurs fikk sin mulighet, og scoret. Reaksjonen til spillerne og viljen vi viste gjør meg svært glad. For det var frustrerende at vi risikerte å tape på straffer etter å kontrollert kampen fullstendig. I straffesparkkonkurranser vet man aldri hva som skjer. Men laget gjorde det strålende. Vi skapte mange sjanser og presset Tottenham hele kampen, sa Chelseas straffeheft David Luiz til Sky Sports etter kampen.
- Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
- Han har vært en av Newcastle's beste spillere denne sesongen. Han har reddet laget så mange ganger. Det er brutalt, sier TV 2-kommentator Endre Olav Osnes.
- Chelsea har vært et av de mest suksessrike lagene i England de siste årene. Å vinne titler er det eneste som gjelder i denne klubben, så vi er glade for å være i finalen, oppsummerte Chelsea-kaptein Cesar Azpilicueta til Viasat 4.
- Det er deilig å se spillere leke fotball på den måten, sa Ronny Deila om Jorginhos arrogante straffe, hvor midtbanespilleren ventet ut keeper og trillet ballen nonchalant i mål.
- Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.
- Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange troféer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.
- Jeg bryr meg ikke. Jeg spiller bare fotball. Det har ingenting å si hva manageren sier, jeg fokuserer bare på fotballen og vil gjøre det best mulig for laget, svarte Hazard på spørsmål om hva han mente om Sarris kritikk.
- Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
- Vi vant mot dem på Wembley. De slo oss her. Jeg foretrekker å tape på straffer fremfor etter fulltid. Gratulerer til Chelsea. Nå skal vi gjøre alt og være klar for FA-cupkampen mot Crystal Palace på søndag, sa Tottenhams suksessjef etter kampen.
- Det er en stor, stor sjanse, men headingen er ikke i nærheten av god nok, sa Trevor Morley.
- Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.
- Både City og Liverpool sviktet i forrige runde. Nå starter Tottenham denne helgen med å vinne. Det er tre lag som kjemper om tittelen nå, sier Osnes.
- Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på at de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betyde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.
- Tottenham er i kjempeform nå, og er i form. Chelsea vil trolig vinne mye fremover, Arsenal vil vinne og dette blir et race til siste dag. Vi er med i racet, og det er det aller viktigste, la han til.

Figure B.31: SVC Poly application results on the "Quotes" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.</p> <p>Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.</p> <p>Fulham var flere ganger frempå og skapte problemer på tampen av omgangen. Ranieris menn ledet fortjent 1-0 til pause.</p> <p>Minuttet senere skjedde det som Tottenham-fansen fryktet. Dele Alli jaget en ball ut mot sidelinjen og i forsøket på å nå ballen holdt 22-åringen seg til hamstringen og måtte legge seg ned utenfor banen. Engelskmannen klarte ikke å komme seg på beina igjen og ble byttet ut. Alli så tydelig preget ut på benken etter byttet.</p> <p>– Vidunderlig fotball av Chelsea Etter en tett og jevn start på kampen presenterte N'golo Kanté seg etter 27 minutters spill.</p> <p>I det 38. minutt viste Chelsea frem vidunderlig fotball. Eden Hazard startet det vakre angrepet, og avsluttet selv i boksen. Plutselig stod det 2-0 og Chelsea stormet mot en ny cupfinale.</p> <p>Tottenham skapte en rekke sjanser det siste kvarteret. Chelsea skapte også sine sjanser og hadde ingen planer om å parkere bussen.</p> <p>Flere scoringer ble det imidlertid ikke i kampen, og kampen måtte avgjøres på straffer.</p> <p>Ti minutter før slutt måtte forøvrig Tottenhams Moussa Sissoko gi seg på grunn av skade. Davinson Sánchez kom inn. Skadeproblemene fortsetter dermed for Tottenham.</p> <p>Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.</p>	<p>Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.</p> <p>Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.</p> <p>Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren.</p> <p>Hazard: – Jeg bryr meg ikke Maurizio Sarri kritiserte som kjent Chelsea-spillerne etter 0-2-tapet mot Arsenal i Premier League. Manageren sa blant annet at Hazard ikke var en leder på banen.</p> <p>Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.</p> <p>Tottenhams manager Mauricio Pochettino hevdet at han ikke var særlig skuffet etter nederlaget.</p> <p>Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.</p> <p>Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.</p> <p>Slik startet lagene:</p> <p>Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.</p> <p>Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente.</p> <p>Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.</p> <p>Dommer: Martin Atkinson, West Yorkshire</p> <p>Chelsea til finale etter seier mot Tottenham i straffesparkkonkurranse</p>
---	--

Figure B.32: SVC Poly application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Maurizio Sarri øyner sitt første trofé som manager for Chelsea etter at blåtrøyene slo Tottenham på straffer torsdag kveld.</p> <p>Sissoko prøvde seg med et brukbar volleyforsøk kort tid før pause, men Dubravka stoppet skuddet. Dermed gikk lagene til pause på 0-0.</p> <p>Det var det som skulle til for at Spurs dro i land nok en sen seier på eget gress. Resultatet gjør at Tottenham nå har sneket seg forbi Manchester City, riktignok med én kamp mer spilt.</p> <p>Hjemvendte Son reddet dagen for Spurs</p> <p>For øyeblikket bunnsolide Liverpool gikk sin 30. strake hjemmekamp i ligaen uten tap. Selv om farlig utsatte Newcastle hang med lenge, så ble det stygge sifre til slutt. Den antatt argeste gullrivalen, Manchester City, ligger nå syv poeng bak.</p> <p>Sist Liverpool tapt en ligakamp på Anfield, var da Crystal Palace vant 2-1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seire. Denne sesongen har det blitt bare seire, med unntak av 0-0-kampen mot Manchester City.</p> <p>For nå er det syv poeng ned til Manchester City, som snublet igjen.</p> <p>For få dager siden tapte de 2-3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.</p> <p>Mål: 0-1 Pierre-Emerick Aubameyang (7), 1-1 Jürgen Locadia (35).</p> <p>Det ble klart etter seier i straffesparkkonkurranse mot Tottenham torsdag kveld.</p> <p>I returoppgjøret mot Tottenham i Ligacupen fikk han svar på tiltale.</p>	<p>PS! Førstkommende lørdag spiller Tottenham hjemme mot Wolverhampton, og Liverpool får besøk av Arsenal. Manchester City spiller borte mot Southampton søndag.</p> <p>Mål: 1-0 Nemanja Matic (28), 2-0 Paul Pogba (64), 3-0 Pogba (78), 3-1 Mathias Jørgensen (88).</p> <p>Mål: 1-0 Christian Eriksen (16), 2-0 Son Heung-min (23), 3-0 Lucas Moura (35), 4-0 Harry Kane (61), 5-0 Son (70).</p> <p>Dommer: Anthony Taylor, England.</p> <p>(Liverpool-Newcastle 4-0, Leicester – Manchester City 2-1) Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.</p> <p>I finalen venter Manchester City. Seier vil bety Sarris første trofé som Chelsea-manager. Mauricio Pochettino derimot må vente enda lenger på sitt første som Tottenham-sjef.</p> <p>Finalen spilles på Wembley siste helgen i februar.</p> <p>(Chelsea - Tottenham 2-1, 2-2 sammenlagt, 6-4 etter straffer) Kun Pep Guardiola og Manchester City står mellom Maurizio Sarri og hans første trofé som Chelsea-manager.</p> <p>Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.</p>
--	--

Figure B.33: SVC Poly application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Tottenham seiret etter overtidsdrama	Mål: 0-1 Yerry Mina (2), 0-2 Lucas Digne (13), 0-3 Gylfi Sigurdsson (str. 22), 1-3 Ben Gibson (37), 1-4 Digne (72), 1-5 Richarlison (90).
Se seiersmålet og høydepunktene i videovinduet øverst!	
Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):	21.484 tilskuere.
Se sammendrag i Sportsnyhetene øverst!	Crystal Palace – Cardiff 0-0
Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.	25.206 tilskuere
Tottenham - Newcastle 1-0	Fulham – Wolverhampton 1-1 (0-0)
Se scoringen i videovinduet øverst!	Mål: 1-0 Ryan Sessegnon (74), 1-1 Romain Saïss (85).
Live: Brighton tok poeng mot Arsenal - referat fra dagens runde	24.382 tilskuere.
Burnley – Everton 1-5 (1-3)	Leicester – Manchester C. 2-1 (1-1)
	Mål: 0-1 Bernardo Silva (14), 1-1 Marc Albrighton (19), 2-1 Ricardo Pereira (81).
32.090 tilskuere.	Gult kort: Martin Montoya (45), Glenn Murray (58), Brighton, Sead Kolasinac (81), Arsenal.
Rødt kort: Fabian Delph (89), Manchester C.	Senere kampstart: Watford – Chelsea 20.30.
Liverpool – Newcastle 4-0 (1-0)	Mål: 1-0 Dejan Lovren (11), 2-0 Mohamed Salah (str. 48), 3-0 Xherdan Shaqiri (79), 4-0 Fabinho (85).
53.318 tilskuere.	
Manchester U. – Huddersfield 3-1 (1-0)	
74.523 tilskuere.	
Tottenham – Bournemouth 5-0 (3-0)	
45.154 tilskuere.	
Joshua King spilte 16 minutter som innbytter for Bournemouth.	
Brighton – Arsenal 1-1 (1-1)	
30.608 tilskuere	

Figure B.34: SVC Poly application results on the "Ignore" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt.</p>	<p>Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.</p>
<p>Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham.</p>	<p>Angrepene fra hjemmelaget kom som perler på snor utover, og Morata burde økt ledelsen til Chelsea etter 58 minutter, men på åpent mål presterte spissen å skyte over.</p>
<p>Etter halvtimen spilt sendte Zappacosta ballen til Ruben Loftus-Cheek som ventet innenfor Nottinghams 16-meter. Chelsea-midtbanemann ble taklet så det sang av Danny Fox, og Chelsea ble tildelt et soleklart straffespark.</p>	<p>Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøket angrep av samme duo som lagde 1-0 målet.</p>
<p>Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene.</p>	<p>Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.</p>
<p>Callum Hudson-Odoi la inn foran mål hvor Morata ventet. Etter flere forsøk satt den endelig for Chelsea-spissen, og hjemmelaget ledet 1-0.</p>	<p>Antoine Griezmann er storklubbens toppscorer med ti mål i serien. Bak ham har ingen scoret mer enn to. Blant dem som har slitt, er tidligere Chelsea-stjerne Diego Costa. Spansk-brasilianeren har bare funnet nettmaskene én gang i ligasammenheng.</p>
<p>Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben.</p>	<p>Sarri ønsket Higuaín inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuaín.</p>
<p>Men den siste sesongene har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjelte spissen scoret begge.</p>	<p>Huddersfield-kampen forrige helg, der Higuaín scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.</p>
<p>Higuaín kommer til Chelsea med et rykte som en notorisk målscorer. Kun fem spillere har scoret mer enn argentineren i topp fem-ligaene siden starten av 2006/07-sesongen.</p>	<p>Morata misbrukte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.</p>
<p>I Chelsea er Higuaín gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong.</p>	<p>Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.</p>
<p>Sparket fra ellevemetersmerket burde nok blitt tatt opp igjen, da en hel haug av spillere fra både Nottingham Forest og Chelsea var innenfor 16-meteren før Fabregas' avslutning:</p>	
<p>Men da en spanjol mislykkes, var det en annen som fikk det til – etter noen forsøk.</p>	
<p>Bare når ettertraktede Callum Hudson-Odoi serverte fra høyre fikk Morata til å score. Først med en tap-in, deretter med et pent hodestøt, hvor han knuste Claudio Yacob i luften.</p>	

Figure B.35: SVC Poly application results on the "Goal/Assist" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.</p> <p>Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.</p> <p>Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombuddet for Arsenal som tenåring.</p> <p>Chelsea-spiss klar for La Liga-gigant</p> <p>Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.</p> <p>Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.</p> <p>Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.</p> <p>Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.</p> <p>Watford føler seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.</p> <p>Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.</p> <p>Fotballryktene: – Morata bare timer unna overgang</p> <p>Med sommerens signering av Jorginho, og Higuain inn i januarvinduet, har Sarri hentet inn to viktige brikker fra tiden sin i Napoli, som vet hvordan italieneren ønsker å spille.</p> <p>Siden Roman Abramovitsjs inntog i Chelsea har stjernespissene vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuain.</p> <p>Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.</p>	<p>Álvaro Morata (26) lånes ut fra Chelsea til Atlético Madrid.</p> <p>Alvaro Morata er nær ved å forlate Chelsea. Her er dagens fotballykter!</p> <p>Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.</p> <p>Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.</p> <p>Det ser ut til at den spanske midtbanespilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalene med Arsenal gikk i stå, skriver ESPN.</p> <p>PSG har vært koblet til Evertons midtbanespiller Idrissa Gueye en stund. Ifølge Liverpool Echo har de imidlertid ikke lagt inn noe formelt bud enda.</p> <p>Chelsea har lenge vært koblet til Zenits argentinske midtbanespiller Leandro Paredes, men nå har Paris Saint-Germain seilet opp som favoritt til å signere 24-åringen, skriver The Telegraph.</p> <p>Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter waliserens landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasseklubb» som Juventus, skriver Sky Sports.</p> <p>Chelsea har en lang tradisjon for å hente stjernespiss, men få har levd opp til forventningene på Stamford Bridge.</p> <p>Siden den gang har Higuain spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuain, og ikke den som mislykkes i Milano.</p>
--	--

Figure B.36: SVC Poly application results on the "Transfer" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.
- Utfordringen er at Chelsea har vinger som liker å føre ballen langt inn i banen, og da har Higuain ofte allerede løpt i offside før pasningen kommer, sier Vinje.
- Jeg har mer troa etter kampen mot Huddersfield. Han er jo en målscore, men han har slitt denne sesongen. Spørsmålet er om Chelsea får den Higuain som scoret 36 ligamål på en sesong i Napoli, eller den som slet i Milan denne sesongen.
- Det er denne rekken Higuain nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.
- Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Blir han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.
- Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.
- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.
- Det er en av de to-tre vanskeligste kampene som er. Men toppkamper lever sitt eget liv, og Chelsea har ofte vært bedre borte mot topplagene enn mot de antatt svakere lagene.
- Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.
- Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:
- Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.

Figure B.37: SVC Poly application results on the "Quotes" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Chelsea-stjerne forlot banen i tårer	Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.
Chelsea - Nottingham Forest 2-0 (0-0)	
Chelsea hadde stort sett kontroll på Nottingham Forest i FA-cupens tredje runde. Men det var duoen Álvaro Morata og Callum Hudson-Odoi som utgjorde forskjellen i 2-0 seieren.	Etter drøye timen spilt begynte sjansene å bli større for Nottingham. Nærmest redusering var Joe Lolley, men spissen måtte nøye seg med nettveggen denne gang.
Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.	Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.
Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.	Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fàbregas farvel med engelsk fotball.
Mot slutten av omgangen viste Nottingham mer selvtilitt og utfordret Chelsea. Noen helt store sjanser ble det ikke, men etter å ha tilbragt store deler av omgangen på egen banehalvdel, var det i hvert fall et steg i riktig retning for gjestene.	- Med det blikket for spillet og timingen på pasningene, er han unik i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.
Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.	Thorstvedt mener likevel Higuain-overgangen var en sårt tiltrent forsterkning i Chelsea-stallen.
Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.	Higuain fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.
Hans nye klubb ligger på andreplass i La Liga, fem poeng bak Barcelona. Som Sarri, har Atlético Madrid-manager Diego Simeone slitt med å få angrepsspillerne til å score.	På søndag møter en meget tøff utfordring for Higuain og Chelsea, når de gjester Manchester City på Etihad. Supporterleder Vinje forventer en svært tøff kamp mot de regjerende mesterne.
Spillere som Andriy Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Álvaro Morata, har ikledd seg den blå drakten uten nevneverdig suksess.	- Higuain kan ikke bare måles på antall scoringer
Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.	- I Jorginho og Higuain har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.
Chelsea vant kampen 2-0, og fansen tok dermed ikke farvel med FA-cupen.	Hudson-Odoi - som jaktes av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.
De tok imidlertid trolig farvel med den spanske midtbanespilleren Cesc Fàbregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.	Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.
Det var dermed passende at Maurizio Sarri ga Fabregas kapteinsbindet, men det ble ingen fantastisk avskjed for Fabregas – selv om det kunne blitt det.	Utskjelte Morata sendte Chelsea videre da Fabregas tok farvel med Stamford Bridge
Vondt ble til verre for Fabregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.	(Chelsea – Nottingham Forest 2-0) Cesc Fàbregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.
Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.	

Figure B.38: SVC Poly application results on the "Irrelevant" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

B.5 RNN

B.5.1 Ful Tables from Training Experiments

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	11.146	0.481	0.861	0.826	0.861	0.860	0.867	0.879	0.854	0.982	0.688	0.896
16	11.366	0.484	0.859	0.823	0.859	0.858	0.867	0.876	0.855	0.982	0.683	0.894
19	11.364	0.487	0.862	0.828	0.862	0.862	0.870	0.877	0.868	0.980	0.684	0.899
22	11.473	0.480	0.870	0.837	0.870	0.869	0.876	0.884	0.875	0.983	0.704	0.899
25	11.391	0.487	0.858	0.823	0.858	0.858	0.867	0.872	0.861	0.977	0.687	0.891
28	11.441	0.485	0.865	0.831	0.865	0.865	0.875	0.877	0.873	0.978	0.704	0.891
31	11.628	0.480	0.863	0.828	0.863	0.862	0.873	0.885	0.860	0.982	0.696	0.886
34	11.658	0.488	0.869	0.836	0.869	0.867	0.875	0.888	0.871	0.981	0.705	0.892
37	12.071	0.476	0.867	0.833	0.867	0.864	0.871	0.890	0.861	0.979	0.706	0.884
40	13.161	0.489	0.860	0.825	0.860	0.860	0.870	0.873	0.858	0.981	0.698	0.887
43	13.234	0.476	0.872	0.840	0.872	0.870	0.877	0.895	0.869	0.980	0.714	0.894
46	13.786	0.493	0.874	0.842	0.874	0.872	0.878	0.890	0.880	0.980	0.715	0.896
49	13.248	0.489	0.873	0.841	0.873	0.871	0.879	0.893	0.872	0.979	0.720	0.890
52	13.875	0.483	0.871	0.839	0.871	0.870	0.877	0.888	0.875	0.975	0.716	0.895
55	12.788	0.485	0.876	0.844	0.876	0.873	0.879	0.900	0.875	0.979	0.715	0.894
58	13.134	0.504	0.869	0.836	0.869	0.868	0.876	0.883	0.873	0.976	0.717	0.890
61	11.915	0.474	0.874	0.842	0.874	0.871	0.876	0.895	0.881	0.978	0.720	0.879
64	11.593	0.468	0.867	0.834	0.867	0.865	0.874	0.890	0.867	0.979	0.708	0.881
67	12.031	0.473	0.869	0.835	0.869	0.866	0.873	0.891	0.867	0.978	0.708	0.887
70	11.917	0.469	0.870	0.838	0.870	0.868	0.877	0.892	0.869	0.980	0.714	0.886
73	12.094	0.475	0.873	0.841	0.873	0.870	0.877	0.888	0.881	0.980	0.710	0.890
76	11.748	0.456	0.874	0.842	0.874	0.871	0.878	0.892	0.880	0.978	0.725	0.882
79	12.073	0.464	0.875	0.844	0.875	0.873	0.882	0.896	0.872	0.980	0.721	0.897
82	12.031	0.462	0.861	0.826	0.861	0.858	0.870	0.884	0.856	0.974	0.694	0.885
85	12.099	0.459	0.868	0.835	0.868	0.865	0.874	0.893	0.874	0.969	0.709	0.879
88	12.393	0.474	0.874	0.842	0.874	0.871	0.879	0.897	0.872	0.980	0.730	0.877
91	12.361	0.462	0.873	0.840	0.873	0.869	0.877	0.891	0.880	0.979	0.712	0.886
94	12.342	0.459	0.870	0.838	0.870	0.869	0.877	0.890	0.870	0.977	0.716	0.890
97	13.409	0.488	0.871	0.838	0.871	0.867	0.873	0.886	0.877	0.980	0.708	0.886
100	14.296	0.486	0.862	0.828	0.862	0.860	0.870	0.887	0.851	0.978	0.699	0.886
103	15.031	0.482	0.875	0.843	0.875	0.871	0.877	0.894	0.877	0.978	0.724	0.882
106	15.016	0.490	0.866	0.832	0.866	0.863	0.871	0.880	0.878	0.976	0.701	0.879
109	15.115	0.490	0.874	0.843	0.874	0.872	0.879	0.892	0.878	0.980	0.730	0.880
112	14.673	0.489	0.869	0.837	0.869	0.866	0.876	0.893	0.866	0.975	0.711	0.887
115	15.392	0.486	0.873	0.841	0.873	0.870	0.877	0.889	0.874	0.977	0.726	0.885
118	15.036	0.501	0.870	0.838	0.870	0.868	0.877	0.888	0.874	0.983	0.706	0.887
121	15.321	0.486	0.872	0.839	0.872	0.869	0.876	0.880	0.884	0.979	0.714	0.887
124	14.945	0.492	0.873	0.840	0.873	0.870	0.877	0.896	0.869	0.976	0.720	0.887
127	15.397	0.483	0.870	0.837	0.870	0.866	0.875	0.894	0.871	0.977	0.707	0.882
130	15.344	0.499	0.870	0.837	0.870	0.866	0.873	0.892	0.876	0.977	0.712	0.872
133	15.235	0.494	0.870	0.837	0.870	0.865	0.872	0.885	0.875	0.977	0.702	0.888
136	15.007	0.487	0.861	0.828	0.861	0.860	0.872	0.878	0.862	0.973	0.710	0.877
139	15.601	0.486	0.869	0.836	0.869	0.866	0.875	0.888	0.874	0.976	0.711	0.882
142	15.632	0.492	0.866	0.832	0.866	0.864	0.873	0.878	0.874	0.974	0.717	0.880
145	15.555	0.499	0.868	0.835	0.868	0.865	0.874	0.883	0.878	0.980	0.714	0.871
148	15.229	0.482	0.871	0.838	0.871	0.868	0.874	0.896	0.866	0.977	0.717	0.882
151	15.758	0.490	0.861	0.827	0.861	0.859	0.868	0.887	0.851	0.977	0.693	0.884
154	15.540	0.494	0.868	0.835	0.868	0.866	0.873	0.885	0.870	0.977	0.715	0.881
157	15.444	0.493	0.876	0.845	0.876	0.873	0.881	0.893	0.886	0.977	0.732	0.879
160	15.440	0.499	0.861	0.827	0.861	0.859	0.872	0.881	0.854	0.978	0.705	0.878
163	15.808	0.492	0.869	0.836	0.869	0.866	0.871	0.896	0.865	0.979	0.704	0.884
166	15.750	0.483	0.868	0.834	0.868	0.865	0.874	0.885	0.873	0.976	0.714	0.879
169	15.839	0.496	0.875	0.844	0.875	0.873	0.881	0.899	0.873	0.977	0.729	0.885
172	15.807	0.484	0.864	0.831	0.864	0.861	0.870	0.885	0.872	0.973	0.701	0.874
175	16.059	0.486	0.874	0.842	0.874	0.871	0.878	0.890	0.887	0.979	0.715	0.885
178	16.131	0.493	0.869	0.836	0.869	0.865	0.873	0.884	0.872	0.976	0.711	0.884
181	15.894	0.499	0.871	0.838	0.871	0.868	0.875	0.894	0.868	0.978	0.707	0.893
184	15.821	0.491	0.864	0.830	0.864	0.861	0.870	0.891	0.860	0.976	0.702	0.877
187	16.258	0.500	0.870	0.837	0.870	0.868	0.876	0.889	0.876	0.979	0.721	0.873
190	16.074	0.498	0.869	0.835	0.869	0.865	0.870	0.884	0.873	0.974	0.705	0.890
193	16.323	0.503	0.863	0.829	0.863	0.859	0.866	0.877	0.873	0.978	0.692	0.876
196	15.964	0.490	0.870	0.837	0.870	0.867	0.876	0.890	0.872	0.977	0.718	0.879
199	16.291	0.495	0.869	0.836	0.869	0.866	0.874	0.879	0.877	0.977	0.721	0.876
202	16.371	0.494	0.863	0.828	0.863	0.860	0.867	0.879	0.874	0.972	0.700	0.874
205	16.192	0.506	0.873	0.841	0.873	0.871	0.878	0.884	0.881	0.977	0.722	0.894
208	16.209	0.499	0.862	0.829	0.862	0.861	0.871	0.862	0.877	0.977	0.697	0.889
211	16.539	0.489	0.870	0.838	0.870	0.867	0.875	0.892	0.876	0.974	0.713	0.881
214	16.303	0.492	0.871	0.838	0.871	0.868	0.874	0.886	0.875	0.975	0.710	0.892
217	16.507	0.496	0.865	0.831	0.865	0.861	0.867	0.883	0.872	0.976	0.693	0.881
220	16.178	0.498	0.864	0.830	0.864	0.861	0.868	0.871	0.875	0.978	0.700	0.883
223	16.357	0.481	0.875	0.842	0.875	0.871	0.876	0.894	0.881	0.976	0.719	0.883
226	16.409	0.493	0.868	0.835	0.868	0.866	0.875	0.891	0.867	0.976	0.714	0.881
229	16.758	0.493	0.865	0.831	0.865	0.862	0.871	0.885	0.868	0.973	0.702	0.882
232	16.488	0.490	0.872	0.839	0.872	0.869	0.875	0.880	0.884	0.979	0.717	0.886
235	15.194	0.468	0.864	0.830	0.864	0.861	0.871	0.888	0.853	0.977	0.708	0.878
238	15.191	0.466	0.864	0.830	0.864	0.861	0.867	0.882	0.866	0.976	0.699	0.881
241	15.217	0.470	0.861	0.827	0.861	0.857	0.866	0.884	0.858	0.976	0.687	0.879
244	15.083	0.466	0.861	0.826	0.861	0.857	0.866	0.884	0.848	0.974	0.699	0.879
247	15.446	0.465	0.859	0.823	0.859	0.854	0.863	0.888	0.850	0.974	0.684	0.875

Table B.18: Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 256

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
10	11.837	0.434	0.855	0.819	0.855	0.856	0.865	0.869	0.853	0.982	0.671	0.903
13	12.286	0.457	0.860	0.824	0.860	0.858	0.866	0.881	0.858	0.982	0.674	0.894
16	12.522	0.462	0.850	0.816	0.850	0.850	0.869	0.824	0.861	0.981	0.683	0.900
19	12.666	0.455	0.867	0.835	0.867	0.867	0.875	0.884	0.866	0.981	0.701	0.903
22	12.384	0.464	0.858	0.823	0.858	0.856	0.867	0.884	0.851	0.977	0.684	0.886
25	12.846	0.457	0.868	0.835	0.868	0.867	0.875	0.887	0.866	0.982	0.712	0.889
28	12.525	0.456	0.852	0.817	0.852	0.850	0.867	0.884	0.815	0.981	0.684	0.885
31	12.651	0.464	0.873	0.841	0.873	0.871	0.879	0.895	0.869	0.980	0.717	0.894
34	12.759	0.449	0.874	0.841	0.874	0.871	0.877	0.896	0.874	0.981	0.709	0.892
37	12.716	0.460	0.874	0.843	0.874	0.872	0.880	0.892	0.877	0.977	0.719	0.895
40	12.951	0.450	0.872	0.839	0.872	0.870	0.876	0.887	0.880	0.979	0.710	0.894
43	12.931	0.456	0.864	0.831	0.864	0.862	0.872	0.881	0.865	0.978	0.692	0.892
46	13.006	0.457	0.874	0.842	0.874	0.871	0.878	0.897	0.871	0.981	0.718	0.889
49	12.946	0.442	0.871	0.839	0.871	0.869	0.876	0.884	0.879	0.981	0.713	0.888
52	13.237	0.446	0.876	0.845	0.876	0.874	0.882	0.888	0.886	0.980	0.728	0.890
55	13.078	0.449	0.875	0.844	0.875	0.874	0.882	0.895	0.877	0.977	0.726	0.895
58	12.822	0.453	0.870	0.838	0.870	0.869	0.877	0.888	0.868	0.975	0.728	0.884
61	13.307	0.463	0.865	0.831	0.865	0.864	0.871	0.882	0.867	0.974	0.709	0.887
64	13.460	0.448	0.869	0.836	0.869	0.866	0.873	0.888	0.875	0.977	0.707	0.884
67	13.527	0.449	0.866	0.833	0.866	0.865	0.874	0.889	0.859	0.976	0.704	0.897
70	13.454	0.450	0.877	0.846	0.877	0.875	0.882	0.899	0.871	0.981	0.731	0.894
73	13.069	0.450	0.870	0.837	0.870	0.869	0.877	0.888	0.868	0.978	0.716	0.893
76	12.981	0.468	0.868	0.834	0.868	0.865	0.873	0.890	0.870	0.973	0.710	0.882
79	12.993	0.450	0.872	0.839	0.872	0.870	0.876	0.886	0.872	0.979	0.721	0.892
82	13.375	0.453	0.869	0.836	0.869	0.866	0.871	0.885	0.878	0.979	0.704	0.885
85	13.382	0.452	0.872	0.839	0.872	0.869	0.875	0.891	0.876	0.975	0.707	0.894
88	13.307	0.468	0.866	0.832	0.866	0.862	0.873	0.889	0.859	0.977	0.702	0.884
91	13.264	0.450	0.867	0.834	0.867	0.863	0.872	0.896	0.858	0.975	0.705	0.883
94	13.484	0.463	0.871	0.839	0.871	0.870	0.876	0.891	0.872	0.977	0.715	0.893
97	13.474	0.460	0.866	0.833	0.866	0.866	0.876	0.884	0.868	0.973	0.712	0.892
100	13.477	0.455	0.868	0.834	0.868	0.864	0.869	0.891	0.867	0.976	0.698	0.885
103	13.490	0.462	0.867	0.834	0.867	0.864	0.870	0.891	0.862	0.977	0.699	0.893
106	13.623	0.451	0.872	0.840	0.872	0.870	0.878	0.889	0.875	0.979	0.720	0.888
109	13.737	0.468	0.868	0.835	0.868	0.865	0.873	0.880	0.880	0.978	0.704	0.884
112	13.563	0.458	0.870	0.837	0.870	0.868	0.876	0.893	0.867	0.977	0.720	0.881
115	13.612	0.466	0.869	0.836	0.869	0.866	0.872	0.885	0.875	0.976	0.710	0.887
118	13.657	0.466	0.879	0.848	0.879	0.875	0.880	0.896	0.890	0.973	0.735	0.880
121	13.583	0.456	0.867	0.834	0.867	0.864	0.872	0.892	0.868	0.972	0.708	0.881
124	13.582	0.460	0.867	0.834	0.867	0.865	0.871	0.880	0.872	0.974	0.713	0.885
127	13.821	0.458	0.870	0.838	0.870	0.868	0.876	0.892	0.864	0.977	0.716	0.892
130	13.335	0.456	0.877	0.846	0.877	0.876	0.882	0.889	0.875	0.980	0.730	0.905
133	13.908	0.462	0.869	0.836	0.869	0.867	0.876	0.886	0.865	0.976	0.715	0.891
136	13.678	0.454	0.873	0.841	0.873	0.871	0.877	0.886	0.875	0.972	0.718	0.902
139	13.844	0.459	0.873	0.840	0.873	0.870	0.876	0.894	0.878	0.972	0.721	0.884
142	13.977	0.455	0.874	0.842	0.874	0.872	0.879	0.891	0.880	0.975	0.730	0.884
145	14.163	0.475	0.873	0.841	0.873	0.871	0.879	0.890	0.870	0.978	0.721	0.895
148	13.846	0.465	0.869	0.836	0.869	0.866	0.873	0.890	0.867	0.976	0.710	0.888
151	13.803	0.463	0.874	0.842	0.874	0.871	0.877	0.894	0.879	0.975	0.722	0.886
154	13.795	0.469	0.867	0.833	0.867	0.865	0.872	0.882	0.872	0.977	0.708	0.884
157	14.195	0.471	0.866	0.832	0.866	0.864	0.871	0.885	0.866	0.976	0.701	0.889
160	13.794	0.445	0.866	0.833	0.866	0.864	0.872	0.883	0.873	0.977	0.702	0.886
163	14.034	0.461	0.868	0.835	0.868	0.866	0.873	0.892	0.863	0.975	0.710	0.889
166	14.159	0.457	0.869	0.836	0.869	0.867	0.874	0.886	0.873	0.975	0.715	0.887
169	14.150	0.461	0.867	0.833	0.867	0.865	0.873	0.887	0.865	0.976	0.710	0.887
172	13.999	0.458	0.873	0.841	0.873	0.870	0.876	0.888	0.876	0.977	0.717	0.893
175	14.006	0.443	0.869	0.836	0.869	0.867	0.874	0.886	0.873	0.972	0.713	0.890
178	14.137	0.459	0.875	0.843	0.875	0.872	0.878	0.896	0.877	0.975	0.731	0.881
181	14.082	0.456	0.868	0.836	0.868	0.865	0.876	0.898	0.849	0.972	0.715	0.892
184	14.272	0.461	0.877	0.846	0.877	0.874	0.879	0.891	0.885	0.973	0.731	0.889
187	14.197	0.451	0.870	0.837	0.870	0.867	0.873	0.888	0.879	0.967	0.718	0.882
190	14.407	0.459	0.870	0.838	0.870	0.868	0.877	0.885	0.870	0.975	0.723	0.888
193	14.448	0.455	0.867	0.834	0.867	0.865	0.875	0.886	0.862	0.978	0.712	0.886
196	14.287	0.454	0.869	0.835	0.869	0.865	0.870	0.892	0.869	0.971	0.709	0.880
199	14.145	0.454	0.871	0.838	0.871	0.867	0.874	0.895	0.871	0.975	0.712	0.882
200	12.266	0.651	0.868	0.834	0.868	0.864	0.871	0.902	0.867	0.969	0.702	0.879
202	14.459	0.471	0.859	0.825	0.859	0.858	0.870	0.856	0.875	0.976	0.700	0.883
205	14.224	0.454	0.871	0.838	0.871	0.868	0.872	0.889	0.880	0.967	0.720	0.884
208	14.202	0.449	0.868	0.834	0.868	0.865	0.871	0.883	0.881	0.975	0.705	0.881
211	14.577	0.462	0.873	0.840	0.873	0.870	0.876	0.891	0.873	0.971	0.730	0.886
214	14.411	0.463	0.875	0.843	0.875	0.872	0.878	0.896	0.879	0.974	0.725	0.884
217	14.754	0.467	0.868	0.834	0.868	0.865	0.869	0.877	0.874	0.974	0.714	0.884
220	14.630	0.463	0.867	0.834	0.867	0.866	0.873	0.875	0.881	0.974	0.707	0.893
223	14.801	0.462	0.879	0.848	0.879	0.875	0.881	0.901	0.883	0.975	0.728	0.886
226	14.727	0.458	0.874	0.842	0.874	0.870	0.875	0.892	0.881	0.973	0.720	0.884
229	14.795	0.466	0.874	0.842	0.874	0.871	0.878	0.892	0.883	0.973	0.727	0.881
232	14.635	0.466	0.865	0.830	0.865	0.862	0.870	0.887	0.863	0.975	0.704	0.883
235	14.728	0.463	0.873	0.840	0.873	0.870	0.877	0.895	0.874	0.971	0.719	0.890
238	14.736	0.468	0.876	0.844	0.876	0.873	0.878	0.892	0.882	0.976	0.723	0.890
241	14.893	0.456	0.873	0.840	0.873	0.870	0.875	0.889	0.877	0.973	0.719	0.894
244	14.709	0.464	0.867	0.833	0.867	0.863	0.871	0.885	0.870	0.976	0.705	0.880
247	14.805	0.468	0.870	0.837	0.870	0.868	0.875	0.888	0.863	0.976	0.718	0.894

Table B.19: Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 128

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	11.188	0.434	0.865	0.831	0.865	0.863	0.870	0.888	0.859	0.979	0.687	0.903
16	12.256	0.441	0.864	0.829	0.864	0.861	0.866	0.882	0.860	0.979	0.683	0.901
19	12.637	0.429	0.860	0.824	0.860	0.858	0.865	0.878	0.858	0.978	0.681	0.894
22	12.418	0.428	0.869	0.835	0.869	0.867	0.874	0.893	0.858	0.976	0.708	0.903
25	12.530	0.435	0.862	0.828	0.862	0.860	0.869	0.885	0.857	0.979	0.684	0.894
28	12.602	0.446	0.869	0.836	0.869	0.867	0.874	0.891	0.865	0.978	0.705	0.896
31	12.464	0.428	0.869	0.836	0.869	0.868	0.874	0.884	0.871	0.978	0.703	0.902
34	12.434	0.428	0.868	0.835	0.868	0.867	0.875	0.886	0.869	0.981	0.704	0.895
37	12.761	0.437	0.870	0.837	0.870	0.869	0.875	0.886	0.877	0.978	0.708	0.895
40	12.838	0.434	0.866	0.832	0.866	0.864	0.870	0.878	0.870	0.977	0.703	0.890
43	12.338	0.435	0.869	0.836	0.869	0.868	0.875	0.891	0.869	0.975	0.713	0.890
46	12.545	0.439	0.865	0.830	0.865	0.861	0.866	0.891	0.863	0.973	0.686	0.891
49	12.987	0.434	0.873	0.841	0.873	0.871	0.878	0.890	0.875	0.977	0.720	0.894
52	12.900	0.440	0.872	0.840	0.872	0.871	0.880	0.892	0.870	0.978	0.718	0.895
55	12.914	0.443	0.875	0.843	0.875	0.873	0.879	0.894	0.877	0.976	0.719	0.897
58	13.218	0.427	0.871	0.838	0.871	0.870	0.877	0.889	0.867	0.976	0.722	0.894
61	13.019	0.432	0.872	0.839	0.872	0.869	0.874	0.894	0.873	0.970	0.716	0.891
64	13.034	0.423	0.876	0.845	0.876	0.875	0.880	0.895	0.870	0.976	0.728	0.905
67	12.880	0.450	0.872	0.840	0.872	0.870	0.877	0.887	0.876	0.977	0.717	0.893
70	13.084	0.436	0.872	0.839	0.872	0.869	0.875	0.890	0.878	0.972	0.720	0.884
73	12.983	0.437	0.871	0.838	0.871	0.870	0.877	0.891	0.870	0.973	0.720	0.894
76	13.318	0.444	0.864	0.830	0.864	0.863	0.872	0.873	0.867	0.974	0.714	0.887
79	13.098	0.440	0.866	0.833	0.866	0.864	0.873	0.884	0.871	0.971	0.706	0.888
82	12.831	0.446	0.872	0.839	0.872	0.870	0.877	0.886	0.878	0.975	0.718	0.895
85	13.014	0.440	0.873	0.840	0.873	0.871	0.877	0.892	0.870	0.975	0.728	0.888
88	12.972	0.446	0.873	0.840	0.873	0.870	0.875	0.893	0.870	0.975	0.720	0.890
91	13.145	0.442	0.876	0.845	0.876	0.875	0.880	0.894	0.872	0.975	0.734	0.897
94	13.402	0.444	0.875	0.843	0.875	0.873	0.879	0.892	0.880	0.971	0.725	0.896
97	12.882	0.443	0.872	0.839	0.872	0.869	0.874	0.887	0.875	0.968	0.719	0.895
100	13.128	0.445	0.868	0.834	0.868	0.865	0.871	0.890	0.867	0.970	0.705	0.894
103	13.237	0.435	0.872	0.839	0.872	0.869	0.876	0.888	0.878	0.973	0.713	0.892
106	13.575	0.436	0.871	0.838	0.871	0.868	0.873	0.891	0.874	0.971	0.715	0.887
109	13.290	0.447	0.867	0.833	0.867	0.864	0.870	0.882	0.873	0.974	0.701	0.891
112	12.360	0.424	0.871	0.838	0.871	0.869	0.876	0.887	0.877	0.976	0.713	0.890
115	8.507	0.407	0.870	0.837	0.870	0.867	0.874	0.885	0.880	0.974	0.711	0.888
118	9.586	0.496	0.871	0.838	0.871	0.868	0.873	0.897	0.868	0.972	0.715	0.887
121	9.593	0.511	0.868	0.835	0.868	0.866	0.872	0.884	0.874	0.971	0.712	0.888
124	9.726	0.529	0.878	0.847	0.878	0.876	0.881	0.895	0.877	0.973	0.736	0.898
127	9.838	0.592	0.870	0.837	0.870	0.866	0.872	0.893	0.867	0.971	0.715	0.886
130	10.590	0.691	0.870	0.837	0.870	0.866	0.872	0.898	0.865	0.970	0.707	0.888
133	9.729	0.433	0.867	0.833	0.867	0.866	0.873	0.885	0.861	0.970	0.716	0.896
136	9.970	0.555	0.866	0.832	0.866	0.863	0.870	0.888	0.866	0.973	0.709	0.879
139	9.970	0.522	0.866	0.833	0.866	0.863	0.870	0.888	0.854	0.974	0.705	0.891
142	9.885	0.553	0.867	0.834	0.867	0.864	0.871	0.888	0.867	0.970	0.709	0.890
145	9.851	0.511	0.872	0.839	0.872	0.868	0.874	0.892	0.874	0.972	0.719	0.886
148	10.696	0.598	0.870	0.837	0.870	0.867	0.873	0.887	0.867	0.970	0.716	0.896
151	9.199	0.424	0.873	0.841	0.873	0.871	0.877	0.890	0.875	0.971	0.723	0.898
154	10.000	0.480	0.869	0.835	0.869	0.866	0.871	0.893	0.863	0.971	0.716	0.885
157	10.096	0.550	0.866	0.832	0.866	0.863	0.869	0.887	0.862	0.968	0.709	0.889
160	9.987	0.532	0.868	0.834	0.868	0.865	0.871	0.886	0.870	0.975	0.705	0.888
163	10.359	0.644	0.870	0.838	0.870	0.866	0.873	0.898	0.868	0.968	0.706	0.891
166	11.009	0.625	0.870	0.837	0.870	0.866	0.874	0.894	0.866	0.971	0.711	0.890
169	9.086	0.409	0.876	0.845	0.876	0.874	0.879	0.894	0.874	0.973	0.731	0.899
172	9.028	0.407	0.867	0.833	0.867	0.864	0.870	0.891	0.866	0.966	0.705	0.892
175	9.153	0.402	0.867	0.833	0.867	0.865	0.873	0.892	0.861	0.972	0.710	0.889
178	9.200	0.409	0.871	0.838	0.871	0.868	0.874	0.889	0.870	0.976	0.720	0.886
181	9.242	0.411	0.871	0.839	0.871	0.868	0.873	0.888	0.873	0.972	0.717	0.891
184	9.213	0.405	0.875	0.844	0.875	0.873	0.880	0.893	0.875	0.974	0.728	0.895
187	10.410	0.416	0.868	0.835	0.868	0.866	0.872	0.884	0.871	0.970	0.716	0.891
190	10.148	0.449	0.871	0.838	0.871	0.869	0.875	0.886	0.880	0.966	0.716	0.896
193	10.217	0.437	0.868	0.835	0.868	0.865	0.871	0.891	0.871	0.970	0.711	0.881
196	10.271	0.460	0.859	0.825	0.859	0.856	0.867	0.880	0.847	0.970	0.704	0.878
199	10.295	0.446	0.868	0.835	0.868	0.865	0.872	0.896	0.857	0.972	0.707	0.891
202	11.102	0.442	0.876	0.844	0.876	0.873	0.878	0.892	0.880	0.969	0.726	0.899
205	13.935	0.448	0.863	0.828	0.863	0.860	0.867	0.879	0.861	0.972	0.696	0.891
208	14.014	0.437	0.868	0.835	0.868	0.866	0.872	0.890	0.864	0.968	0.715	0.891
211	14.264	0.451	0.875	0.844	0.875	0.873	0.878	0.889	0.882	0.971	0.727	0.893
214	14.106	0.448	0.868	0.835	0.868	0.864	0.872	0.892	0.872	0.967	0.702	0.889
217	14.450	0.441	0.864	0.830	0.864	0.863	0.872	0.876	0.875	0.972	0.703	0.889
220	14.008	0.445	0.862	0.828	0.862	0.859	0.869	0.890	0.848	0.973	0.703	0.881
223	14.038	0.437	0.870	0.837	0.870	0.867	0.874	0.890	0.869	0.971	0.716	0.891
226	14.132	0.441	0.867	0.833	0.867	0.863	0.870	0.891	0.867	0.964	0.714	0.876
229	14.251	0.452	0.870	0.836	0.870	0.866	0.871	0.892	0.872	0.969	0.709	0.888
232	14.118	0.443	0.871	0.839	0.871	0.869	0.875	0.887	0.872	0.975	0.714	0.895
235	13.998	0.447	0.870	0.837	0.870	0.866	0.872	0.888	0.873	0.971	0.707	0.891
238	14.313	0.454	0.867	0.834	0.867	0.863	0.870	0.887	0.869	0.966	0.703	0.890
241	14.531	0.437	0.866	0.833	0.866	0.863	0.871	0.889	0.859	0.971	0.708	0.890
244	14.321	0.447	0.872	0.839	0.872	0.869	0.876	0.894	0.866	0.968	0.717	0.899
247	14.277	0.446	0.868	0.835	0.868	0.865	0.872	0.892	0.868	0.964	0.715	0.888

Table B.20: Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 64

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	12.357	0.464	0.860	0.825	0.860	0.859	0.869	0.884	0.849	0.977	0.689	0.896
16	12.504	0.450	0.856	0.820	0.856	0.853	0.858	0.872	0.856	0.971	0.665	0.902
19	12.452	0.458	0.866	0.831	0.866	0.862	0.867	0.887	0.860	0.976	0.686	0.902
22	12.245	0.451	0.869	0.835	0.869	0.867	0.872	0.884	0.872	0.976	0.699	0.904
25	12.248	0.452	0.864	0.830	0.864	0.863	0.871	0.884	0.856	0.974	0.704	0.898
28	12.427	0.458	0.871	0.838	0.871	0.870	0.877	0.884	0.875	0.975	0.715	0.901
31	12.466	0.443	0.861	0.825	0.861	0.859	0.864	0.876	0.869	0.971	0.682	0.895
34	12.809	0.449	0.868	0.834	0.868	0.866	0.871	0.889	0.865	0.973	0.705	0.898
37	12.766	0.448	0.859	0.823	0.859	0.857	0.866	0.884	0.845	0.965	0.694	0.895
40	12.329	0.447	0.859	0.824	0.859	0.858	0.865	0.874	0.870	0.968	0.687	0.891
43	12.624	0.442	0.865	0.830	0.865	0.862	0.868	0.881	0.863	0.973	0.695	0.900
46	12.603	0.450	0.860	0.825	0.860	0.858	0.866	0.878	0.858	0.975	0.690	0.889
49	12.562	0.452	0.871	0.838	0.871	0.869	0.875	0.894	0.863	0.975	0.716	0.896
52	12.412	0.454	0.861	0.826	0.861	0.859	0.866	0.887	0.848	0.970	0.689	0.900
55	12.884	0.459	0.873	0.840	0.873	0.869	0.874	0.890	0.879	0.971	0.706	0.898
58	13.183	0.456	0.867	0.834	0.867	0.864	0.871	0.892	0.858	0.972	0.701	0.899
61	12.871	0.447	0.873	0.841	0.873	0.871	0.876	0.893	0.873	0.967	0.721	0.900
64	12.997	0.444	0.865	0.830	0.865	0.862	0.867	0.883	0.865	0.965	0.707	0.889
67	12.990	0.456	0.862	0.829	0.862	0.862	0.871	0.872	0.861	0.970	0.706	0.899
70	12.948	0.449	0.862	0.828	0.862	0.860	0.866	0.868	0.870	0.973	0.691	0.897
73	12.947	0.460	0.862	0.828	0.862	0.859	0.866	0.882	0.857	0.970	0.694	0.894
76	13.118	0.461	0.867	0.834	0.867	0.866	0.874	0.878	0.871	0.972	0.715	0.895
79	12.860	0.454	0.873	0.840	0.873	0.869	0.875	0.896	0.870	0.964	0.714	0.900
82	13.126	0.456	0.875	0.843	0.875	0.871	0.876	0.891	0.880	0.971	0.724	0.892
85	13.373	0.445	0.867	0.834	0.867	0.864	0.870	0.885	0.868	0.963	0.703	0.902
88	13.297	0.457	0.868	0.834	0.868	0.864	0.870	0.887	0.861	0.974	0.710	0.890
91	13.200	0.449	0.863	0.829	0.863	0.860	0.868	0.889	0.849	0.966	0.695	0.901
94	13.096	0.452	0.867	0.833	0.867	0.864	0.870	0.887	0.859	0.969	0.709	0.895
97	13.116	0.438	0.869	0.835	0.869	0.866	0.872	0.893	0.873	0.960	0.716	0.888
100	13.372	0.453	0.873	0.841	0.873	0.871	0.877	0.890	0.871	0.968	0.725	0.902
103	13.344	0.448	0.865	0.830	0.865	0.862	0.867	0.885	0.867	0.969	0.697	0.892
106	13.108	0.444	0.867	0.833	0.867	0.864	0.871	0.886	0.875	0.956	0.713	0.892
109	13.363	0.455	0.865	0.831	0.865	0.863	0.869	0.883	0.871	0.967	0.697	0.898
112	13.309	0.455	0.866	0.832	0.866	0.863	0.869	0.888	0.863	0.966	0.709	0.891
115	13.235	0.442	0.867	0.833	0.867	0.863	0.868	0.891	0.866	0.969	0.699	0.891
118	13.355	0.449	0.876	0.845	0.876	0.873	0.879	0.896	0.878	0.972	0.725	0.895
121	12.944	0.448	0.869	0.836	0.869	0.866	0.873	0.889	0.875	0.969	0.706	0.893
124	13.135	0.452	0.867	0.833	0.867	0.864	0.870	0.882	0.872	0.967	0.703	0.894
127	13.193	0.456	0.869	0.836	0.869	0.867	0.873	0.893	0.864	0.967	0.713	0.898
130	13.598	0.453	0.871	0.838	0.871	0.868	0.873	0.887	0.871	0.971	0.712	0.898
133	13.391	0.458	0.866	0.832	0.866	0.863	0.871	0.886	0.869	0.968	0.699	0.894
136	13.687	0.458	0.872	0.840	0.872	0.871	0.876	0.893	0.868	0.966	0.720	0.905
139	13.223	0.450	0.871	0.838	0.871	0.867	0.872	0.891	0.873	0.964	0.709	0.898
142	13.702	0.450	0.874	0.842	0.874	0.870	0.876	0.894	0.869	0.969	0.715	0.904
145	13.474	0.441	0.867	0.834	0.867	0.863	0.868	0.890	0.867	0.965	0.701	0.896
148	13.249	0.453	0.866	0.832	0.866	0.864	0.870	0.892	0.868	0.964	0.700	0.894
151	13.516	0.457	0.866	0.832	0.866	0.863	0.869	0.891	0.861	0.968	0.703	0.891
154	13.346	0.456	0.865	0.831	0.865	0.861	0.870	0.895	0.855	0.963	0.703	0.892
157	13.489	0.455	0.867	0.833	0.867	0.863	0.869	0.894	0.860	0.960	0.711	0.891
160	13.840	0.458	0.871	0.838	0.871	0.868	0.873	0.898	0.864	0.966	0.719	0.892
163	13.798	0.452	0.867	0.833	0.867	0.864	0.869	0.893	0.863	0.964	0.708	0.891
166	13.804	0.453	0.870	0.838	0.870	0.868	0.874	0.888	0.873	0.966	0.715	0.899
169	13.738	0.443	0.866	0.832	0.866	0.863	0.869	0.888	0.862	0.963	0.703	0.898
172	13.405	0.437	0.867	0.833	0.867	0.864	0.869	0.889	0.862	0.961	0.711	0.899
175	13.985	0.459	0.870	0.837	0.870	0.867	0.872	0.896	0.869	0.963	0.716	0.891
178	14.104	0.448	0.869	0.835	0.869	0.866	0.873	0.901	0.861	0.966	0.710	0.894
181	13.687	0.450	0.867	0.833	0.867	0.865	0.872	0.886	0.865	0.965	0.713	0.894
184	13.934	0.453	0.873	0.841	0.873	0.869	0.876	0.895	0.877	0.964	0.715	0.896
187	13.970	0.436	0.873	0.840	0.873	0.871	0.875	0.893	0.878	0.961	0.727	0.893
190	14.142	0.448	0.873	0.841	0.873	0.871	0.877	0.885	0.883	0.966	0.729	0.894
193	13.877	0.462	0.866	0.832	0.866	0.864	0.869	0.885	0.870	0.961	0.709	0.893
196	14.082	0.444	0.873	0.841	0.873	0.870	0.876	0.890	0.872	0.970	0.722	0.897
199	13.937	0.454	0.861	0.826	0.861	0.859	0.865	0.885	0.865	0.963	0.694	0.887
202	13.801	0.446	0.861	0.826	0.861	0.858	0.864	0.883	0.855	0.963	0.695	0.894
205	14.189	0.449	0.875	0.843	0.875	0.872	0.877	0.903	0.867	0.964	0.724	0.900
208	13.771	0.447	0.863	0.828	0.863	0.861	0.868	0.883	0.857	0.967	0.703	0.893
211	13.814	0.447	0.870	0.838	0.870	0.869	0.874	0.884	0.872	0.967	0.724	0.896
214	14.369	0.445	0.868	0.835	0.868	0.865	0.872	0.895	0.866	0.960	0.714	0.892
217	14.177	0.450	0.869	0.835	0.869	0.866	0.871	0.890	0.870	0.964	0.710	0.894
220	13.982	0.436	0.870	0.837	0.870	0.866	0.872	0.893	0.877	0.955	0.713	0.892
223	14.255	0.456	0.866	0.832	0.866	0.864	0.869	0.883	0.868	0.962	0.709	0.898
226	14.002	0.457	0.866	0.833	0.866	0.863	0.869	0.885	0.863	0.967	0.703	0.898
229	14.293	0.464	0.867	0.833	0.867	0.865	0.870	0.894	0.864	0.955	0.718	0.891
232	14.139	0.459	0.866	0.832	0.866	0.864	0.870	0.888	0.865	0.962	0.711	0.892
235	13.387	0.450	0.868	0.835	0.868	0.866	0.873	0.898	0.855	0.960	0.722	0.894
238	12.811	0.460	0.867	0.834	0.867	0.865	0.869	0.886	0.868	0.961	0.718	0.894
241	13.409	0.448	0.862	0.828	0.862	0.860	0.867	0.888	0.858	0.963	0.697	0.893
244	13.787	0.448	0.862	0.827	0.862	0.860	0.865	0.885	0.859	0.956	0.699	0.901
247	13.100	0.456	0.872	0.839	0.872	0.870	0.876	0.896	0.870	0.964	0.723	0.897

Table B.21: Performances and execution times for RNN on different embedding dimensions, when LSTM neurons = 32

Para	Time		Metrics					f1 score for each class				
	LSTM Neurons	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
13	7.606	0.434	0.853	0.815	0.853	0.850	0.855	0.874	0.849	0.952	0.687	0.887
16	7.399	0.430	0.855	0.818	0.855	0.854	0.861	0.875	0.858	0.957	0.693	0.885
19	7.652	0.428	0.863	0.828	0.863	0.861	0.868	0.882	0.855	0.964	0.704	0.901
22	7.679	0.429	0.860	0.824	0.860	0.857	0.863	0.893	0.842	0.965	0.694	0.892
25	7.735	0.430	0.863	0.828	0.863	0.859	0.865	0.886	0.861	0.959	0.696	0.892
28	7.747	0.430	0.863	0.828	0.863	0.860	0.865	0.888	0.856	0.967	0.700	0.887
31	7.795	0.428	0.867	0.833	0.867	0.864	0.870	0.891	0.863	0.968	0.705	0.894
34	7.844	0.434	0.873	0.841	0.873	0.872	0.878	0.892	0.869	0.973	0.728	0.895
37	7.840	0.430	0.869	0.836	0.869	0.866	0.872	0.890	0.861	0.972	0.711	0.896
40	7.864	0.431	0.867	0.832	0.867	0.863	0.869	0.890	0.862	0.971	0.707	0.886
43	7.961	0.432	0.867	0.833	0.867	0.866	0.874	0.882	0.858	0.972	0.712	0.908
46	7.791	0.425	0.863	0.830	0.863	0.862	0.872	0.880	0.864	0.969	0.706	0.889
49	9.464	0.424	0.865	0.831	0.865	0.863	0.869	0.890	0.854	0.970	0.706	0.894
52	13.533	0.455	0.868	0.835	0.868	0.866	0.871	0.887	0.862	0.973	0.715	0.890
55	13.371	0.462	0.871	0.839	0.871	0.869	0.876	0.890	0.861	0.973	0.720	0.901
58	13.616	0.459	0.869	0.836	0.869	0.867	0.873	0.886	0.865	0.975	0.720	0.891
61	13.495	0.452	0.872	0.839	0.872	0.869	0.875	0.892	0.872	0.973	0.717	0.889
64	12.791	0.440	0.869	0.835	0.869	0.866	0.872	0.886	0.868	0.976	0.707	0.895
67	13.569	0.456	0.865	0.831	0.865	0.862	0.869	0.881	0.869	0.973	0.696	0.891
70	13.337	0.451	0.869	0.835	0.869	0.866	0.872	0.886	0.873	0.972	0.713	0.887
73	13.500	0.438	0.868	0.835	0.868	0.866	0.874	0.882	0.874	0.973	0.718	0.884
76	12.877	0.445	0.867	0.833	0.867	0.865	0.873	0.888	0.868	0.968	0.708	0.892
79	13.410	0.447	0.872	0.840	0.872	0.870	0.877	0.890	0.873	0.975	0.722	0.890
82	13.474	0.442	0.865	0.830	0.865	0.862	0.869	0.886	0.866	0.971	0.707	0.879
85	13.459	0.452	0.867	0.833	0.867	0.864	0.870	0.889	0.871	0.972	0.703	0.887
88	11.143	0.434	0.865	0.831	0.865	0.863	0.872	0.883	0.864	0.969	0.717	0.882
91	8.858	0.420	0.865	0.831	0.865	0.863	0.871	0.878	0.874	0.974	0.700	0.890
94	8.946	0.419	0.870	0.838	0.870	0.869	0.876	0.887	0.871	0.975	0.719	0.892
97	8.997	0.421	0.873	0.841	0.873	0.872	0.879	0.889	0.875	0.977	0.726	0.891
100	8.780	0.423	0.859	0.825	0.859	0.857	0.867	0.880	0.865	0.972	0.685	0.882
103	9.054	0.423	0.860	0.825	0.860	0.858	0.868	0.871	0.865	0.975	0.703	0.878
106	9.196	0.428	0.865	0.832	0.865	0.862	0.870	0.881	0.874	0.969	0.701	0.887
109	9.165	0.423	0.869	0.836	0.869	0.867	0.874	0.885	0.871	0.976	0.714	0.889
112	8.986	0.425	0.873	0.841	0.873	0.871	0.877	0.892	0.874	0.973	0.722	0.892
115	9.285	0.424	0.864	0.830	0.864	0.861	0.869	0.889	0.854	0.974	0.705	0.885
118	9.482	0.424	0.873	0.841	0.873	0.872	0.877	0.888	0.874	0.977	0.731	0.888
121	9.533	0.424	0.864	0.829	0.864	0.860	0.867	0.880	0.868	0.975	0.696	0.882
124	9.258	0.428	0.868	0.835	0.868	0.867	0.874	0.880	0.872	0.977	0.710	0.896
127	9.611	0.430	0.873	0.841	0.873	0.871	0.877	0.883	0.877	0.977	0.721	0.898
130	9.768	0.435	0.875	0.843	0.875	0.872	0.878	0.889	0.891	0.976	0.720	0.884
133	9.636	0.434	0.866	0.834	0.866	0.867	0.879	0.860	0.881	0.978	0.724	0.892
136	9.495	0.436	0.861	0.827	0.861	0.859	0.868	0.868	0.876	0.975	0.694	0.884
139	9.765	0.440	0.857	0.822	0.857	0.855	0.866	0.876	0.858	0.972	0.692	0.876
142	9.920	0.439	0.868	0.834	0.868	0.866	0.873	0.885	0.872	0.974	0.708	0.891
145	9.920	0.438	0.865	0.831	0.865	0.863	0.872	0.884	0.866	0.973	0.709	0.882
148	9.757	0.438	0.872	0.839	0.872	0.870	0.876	0.887	0.881	0.975	0.721	0.884
151	10.068	0.438	0.868	0.835	0.868	0.864	0.874	0.901	0.846	0.975	0.711	0.890
154	10.289	0.441	0.874	0.842	0.874	0.871	0.878	0.897	0.878	0.974	0.717	0.887
157	10.186	0.443	0.870	0.837	0.870	0.867	0.873	0.897	0.863	0.979	0.706	0.889
160	9.936	0.437	0.864	0.829	0.864	0.861	0.868	0.882	0.866	0.976	0.703	0.880
163	10.357	0.442	0.870	0.837	0.870	0.867	0.875	0.892	0.871	0.977	0.716	0.878
166	10.659	0.451	0.870	0.837	0.870	0.868	0.876	0.886	0.875	0.976	0.718	0.885
169	10.593	0.444	0.871	0.838	0.871	0.868	0.874	0.889	0.873	0.977	0.715	0.885
172	10.254	0.445	0.868	0.834	0.868	0.865	0.872	0.883	0.873	0.977	0.714	0.880
175	10.633	0.450	0.861	0.826	0.861	0.860	0.872	0.883	0.859	0.976	0.700	0.882
178	10.871	0.438	0.866	0.832	0.866	0.863	0.871	0.884	0.870	0.977	0.703	0.881
181	10.899	0.442	0.862	0.828	0.862	0.860	0.870	0.882	0.869	0.971	0.708	0.872
184	13.821	0.472	0.867	0.833	0.867	0.864	0.872	0.885	0.869	0.973	0.711	0.884
187	14.379	0.478	0.867	0.833	0.867	0.863	0.871	0.888	0.872	0.977	0.703	0.877
190	14.386	0.476	0.873	0.840	0.873	0.871	0.878	0.892	0.878	0.975	0.718	0.891
193	14.510	0.478	0.862	0.827	0.862	0.860	0.867	0.884	0.865	0.972	0.700	0.878
196	14.019	0.469	0.872	0.840	0.872	0.870	0.877	0.888	0.879	0.977	0.717	0.888
199	14.771	0.477	0.861	0.826	0.861	0.860	0.869	0.873	0.864	0.971	0.707	0.884
202	14.779	0.484	0.870	0.837	0.870	0.867	0.876	0.892	0.868	0.976	0.719	0.882
205	13.343	0.478	0.866	0.832	0.866	0.864	0.871	0.887	0.868	0.976	0.703	0.885
208	11.054	0.461	0.868	0.834	0.868	0.866	0.873	0.889	0.870	0.977	0.703	0.889
211	11.652	0.454	0.866	0.832	0.866	0.863	0.870	0.881	0.871	0.975	0.706	0.882
214	12.004	0.450	0.868	0.835	0.868	0.866	0.874	0.885	0.870	0.979	0.705	0.892
217	11.907	0.453	0.854	0.819	0.854	0.852	0.865	0.878	0.839	0.976	0.691	0.876
220	11.391	0.451	0.870	0.837	0.870	0.866	0.873	0.893	0.867	0.979	0.712	0.879
223	12.058	0.456	0.859	0.824	0.859	0.855	0.864	0.884	0.868	0.958	0.677	0.887
226	12.379	0.464	0.865	0.831	0.865	0.863	0.872	0.872	0.878	0.979	0.697	0.887
229	12.215	0.462	0.869	0.835	0.869	0.865	0.872	0.892	0.866	0.978	0.703	0.885
232	11.909	0.456	0.871	0.838	0.871	0.868	0.875	0.889	0.874	0.978	0.710	0.891
235	12.331	0.457	0.871	0.838	0.871	0.868	0.876	0.891	0.874	0.973	0.720	0.882
238	12.750	0.463	0.871	0.839	0.871	0.869	0.875	0.889	0.877	0.976	0.714	0.890
241	12.572	0.458	0.868	0.834	0.868	0.866	0.874	0.884	0.874	0.975	0.704	0.894
244	12.284	0.457	0.870	0.838	0.870	0.868	0.878	0.893	0.869	0.974	0.725	0.881
247	12.816	0.463	0.870	0.836	0.870	0.866	0.872	0.892	0.876	0.976	0.706	0.878
250	13.065	0.463	0.866	0.832	0.866	0.864	0.873	0.882	0.871	0.979	0.702	0.885
253	12.993	0.477	0.862	0.828	0.862	0.860	0.870	0.879	0.868	0.974	0.694	0.883

Table B.22: Performances and execution times for RNN on different LSTM layers, when embedding dimension is 125

Para Dropout Rate	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.0225	13.659	0.453	0.871	0.838	0.871	0.868	0.874	0.887	0.870	0.974	0.720	0.891
0.035	13.437	0.446	0.863	0.828	0.863	0.861	0.871	0.891	0.850	0.970	0.710	0.883
0.0475	13.517	0.464	0.867	0.833	0.867	0.865	0.870	0.884	0.867	0.969	0.705	0.898
0.06	13.179	0.458	0.866	0.832	0.866	0.863	0.868	0.889	0.860	0.971	0.698	0.897
0.0725	13.181	0.453	0.869	0.836	0.869	0.867	0.874	0.892	0.868	0.971	0.713	0.892
0.085	13.868	0.452	0.861	0.825	0.861	0.859	0.866	0.876	0.863	0.974	0.699	0.881
0.0975	13.233	0.455	0.867	0.834	0.867	0.866	0.873	0.890	0.862	0.971	0.718	0.888
0.11	13.493	0.455	0.863	0.829	0.863	0.861	0.868	0.889	0.857	0.968	0.706	0.884
0.1225	13.207	0.461	0.871	0.838	0.871	0.868	0.874	0.896	0.864	0.975	0.716	0.891
0.135	13.767	0.461	0.866	0.832	0.866	0.864	0.870	0.891	0.864	0.972	0.704	0.891
0.1475	13.385	0.454	0.865	0.831	0.865	0.864	0.870	0.886	0.860	0.970	0.713	0.889
0.16	13.425	0.458	0.865	0.831	0.865	0.863	0.869	0.888	0.860	0.969	0.710	0.887
0.1725	13.695	0.451	0.863	0.828	0.863	0.861	0.868	0.883	0.864	0.974	0.697	0.888
0.185	11.866	0.432	0.869	0.835	0.869	0.866	0.871	0.890	0.866	0.974	0.710	0.890
0.1975	9.130	0.428	0.864	0.830	0.864	0.861	0.870	0.891	0.854	0.975	0.698	0.887
0.21	9.115	0.424	0.873	0.841	0.873	0.871	0.876	0.897	0.865	0.977	0.722	0.895
0.2225	9.123	0.429	0.870	0.837	0.870	0.868	0.874	0.891	0.872	0.967	0.722	0.890
0.235	9.114	0.425	0.868	0.834	0.868	0.865	0.870	0.888	0.863	0.973	0.712	0.889
0.2475	9.106	0.420	0.865	0.831	0.865	0.862	0.870	0.890	0.858	0.975	0.705	0.885
0.26	9.141	0.438	0.870	0.836	0.870	0.867	0.873	0.891	0.865	0.972	0.720	0.887
0.2725	9.114	0.424	0.863	0.829	0.863	0.862	0.871	0.885	0.855	0.972	0.703	0.896
0.285	9.106	0.429	0.871	0.838	0.871	0.869	0.875	0.894	0.868	0.973	0.717	0.892
0.2975	9.126	0.427	0.869	0.835	0.869	0.866	0.872	0.888	0.866	0.974	0.713	0.891
0.31	9.116	0.429	0.867	0.833	0.867	0.864	0.869	0.892	0.864	0.969	0.704	0.890
0.3225	9.110	0.425	0.874	0.842	0.874	0.871	0.877	0.892	0.876	0.976	0.722	0.891
0.335	9.140	0.425	0.859	0.824	0.859	0.858	0.868	0.877	0.855	0.972	0.701	0.883
0.3475	9.150	0.426	0.867	0.833	0.867	0.864	0.873	0.895	0.859	0.976	0.710	0.881
0.36	9.123	0.425	0.866	0.832	0.866	0.863	0.869	0.887	0.864	0.972	0.702	0.889
0.3725	9.129	0.428	0.868	0.834	0.868	0.866	0.873	0.887	0.870	0.974	0.711	0.888
0.385	9.129	0.425	0.866	0.832	0.866	0.863	0.870	0.891	0.858	0.975	0.707	0.887
0.3975	9.116	0.429	0.867	0.832	0.867	0.863	0.868	0.895	0.857	0.973	0.703	0.888
0.41	9.114	0.425	0.862	0.827	0.862	0.861	0.869	0.880	0.859	0.976	0.699	0.890
0.4225	9.175	0.429	0.865	0.831	0.865	0.862	0.869	0.890	0.852	0.975	0.709	0.883
0.435	9.129	0.426	0.865	0.831	0.865	0.863	0.869	0.882	0.867	0.976	0.703	0.885
0.4475	9.121	0.422	0.868	0.834	0.868	0.866	0.871	0.885	0.864	0.974	0.711	0.894
0.46	9.070	0.417	0.869	0.836	0.869	0.867	0.873	0.892	0.864	0.973	0.711	0.894
0.4725	9.069	0.421	0.868	0.835	0.868	0.867	0.873	0.873	0.877	0.979	0.712	0.893
0.485	9.061	0.418	0.865	0.830	0.865	0.863	0.870	0.880	0.863	0.977	0.706	0.889
0.4975	9.053	0.416	0.872	0.839	0.872	0.869	0.875	0.893	0.873	0.973	0.715	0.892
0.51	13.020	0.453	0.871	0.839	0.871	0.868	0.874	0.892	0.875	0.971	0.715	0.888
0.5225	13.419	0.451	0.872	0.840	0.872	0.870	0.876	0.887	0.875	0.977	0.717	0.894
0.535	13.620	0.453	0.870	0.836	0.870	0.867	0.873	0.893	0.871	0.972	0.708	0.893
0.5475	13.752	0.442	0.868	0.835	0.868	0.866	0.872	0.886	0.869	0.975	0.708	0.892
0.56	13.043	0.455	0.872	0.839	0.872	0.868	0.873	0.891	0.876	0.974	0.708	0.893
0.5725	13.416	0.453	0.867	0.833	0.867	0.865	0.872	0.879	0.872	0.973	0.711	0.890
0.585	13.319	0.455	0.873	0.841	0.873	0.871	0.878	0.891	0.879	0.976	0.718	0.890
0.5975	13.831	0.449	0.867	0.834	0.867	0.865	0.873	0.883	0.872	0.976	0.708	0.885
0.61	13.541	0.453	0.858	0.824	0.858	0.857	0.866	0.866	0.861	0.979	0.693	0.887
0.6225	13.206	0.458	0.870	0.837	0.870	0.868	0.876	0.896	0.862	0.975	0.711	0.898
0.635	13.812	0.447	0.869	0.836	0.869	0.868	0.874	0.886	0.867	0.978	0.714	0.893
0.6475	13.790	0.454	0.873	0.841	0.873	0.871	0.876	0.894	0.872	0.977	0.718	0.892
0.66	13.516	0.440	0.872	0.839	0.872	0.868	0.874	0.892	0.874	0.976	0.702	0.896
0.6725	13.220	0.462	0.873	0.841	0.873	0.870	0.876	0.895	0.876	0.977	0.707	0.894
0.685	13.772	0.474	0.873	0.840	0.873	0.869	0.875	0.898	0.865	0.980	0.715	0.889
0.6975	13.696	0.457	0.877	0.846	0.877	0.874	0.880	0.902	0.874	0.979	0.717	0.899
0.71	13.586	0.446	0.873	0.841	0.873	0.871	0.878	0.895	0.873	0.975	0.720	0.892
0.7225	13.473	0.446	0.879	0.848	0.879	0.876	0.882	0.901	0.881	0.976	0.726	0.897
0.735	13.180	0.445	0.880	0.850	0.880	0.879	0.884	0.898	0.880	0.980	0.733	0.902
0.7475	13.619	0.455	0.876	0.846	0.876	0.875	0.885	0.895	0.870	0.977	0.730	0.906
0.76	13.663	0.447	0.879	0.848	0.879	0.877	0.884	0.900	0.875	0.981	0.733	0.895
0.7725	13.204	0.452	0.875	0.844	0.875	0.873	0.880	0.892	0.877	0.980	0.714	0.902
0.785	13.309	0.451	0.879	0.848	0.879	0.877	0.883	0.894	0.885	0.978	0.729	0.898
0.7975	13.624	0.452	0.878	0.848	0.878	0.876	0.883	0.900	0.869	0.979	0.732	0.901
0.81	13.717	0.442	0.881	0.850	0.881	0.879	0.884	0.900	0.879	0.979	0.731	0.905
0.8225	13.425	0.462	0.881	0.851	0.881	0.880	0.887	0.896	0.883	0.980	0.731	0.908
0.835	13.462	0.457	0.877	0.847	0.877	0.876	0.884	0.896	0.872	0.983	0.723	0.905
0.8475	13.085	0.455	0.880	0.850	0.880	0.878	0.883	0.891	0.889	0.982	0.727	0.900
0.86	13.790	0.443	0.878	0.847	0.878	0.876	0.882	0.892	0.878	0.977	0.725	0.906
0.8725	13.604	0.456	0.883	0.853	0.883	0.881	0.887	0.891	0.891	0.981	0.737	0.906
0.885	13.342	0.447	0.881	0.852	0.881	0.880	0.887	0.894	0.890	0.981	0.727	0.905
0.8975	12.995	0.445	0.878	0.848	0.878	0.877	0.887	0.895	0.876	0.979	0.735	0.901
0.91	13.596	0.451	0.884	0.855	0.884	0.883	0.889	0.902	0.881	0.982	0.733	0.915
0.9225	13.898	0.460	0.883	0.853	0.883	0.881	0.886	0.900	0.888	0.981	0.727	0.911
0.935	13.537	0.455	0.887	0.859	0.887	0.885	0.892	0.907	0.884	0.982	0.740	0.912
0.9475	13.701	0.463	0.877	0.846	0.877	0.874	0.881	0.900	0.871	0.983	0.707	0.912
0.96	13.158	0.459	0.870	0.837	0.870	0.866	0.872	0.892	0.863	0.982	0.682	0.910
0.9725	13.628	0.456	0.854	0.818	0.854	0.846	0.856	0.882	0.847	0.983	0.615	0.904
0.985	13.903	0.456	0.799	0.751	0.799	0.780	0.792	0.842	0.775	0.982	0.432	0.870
0.9975	13.584	0.450	0.455	0.346	0.455	0.409	0.472	0.533	0.064	0.707	0.210	0.530

Table B.23: Performances and execution times for RNN on different dropout rates, when the dropout layer is before the LSTM layer, embedding dimension is 125 and LSTM neurons is 105

Para Dropout Rate	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.0225	13.296	0.441	0.865	0.830	0.865	0.862	0.869	0.888	0.863	0.970	0.704	0.884
0.035	13.312	0.448	0.864	0.830	0.864	0.862	0.870	0.889	0.854	0.971	0.710	0.887
0.0475	13.665	0.446	0.862	0.827	0.862	0.859	0.867	0.891	0.849	0.970	0.704	0.881
0.06	13.230	0.449	0.863	0.829	0.863	0.860	0.869	0.885	0.861	0.973	0.697	0.884
0.0725	12.865	0.447	0.869	0.835	0.869	0.867	0.872	0.890	0.865	0.968	0.713	0.897
0.085	13.357	0.445	0.867	0.833	0.867	0.864	0.869	0.885	0.867	0.968	0.707	0.891
0.0975	13.520	0.442	0.865	0.830	0.865	0.861	0.866	0.889	0.860	0.970	0.696	0.892
0.11	13.461	0.445	0.868	0.834	0.868	0.864	0.871	0.889	0.869	0.976	0.704	0.884
0.1225	13.348	0.454	0.869	0.835	0.869	0.867	0.873	0.890	0.867	0.968	0.721	0.889
0.135	13.318	0.452	0.872	0.840	0.872	0.869	0.874	0.896	0.873	0.969	0.721	0.883
0.1475	13.197	0.463	0.866	0.832	0.866	0.864	0.870	0.887	0.866	0.970	0.712	0.882
0.16	13.316	0.454	0.867	0.832	0.867	0.864	0.870	0.888	0.871	0.971	0.702	0.889
0.1725	13.246	0.447	0.868	0.834	0.868	0.866	0.871	0.888	0.871	0.969	0.712	0.888
0.185	13.251	0.454	0.867	0.833	0.867	0.865	0.870	0.891	0.861	0.970	0.715	0.886
0.1975	13.656	0.441	0.862	0.827	0.862	0.858	0.865	0.887	0.857	0.968	0.695	0.884
0.21	13.603	0.444	0.865	0.830	0.865	0.863	0.869	0.886	0.861	0.975	0.709	0.883
0.2225	13.280	0.433	0.858	0.823	0.858	0.857	0.865	0.868	0.858	0.973	0.700	0.885
0.235	13.003	0.443	0.866	0.833	0.866	0.865	0.872	0.884	0.860	0.970	0.716	0.895
0.2475	13.238	0.446	0.859	0.823	0.859	0.857	0.862	0.880	0.861	0.967	0.689	0.885
0.26	13.422	0.460	0.863	0.828	0.863	0.860	0.865	0.884	0.863	0.973	0.695	0.885
0.2725	13.259	0.455	0.868	0.835	0.868	0.865	0.872	0.891	0.868	0.971	0.708	0.890
0.285	13.190	0.439	0.866	0.832	0.866	0.865	0.870	0.879	0.871	0.970	0.712	0.891
0.2975	12.865	0.449	0.861	0.826	0.861	0.858	0.865	0.892	0.849	0.971	0.696	0.883
0.31	13.371	0.453	0.867	0.833	0.867	0.863	0.868	0.890	0.869	0.970	0.703	0.883
0.3225	13.298	0.451	0.867	0.832	0.867	0.863	0.869	0.890	0.861	0.972	0.704	0.890
0.335	13.565	0.444	0.865	0.831	0.865	0.862	0.867	0.888	0.859	0.968	0.706	0.890
0.3475	12.998	0.456	0.863	0.828	0.863	0.860	0.866	0.882	0.868	0.971	0.696	0.882
0.36	13.383	0.442	0.869	0.835	0.869	0.865	0.870	0.887	0.868	0.972	0.707	0.892
0.3725	13.474	0.440	0.855	0.819	0.855	0.850	0.860	0.884	0.825	0.963	0.687	0.892
0.385	13.650	0.451	0.866	0.832	0.866	0.863	0.868	0.890	0.863	0.969	0.707	0.888
0.3975	13.366	0.447	0.865	0.831	0.865	0.862	0.868	0.890	0.863	0.973	0.696	0.888
0.41	13.093	0.449	0.866	0.832	0.866	0.863	0.870	0.888	0.864	0.968	0.706	0.892
0.4225	13.467	0.448	0.864	0.829	0.864	0.861	0.866	0.882	0.867	0.972	0.700	0.885
0.435	13.559	0.449	0.860	0.824	0.860	0.856	0.860	0.878	0.858	0.970	0.687	0.887
0.4475	13.370	0.439	0.870	0.836	0.870	0.867	0.872	0.889	0.868	0.978	0.714	0.885
0.46	13.062	0.454	0.864	0.829	0.864	0.860	0.865	0.886	0.861	0.970	0.700	0.885
0.4725	13.236	0.444	0.869	0.835	0.869	0.866	0.872	0.891	0.872	0.971	0.714	0.880
0.485	13.372	0.450	0.859	0.824	0.859	0.855	0.863	0.889	0.842	0.970	0.694	0.880
0.4975	13.385	0.453	0.851	0.814	0.851	0.849	0.859	0.848	0.857	0.970	0.686	0.886
0.51	13.536	0.439	0.873	0.841	0.873	0.870	0.876	0.897	0.870	0.971	0.723	0.891
0.5225	12.542	0.439	0.868	0.835	0.868	0.865	0.872	0.886	0.873	0.969	0.708	0.889
0.535	13.711	0.446	0.868	0.835	0.868	0.865	0.873	0.896	0.854	0.976	0.712	0.885
0.5475	13.298	0.455	0.856	0.820	0.856	0.851	0.858	0.878	0.858	0.969	0.672	0.881
0.56	13.238	0.449	0.861	0.826	0.861	0.857	0.863	0.882	0.860	0.975	0.683	0.887
0.5725	12.895	0.447	0.861	0.826	0.861	0.858	0.863	0.884	0.860	0.969	0.695	0.880
0.585	13.388	0.450	0.862	0.826	0.862	0.858	0.863	0.883	0.857	0.969	0.691	0.889
0.5975	13.525	0.442	0.868	0.834	0.868	0.865	0.872	0.892	0.867	0.965	0.714	0.887
0.61	13.459	0.445	0.864	0.830	0.864	0.858	0.865	0.885	0.870	0.975	0.676	0.885
0.6225	13.332	0.456	0.859	0.825	0.859	0.856	0.866	0.885	0.844	0.967	0.705	0.881
0.635	13.011	0.444	0.868	0.835	0.868	0.865	0.871	0.887	0.866	0.977	0.708	0.889
0.6475	13.665	0.449	0.869	0.836	0.869	0.865	0.872	0.890	0.873	0.970	0.701	0.892
0.66	13.430	0.442	0.867	0.833	0.867	0.864	0.871	0.890	0.862	0.970	0.715	0.884
0.6725	13.250	0.438	0.863	0.828	0.863	0.860	0.867	0.886	0.851	0.970	0.706	0.887
0.685	13.197	0.452	0.858	0.822	0.858	0.856	0.863	0.876	0.852	0.965	0.698	0.891
0.6975	13.305	0.440	0.868	0.835	0.868	0.865	0.871	0.885	0.873	0.971	0.710	0.886
0.71	13.293	0.443	0.869	0.835	0.869	0.865	0.869	0.888	0.869	0.971	0.703	0.894
0.7225	13.510	0.452	0.858	0.822	0.858	0.855	0.859	0.882	0.850	0.966	0.681	0.894
0.735	13.189	0.453	0.868	0.834	0.868	0.864	0.869	0.888	0.864	0.968	0.714	0.888
0.7475	12.709	0.437	0.860	0.825	0.860	0.857	0.863	0.883	0.859	0.971	0.685	0.885
0.76	13.686	0.444	0.866	0.832	0.866	0.862	0.868	0.887	0.864	0.965	0.704	0.892
0.7725	13.301	0.442	0.856	0.820	0.856	0.853	0.859	0.874	0.858	0.966	0.683	0.882
0.785	13.357	0.443	0.860	0.824	0.860	0.857	0.863	0.879	0.856	0.970	0.690	0.891
0.7975	13.122	0.446	0.863	0.829	0.863	0.861	0.867	0.883	0.862	0.967	0.704	0.888
0.81	13.073	0.445	0.858	0.822	0.858	0.854	0.862	0.877	0.854	0.972	0.696	0.872
0.8225	12.968	0.438	0.863	0.828	0.863	0.860	0.866	0.887	0.867	0.966	0.693	0.886
0.835	13.091	0.450	0.858	0.822	0.858	0.853	0.859	0.880	0.855	0.961	0.681	0.890
0.8475	13.366	0.452	0.861	0.825	0.861	0.857	0.861	0.880	0.867	0.969	0.687	0.881
0.86	13.128	0.447	0.854	0.818	0.854	0.851	0.860	0.856	0.857	0.966	0.690	0.886
0.8725	13.317	0.441	0.861	0.827	0.861	0.859	0.866	0.882	0.861	0.965	0.699	0.887
0.885	13.672	0.450	0.854	0.818	0.854	0.851	0.860	0.879	0.843	0.963	0.688	0.882
0.8975	13.540	0.441	0.861	0.826	0.861	0.857	0.862	0.888	0.851	0.962	0.685	0.897
0.91	13.071	0.448	0.856	0.819	0.856	0.851	0.858	0.879	0.857	0.969	0.669	0.879
0.9225	13.174	0.446	0.864	0.830	0.864	0.860	0.867	0.881	0.873	0.962	0.698	0.888
0.935	13.478	0.445	0.861	0.826	0.861	0.857	0.862	0.878	0.870	0.964	0.678	0.895
0.9475	13.191	0.440	0.855	0.818	0.855	0.853	0.859	0.870	0.855	0.963	0.672	0.906
0.96	13.299	0.435	0.852	0.817	0.852	0.851	0.867	0.871	0.836	0.965	0.688	0.896
0.9725	13.025	0.438	0.852	0.817	0.852	0.847	0.864	0.890	0.803	0.970	0.677	0.894
0.985	13.361	0.451	0.861	0.826	0.861	0.854	0.861	0.886	0.867	0.971	0.654	0.893
0.9975	13.478	0.458	0.617	0.576	0.617	0.542	0.605	0.592	0.456	0.966	0.000	0.698

Table B.24: Performances and execution times for RNN on different dropout rates, when the dropout layer is after the LSTM layer, embedding dimension is 125 and LSTM neurons is 105

B.5.2 All Application Results

Tottenhams Harry Winks sørget for seier etter overtid drama. Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikset seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexandar Mitrovic dratt ned i feltet av Jan Vertonghen.

Claudio Ranieries menn fortsette å presse Tottenham, og etter nytt hjørnespark satte Harry Kanes erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

På overtid svingte innbytter Nkoudou ballen inn i feltet der Harry Winks headet ballen i mål i siste minutt av overtiden. Dermed vant Tottenham 2-1 på Craven Cottage.

Tottenham uten Harry Kane (skadet) og Heung-Min Son (Asiamesterskapet) slet lenge mot Fulham. Fernando Llorente, som erstattet Kane, satte ballen i eget mål etter et kvarter.

Fernando Llorente fikk den store sjansen til å bli helten igjen for Tottenham. Med ti minutt igjen slo Eriksen et frispark inn i feltet. Ballen skled av hodet til spanjolen og like utenfor mål. Til Llorente og Tottenham-fansens store fortvilelse.

Dier bommet for SpursN'golo Kanté og Eden Hazards scoret målene for Chelsea på Stamford Bridge, mens Tottenhams reduseringsmål ble satt inn av Fernando Llorente.

Spurs løftet seg etter pause - kampen avgjort på straffesparkkonkurranseLike etter pause reduserte Tottenham. Harry Kane-erstatteren Fernando Llorente headet inn 1-2-reduseringen seks minutter ut i omgangen, og dermed trengte Tottenham kun ett mål for å ta seg videre til ligacupens finale.

Christian Eriksen scoret sikkert på Tottenhams første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenhams andre straffespark.

Azpilicueta satte 2-2 for Chelsea. Så blåste Eric Dier ballen over for Tottenham, og Chelsea var i førerretet. Jorginho satte arrogant inn 3-2-ledelse med et frekt straffespark.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

Tottenham styrte mye av banespillet, men slet med å komme til de store sjansene. Der var Fulham farligere. Ryan Babel var nær å doble ledelsen fem minutter før pause. Hodestøtet fra fem meter gikk over mål.

Fulham skapte enda mer. To minutter senere la Babel inn til Andre Schurrle som banket til på hel volley fra kort avstand. Lloris vartet opp med en mesterlig redning, men ballen endte hos Mitrovic som headet ballen i mål. Serberen var imidlertid i offside og scoringen ble annullert.

I andreomgang slo Tottenham tilbake. Seks minutter ut i omgangen slo Christian Eriksen et perfekt innlegg til Dele Alli som headet ballen i mål fra kloss hold. 1-1 og kamp igjen på Craven Cottage.

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Midtbanespilleren dundret løs fra 16 meters hold. Ballen føk gjennom beina på et par Spurs-spillere, og i mål via Tottenhams keeper Paolo Gazzaniga. Paolo Gazzaniga fikk tillit fra start på bekostning av Hugo Lloris.

I det 38. minutt viste Chelsea frem vidunderlig fotball. Eden Hazard startet det vakre angrepet, og avsluttet selv i boksen. Plutselig stod det 2-0 og Chelsea stormet mot en ny cupfinale.

Figure B.39: RNN application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Ti minutter før slutt måtte forøvrig Tottenhams Moussa Sissoko gi seg på grunn av skade. Davinson Sánchez kom inn. Skadeproblemene fortsetter dermed for Tottenham.

– Det er en fantastisk følelse. I den første omgangen kunne vi scoret tre eller fire. Vi kontrollerte kampen også etter pause. Spurs fikk sin mulighet, og scoret. Reaksjonen til spillerne og viljen vi viste gjør meg svært glad. For det var frustrerende at vi risikerte å tape på straffer etter å kontrollert kampen fullstendig. I straffesparkkonkurranser vet man aldri hva som skjer. Men laget gjorde det strålende. Vi skapte mange sjanser og presset Tottenham hele kampen, sa Chelseas straffehelt David Luiz til Sky Sports etter kampen.

Son, som også scoret i midtukekampen mot Watford, har nå scoret i begge kampene etter sin hjemkomst fra Asiamesterskapet.

Heung-min Son sørget for tre Tottenham-poeng med sen scoring.

Newcastle var på vei mot nok et kruttsterkt resultat mot et topplag, men Heung-min Son ville det annerledes. Med åtte minutter igjen av ordinær tid scoret sørkoreaneren sitt tiende ligamål for sesongen.

Slik var kampenDet var Tottenham som var nærmest scoring i den første omgangen. Lucas Moura fikk en enorm mulighet etter et kvarter, men brasilianerens heading gikk utenfor mål.

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvspretten etter en corner som ble svakt halvklarert.

Tidlig i andre omgang økte Mohamed Salah til 2–0 fra straffemerket etter at han selv ble dratt i armen av Paul Dummett. Straffen var likevel billig, og Salah blir fra flere holdt beskyldt for å filme. Uansett var det svakt av Dummett å bruke armen i duellen, og straffen satte Salah sikkert forbi keeper Martin Dúbravka.

Mål: 1–0 Nemanja Matic (28), 2–0 Paul Pogba (64), 3–0 Pogba (78), 3–1 Mathias Jørgensen (88).

Bernardo Silva sendte Manchester City i ledelsen, men Marc Albrighton og Ricardo Pereira scoret i hver sin omgang og sørget for 2–1-seier til Leicester. Vinnermålet til Pereira var et herlig langskudd, og Fabian Delph pådro seg rødt kort på tampen av kampen.

Mål: 1–0 Dejan Lovren (11), 2–0 Mohamed Salah (str. 48), 3–0 Xherdan Shaqiri (79), 4–0 Fabinho (85).

Mål: 0–1 Pierre-Emerick Aubameyang (7), 1–1 Jürgen Locadia (35).

Men etter pause hevet Tottenham seg, og Fernando Llorente utlignet den sammenlagte ledelsen rett etter pause med et kontant hodestøt.

Midtveis i omgangen var det Erik Lamela som fikk en sjanse. Innlegget fra Jan Vertonghen var av det presise slaget, men headingen fra Lamela var akkurat ikke god nok. Ballen smalt i tverrliggeren. Returen falt til Moura, men heller ikke denne gang traff angriperen mål.

Nytt stolpetreffRondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frempå igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut.

Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Først vant Llorente duellen, før Son dro seg fri og sendte i vei et skudd fra 18 meter. Skuddet gikk rett på Dúbravka, men keeperen klarte likevel ikke å stoppe det.

På tampen ordnet Xherdan Shaqiri 3–0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4–0.

Tottenham knuste Bournemouth 5–0, og tok over annenplassen på tabellen – seks poeng bak Liverpool. Mauricio Pochettinos lag har scoret vanvittige 11 mål på få dager, etter 6–2-seieren borte mot Everton lille julaften.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

Mål: 1–0 Ryan Sessegnon (74), 1–1 Romain Saiss (85).

Mål: 0–1 Bernardo Silva (14), 1–1 Marc Albrighton (19), 2–1 Ricardo Pereira (81).

I straffesparkkonkurransen scoret Willian, Azpilicueta, Jorginho og David Luiz, mens Eric Dier banket ballen langt opp på tribunen, og Lucas Moura rett i fanget på Kepa, dermed hjalp det lite at Christian Eriksen og Erik Lamela scoret på de to første forsøkene.

N’Golo Kanté banket inn 1–0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2–0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Figure B.40: RNN application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.
- Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.
- Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.
- Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.
- Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
- Gazzaniga hadde ingen sjanse og det var virkelig et mål med klasse av hjemmelaget. Det der er smart fotball. De angrep raskt og avsluttet vidunderlig, beskrev Andy Townsend etter scoringen som sørget for at Chelsea kunne gå til pause med 2-0.
- Han har vært en av Newcastles beste spillere denne sesongen. Han har reddet laget så mange ganger. Det er brutalt, sier TV 2-kommentator Endre Olav Osnes.
- Det er en stor, stor sjanse, men headingen er ikke i nærheten av god nok, sa Trevor Morley.
- Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.
- Det er deilig å se spillere leke fotball på den måten, sa Ronny Deila om Jorginhos arrogante straffe, hvor midtbanespilleren ventet ut keeper og trillet ballen nonchalant i mål.
- Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.
- Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange trofæer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.
- Jeg bryr meg ikke. Jeg spiller bare fotball. Det har ingenting å si hva manageren sier, jeg fokuserer bare på fotballen og vil gjøre det best mulig for laget, svarte Hazard på spørsmål om hva han mente om Sarris kritikk.
- Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
- Vi vant mot dem på Wembley. De slo oss her. Jeg foretrekker å tape på straffer fremfor etter fulltid. Gratulerer til Chelsea. Nå skal vi gjøre alt og være klar for FA-cupkampen mot Crystal Palace på søndag, sa Tottenhams suksessjef etter kampen.
- Både City og Liverpool sviktet i forrige runde. Nå starter Tottenham denne helgen med å vinne. Det er tre lag som kjemper om tittelen nå, sier Osnes.
- Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på at de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betydde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.
- Tottenham er i kjempeform nå, og er i form. Chelsea vil trolig vinne mye fremover, Arsenal vil vinne og dette blir et race til siste dag. Vi er med i racet, og det er det aller viktigste, la han til.
- Chelsea har vært et av de mest suksessrike lagene i England de siste årene. Å vinne titler er det eneste som gjelder i denne klubben, så vi er glade for å være i finalen, oppsummerte Chelsea-kaptein Cesar Azpilicueta til Viasat 4.

Figure B.41: RNN application results on the "Quotes" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Tottenham seiret etter overtidsdrama

Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.

Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.

Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.

Fulham var flere ganger frempå og skapte problemer på tampen av omgangen. Ranieris menn ledet fortjent 1-0 til pause.

Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren.

Hazard: – Jeg bryr meg ikke Mauricio Sarri kritiserte som kjent Chelsea-spillerne etter 0-2-tapet mot Arsenal i Premier League. Manageren sa blant annet at Hazard ikke var en leder på banen.

Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.

Tottenhams manager Mauricio Pochettino hevdet at han ikke var særlig skuffet etter nederlaget.

Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.

– Vidunderlig fotball av Chelsea Etter en tett og jevn start på kampen presenterte N'golo Kanté seg etter 27 minutters spill.

Tottenham skapte en rekke sjanser det siste kvarteret. Chelsea skapte også sine sjanser og hadde ingen planer om å parkere bussen.

Dommer: Martin Atkinson, West Yorkshire

Chelsea til finale etter seier mot Tottenham i straffesparkkonkurranse

Maurizio Sarri øyner sitt første trofé som manager for Chelsea etter at blåtrøyene slo Tottenham på straffer torsdag kveld.

Angriperen fyrte løs fra 18 meter. Skuddet gikk rett Martin Dubravka, men keeperen klarte ikke å stoppe skuddet.

Scoringen gjorde at Spurs nok en gang dro i land en seier i sluttminuttene. Det betyr at Tottenham nå er oppe på en andreplass, men med én kamp mer spilt enn Manchester City.

Sissoko prøvde seg med et brukbar volleyforsøk kort tid før pause, men Dubravka stoppet skuddet. Dermed gikk lagene til pause på 0-0.

Etter 72 minutter kokte det over for Mitrovic og Sánchez. Begge kamphanene hadde ved flere anledninger hakket på hverandre, og i denne situasjonen dro de hverandre ned i bakken. Begge ble straffet med gult kort.

Minuttet senere skjedde det som Tottenham-fansen fryktet. Dele Alli jaget en ball ut mot sidelinjen og i forsøket på å nå ballen holdt 22-åringen seg til hamstringen og måtte legge seg ned utenfor banen. Engelskmannen klarte ikke å komme seg på beina igjen og ble byttet ut. Alli så tydelig preget ut på benken etter byttet.

Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.

Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.

Flere scoringer ble det imidlertid ikke i kampen, og kampen måtte avgjøres på straffer.

Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.

Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.

Slik startet lagene:

Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.

Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente.

Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.

Figure B.42: RNN application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Det var det som skulle til for at Spurs dro i land nok en sen seier på eget gress. Resultatet gjør at Tottenham nå har sneket seg forbi Manchester City, riktignok med én kamp mer spilt.

Hjemvendte Son reddet dagen for Spurs

For øyeblikket bunnsolide Liverpool gikk sin 30. strake hjemmekamp i ligaen uten tap. Selv om farlig utsatte Newcastle hang med lenge, så ble det stygge sifre til slutt. Den antatt argeste gullrivalen, Manchester City, ligger nå syv poeng bak.

Men de to siste rundene har gjort Liverpool til storfavoritter når det gjelder ligagullet.

PS! Førstkommende lørdag spiller Tottenham hjemme mot Wolverhampton, og Liverpool får besøk av Arsenal. Manchester City spiller borte mot Southampton søndag.

Burnley – Everton 1–5 (1–3)

Senere kampstart: Watford – Chelsea 20.30.

(Liverpool–Newcastle 4–0, Leicester – Manchester City 2–1) Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.

Sist Liverpool tapt en ligakamp på Anfield, var da Crystal Palace vant 2–1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seiere. Denne sesongen har det blitt bare seiere, med unntak av 0–0-kampen mot Manchester City.

For nå er det syv poeng ned til Manchester City, som snublet igjen.

For få dager siden tapte de 2–3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.

Det ble klart etter seier i straffesparkkonkurranse mot Tottenham torsdag kveld.

Crystal Palace – Cardiff 0–0

Fulham – Wolverhampton 1–1 (0–0)

Leicester – Manchester C. 2–1 (1–1)

Liverpool – Newcastle 4–0 (1–0)

Manchester U. – Huddersfield 3–1 (1–0)

Mål: 1–0 Christian Eriksen (16), 2–0 Son Heung-min (23), 3–0 Lucas Moura (35), 4–0 Harry Kane (61), 5–0 Son (70).

Joshua King spilte 16 minutter som innbytter for Bournemouth.

Brighton – Arsenal 1–1 (1–1)

Dommer: Anthony Taylor, England.

Gult kort: Martín Montoya (45), Glenn Murray (58), Brighton, Sea Kolasinac (81), Arsenal.

Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.

I returoppgjøret mot Tottenham i Ligacupen fikk han svar på tiltale.

I finalen venter Manchester City. Seier vil bety Sarris første trofé som Chelsea-manager. Mauricio Pochettino derimot må vente enda lenger på sitt første som Tottenham-sjef.

Finalen spilles på Wembley siste helgen i februar.

Chelsea til ligacupfinale etter straffeseier

(Chelsea - Tottenham 2–1, 2–2 sammenlagt, 6–4 etter straffer) Kun Pep Guardiola og Manchester City står mellom Maurizio Sarri og hans første trofé som Chelsea-manager.

Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.

Figure B.43: RNN application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Se seiersmålet og høydepunktene i videovinduet øverst!	25.206 tilskuere
Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):	24.382 tilskuere.
Se sammendrag i Sportsnyhetene øverst!	32.090 tilskuere.
Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.	Rødt kort: Fabian Delph (89), Manchester C.
Tottenham - Newcastle 1-0	53.318 tilskuere.
Se scoringen i videovinduet øverst!	74.523 tilskuere.
Live: Brighton tok poeng mot Arsenal - referat fra dagens runde	Tottenham – Bournemouth 5–0 (3–0)
21.484 tilskuere.	45.154 tilskuere.
	30.608 tilskuere

Figure B.44: RNN application results on the "Ignore" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt.

Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham.

Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene.

Callum Hudson-Odoi la inn foran mål hvor Morata ventet. Etter flere forsøk satt den endelig for Chelsea-spissen, og hjemmelaget ledet 1-0.

Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.

Angrepene fra hjemmelaget kom som perler på snor utover, og Morata burde økt ledelsen til Chelsea etter 58 minutter, men på åpent mål presterte spissen å skyte over.

Men den siste sesongen har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjelte spissen scoret begge.

I Chelsea er Higuain gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong.

Huddersfield-kampen forrige helg, der Higuain scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

Morata misbrakte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.

Bare når ettertraktede Callum Hudson-Odoi serverte fra høyre fikk Morata til å score. Først med en tap-in, deretter med et pent hodestøt, hvor han knuste Claudio Yacob i luften.

Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøket angrep av samme duo som lagde 1-0 målet.

Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.

Antoine Griezmann er storklubbens toppscorer med ti mål i serien. Bak ham har ingen scoret mer enn to. Blant dem som har slitt, er tidligere Chelsea-stjerne Diego Costa. Spansk-brasilianeren har bare funnet nettmaskene én gang i ligasammenheng.

Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben.

Figure B.45: RNN application results on the "Goal/Assist" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.

Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.

Chelsea-spiss klar for La Liga-gigant

Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.

Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.

Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.

Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.

Watford føler seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.

Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.

Fotballryktene: – Morata bare timer unna overgang

På søndag møter en meget tøff utfordring for Higuain og Chelsea, når de gjester Manchester City på Etihad. Supporterleder Vinje forventer en svært tøff kamp mot de regjerende mesterne.

Siden Roman Abramovitsjs inntog i Chelsea har stjernespissene vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuain.

Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.

Álvaro Morata (26) lånes ut fra Chelsea til Atlético Madrid.

Alvaro Morata er nær ved å forlate Chelsea. Her er dagens fotballykter!

Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.

Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.

PSG har vært koblet til Evertons midtbanespiller Idrissa Gueye en stund. Ifølge Liverpool Echo har de imidlertid ikke lagt inn noe formelt bud enda.

Chelsea har lenge vært koblet til Zenits argentinske midtbanespiller Leandro Paredes, men nå har Paris Saint-Germain seilet opp som favoritt til å signere 24-åringen, skriver The Telegraph.

Chelsea har en lang tradisjon for å hente stjernespiss, men få har levd opp til forventningene på Stamford Bridge.

Siden den gang har Higuain spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuain, og ikke den som mislykkes i Milano.

Med sommerens signering av Jorginho, og Higuain inn i januarvinduet, har Sarri hentet inn to viktige brikker fra tiden sin i Napoli, som vet hvordan italieneren ønsker å spille.

Figure B.46: RNN application results on the "Transfer" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Med det blikket for spillet og timingen på pasningene, er han unik i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.
- Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.
- Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Bli han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.
- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Det er en av de to-tre vanskeligste kampene som er. Men toppkamper lever sitt eget liv, og Chelsea har ofte vært bedre borte mot topplagene enn mot de antatt svakere lagene.
- Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.
- Higuaín kan ikke bare måles på antall scoringer
- Utfordringen er at Chelsea har vinger som liker å føre ballen langt inn i banen, og da har Higuaín ofte allerede løpt i offside før pasningen kommer, sier Vinje.
- Jeg har mer troa etter kampen mot Huddersfield. Han er jo en målscore, men han har slitt denne sesongen. Spørsmålet er om Chelsea får den Higuaín som scoret 36 ligamål på en sesong i Napoli, eller den som slet i Milan denne sesongen.
- Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.
- Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.
- Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseaas norske supporterklubb, Øystein Vinje:
- I Jorginho og Higuaín har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.
- Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.

Figure B.47: RNN application results on the "Quotes" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Chelsea-stjerne forlot banen i tårer	Mot slutten av omgangen viste Nottingham mer selvtillit og utfordret Chelsea. Noen helt store sjanser ble det ikke, men etter å ha tilbragt store deler av omgangen på egen banehalvdel, var det i hvert fall et steg i riktig retning for gjestene.
Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.	
Chelsea hadde stort sett kontroll på Nottingham Forest i FA-cupens tredje runde. Men det var duoen Álvaro Morata og Callum Hudson-Odoi som utgjorde forskjellen i 2-0 seieren.	Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.
Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.	Etter drøye timen spilt begynte sjansene å bli større for Nottingham. Nærmest redusering var Joe Lolley, men spissen måtte nøye seg med nettveggen denne gang.
Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.	Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.
Etter halvtimen spilt sendte Zappacosta ballen til Ruben Loftus-Cheek som ventet innenfor Nottinghams 16-meter. Chelsea-midtbanemann ble taklet så det sang av Danny Fox, og Chelsea ble tildelt et soleklart straffespark.	Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fábregas farvel med engelsk fotball.
Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.	Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter walisersens landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasselubb» som Juventus, skriver Sky Sports.
Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.	Spillere som Andrij Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Alvaro Morata, har ikledd seg den blå drakten uten nevneverdig suksess.
Hans nye klubb ligger på andreplass i La Liga, fem poeng bak Barcelona. Som Sarri, har Atlético Madrid-manager Diego Simeone slitt med å få angrepsspillerne til å score.	Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.
Det ser ut til at den spanske midtbanspilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalene med Arsenal gikk i stå, skriver ESPN.	Det er denne rekken Higuaín nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.
Higuaín kommer til Chelsea med et rykte som en notorisk målscore. Kun fem spillere har scoret mer enn argentineren i topp fem-ligaene siden starten av 2006/07-sesongen.	De tok imidlertid trolig farvel med den spanske midtbanspilleren Cesc Fábregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.
Sarri ønsket Higuaín inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuaín.	Det var dermed passende at Maurizio Sarri ga Fábregas kapteinsbindet, men det ble ingen fantastisk avskjed for Fábregas – selv om det kunne blitt det.
Thorstvedt mener likevel Higuaín-overgangen var en sårt tiltrengt forsterkning i Chelsea-stallen.	Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.
Higuaín fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.	Sparket fra elleve metersmerket burde nok blitt tatt opp igjen, da en hel haug av spillere fra både Nottingham Forest og Chelsea var innenfor 16-meteren før Fábregas' avslutning:
Chelsea vant kampen 2-0, og fansen tok dermed ikke farvel med FA-cupen.	Vondt ble til verre for Fábregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.
Fábregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.	Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.
Men da en spanjol mislykkes, var det en annen som fikk det til – etter noen forsøk.	Utskjelte Morata sendte Chelsea videre da Fábregas tok farvel med Stamford Bridge
Hudson-Odoi - som jaktet av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.	(Chelsea – Nottingham Forest 2-0) Cesc Fábregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.

Figure B.48: RNN application results on the "Irrelevant" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

B.6 CNN

B.6.1 Ful Tables from Training Experiments

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	3.727	0.234	0.847	0.808	0.847	0.842	0.847	0.869	0.851	0.969	0.640	0.882
16	3.698	0.234	0.839	0.799	0.839	0.833	0.840	0.867	0.842	0.958	0.622	0.877
19	3.733	0.241	0.844	0.804	0.844	0.839	0.844	0.865	0.849	0.960	0.639	0.880
22	3.748	0.223	0.848	0.810	0.848	0.842	0.847	0.870	0.856	0.963	0.644	0.878
25	3.745	0.229	0.847	0.808	0.847	0.843	0.848	0.876	0.841	0.965	0.644	0.887
28	3.768	0.223	0.853	0.815	0.853	0.849	0.854	0.873	0.848	0.967	0.665	0.893
31	3.807	0.246	0.850	0.812	0.850	0.845	0.849	0.870	0.847	0.965	0.657	0.883
34	4.043	0.243	0.848	0.809	0.848	0.844	0.848	0.869	0.857	0.959	0.651	0.885
37	6.505	0.277	0.853	0.815	0.853	0.848	0.853	0.876	0.852	0.969	0.657	0.887
40	6.754	0.282	0.849	0.810	0.849	0.844	0.849	0.869	0.849	0.966	0.655	0.884
43	6.740	0.275	0.848	0.809	0.848	0.841	0.846	0.869	0.854	0.965	0.637	0.880
46	6.966	0.282	0.859	0.823	0.859	0.855	0.859	0.877	0.868	0.968	0.668	0.893
49	7.066	0.286	0.859	0.823	0.859	0.854	0.860	0.882	0.858	0.967	0.673	0.893
52	7.145	0.289	0.848	0.809	0.848	0.844	0.848	0.869	0.846	0.965	0.644	0.896
55	7.119	0.291	0.853	0.816	0.853	0.848	0.853	0.876	0.855	0.966	0.661	0.884
58	7.044	0.289	0.851	0.813	0.851	0.847	0.852	0.883	0.844	0.963	0.661	0.883
61	7.037	0.294	0.849	0.811	0.849	0.845	0.850	0.873	0.843	0.969	0.646	0.893
64	7.440	0.296	0.852	0.814	0.852	0.847	0.851	0.872	0.858	0.967	0.655	0.881
67	7.517	0.299	0.858	0.821	0.858	0.853	0.858	0.879	0.860	0.963	0.675	0.889
70	7.540	0.290	0.851	0.813	0.851	0.846	0.851	0.872	0.850	0.967	0.653	0.889
73	8.063	0.301	0.856	0.820	0.856	0.851	0.856	0.878	0.857	0.977	0.660	0.881
76	7.828	0.301	0.850	0.812	0.850	0.845	0.848	0.872	0.853	0.966	0.647	0.886
79	7.993	0.298	0.848	0.809	0.848	0.844	0.849	0.873	0.835	0.968	0.650	0.895
82	7.715	0.314	0.856	0.819	0.856	0.851	0.855	0.879	0.851	0.964	0.668	0.891
85	7.946	0.289	0.854	0.817	0.854	0.850	0.854	0.874	0.854	0.971	0.665	0.886
88	8.137	0.302	0.848	0.809	0.848	0.844	0.848	0.866	0.854	0.960	0.658	0.881
91	7.970	0.301	0.858	0.821	0.858	0.852	0.857	0.877	0.860	0.966	0.666	0.894
94	8.397	0.312	0.849	0.810	0.849	0.845	0.848	0.867	0.852	0.969	0.648	0.888
97	8.623	0.312	0.856	0.819	0.856	0.853	0.857	0.878	0.856	0.970	0.668	0.891
100	8.222	0.318	0.858	0.822	0.858	0.854	0.858	0.877	0.862	0.970	0.669	0.890
103	8.246	0.321	0.853	0.815	0.853	0.847	0.852	0.877	0.842	0.972	0.654	0.892
106	8.019	0.321	0.854	0.816	0.854	0.849	0.853	0.881	0.849	0.964	0.667	0.886
109	8.644	0.323	0.864	0.829	0.864	0.858	0.864	0.891	0.863	0.971	0.684	0.883
112	8.346	0.318	0.859	0.822	0.859	0.853	0.857	0.881	0.860	0.966	0.672	0.886
115	8.467	0.326	0.857	0.821	0.857	0.851	0.856	0.882	0.856	0.969	0.663	0.887
118	8.569	0.247	0.856	0.819	0.856	0.850	0.854	0.879	0.859	0.964	0.661	0.888
121	8.817	0.247	0.855	0.818	0.855	0.849	0.854	0.879	0.855	0.970	0.656	0.885
124	8.258	0.240	0.858	0.821	0.858	0.853	0.857	0.881	0.863	0.966	0.664	0.890
127	8.757	0.245	0.863	0.828	0.863	0.858	0.863	0.885	0.863	0.970	0.680	0.890
130	9.115	0.245	0.852	0.814	0.852	0.846	0.851	0.877	0.853	0.969	0.652	0.881
133	9.012	0.242	0.857	0.820	0.857	0.852	0.856	0.875	0.864	0.969	0.667	0.884
136	8.900	0.247	0.859	0.824	0.859	0.854	0.859	0.878	0.864	0.968	0.672	0.888
139	8.887	0.242	0.861	0.825	0.861	0.857	0.860	0.875	0.866	0.970	0.671	0.901
142	8.857	0.245	0.860	0.824	0.860	0.854	0.858	0.882	0.862	0.972	0.665	0.890
145	8.891	0.246	0.860	0.824	0.860	0.856	0.861	0.885	0.859	0.972	0.670	0.893
148	8.975	0.239	0.856	0.819	0.856	0.850	0.854	0.875	0.860	0.965	0.664	0.888
151	8.960	0.249	0.860	0.824	0.860	0.854	0.859	0.879	0.863	0.970	0.673	0.886
154	9.101	0.237	0.854	0.817	0.854	0.848	0.853	0.880	0.853	0.965	0.654	0.887
157	9.507	0.246	0.852	0.815	0.852	0.847	0.850	0.874	0.856	0.968	0.642	0.893
160	9.516	0.250	0.860	0.824	0.860	0.855	0.859	0.880	0.862	0.967	0.676	0.891
163	9.239	0.244	0.856	0.820	0.856	0.851	0.856	0.883	0.859	0.962	0.662	0.889
166	9.235	0.248	0.852	0.815	0.852	0.846	0.851	0.874	0.853	0.968	0.654	0.882
169	9.623	0.234	0.862	0.827	0.862	0.857	0.862	0.878	0.867	0.970	0.680	0.890
172	9.627	0.247	0.861	0.825	0.861	0.855	0.861	0.884	0.858	0.974	0.676	0.886
175	9.714	0.247	0.860	0.824	0.860	0.856	0.860	0.881	0.853	0.977	0.672	0.896
178	9.970	0.245	0.854	0.817	0.854	0.849	0.853	0.881	0.844	0.968	0.658	0.895
181	9.922	0.247	0.860	0.824	0.860	0.854	0.860	0.883	0.861	0.968	0.670	0.889
184	9.665	0.248	0.862	0.826	0.862	0.856	0.860	0.885	0.861	0.972	0.674	0.891
187	9.718	0.250	0.863	0.828	0.863	0.858	0.862	0.885	0.854	0.969	0.687	0.894
190	9.734	0.243	0.855	0.818	0.855	0.850	0.855	0.882	0.848	0.966	0.665	0.887
193	10.002	0.244	0.861	0.825	0.861	0.857	0.861	0.883	0.860	0.971	0.682	0.889
196	9.908	0.248	0.860	0.824	0.860	0.854	0.858	0.879	0.870	0.963	0.669	0.888
199	9.789	0.249	0.864	0.829	0.864	0.859	0.863	0.884	0.865	0.976	0.685	0.886
202	10.046	0.248	0.856	0.819	0.856	0.851	0.855	0.877	0.860	0.964	0.662	0.891
205	9.983	0.249	0.860	0.824	0.860	0.855	0.859	0.877	0.868	0.968	0.677	0.886
208	10.292	0.244	0.854	0.817	0.854	0.850	0.854	0.875	0.850	0.972	0.669	0.882
211	10.260	0.251	0.853	0.816	0.853	0.849	0.854	0.881	0.851	0.963	0.666	0.883
214	10.068	0.253	0.862	0.826	0.862	0.855	0.861	0.885	0.869	0.971	0.669	0.884
217	10.052	0.244	0.861	0.826	0.861	0.856	0.861	0.881	0.864	0.969	0.680	0.887
220	10.080	0.246	0.862	0.827	0.862	0.858	0.863	0.881	0.863	0.969	0.685	0.892
223	10.309	0.244	0.857	0.821	0.857	0.853	0.858	0.879	0.854	0.971	0.667	0.896
226	10.637	0.251	0.859	0.823	0.859	0.853	0.857	0.879	0.862	0.970	0.667	0.887
229	10.345	0.238	0.857	0.821	0.857	0.851	0.856	0.886	0.857	0.970	0.664	0.877
232	10.557	0.248	0.859	0.823	0.859	0.853	0.857	0.883	0.857	0.967	0.671	0.888
235	10.645	0.251	0.856	0.819	0.856	0.850	0.853	0.880	0.852	0.973	0.655	0.890
238	10.478	0.246	0.860	0.824	0.860	0.855	0.859	0.882	0.855	0.974	0.672	0.893
241	10.424	0.248	0.858	0.822	0.858	0.852	0.856	0.879	0.862	0.969	0.658	0.895
244	10.782	0.254	0.867	0.833	0.867	0.863	0.867	0.883	0.874	0.969	0.688	0.899
247	10.892	0.245	0.862	0.827	0.862	0.856	0.861	0.884	0.867	0.976	0.680	0.874

Table B.25: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 2 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	3.909	0.212	0.846	0.806	0.846	0.840	0.845	0.863	0.852	0.965	0.646	0.873
16	4.284	0.224	0.844	0.804	0.844	0.837	0.842	0.865	0.851	0.958	0.631	0.882
19	4.105	0.224	0.844	0.805	0.844	0.838	0.843	0.872	0.847	0.956	0.637	0.877
22	4.386	0.233	0.841	0.801	0.841	0.834	0.840	0.862	0.844	0.960	0.623	0.883
25	4.450	0.231	0.849	0.811	0.849	0.846	0.851	0.863	0.857	0.964	0.658	0.888
28	4.261	0.228	0.847	0.808	0.847	0.841	0.846	0.873	0.851	0.957	0.640	0.886
31	3.911	0.216	0.854	0.817	0.854	0.848	0.853	0.881	0.856	0.966	0.656	0.880
34	4.359	0.225	0.856	0.819	0.856	0.851	0.857	0.880	0.857	0.965	0.669	0.886
37	4.606	0.235	0.859	0.822	0.859	0.854	0.858	0.878	0.861	0.969	0.674	0.889
40	5.297	0.237	0.853	0.815	0.853	0.847	0.852	0.875	0.856	0.962	0.658	0.885
43	4.599	0.231	0.848	0.809	0.848	0.844	0.848	0.869	0.852	0.965	0.642	0.890
46	4.909	0.234	0.856	0.819	0.856	0.851	0.855	0.879	0.852	0.965	0.664	0.895
49	5.292	0.244	0.856	0.820	0.856	0.852	0.857	0.875	0.862	0.973	0.660	0.889
52	5.648	0.244	0.852	0.814	0.852	0.847	0.852	0.876	0.855	0.964	0.656	0.885
55	6.153	0.248	0.849	0.810	0.849	0.842	0.847	0.879	0.845	0.964	0.641	0.884
58	5.834	0.252	0.849	0.810	0.849	0.843	0.848	0.872	0.854	0.961	0.648	0.879
61	5.093	0.239	0.858	0.822	0.858	0.853	0.858	0.884	0.855	0.966	0.670	0.890
64	6.382	0.247	0.856	0.820	0.856	0.852	0.856	0.875	0.863	0.962	0.665	0.894
67	7.160	0.259	0.854	0.817	0.854	0.848	0.854	0.877	0.856	0.969	0.659	0.878
70	7.064	0.259	0.861	0.825	0.861	0.856	0.860	0.880	0.864	0.969	0.679	0.886
73	7.268	0.257	0.849	0.811	0.849	0.845	0.849	0.875	0.847	0.965	0.650	0.887
76	7.249	0.258	0.849	0.811	0.849	0.843	0.847	0.876	0.845	0.965	0.639	0.888
79	6.978	0.261	0.860	0.824	0.860	0.857	0.862	0.880	0.863	0.966	0.684	0.892
82	7.369	0.259	0.856	0.818	0.856	0.850	0.854	0.873	0.859	0.970	0.664	0.887
85	7.547	0.269	0.851	0.813	0.851	0.846	0.851	0.873	0.854	0.964	0.646	0.891
88	7.607	0.270	0.851	0.813	0.851	0.846	0.851	0.879	0.847	0.964	0.655	0.883
91	7.467	0.270	0.856	0.820	0.856	0.852	0.856	0.875	0.866	0.967	0.664	0.886
94	7.867	0.268	0.855	0.817	0.855	0.849	0.853	0.873	0.861	0.965	0.657	0.890
97	7.960	0.267	0.854	0.817	0.854	0.848	0.852	0.879	0.853	0.965	0.652	0.891
100	7.940	0.269	0.863	0.829	0.863	0.858	0.863	0.883	0.865	0.967	0.681	0.892
103	7.540	0.272	0.856	0.820	0.856	0.851	0.854	0.876	0.859	0.967	0.659	0.892
106	7.645	0.269	0.854	0.816	0.854	0.848	0.852	0.873	0.858	0.967	0.656	0.887
109	7.808	0.278	0.859	0.824	0.859	0.853	0.858	0.881	0.873	0.961	0.669	0.884
112	7.690	0.272	0.856	0.820	0.856	0.851	0.856	0.879	0.857	0.964	0.673	0.884
115	8.543	0.277	0.859	0.823	0.859	0.852	0.857	0.882	0.859	0.968	0.660	0.890
118	8.122	0.278	0.860	0.825	0.860	0.855	0.860	0.885	0.861	0.970	0.666	0.893
121	8.197	0.284	0.855	0.818	0.855	0.849	0.855	0.873	0.862	0.968	0.660	0.885
124	8.518	0.287	0.858	0.821	0.858	0.852	0.856	0.880	0.864	0.965	0.669	0.885
127	8.378	0.280	0.865	0.830	0.865	0.859	0.864	0.888	0.864	0.972	0.679	0.895
130	8.467	0.284	0.855	0.818	0.855	0.849	0.852	0.878	0.859	0.963	0.656	0.888
133	8.461	0.274	0.852	0.815	0.852	0.846	0.850	0.880	0.848	0.965	0.649	0.886
136	8.681	0.287	0.859	0.823	0.859	0.854	0.857	0.882	0.862	0.963	0.675	0.887
139	8.676	0.287	0.857	0.820	0.857	0.849	0.854	0.876	0.863	0.968	0.648	0.892
142	8.612	0.281	0.859	0.823	0.859	0.855	0.859	0.880	0.858	0.965	0.671	0.899
145	8.978	0.293	0.859	0.823	0.859	0.854	0.859	0.885	0.860	0.969	0.672	0.883
148	8.745	0.290	0.855	0.819	0.855	0.850	0.855	0.875	0.852	0.975	0.658	0.891
151	8.716	0.288	0.858	0.821	0.858	0.853	0.857	0.875	0.862	0.971	0.668	0.890
154	8.951	0.290	0.851	0.813	0.851	0.846	0.850	0.873	0.856	0.967	0.646	0.887
157	9.080	0.291	0.857	0.821	0.857	0.851	0.854	0.874	0.867	0.966	0.657	0.890
160	9.130	0.291	0.858	0.821	0.858	0.853	0.858	0.878	0.864	0.966	0.670	0.888
163	8.842	0.288	0.859	0.823	0.859	0.854	0.858	0.880	0.867	0.969	0.667	0.887
166	8.908	0.291	0.864	0.829	0.864	0.861	0.864	0.883	0.869	0.970	0.683	0.899
169	9.275	0.296	0.856	0.820	0.856	0.852	0.857	0.876	0.864	0.970	0.662	0.888
172	9.176	0.292	0.859	0.823	0.859	0.854	0.858	0.877	0.865	0.972	0.666	0.890
175	9.262	0.293	0.863	0.828	0.863	0.858	0.862	0.888	0.861	0.971	0.675	0.895
178	9.195	0.295	0.860	0.824	0.860	0.853	0.859	0.879	0.864	0.971	0.661	0.891
181	9.148	0.298	0.856	0.819	0.856	0.853	0.856	0.873	0.858	0.968	0.666	0.897
184	9.529	0.297	0.858	0.822	0.858	0.853	0.858	0.883	0.861	0.964	0.666	0.889
187	9.587	0.300	0.856	0.820	0.856	0.850	0.854	0.877	0.862	0.969	0.646	0.897
190	9.682	0.294	0.863	0.829	0.863	0.858	0.862	0.883	0.865	0.969	0.681	0.892
193	9.742	0.303	0.853	0.816	0.853	0.848	0.853	0.875	0.853	0.969	0.655	0.887
196	9.456	0.303	0.855	0.818	0.855	0.848	0.853	0.879	0.859	0.964	0.659	0.880
199	9.486	0.304	0.858	0.822	0.858	0.854	0.858	0.873	0.866	0.968	0.668	0.894
202	9.862	0.298	0.863	0.828	0.863	0.858	0.862	0.882	0.871	0.961	0.687	0.888
205	9.511	0.307	0.856	0.820	0.856	0.850	0.855	0.876	0.865	0.963	0.661	0.886
208	9.822	0.305	0.859	0.823	0.859	0.853	0.858	0.882	0.854	0.967	0.673	0.890
211	9.758	0.304	0.861	0.826	0.861	0.855	0.859	0.887	0.857	0.969	0.671	0.891
214	10.185	0.312	0.862	0.827	0.862	0.858	0.863	0.882	0.861	0.970	0.683	0.896
217	10.019	0.295	0.854	0.817	0.854	0.849	0.853	0.875	0.858	0.968	0.657	0.886
220	9.726	0.261	0.861	0.825	0.861	0.854	0.858	0.883	0.861	0.968	0.670	0.889
223	10.047	0.234	0.863	0.828	0.863	0.857	0.860	0.881	0.866	0.968	0.676	0.894
226	9.838	0.238	0.869	0.836	0.869	0.865	0.868	0.886	0.872	0.974	0.693	0.897
229	9.835	0.241	0.864	0.829	0.864	0.860	0.863	0.885	0.864	0.968	0.681	0.901
232	10.051	0.244	0.862	0.827	0.862	0.858	0.862	0.884	0.865	0.967	0.680	0.894
235	10.120	0.242	0.856	0.820	0.856	0.851	0.856	0.874	0.857	0.971	0.665	0.890
238	10.419	0.246	0.858	0.822	0.858	0.852	0.856	0.881	0.864	0.958	0.666	0.892
241	10.402	0.245	0.859	0.823	0.859	0.853	0.857	0.883	0.859	0.968	0.666	0.887
244	10.280	0.249	0.862	0.827	0.862	0.858	0.863	0.885	0.858	0.969	0.690	0.889
247	10.369	0.247	0.858	0.821	0.858	0.853	0.857	0.882	0.860	0.968	0.667	0.885

Table B.26: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 2 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.874	0.234	0.848	0.809	0.848	0.844	0.848	0.866	0.847	0.959	0.654	0.892
16	4.845	0.229	0.843	0.803	0.843	0.837	0.843	0.872	0.850	0.952	0.635	0.877
19	4.651	0.230	0.852	0.814	0.852	0.848	0.853	0.877	0.860	0.958	0.663	0.880
22	5.543	0.239	0.852	0.814	0.852	0.847	0.853	0.873	0.851	0.972	0.648	0.891
25	5.303	0.235	0.855	0.818	0.855	0.850	0.853	0.879	0.857	0.970	0.652	0.892
28	5.657	0.237	0.845	0.805	0.845	0.841	0.846	0.865	0.842	0.967	0.642	0.890
31	5.774	0.233	0.854	0.816	0.854	0.848	0.853	0.882	0.857	0.957	0.665	0.879
34	5.393	0.229	0.848	0.809	0.848	0.844	0.848	0.868	0.851	0.964	0.648	0.891
37	5.898	0.242	0.849	0.811	0.849	0.843	0.847	0.872	0.853	0.955	0.650	0.886
40	5.808	0.244	0.846	0.807	0.846	0.841	0.847	0.869	0.846	0.961	0.647	0.883
43	6.016	0.242	0.853	0.816	0.853	0.848	0.854	0.881	0.859	0.966	0.657	0.877
46	6.172	0.237	0.852	0.814	0.852	0.847	0.853	0.888	0.843	0.964	0.654	0.887
49	6.697	0.237	0.855	0.818	0.855	0.849	0.853	0.875	0.863	0.962	0.659	0.889
52	6.314	0.254	0.847	0.808	0.847	0.841	0.846	0.873	0.843	0.963	0.635	0.893
55	6.549	0.248	0.855	0.818	0.855	0.850	0.854	0.875	0.859	0.968	0.659	0.887
58	6.725	0.247	0.855	0.818	0.855	0.850	0.855	0.878	0.859	0.961	0.663	0.890
61	6.959	0.250	0.849	0.811	0.849	0.844	0.848	0.875	0.847	0.956	0.646	0.894
64	6.837	0.244	0.848	0.809	0.848	0.842	0.847	0.873	0.855	0.955	0.638	0.890
67	7.199	0.248	0.857	0.820	0.857	0.852	0.856	0.880	0.859	0.966	0.667	0.887
70	7.114	0.245	0.859	0.823	0.859	0.854	0.859	0.882	0.858	0.963	0.682	0.888
73	6.897	0.248	0.855	0.818	0.855	0.849	0.853	0.878	0.859	0.964	0.660	0.883
76	7.152	0.253	0.861	0.825	0.861	0.855	0.861	0.882	0.867	0.965	0.676	0.887
79	7.130	0.254	0.853	0.816	0.853	0.850	0.853	0.874	0.853	0.963	0.658	0.901
82	7.272	0.253	0.855	0.818	0.855	0.851	0.855	0.877	0.854	0.964	0.660	0.898
85	7.420	0.249	0.858	0.822	0.858	0.853	0.856	0.879	0.863	0.962	0.666	0.895
88	7.477	0.254	0.856	0.820	0.856	0.851	0.855	0.879	0.861	0.964	0.668	0.885
91	7.140	0.252	0.854	0.817	0.854	0.850	0.854	0.873	0.860	0.968	0.655	0.893
94	7.544	0.257	0.848	0.810	0.848	0.841	0.846	0.870	0.854	0.960	0.638	0.885
97	7.879	0.256	0.857	0.820	0.857	0.851	0.855	0.885	0.855	0.959	0.668	0.887
100	7.632	0.255	0.856	0.819	0.856	0.852	0.856	0.872	0.857	0.966	0.668	0.898
103	7.820	0.246	0.853	0.817	0.853	0.846	0.852	0.878	0.860	0.962	0.643	0.886
106	7.893	0.255	0.853	0.816	0.853	0.849	0.854	0.876	0.857	0.969	0.660	0.881
109	8.448	0.256	0.860	0.824	0.860	0.854	0.858	0.879	0.866	0.969	0.661	0.896
112	7.785	0.260	0.858	0.822	0.858	0.852	0.857	0.879	0.862	0.967	0.658	0.891
115	7.995	0.254	0.849	0.811	0.849	0.843	0.847	0.874	0.845	0.968	0.641	0.888
118	8.228	0.256	0.859	0.823	0.859	0.856	0.860	0.881	0.858	0.972	0.677	0.890
121	8.360	0.260	0.855	0.818	0.855	0.849	0.855	0.882	0.850	0.959	0.668	0.888
124	7.961	0.257	0.858	0.822	0.858	0.852	0.856	0.880	0.858	0.971	0.660	0.892
127	8.182	0.263	0.847	0.807	0.847	0.840	0.844	0.874	0.848	0.960	0.633	0.886
130	8.711	0.267	0.859	0.824	0.859	0.854	0.859	0.878	0.861	0.972	0.672	0.887
133	8.645	0.265	0.859	0.824	0.859	0.853	0.858	0.883	0.861	0.963	0.665	0.895
136	8.885	0.266	0.853	0.815	0.853	0.847	0.851	0.876	0.858	0.961	0.647	0.895
139	8.694	0.266	0.859	0.823	0.859	0.853	0.857	0.879	0.859	0.972	0.657	0.896
142	8.592	0.254	0.863	0.828	0.863	0.858	0.862	0.886	0.866	0.962	0.680	0.896
145	8.753	0.271	0.855	0.818	0.855	0.851	0.855	0.881	0.848	0.965	0.663	0.896
148	8.843	0.262	0.849	0.811	0.849	0.842	0.847	0.874	0.853	0.961	0.641	0.881
151	8.749	0.268	0.850	0.812	0.850	0.844	0.848	0.871	0.859	0.963	0.646	0.881
154	8.853	0.273	0.857	0.821	0.857	0.850	0.855	0.877	0.866	0.961	0.655	0.892
157	8.980	0.261	0.865	0.830	0.865	0.859	0.863	0.886	0.871	0.967	0.687	0.883
160	8.949	0.270	0.858	0.821	0.858	0.852	0.855	0.884	0.858	0.965	0.662	0.890
163	9.066	0.274	0.856	0.819	0.856	0.850	0.854	0.877	0.861	0.960	0.659	0.892
166	8.966	0.263	0.853	0.816	0.853	0.848	0.855	0.880	0.852	0.949	0.670	0.891
169	9.497	0.276	0.858	0.822	0.858	0.853	0.858	0.880	0.865	0.963	0.669	0.887
172	9.125	0.269	0.857	0.821	0.857	0.852	0.857	0.881	0.854	0.965	0.667	0.893
175	9.196	0.270	0.851	0.812	0.851	0.845	0.850	0.876	0.854	0.963	0.649	0.884
178	9.368	0.279	0.857	0.821	0.857	0.851	0.857	0.887	0.849	0.957	0.671	0.894
181	9.065	0.276	0.856	0.820	0.856	0.850	0.855	0.882	0.863	0.957	0.657	0.890
184	9.264	0.269	0.856	0.820	0.856	0.851	0.855	0.881	0.858	0.964	0.657	0.895
187	9.396	0.275	0.857	0.821	0.857	0.853	0.858	0.878	0.856	0.964	0.668	0.899
190	9.326	0.276	0.853	0.815	0.853	0.847	0.850	0.879	0.859	0.958	0.650	0.888
193	9.613	0.283	0.858	0.823	0.858	0.852	0.857	0.878	0.860	0.963	0.671	0.890
196	9.869	0.281	0.852	0.814	0.852	0.847	0.851	0.869	0.863	0.965	0.656	0.880
199	9.743	0.277	0.860	0.825	0.860	0.856	0.860	0.878	0.862	0.970	0.678	0.893
202	9.683	0.271	0.855	0.818	0.855	0.850	0.854	0.882	0.851	0.964	0.662	0.893
205	9.757	0.275	0.857	0.821	0.857	0.852	0.857	0.879	0.865	0.966	0.669	0.880
208	9.579	0.276	0.857	0.820	0.857	0.852	0.856	0.880	0.857	0.964	0.668	0.892
211	9.821	0.276	0.856	0.820	0.856	0.849	0.853	0.882	0.865	0.955	0.658	0.886
214	9.690	0.279	0.862	0.827	0.862	0.857	0.862	0.889	0.858	0.965	0.675	0.896
217	9.759	0.281	0.854	0.817	0.854	0.849	0.853	0.877	0.856	0.961	0.657	0.891
220	9.693	0.281	0.858	0.822	0.858	0.852	0.856	0.881	0.860	0.962	0.659	0.896
223	10.240	0.273	0.855	0.819	0.855	0.849	0.854	0.882	0.858	0.960	0.658	0.890
226	9.837	0.283	0.862	0.826	0.862	0.856	0.860	0.886	0.855	0.969	0.676	0.898
229	10.051	0.284	0.862	0.827	0.862	0.857	0.861	0.885	0.861	0.971	0.672	0.894
232	10.002	0.289	0.859	0.823	0.859	0.852	0.856	0.878	0.865	0.963	0.665	0.892
235	9.801	0.283	0.858	0.822	0.858	0.853	0.857	0.881	0.861	0.961	0.676	0.884
238	9.935	0.287	0.859	0.823	0.859	0.852	0.856	0.882	0.864	0.962	0.659	0.895
241	10.225	0.282	0.852	0.814	0.852	0.846	0.850	0.878	0.845	0.967	0.650	0.889
244	10.228	0.281	0.858	0.822	0.858	0.852	0.856	0.880	0.863	0.969	0.656	0.892
247	10.207	0.285	0.857	0.820	0.857	0.852	0.857	0.882	0.844	0.972	0.666	0.898

Table B.27: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 2 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.877	0.224	0.844	0.804	0.844	0.839	0.844	0.872	0.844	0.954	0.645	0.880
16	5.160	0.227	0.841	0.801	0.841	0.835	0.841	0.870	0.843	0.955	0.622	0.887
19	4.994	0.234	0.855	0.818	0.855	0.853	0.859	0.874	0.861	0.961	0.672	0.896
22	5.018	0.232	0.851	0.814	0.851	0.848	0.854	0.876	0.852	0.956	0.670	0.886
25	5.778	0.230	0.849	0.810	0.849	0.844	0.850	0.874	0.849	0.961	0.651	0.885
28	5.444	0.232	0.845	0.805	0.845	0.841	0.846	0.875	0.837	0.953	0.646	0.892
31	5.667	0.236	0.856	0.819	0.856	0.852	0.857	0.875	0.864	0.958	0.666	0.898
34	5.770	0.238	0.859	0.823	0.859	0.853	0.857	0.886	0.864	0.958	0.664	0.891
37	6.147	0.237	0.849	0.810	0.849	0.843	0.848	0.879	0.852	0.957	0.652	0.872
40	6.099	0.238	0.852	0.815	0.852	0.847	0.852	0.875	0.856	0.957	0.664	0.886
43	5.865	0.227	0.843	0.803	0.843	0.838	0.842	0.869	0.843	0.960	0.634	0.882
46	6.378	0.242	0.849	0.810	0.849	0.842	0.847	0.878	0.858	0.958	0.639	0.877
49	6.007	0.235	0.856	0.819	0.856	0.851	0.856	0.873	0.862	0.965	0.660	0.896
52	6.485	0.240	0.853	0.816	0.853	0.848	0.853	0.878	0.858	0.959	0.656	0.890
55	6.457	0.237	0.851	0.813	0.851	0.844	0.851	0.876	0.864	0.962	0.645	0.873
58	6.842	0.243	0.849	0.811	0.849	0.843	0.848	0.880	0.847	0.959	0.651	0.877
61	6.614	0.247	0.858	0.822	0.858	0.852	0.856	0.884	0.866	0.955	0.663	0.893
64	7.119	0.235	0.862	0.827	0.862	0.858	0.862	0.882	0.865	0.964	0.680	0.899
67	7.307	0.238	0.855	0.818	0.855	0.850	0.853	0.879	0.860	0.954	0.660	0.895
70	7.070	0.234	0.846	0.807	0.846	0.841	0.847	0.872	0.857	0.952	0.645	0.879
73	7.233	0.236	0.853	0.816	0.853	0.848	0.852	0.877	0.863	0.963	0.652	0.884
76	7.370	0.248	0.849	0.811	0.849	0.844	0.850	0.871	0.856	0.949	0.647	0.894
79	7.159	0.245	0.853	0.816	0.853	0.848	0.853	0.874	0.859	0.957	0.658	0.893
82	7.317	0.247	0.854	0.817	0.854	0.848	0.853	0.881	0.855	0.956	0.649	0.899
85	8.017	0.244	0.852	0.815	0.852	0.843	0.849	0.875	0.866	0.962	0.631	0.881
88	7.603	0.244	0.855	0.819	0.855	0.849	0.854	0.876	0.857	0.960	0.661	0.890
91	7.654	0.251	0.857	0.820	0.857	0.851	0.855	0.885	0.855	0.956	0.662	0.895
94	8.006	0.249	0.853	0.815	0.853	0.847	0.850	0.876	0.861	0.949	0.651	0.895
97	6.724	0.224	0.855	0.819	0.855	0.849	0.853	0.877	0.869	0.959	0.652	0.886
100	4.392	0.197	0.855	0.818	0.855	0.849	0.855	0.879	0.851	0.963	0.655	0.896
103	4.060	0.204	0.855	0.818	0.855	0.851	0.855	0.878	0.857	0.961	0.657	0.902
106	4.187	0.214	0.855	0.818	0.855	0.849	0.854	0.881	0.861	0.961	0.656	0.887
109	4.578	0.272	0.853	0.816	0.853	0.846	0.850	0.876	0.869	0.953	0.644	0.887
112	4.675	0.258	0.854	0.817	0.854	0.850	0.855	0.872	0.866	0.961	0.663	0.886
115	4.735	0.254	0.851	0.813	0.851	0.846	0.851	0.875	0.851	0.953	0.661	0.887
118	4.768	0.261	0.856	0.820	0.856	0.851	0.856	0.884	0.855	0.964	0.666	0.889
121	4.722	0.258	0.856	0.819	0.856	0.850	0.854	0.878	0.859	0.963	0.655	0.897
124	4.870	0.277	0.847	0.808	0.847	0.839	0.845	0.876	0.852	0.952	0.640	0.878
127	4.777	0.247	0.854	0.816	0.854	0.850	0.854	0.875	0.855	0.954	0.672	0.893
130	4.913	0.347	0.854	0.817	0.854	0.848	0.852	0.880	0.856	0.951	0.657	0.893
133	5.128	0.507	0.848	0.809	0.848	0.840	0.846	0.872	0.858	0.950	0.639	0.883
136	5.990	0.410	0.855	0.818	0.855	0.849	0.854	0.881	0.861	0.957	0.653	0.893
139	5.032	0.223	0.856	0.819	0.856	0.850	0.853	0.877	0.861	0.959	0.663	0.891
142	4.587	0.233	0.855	0.818	0.855	0.849	0.853	0.882	0.857	0.953	0.661	0.891
145	5.062	0.270	0.853	0.816	0.853	0.846	0.851	0.883	0.860	0.951	0.653	0.886
148	5.022	0.285	0.857	0.821	0.857	0.852	0.856	0.877	0.864	0.958	0.667	0.893
151	5.044	0.265	0.853	0.816	0.853	0.846	0.851	0.878	0.858	0.951	0.659	0.886
154	5.127	0.292	0.849	0.811	0.849	0.840	0.845	0.880	0.851	0.952	0.632	0.886
157	5.149	0.293	0.860	0.825	0.860	0.855	0.860	0.887	0.857	0.962	0.673	0.895
160	5.142	0.282	0.853	0.816	0.853	0.847	0.852	0.871	0.868	0.956	0.657	0.886
163	5.268	0.294	0.856	0.819	0.856	0.849	0.854	0.875	0.865	0.962	0.653	0.892
166	5.298	0.344	0.853	0.815	0.853	0.846	0.851	0.879	0.859	0.952	0.662	0.880
169	5.817	0.464	0.853	0.816	0.853	0.843	0.849	0.876	0.867	0.951	0.638	0.885
172	5.561	0.221	0.855	0.819	0.855	0.850	0.855	0.879	0.861	0.963	0.662	0.887
175	4.647	0.214	0.857	0.820	0.857	0.851	0.855	0.879	0.862	0.958	0.667	0.890
178	5.220	0.289	0.850	0.812	0.850	0.845	0.850	0.872	0.856	0.951	0.650	0.897
181	5.311	0.276	0.853	0.816	0.853	0.844	0.849	0.878	0.864	0.951	0.634	0.891
184	5.390	0.283	0.854	0.817	0.854	0.847	0.851	0.877	0.853	0.961	0.651	0.892
187	5.413	0.279	0.851	0.813	0.851	0.843	0.849	0.877	0.863	0.955	0.639	0.882
190	5.522	0.269	0.849	0.811	0.849	0.843	0.848	0.875	0.858	0.957	0.637	0.886
193	5.451	0.267	0.854	0.817	0.854	0.848	0.854	0.882	0.858	0.957	0.656	0.887
196	5.475	0.296	0.856	0.819	0.856	0.850	0.854	0.880	0.863	0.955	0.657	0.893
199	5.731	0.415	0.847	0.808	0.847	0.841	0.846	0.872	0.846	0.961	0.646	0.881
202	6.607	0.405	0.852	0.815	0.852	0.846	0.850	0.878	0.863	0.948	0.651	0.888
205	5.504	0.234	0.854	0.817	0.854	0.849	0.854	0.879	0.858	0.955	0.663	0.891
208	4.964	0.212	0.856	0.820	0.856	0.851	0.855	0.877	0.859	0.962	0.664	0.894
211	5.001	0.215	0.854	0.817	0.854	0.850	0.854	0.870	0.862	0.955	0.665	0.895
214	5.036	0.217	0.858	0.822	0.858	0.851	0.856	0.876	0.866	0.963	0.664	0.886
217	5.065	0.211	0.854	0.816	0.854	0.846	0.851	0.887	0.860	0.959	0.647	0.877
220	5.107	0.225	0.852	0.815	0.852	0.845	0.850	0.879	0.854	0.952	0.650	0.891
223	5.127	0.218	0.854	0.817	0.854	0.847	0.852	0.879	0.854	0.960	0.651	0.893
226	5.169	0.217	0.851	0.814	0.851	0.845	0.850	0.875	0.857	0.951	0.652	0.892
229	5.183	0.212	0.860	0.825	0.860	0.854	0.859	0.889	0.866	0.953	0.668	0.895
232	5.232	0.218	0.855	0.819	0.855	0.848	0.854	0.880	0.866	0.957	0.646	0.890
235	5.574	0.221	0.852	0.815	0.852	0.845	0.850	0.875	0.860	0.961	0.640	0.890
238	6.362	0.231	0.859	0.823	0.859	0.854	0.858	0.881	0.862	0.963	0.669	0.892
241	5.519	0.242	0.854	0.817	0.854	0.848	0.853	0.883	0.855	0.958	0.655	0.889
244	5.715	0.230	0.847	0.809	0.847	0.839	0.845	0.875	0.858	0.947	0.630	0.885
247	5.770	0.226	0.851	0.813	0.851	0.844	0.849	0.881	0.861	0.954	0.647	0.878

Table B.28: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 2 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.969	0.249	0.847	0.808	0.847	0.842	0.847	0.858	0.861	0.972	0.644	0.874
16	6.637	0.264	0.836	0.794	0.836	0.833	0.839	0.864	0.835	0.959	0.632	0.875
19	6.034	0.263	0.847	0.808	0.847	0.843	0.849	0.866	0.847	0.969	0.660	0.874
22	6.507	0.260	0.845	0.806	0.845	0.841	0.846	0.863	0.853	0.970	0.647	0.874
25	6.143	0.262	0.851	0.812	0.851	0.847	0.851	0.866	0.855	0.974	0.652	0.888
28	6.229	0.272	0.853	0.816	0.853	0.851	0.855	0.865	0.855	0.976	0.672	0.886
31	6.488	0.262	0.853	0.816	0.853	0.849	0.855	0.878	0.847	0.971	0.669	0.882
34	6.829	0.270	0.855	0.818	0.855	0.851	0.856	0.878	0.848	0.972	0.681	0.878
37	6.738	0.284	0.848	0.808	0.848	0.845	0.850	0.871	0.839	0.975	0.657	0.881
40	6.540	0.272	0.857	0.821	0.857	0.853	0.857	0.877	0.855	0.972	0.672	0.891
43	7.155	0.282	0.850	0.812	0.850	0.847	0.852	0.865	0.865	0.970	0.654	0.881
46	6.796	0.276	0.852	0.814	0.852	0.848	0.853	0.872	0.857	0.971	0.662	0.879
49	6.744	0.281	0.851	0.813	0.851	0.847	0.852	0.874	0.854	0.972	0.672	0.861
52	7.366	0.285	0.860	0.825	0.860	0.857	0.862	0.885	0.857	0.969	0.686	0.888
55	7.092	0.287	0.856	0.818	0.856	0.851	0.856	0.874	0.859	0.975	0.665	0.883
58	7.327	0.288	0.860	0.824	0.860	0.857	0.863	0.884	0.857	0.976	0.681	0.884
61	7.273	0.286	0.850	0.812	0.850	0.846	0.852	0.872	0.847	0.969	0.658	0.883
64	7.339	0.293	0.858	0.822	0.858	0.855	0.862	0.878	0.858	0.972	0.688	0.881
67	7.430	0.289	0.860	0.824	0.860	0.857	0.861	0.874	0.863	0.971	0.689	0.887
70	7.658	0.302	0.855	0.818	0.855	0.852	0.856	0.874	0.854	0.976	0.672	0.882
73	7.426	0.295	0.849	0.811	0.849	0.846	0.851	0.867	0.852	0.969	0.658	0.885
76	7.860	0.305	0.858	0.821	0.858	0.855	0.860	0.879	0.854	0.967	0.686	0.888
79	7.844	0.299	0.860	0.824	0.860	0.856	0.860	0.881	0.864	0.977	0.677	0.879
82	8.393	0.305	0.855	0.817	0.855	0.850	0.855	0.879	0.850	0.976	0.665	0.878
85	8.083	0.305	0.853	0.815	0.853	0.849	0.854	0.877	0.847	0.972	0.665	0.881
88	7.909	0.310	0.860	0.824	0.860	0.856	0.861	0.880	0.857	0.975	0.681	0.885
91	8.588	0.310	0.857	0.821	0.857	0.854	0.860	0.881	0.853	0.977	0.672	0.889
94	8.216	0.313	0.859	0.823	0.859	0.855	0.860	0.884	0.855	0.977	0.675	0.884
97	8.476	0.317	0.856	0.820	0.856	0.853	0.857	0.877	0.853	0.975	0.671	0.889
100	8.143	0.313	0.864	0.829	0.864	0.858	0.863	0.881	0.867	0.976	0.679	0.889
103	8.530	0.323	0.855	0.818	0.855	0.852	0.857	0.875	0.856	0.975	0.665	0.887
106	8.294	0.326	0.860	0.824	0.860	0.856	0.861	0.883	0.857	0.976	0.680	0.883
109	8.674	0.320	0.863	0.828	0.863	0.860	0.865	0.885	0.857	0.972	0.689	0.895
112	9.039	0.324	0.859	0.822	0.859	0.854	0.858	0.873	0.861	0.972	0.672	0.894
115	8.798	0.334	0.860	0.824	0.860	0.855	0.859	0.883	0.856	0.974	0.669	0.892
118	8.796	0.252	0.859	0.823	0.859	0.856	0.860	0.876	0.861	0.975	0.686	0.880
121	8.939	0.252	0.858	0.822	0.858	0.856	0.861	0.873	0.865	0.973	0.679	0.889
124	8.699	0.242	0.865	0.831	0.865	0.862	0.867	0.883	0.865	0.976	0.691	0.894
127	9.036	0.250	0.864	0.829	0.864	0.861	0.865	0.880	0.863	0.974	0.691	0.896
130	8.888	0.253	0.858	0.822	0.858	0.854	0.859	0.880	0.858	0.973	0.676	0.883
133	9.237	0.250	0.863	0.828	0.863	0.859	0.863	0.881	0.867	0.973	0.685	0.888
136	9.325	0.247	0.866	0.832	0.866	0.864	0.868	0.881	0.865	0.977	0.693	0.903
139	9.337	0.246	0.857	0.820	0.857	0.852	0.857	0.879	0.855	0.974	0.671	0.882
142	9.223	0.242	0.863	0.828	0.863	0.859	0.863	0.882	0.867	0.976	0.680	0.888
145	9.412	0.245	0.864	0.829	0.864	0.861	0.866	0.883	0.863	0.977	0.693	0.889
148	9.512	0.238	0.858	0.822	0.858	0.855	0.860	0.882	0.852	0.975	0.668	0.897
151	9.538	0.249	0.863	0.828	0.863	0.861	0.865	0.883	0.857	0.974	0.691	0.899
154	9.165	0.241	0.862	0.827	0.862	0.858	0.864	0.886	0.863	0.977	0.680	0.887
157	9.616	0.253	0.857	0.820	0.857	0.852	0.858	0.874	0.863	0.972	0.667	0.886
160	9.607	0.248	0.861	0.825	0.861	0.858	0.863	0.881	0.860	0.976	0.682	0.890
163	9.464	0.260	0.863	0.828	0.863	0.861	0.865	0.877	0.864	0.977	0.689	0.896
166	9.799	0.245	0.864	0.829	0.864	0.859	0.864	0.880	0.867	0.979	0.683	0.890
169	9.946	0.248	0.865	0.830	0.865	0.861	0.865	0.879	0.862	0.973	0.693	0.897
172	9.876	0.244	0.863	0.828	0.863	0.859	0.864	0.884	0.864	0.978	0.681	0.890
175	9.647	0.248	0.856	0.820	0.856	0.853	0.858	0.880	0.853	0.972	0.676	0.885
178	9.817	0.240	0.865	0.831	0.865	0.861	0.865	0.884	0.867	0.970	0.689	0.895
181	10.001	0.253	0.859	0.823	0.859	0.856	0.860	0.873	0.864	0.973	0.675	0.894
184	10.033	0.250	0.864	0.830	0.864	0.861	0.865	0.880	0.866	0.977	0.686	0.896
187	9.879	0.245	0.863	0.828	0.863	0.860	0.863	0.881	0.863	0.973	0.682	0.899
190	9.991	0.248	0.863	0.828	0.863	0.859	0.864	0.882	0.858	0.974	0.692	0.891
193	9.974	0.252	0.860	0.824	0.860	0.857	0.862	0.878	0.862	0.979	0.676	0.891
196	10.175	0.245	0.859	0.823	0.859	0.856	0.860	0.874	0.860	0.975	0.675	0.895
199	10.358	0.248	0.864	0.829	0.864	0.860	0.864	0.876	0.867	0.977	0.689	0.892
202	10.369	0.251	0.863	0.828	0.863	0.860	0.866	0.880	0.863	0.976	0.692	0.889
205	10.290	0.248	0.865	0.830	0.865	0.862	0.867	0.885	0.861	0.974	0.689	0.899
208	10.347	0.252	0.865	0.830	0.865	0.861	0.865	0.883	0.866	0.972	0.692	0.892
211	10.299	0.249	0.862	0.827	0.862	0.857	0.861	0.888	0.854	0.971	0.684	0.887
214	10.502	0.256	0.866	0.831	0.866	0.861	0.866	0.888	0.865	0.976	0.692	0.886
217	10.321	0.249	0.865	0.831	0.865	0.862	0.866	0.879	0.867	0.973	0.697	0.893
220	9.896	0.242	0.865	0.830	0.865	0.862	0.866	0.884	0.855	0.978	0.691	0.902
223	10.313	0.248	0.869	0.836	0.869	0.865	0.870	0.890	0.869	0.976	0.699	0.893
226	10.428	0.255	0.864	0.829	0.864	0.859	0.864	0.879	0.868	0.978	0.681	0.891
229	10.533	0.252	0.860	0.825	0.860	0.859	0.864	0.878	0.857	0.975	0.684	0.900
232	10.590	0.250	0.863	0.828	0.863	0.859	0.864	0.887	0.861	0.976	0.684	0.886
235	10.819	0.254	0.865	0.831	0.865	0.861	0.864	0.880	0.868	0.979	0.683	0.892
238	10.690	0.248	0.867	0.833	0.867	0.863	0.868	0.885	0.871	0.973	0.698	0.889
241	10.783	0.253	0.863	0.828	0.863	0.859	0.863	0.885	0.854	0.974	0.689	0.893
244	10.701	0.245	0.867	0.833	0.867	0.863	0.868	0.885	0.872	0.978	0.690	0.891
247	10.979	0.254	0.870	0.836	0.870	0.867	0.870	0.888	0.867	0.978	0.701	0.900

Table B.29: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 3 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.309	0.236	0.847	0.808	0.847	0.844	0.848	0.862	0.853	0.969	0.649	0.885
16	5.223	0.230	0.848	0.808	0.848	0.843	0.847	0.869	0.849	0.970	0.646	0.884
19	5.501	0.242	0.851	0.813	0.851	0.848	0.853	0.874	0.850	0.975	0.659	0.882
22	5.615	0.242	0.856	0.819	0.856	0.854	0.859	0.876	0.855	0.972	0.672	0.893
25	5.957	0.241	0.854	0.816	0.854	0.851	0.854	0.869	0.856	0.975	0.667	0.885
28	5.976	0.256	0.848	0.809	0.848	0.844	0.850	0.868	0.847	0.967	0.657	0.884
31	5.536	0.258	0.847	0.807	0.847	0.844	0.848	0.863	0.853	0.968	0.658	0.877
34	5.694	0.257	0.857	0.821	0.857	0.854	0.860	0.877	0.853	0.971	0.678	0.893
37	5.935	0.264	0.850	0.812	0.850	0.847	0.852	0.872	0.857	0.961	0.669	0.876
40	6.272	0.255	0.851	0.813	0.851	0.847	0.852	0.871	0.857	0.964	0.652	0.889
43	5.901	0.257	0.849	0.810	0.849	0.845	0.849	0.868	0.844	0.976	0.651	0.883
46	6.273	0.259	0.851	0.813	0.851	0.848	0.853	0.871	0.853	0.967	0.661	0.887
49	6.155	0.263	0.850	0.812	0.850	0.846	0.851	0.872	0.848	0.978	0.658	0.875
52	6.581	0.263	0.857	0.821	0.857	0.855	0.860	0.877	0.860	0.971	0.676	0.889
55	6.331	0.260	0.861	0.825	0.861	0.857	0.862	0.884	0.856	0.977	0.679	0.891
58	6.816	0.266	0.854	0.817	0.854	0.852	0.857	0.867	0.861	0.971	0.672	0.889
61	6.519	0.277	0.861	0.826	0.861	0.856	0.862	0.885	0.853	0.975	0.682	0.886
64	7.009	0.271	0.853	0.815	0.853	0.849	0.854	0.874	0.855	0.972	0.668	0.876
67	7.316	0.266	0.855	0.818	0.855	0.853	0.858	0.875	0.846	0.976	0.675	0.892
70	7.149	0.267	0.855	0.818	0.855	0.853	0.858	0.872	0.853	0.969	0.672	0.897
73	6.817	0.271	0.860	0.825	0.860	0.858	0.863	0.882	0.855	0.975	0.682	0.894
76	7.469	0.273	0.862	0.826	0.862	0.857	0.861	0.880	0.863	0.975	0.684	0.883
79	7.723	0.276	0.858	0.822	0.858	0.855	0.859	0.877	0.859	0.968	0.677	0.894
82	7.397	0.267	0.857	0.820	0.857	0.854	0.858	0.873	0.857	0.971	0.679	0.888
85	7.358	0.273	0.858	0.821	0.858	0.855	0.861	0.877	0.859	0.969	0.688	0.881
88	8.045	0.282	0.864	0.830	0.864	0.859	0.863	0.879	0.871	0.972	0.690	0.882
91	7.692	0.281	0.855	0.818	0.855	0.851	0.858	0.876	0.849	0.966	0.676	0.888
94	7.744	0.283	0.858	0.822	0.858	0.856	0.862	0.877	0.856	0.978	0.686	0.885
97	7.514	0.280	0.859	0.823	0.859	0.857	0.862	0.870	0.866	0.976	0.683	0.888
100	7.731	0.282	0.856	0.820	0.856	0.853	0.859	0.872	0.856	0.970	0.675	0.893
103	7.937	0.286	0.859	0.823	0.859	0.854	0.859	0.879	0.859	0.973	0.674	0.886
106	7.972	0.282	0.856	0.819	0.856	0.851	0.855	0.876	0.852	0.975	0.665	0.888
109	7.851	0.286	0.856	0.819	0.856	0.852	0.856	0.872	0.862	0.974	0.664	0.885
112	8.340	0.292	0.859	0.823	0.859	0.855	0.860	0.878	0.862	0.975	0.674	0.884
115	8.535	0.293	0.857	0.821	0.857	0.854	0.858	0.879	0.859	0.970	0.672	0.888
118	8.353	0.290	0.859	0.824	0.859	0.854	0.859	0.880	0.861	0.967	0.675	0.890
121	8.589	0.294	0.864	0.829	0.864	0.859	0.863	0.881	0.868	0.979	0.682	0.886
124	8.799	0.290	0.864	0.829	0.864	0.860	0.865	0.885	0.858	0.976	0.689	0.891
127	8.396	0.289	0.858	0.822	0.858	0.855	0.860	0.874	0.857	0.977	0.675	0.891
130	8.267	0.292	0.867	0.832	0.867	0.863	0.867	0.885	0.868	0.975	0.689	0.898
133	8.476	0.293	0.859	0.823	0.859	0.856	0.861	0.878	0.857	0.971	0.681	0.894
136	7.050	0.267	0.864	0.829	0.864	0.860	0.864	0.885	0.861	0.974	0.682	0.896
139	8.874	0.297	0.860	0.825	0.860	0.857	0.862	0.879	0.862	0.979	0.679	0.885
142	8.727	0.298	0.855	0.818	0.855	0.852	0.857	0.868	0.857	0.974	0.672	0.891
145	8.551	0.302	0.862	0.826	0.862	0.859	0.864	0.881	0.862	0.973	0.687	0.891
148	8.829	0.294	0.862	0.827	0.862	0.859	0.864	0.883	0.862	0.974	0.686	0.890
151	9.187	0.303	0.865	0.831	0.865	0.861	0.866	0.881	0.863	0.975	0.686	0.900
154	9.003	0.300	0.862	0.826	0.862	0.859	0.863	0.877	0.863	0.971	0.689	0.897
157	8.998	0.299	0.862	0.827	0.862	0.859	0.863	0.880	0.866	0.973	0.682	0.893
160	8.709	0.311	0.865	0.830	0.865	0.862	0.867	0.881	0.866	0.977	0.690	0.896
163	9.293	0.308	0.864	0.829	0.864	0.860	0.865	0.880	0.858	0.974	0.694	0.895
166	9.422	0.307	0.864	0.829	0.864	0.860	0.865	0.884	0.863	0.977	0.692	0.885
169	9.989	0.308	0.859	0.823	0.859	0.856	0.860	0.876	0.856	0.971	0.679	0.898
172	9.575	0.310	0.862	0.826	0.862	0.859	0.864	0.881	0.860	0.972	0.690	0.891
175	9.457	0.307	0.861	0.825	0.861	0.856	0.860	0.876	0.864	0.974	0.678	0.888
178	9.418	0.302	0.862	0.827	0.862	0.859	0.864	0.885	0.858	0.979	0.681	0.891
181	9.442	0.307	0.859	0.823	0.859	0.855	0.861	0.880	0.850	0.975	0.675	0.895
184	9.781	0.306	0.866	0.832	0.866	0.861	0.867	0.883	0.871	0.975	0.692	0.886
187	9.470	0.309	0.859	0.822	0.859	0.855	0.859	0.874	0.854	0.973	0.680	0.895
190	9.945	0.315	0.864	0.829	0.864	0.859	0.865	0.887	0.856	0.974	0.683	0.893
193	9.713	0.314	0.860	0.824	0.860	0.855	0.860	0.879	0.861	0.977	0.678	0.880
196	9.715	0.322	0.863	0.828	0.863	0.860	0.865	0.875	0.865	0.977	0.693	0.893
199	9.592	0.315	0.862	0.827	0.862	0.859	0.864	0.878	0.856	0.975	0.689	0.898
202	9.708	0.322	0.859	0.823	0.859	0.855	0.859	0.879	0.858	0.970	0.672	0.895
205	10.073	0.316	0.865	0.830	0.865	0.859	0.863	0.885	0.868	0.975	0.675	0.891
208	9.883	0.322	0.859	0.823	0.859	0.856	0.861	0.882	0.851	0.970	0.684	0.893
211	10.048	0.322	0.863	0.827	0.863	0.858	0.862	0.880	0.856	0.975	0.690	0.889
214	9.836	0.324	0.861	0.826	0.861	0.857	0.861	0.883	0.855	0.971	0.682	0.895
217	10.011	0.295	0.865	0.831	0.865	0.862	0.867	0.886	0.854	0.974	0.695	0.902
220	10.306	0.269	0.860	0.825	0.860	0.857	0.863	0.879	0.863	0.974	0.681	0.886
223	10.314	0.243	0.860	0.824	0.860	0.857	0.862	0.879	0.856	0.976	0.682	0.889
226	10.163	0.244	0.861	0.825	0.861	0.856	0.861	0.885	0.862	0.971	0.671	0.890
229	10.548	0.248	0.860	0.825	0.860	0.857	0.862	0.887	0.856	0.973	0.674	0.893
232	10.203	0.240	0.859	0.822	0.859	0.855	0.858	0.876	0.856	0.971	0.671	0.897
235	10.196	0.245	0.864	0.829	0.864	0.860	0.865	0.884	0.862	0.978	0.683	0.895
238	10.261	0.245	0.860	0.824	0.860	0.855	0.859	0.878	0.865	0.976	0.668	0.888
241	10.254	0.244	0.863	0.828	0.863	0.860	0.867	0.879	0.869	0.971	0.691	0.891
244	10.591	0.243	0.865	0.830	0.865	0.862	0.867	0.885	0.862	0.972	0.697	0.894
247	10.508	0.237	0.856	0.819	0.856	0.851	0.854	0.871	0.859	0.969	0.665	0.889

Table B.30: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 3 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.302	0.230	0.846	0.807	0.846	0.842	0.847	0.869	0.850	0.967	0.644	0.881
16	5.443	0.230	0.847	0.808	0.847	0.844	0.850	0.867	0.834	0.967	0.666	0.884
19	5.610	0.232	0.848	0.809	0.848	0.845	0.852	0.871	0.839	0.972	0.656	0.886
22	5.556	0.235	0.849	0.810	0.849	0.844	0.848	0.868	0.852	0.972	0.650	0.879
25	5.319	0.237	0.845	0.805	0.845	0.841	0.847	0.862	0.856	0.971	0.644	0.875
28	5.138	0.238	0.850	0.812	0.850	0.846	0.852	0.875	0.849	0.967	0.661	0.876
31	5.964	0.234	0.852	0.814	0.852	0.849	0.853	0.869	0.861	0.973	0.656	0.885
34	5.697	0.241	0.850	0.811	0.850	0.846	0.851	0.875	0.849	0.972	0.656	0.876
37	5.492	0.240	0.848	0.810	0.848	0.845	0.850	0.867	0.853	0.967	0.653	0.883
40	5.870	0.231	0.852	0.814	0.852	0.850	0.855	0.871	0.846	0.977	0.660	0.895
43	5.821	0.238	0.850	0.811	0.850	0.845	0.850	0.866	0.859	0.975	0.651	0.873
46	6.037	0.236	0.852	0.814	0.852	0.848	0.853	0.876	0.848	0.973	0.658	0.884
49	6.560	0.254	0.853	0.815	0.853	0.849	0.855	0.876	0.850	0.973	0.657	0.889
52	6.902	0.247	0.851	0.813	0.851	0.849	0.855	0.864	0.854	0.974	0.663	0.890
55	5.486	0.234	0.852	0.814	0.852	0.849	0.855	0.873	0.851	0.971	0.654	0.897
58	6.393	0.260	0.860	0.825	0.860	0.857	0.863	0.879	0.856	0.971	0.690	0.890
61	6.855	0.254	0.857	0.821	0.857	0.853	0.859	0.881	0.852	0.966	0.677	0.889
64	6.664	0.259	0.854	0.817	0.854	0.850	0.854	0.876	0.857	0.975	0.664	0.877
67	6.750	0.252	0.856	0.819	0.856	0.853	0.858	0.868	0.864	0.978	0.666	0.890
70	7.076	0.254	0.858	0.821	0.858	0.854	0.859	0.881	0.857	0.972	0.672	0.889
73	5.587	0.228	0.850	0.811	0.850	0.845	0.849	0.873	0.855	0.965	0.649	0.881
76	5.886	0.248	0.856	0.819	0.856	0.853	0.858	0.873	0.858	0.970	0.675	0.888
79	4.564	0.223	0.862	0.826	0.862	0.859	0.863	0.881	0.858	0.974	0.686	0.895
82	4.582	0.225	0.862	0.827	0.862	0.859	0.864	0.879	0.865	0.970	0.694	0.887
85	3.996	0.220	0.852	0.815	0.852	0.848	0.854	0.873	0.856	0.966	0.660	0.882
88	4.910	0.227	0.850	0.812	0.850	0.844	0.849	0.869	0.852	0.966	0.647	0.887
91	5.720	0.238	0.848	0.809	0.848	0.844	0.849	0.871	0.842	0.965	0.656	0.885
94	5.719	0.240	0.857	0.820	0.857	0.852	0.856	0.874	0.859	0.975	0.666	0.884
97	4.689	0.233	0.857	0.821	0.857	0.852	0.857	0.877	0.862	0.972	0.664	0.886
100	4.900	0.237	0.855	0.818	0.855	0.851	0.857	0.879	0.852	0.975	0.670	0.882
103	6.464	0.253	0.862	0.826	0.862	0.859	0.865	0.877	0.866	0.973	0.686	0.894
106	5.892	0.246	0.853	0.815	0.853	0.849	0.854	0.876	0.848	0.970	0.661	0.891
109	5.513	0.244	0.858	0.822	0.858	0.854	0.860	0.884	0.851	0.972	0.675	0.890
112	5.855	0.246	0.857	0.821	0.857	0.853	0.857	0.879	0.857	0.970	0.667	0.889
115	6.808	0.248	0.854	0.817	0.854	0.851	0.857	0.876	0.852	0.967	0.670	0.890
118	4.135	0.220	0.858	0.822	0.858	0.855	0.860	0.879	0.853	0.970	0.679	0.893
121	4.112	0.227	0.861	0.825	0.861	0.857	0.861	0.881	0.858	0.973	0.680	0.892
124	4.186	0.229	0.860	0.825	0.860	0.857	0.862	0.883	0.853	0.971	0.687	0.889
127	4.185	0.220	0.860	0.824	0.860	0.855	0.860	0.886	0.852	0.968	0.682	0.888
130	4.246	0.225	0.861	0.825	0.861	0.856	0.861	0.882	0.859	0.974	0.681	0.884
133	4.303	0.234	0.863	0.828	0.863	0.860	0.864	0.879	0.863	0.975	0.685	0.896
136	4.303	0.230	0.863	0.828	0.863	0.858	0.863	0.889	0.855	0.972	0.689	0.885
139	4.325	0.227	0.862	0.827	0.862	0.859	0.863	0.879	0.862	0.974	0.683	0.895
142	6.176	0.260	0.858	0.821	0.858	0.853	0.858	0.883	0.856	0.969	0.675	0.885
145	4.611	0.231	0.855	0.818	0.855	0.852	0.858	0.876	0.851	0.970	0.678	0.886
148	4.558	0.234	0.862	0.826	0.862	0.858	0.862	0.883	0.865	0.973	0.678	0.890
151	4.978	0.233	0.861	0.825	0.861	0.857	0.862	0.881	0.854	0.973	0.684	0.893
154	4.517	0.234	0.856	0.818	0.856	0.851	0.855	0.879	0.851	0.966	0.666	0.893
157	4.558	0.237	0.859	0.822	0.859	0.855	0.859	0.875	0.861	0.970	0.679	0.891
160	4.613	0.227	0.856	0.820	0.856	0.851	0.855	0.870	0.868	0.965	0.657	0.894
163	4.656	0.237	0.861	0.826	0.861	0.857	0.862	0.884	0.858	0.972	0.684	0.887
166	4.685	0.237	0.860	0.825	0.860	0.855	0.859	0.882	0.859	0.972	0.665	0.897
169	4.866	0.237	0.859	0.823	0.859	0.855	0.860	0.883	0.849	0.973	0.677	0.895
172	4.882	0.247	0.860	0.824	0.860	0.856	0.861	0.882	0.860	0.967	0.681	0.889
175	4.917	0.242	0.859	0.823	0.859	0.855	0.860	0.872	0.864	0.971	0.673	0.897
178	6.664	0.246	0.856	0.819	0.856	0.850	0.855	0.873	0.866	0.973	0.660	0.880
181	5.056	0.244	0.862	0.827	0.862	0.858	0.862	0.882	0.860	0.966	0.681	0.901
184	5.286	0.244	0.864	0.829	0.864	0.860	0.864	0.877	0.866	0.974	0.685	0.898
187	5.701	0.250	0.867	0.833	0.867	0.863	0.868	0.885	0.875	0.972	0.693	0.891
190	5.112	0.245	0.860	0.825	0.860	0.857	0.861	0.879	0.863	0.970	0.678	0.892
193	5.209	0.250	0.866	0.832	0.866	0.862	0.866	0.882	0.867	0.975	0.690	0.896
196	5.300	0.247	0.855	0.818	0.855	0.850	0.855	0.873	0.857	0.966	0.672	0.884
199	5.265	0.248	0.857	0.821	0.857	0.852	0.858	0.877	0.861	0.971	0.669	0.881
202	5.341	0.247	0.862	0.827	0.862	0.858	0.862	0.879	0.862	0.974	0.681	0.894
205	5.382	0.239	0.861	0.826	0.861	0.857	0.860	0.881	0.858	0.967	0.679	0.900
208	5.425	0.246	0.862	0.827	0.862	0.859	0.863	0.881	0.863	0.970	0.681	0.898
211	5.510	0.254	0.864	0.829	0.864	0.859	0.864	0.884	0.863	0.975	0.682	0.894
214	5.552	0.251	0.862	0.826	0.862	0.858	0.861	0.879	0.861	0.971	0.680	0.897
217	7.546	0.273	0.859	0.824	0.859	0.855	0.859	0.875	0.864	0.971	0.668	0.896
220	8.310	0.273	0.865	0.830	0.865	0.861	0.865	0.883	0.866	0.974	0.684	0.901
223	6.469	0.265	0.856	0.819	0.856	0.853	0.858	0.879	0.847	0.969	0.674	0.895
226	5.363	0.236	0.864	0.829	0.864	0.860	0.865	0.882	0.867	0.978	0.681	0.891
229	5.390	0.234	0.857	0.821	0.857	0.853	0.858	0.877	0.852	0.974	0.675	0.885
232	5.805	0.240	0.856	0.819	0.856	0.851	0.855	0.880	0.847	0.967	0.669	0.891
235	7.009	0.262	0.858	0.822	0.858	0.853	0.857	0.877	0.862	0.967	0.669	0.890
238	6.990	0.265	0.862	0.827	0.862	0.858	0.863	0.885	0.858	0.970	0.689	0.888
241	8.573	0.287	0.857	0.820	0.857	0.851	0.857	0.876	0.856	0.976	0.662	0.885
244	9.151	0.277	0.858	0.822	0.858	0.854	0.859	0.874	0.859	0.970	0.672	0.895
247	7.186	0.275	0.859	0.823	0.859	0.853	0.858	0.888	0.852	0.973	0.666	0.887

Table B.31: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 3 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	3.128	0.191	0.845	0.805	0.845	0.840	0.845	0.863	0.848	0.968	0.644	0.878
16	3.162	0.198	0.848	0.810	0.848	0.845	0.851	0.865	0.854	0.963	0.656	0.889
19	3.193	0.191	0.845	0.805	0.845	0.840	0.844	0.868	0.849	0.965	0.640	0.876
22	3.134	0.191	0.847	0.808	0.847	0.845	0.853	0.870	0.843	0.973	0.659	0.878
25	3.120	0.203	0.846	0.807	0.846	0.841	0.847	0.868	0.853	0.964	0.649	0.871
28	3.226	0.208	0.852	0.814	0.852	0.849	0.854	0.872	0.849	0.962	0.669	0.892
31	3.381	0.203	0.845	0.806	0.845	0.842	0.848	0.865	0.843	0.967	0.643	0.892
34	3.625	0.203	0.856	0.819	0.856	0.853	0.859	0.879	0.856	0.968	0.679	0.882
37	3.782	0.203	0.851	0.813	0.851	0.848	0.853	0.870	0.853	0.965	0.661	0.890
40	3.918	0.209	0.852	0.815	0.852	0.849	0.853	0.874	0.848	0.968	0.663	0.890
43	4.047	0.209	0.849	0.810	0.849	0.846	0.852	0.869	0.844	0.967	0.666	0.884
46	4.080	0.205	0.851	0.813	0.851	0.847	0.853	0.881	0.845	0.967	0.660	0.880
49	4.110	0.205	0.853	0.815	0.853	0.849	0.854	0.874	0.852	0.962	0.668	0.890
52	4.048	0.216	0.849	0.810	0.849	0.844	0.849	0.876	0.845	0.964	0.656	0.880
55	4.033	0.211	0.853	0.816	0.853	0.850	0.857	0.877	0.845	0.963	0.678	0.889
58	4.190	0.208	0.854	0.817	0.854	0.851	0.856	0.876	0.853	0.971	0.669	0.887
61	4.414	0.204	0.848	0.809	0.848	0.843	0.848	0.876	0.849	0.960	0.649	0.881
64	3.931	0.209	0.860	0.824	0.860	0.857	0.862	0.876	0.857	0.972	0.683	0.897
67	4.376	0.208	0.853	0.815	0.853	0.849	0.854	0.876	0.848	0.968	0.660	0.895
70	4.168	0.215	0.855	0.818	0.855	0.851	0.854	0.874	0.847	0.971	0.663	0.899
73	4.883	0.224	0.856	0.819	0.856	0.853	0.857	0.874	0.853	0.970	0.679	0.888
76	4.299	0.209	0.846	0.806	0.846	0.841	0.846	0.867	0.845	0.967	0.647	0.880
79	5.305	0.220	0.858	0.821	0.858	0.855	0.860	0.877	0.861	0.973	0.673	0.891
82	5.168	0.244	0.860	0.825	0.860	0.857	0.863	0.881	0.860	0.969	0.683	0.894
85	5.288	0.233	0.851	0.813	0.851	0.845	0.851	0.868	0.849	0.963	0.657	0.890
88	5.107	0.241	0.854	0.817	0.854	0.850	0.855	0.879	0.855	0.962	0.668	0.887
91	5.363	0.247	0.854	0.817	0.854	0.850	0.854	0.877	0.855	0.962	0.663	0.891
94	5.118	0.234	0.859	0.823	0.859	0.854	0.860	0.882	0.862	0.961	0.681	0.887
97	5.459	0.228	0.859	0.824	0.859	0.856	0.861	0.877	0.862	0.971	0.678	0.891
100	5.619	0.214	0.859	0.823	0.859	0.856	0.862	0.881	0.857	0.965	0.681	0.897
103	5.038	0.234	0.846	0.807	0.846	0.842	0.848	0.866	0.852	0.965	0.647	0.880
106	4.924	0.222	0.852	0.815	0.852	0.846	0.852	0.877	0.849	0.962	0.665	0.879
109	5.776	0.239	0.859	0.823	0.859	0.855	0.860	0.878	0.852	0.970	0.681	0.895
112	5.691	0.234	0.854	0.817	0.854	0.850	0.855	0.877	0.863	0.969	0.662	0.879
115	6.726	0.226	0.857	0.820	0.857	0.854	0.859	0.876	0.854	0.967	0.680	0.894
118	6.627	0.237	0.848	0.809	0.848	0.844	0.849	0.871	0.849	0.965	0.650	0.883
121	6.699	0.242	0.853	0.815	0.853	0.849	0.854	0.876	0.848	0.960	0.669	0.891
124	6.093	0.236	0.858	0.822	0.858	0.854	0.860	0.879	0.862	0.969	0.674	0.886
127	6.574	0.251	0.854	0.818	0.854	0.849	0.854	0.873	0.859	0.961	0.660	0.893
130	6.892	0.253	0.857	0.821	0.857	0.851	0.856	0.879	0.860	0.960	0.666	0.891
133	6.636	0.242	0.857	0.821	0.857	0.852	0.857	0.882	0.854	0.971	0.664	0.890
136	7.171	0.243	0.851	0.812	0.851	0.846	0.852	0.875	0.854	0.962	0.657	0.883
139	7.132	0.256	0.856	0.820	0.856	0.853	0.858	0.875	0.860	0.967	0.681	0.882
142	7.115	0.240	0.863	0.828	0.863	0.859	0.864	0.877	0.868	0.969	0.687	0.896
145	6.801	0.247	0.856	0.819	0.856	0.851	0.855	0.877	0.855	0.968	0.662	0.895
148	8.675	0.263	0.858	0.822	0.858	0.855	0.861	0.876	0.856	0.973	0.680	0.892
151	8.700	0.258	0.860	0.825	0.860	0.856	0.863	0.882	0.855	0.964	0.689	0.890
154	8.897	0.266	0.850	0.812	0.850	0.845	0.850	0.875	0.842	0.969	0.652	0.885
157	8.867	0.271	0.856	0.819	0.856	0.850	0.854	0.878	0.858	0.967	0.667	0.880
160	8.909	0.267	0.858	0.822	0.858	0.852	0.857	0.882	0.861	0.968	0.674	0.877
163	8.988	0.265	0.856	0.819	0.856	0.852	0.856	0.875	0.860	0.969	0.675	0.880
166	9.208	0.276	0.852	0.814	0.852	0.847	0.852	0.872	0.847	0.966	0.664	0.887
169	9.222	0.270	0.859	0.823	0.859	0.855	0.860	0.880	0.855	0.968	0.681	0.890
172	9.245	0.274	0.862	0.826	0.862	0.859	0.863	0.876	0.861	0.975	0.682	0.898
175	9.140	0.271	0.857	0.820	0.857	0.853	0.857	0.875	0.861	0.964	0.672	0.894
178	9.083	0.268	0.856	0.819	0.856	0.851	0.857	0.878	0.856	0.963	0.667	0.889
181	9.581	0.273	0.858	0.822	0.858	0.853	0.857	0.875	0.868	0.969	0.659	0.894
184	9.494	0.268	0.853	0.815	0.853	0.847	0.852	0.872	0.856	0.965	0.657	0.884
187	9.338	0.267	0.855	0.818	0.855	0.850	0.855	0.881	0.852	0.962	0.667	0.890
190	9.594	0.275	0.862	0.827	0.862	0.859	0.864	0.879	0.865	0.974	0.684	0.895
193	9.398	0.274	0.864	0.829	0.864	0.860	0.866	0.888	0.861	0.973	0.686	0.893
196	9.353	0.269	0.853	0.816	0.853	0.847	0.851	0.882	0.852	0.963	0.655	0.881
199	9.429	0.275	0.856	0.819	0.856	0.852	0.857	0.880	0.851	0.963	0.672	0.895
202	9.514	0.272	0.858	0.821	0.858	0.852	0.856	0.883	0.857	0.968	0.668	0.886
205	9.606	0.271	0.853	0.815	0.853	0.848	0.854	0.874	0.855	0.965	0.660	0.887
208	9.621	0.263	0.860	0.825	0.860	0.856	0.860	0.879	0.866	0.967	0.674	0.893
211	9.799	0.272	0.854	0.817	0.854	0.849	0.855	0.873	0.862	0.966	0.660	0.885
214	9.627	0.277	0.859	0.823	0.859	0.857	0.862	0.874	0.861	0.972	0.681	0.897
217	9.825	0.268	0.857	0.821	0.857	0.853	0.858	0.881	0.857	0.975	0.665	0.885
220	9.895	0.278	0.855	0.818	0.855	0.851	0.855	0.877	0.855	0.967	0.666	0.890
223	9.953	0.281	0.854	0.817	0.854	0.848	0.853	0.880	0.860	0.967	0.654	0.877
226	9.942	0.275	0.850	0.812	0.850	0.847	0.852	0.869	0.853	0.966	0.658	0.888
229	10.010	0.277	0.854	0.817	0.854	0.847	0.852	0.882	0.853	0.967	0.651	0.884
232	10.038	0.280	0.854	0.817	0.854	0.847	0.852	0.877	0.852	0.966	0.651	0.890
235	9.977	0.282	0.858	0.821	0.858	0.853	0.858	0.876	0.858	0.966	0.674	0.891
238	10.283	0.285	0.855	0.817	0.855	0.850	0.855	0.877	0.851	0.969	0.669	0.886
241	10.105	0.272	0.859	0.824	0.859	0.854	0.857	0.878	0.864	0.968	0.669	0.890
244	9.905	0.283	0.855	0.818	0.855	0.852	0.858	0.878	0.848	0.970	0.673	0.891
247	10.164	0.286	0.857	0.821	0.857	0.853	0.858	0.877	0.861	0.971	0.667	0.889

Table B.32: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 3 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	6.215	0.249	0.841	0.801	0.841	0.836	0.842	0.870	0.831	0.959	0.641	0.881
16	6.274	0.252	0.844	0.804	0.844	0.839	0.843	0.866	0.845	0.967	0.634	0.883
19	6.603	0.257	0.842	0.802	0.842	0.837	0.842	0.863	0.849	0.957	0.642	0.876
22	6.427	0.262	0.854	0.816	0.854	0.848	0.851	0.880	0.856	0.967	0.651	0.883
25	6.627	0.264	0.846	0.807	0.846	0.841	0.846	0.869	0.852	0.960	0.647	0.876
28	6.808	0.259	0.848	0.809	0.848	0.842	0.846	0.869	0.854	0.967	0.644	0.874
31	6.617	0.257	0.844	0.803	0.844	0.838	0.842	0.867	0.848	0.966	0.631	0.878
34	6.643	0.265	0.844	0.804	0.844	0.840	0.846	0.872	0.845	0.964	0.642	0.875
37	6.755	0.270	0.852	0.814	0.852	0.848	0.852	0.874	0.862	0.966	0.657	0.880
40	6.769	0.268	0.851	0.813	0.851	0.846	0.851	0.873	0.864	0.964	0.657	0.871
43	6.821	0.273	0.852	0.814	0.852	0.847	0.852	0.874	0.854	0.968	0.650	0.890
46	7.452	0.277	0.854	0.817	0.854	0.847	0.853	0.879	0.862	0.965	0.657	0.874
49	7.193	0.277	0.856	0.818	0.856	0.852	0.856	0.877	0.857	0.969	0.667	0.888
52	7.531	0.276	0.850	0.811	0.850	0.844	0.849	0.874	0.856	0.969	0.649	0.874
55	7.555	0.282	0.851	0.813	0.851	0.844	0.849	0.873	0.852	0.968	0.649	0.880
58	7.462	0.277	0.856	0.819	0.856	0.850	0.855	0.883	0.862	0.965	0.660	0.882
61	7.570	0.280	0.856	0.820	0.856	0.852	0.856	0.873	0.867	0.967	0.665	0.886
64	7.357	0.276	0.857	0.821	0.857	0.851	0.855	0.881	0.863	0.967	0.663	0.883
67	7.836	0.286	0.857	0.820	0.857	0.851	0.855	0.882	0.861	0.961	0.663	0.891
70	8.039	0.288	0.855	0.818	0.855	0.852	0.856	0.874	0.859	0.971	0.665	0.889
73	8.263	0.293	0.859	0.822	0.859	0.854	0.859	0.878	0.873	0.967	0.669	0.883
76	8.508	0.291	0.859	0.823	0.859	0.855	0.860	0.869	0.867	0.970	0.685	0.885
79	7.778	0.290	0.859	0.823	0.859	0.854	0.857	0.879	0.863	0.962	0.670	0.894
82	7.845	0.294	0.860	0.824	0.860	0.855	0.860	0.887	0.863	0.973	0.671	0.881
85	8.201	0.297	0.855	0.818	0.855	0.851	0.855	0.878	0.862	0.966	0.664	0.884
88	8.055	0.299	0.863	0.827	0.863	0.858	0.862	0.884	0.868	0.967	0.678	0.893
91	8.325	0.300	0.859	0.824	0.859	0.855	0.860	0.879	0.865	0.965	0.669	0.899
94	8.214	0.305	0.855	0.819	0.855	0.850	0.855	0.882	0.854	0.972	0.656	0.885
97	8.011	0.302	0.861	0.825	0.861	0.858	0.862	0.877	0.867	0.973	0.679	0.895
100	8.586	0.300	0.864	0.829	0.864	0.860	0.864	0.884	0.870	0.969	0.683	0.892
103	8.916	0.307	0.859	0.823	0.859	0.854	0.858	0.884	0.861	0.970	0.671	0.883
106	8.631	0.310	0.861	0.825	0.861	0.855	0.859	0.884	0.863	0.970	0.672	0.887
109	8.787	0.314	0.859	0.823	0.859	0.854	0.858	0.877	0.871	0.969	0.666	0.888
112	8.694	0.315	0.863	0.828	0.863	0.859	0.863	0.883	0.868	0.972	0.683	0.890
115	8.926	0.312	0.863	0.828	0.863	0.856	0.860	0.886	0.868	0.970	0.668	0.890
118	8.995	0.242	0.859	0.824	0.859	0.855	0.859	0.877	0.868	0.970	0.673	0.885
121	9.372	0.246	0.864	0.829	0.864	0.860	0.864	0.883	0.866	0.968	0.687	0.897
124	8.998	0.241	0.858	0.822	0.858	0.854	0.859	0.881	0.870	0.966	0.669	0.882
127	9.273	0.242	0.861	0.825	0.861	0.857	0.861	0.878	0.868	0.974	0.672	0.892
130	8.967	0.239	0.856	0.820	0.856	0.853	0.858	0.882	0.853	0.966	0.672	0.890
133	9.367	0.246	0.860	0.824	0.860	0.856	0.859	0.877	0.867	0.967	0.672	0.895
136	9.301	0.243	0.866	0.832	0.866	0.862	0.866	0.888	0.865	0.969	0.692	0.895
139	9.530	0.245	0.854	0.817	0.854	0.848	0.852	0.882	0.862	0.966	0.649	0.880
142	9.629	0.238	0.861	0.825	0.861	0.855	0.859	0.876	0.871	0.973	0.669	0.887
145	9.657	0.251	0.863	0.828	0.863	0.859	0.862	0.880	0.871	0.966	0.679	0.899
148	9.319	0.249	0.861	0.826	0.861	0.856	0.862	0.883	0.864	0.970	0.678	0.888
151	9.624	0.245	0.861	0.825	0.861	0.855	0.859	0.879	0.870	0.973	0.664	0.890
154	9.838	0.244	0.860	0.824	0.860	0.854	0.858	0.884	0.865	0.970	0.663	0.890
157	9.719	0.252	0.861	0.826	0.861	0.856	0.861	0.878	0.867	0.967	0.681	0.888
160	9.696	0.249	0.855	0.818	0.855	0.850	0.854	0.881	0.848	0.970	0.660	0.891
163	9.898	0.245	0.865	0.830	0.865	0.861	0.865	0.881	0.870	0.970	0.687	0.895
166	9.694	0.248	0.862	0.827	0.862	0.857	0.860	0.882	0.869	0.969	0.668	0.895
169	9.738	0.250	0.858	0.822	0.858	0.852	0.856	0.880	0.863	0.969	0.660	0.887
172	10.218	0.250	0.853	0.815	0.853	0.848	0.853	0.872	0.866	0.971	0.653	0.878
175	10.250	0.244	0.855	0.818	0.855	0.849	0.853	0.877	0.860	0.969	0.649	0.889
178	10.134	0.240	0.863	0.828	0.863	0.858	0.862	0.884	0.871	0.975	0.671	0.888
181	10.167	0.241	0.863	0.828	0.863	0.859	0.863	0.885	0.869	0.964	0.679	0.898
184	10.177	0.249	0.866	0.831	0.866	0.860	0.863	0.888	0.876	0.968	0.681	0.887
187	10.264	0.246	0.859	0.823	0.859	0.856	0.860	0.872	0.862	0.971	0.682	0.891
190	10.197	0.248	0.858	0.822	0.858	0.853	0.857	0.875	0.863	0.976	0.662	0.891
193	10.356	0.241	0.861	0.826	0.861	0.855	0.859	0.883	0.871	0.965	0.674	0.879
196	10.209	0.251	0.864	0.830	0.864	0.861	0.866	0.883	0.866	0.976	0.688	0.892
199	10.211	0.249	0.863	0.828	0.863	0.857	0.861	0.886	0.866	0.972	0.673	0.887
202	10.593	0.245	0.866	0.831	0.866	0.861	0.866	0.887	0.872	0.969	0.686	0.890
205	10.475	0.247	0.864	0.829	0.864	0.860	0.863	0.876	0.871	0.974	0.686	0.894
208	10.416	0.253	0.862	0.827	0.862	0.857	0.861	0.880	0.873	0.970	0.674	0.890
211	10.492	0.248	0.862	0.827	0.862	0.856	0.860	0.886	0.866	0.970	0.667	0.894
214	10.706	0.254	0.857	0.821	0.857	0.853	0.857	0.878	0.863	0.970	0.669	0.884
217	10.276	0.257	0.865	0.831	0.865	0.860	0.864	0.885	0.867	0.967	0.691	0.891
220	10.555	0.249	0.864	0.829	0.864	0.858	0.863	0.883	0.868	0.973	0.678	0.890
223	10.709	0.246	0.863	0.828	0.863	0.858	0.863	0.886	0.868	0.966	0.682	0.889
226	10.739	0.248	0.864	0.829	0.864	0.860	0.864	0.882	0.868	0.971	0.681	0.897
229	10.681	0.248	0.863	0.829	0.863	0.858	0.863	0.884	0.869	0.966	0.683	0.889
232	10.841	0.245	0.864	0.829	0.864	0.859	0.864	0.881	0.877	0.971	0.675	0.890
235	10.737	0.255	0.860	0.824	0.860	0.855	0.861	0.883	0.861	0.969	0.683	0.879
238	11.006	0.247	0.860	0.824	0.860	0.854	0.857	0.885	0.861	0.968	0.660	0.896
241	10.932	0.257	0.864	0.829	0.864	0.857	0.861	0.883	0.871	0.971	0.675	0.883
244	11.079	0.245	0.864	0.830	0.864	0.860	0.863	0.880	0.871	0.970	0.682	0.896
247	11.059	0.254	0.861	0.826	0.861	0.856	0.860	0.883	0.865	0.970	0.668	0.894

Table B.33: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 3 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.500	0.231	0.845	0.806	0.845	0.841	0.846	0.866	0.843	0.966	0.655	0.876
16	5.418	0.231	0.839	0.798	0.839	0.834	0.839	0.862	0.850	0.957	0.628	0.872
19	5.912	0.246	0.854	0.817	0.854	0.849	0.853	0.875	0.861	0.961	0.657	0.890
22	5.294	0.237	0.845	0.806	0.845	0.841	0.846	0.858	0.862	0.968	0.647	0.871
25	5.471	0.241	0.840	0.799	0.840	0.835	0.840	0.864	0.846	0.961	0.635	0.867
28	5.925	0.244	0.842	0.802	0.842	0.837	0.841	0.848	0.866	0.970	0.619	0.879
31	5.302	0.240	0.851	0.814	0.851	0.847	0.853	0.871	0.861	0.961	0.663	0.881
34	5.987	0.245	0.850	0.813	0.850	0.845	0.851	0.874	0.857	0.962	0.646	0.886
37	6.188	0.254	0.856	0.819	0.856	0.852	0.856	0.872	0.863	0.968	0.665	0.890
40	5.817	0.247	0.860	0.824	0.860	0.855	0.860	0.882	0.867	0.965	0.677	0.884
43	6.349	0.250	0.845	0.805	0.845	0.840	0.845	0.866	0.854	0.966	0.640	0.876
46	6.359	0.246	0.857	0.820	0.857	0.851	0.855	0.873	0.870	0.968	0.664	0.880
49	6.207	0.252	0.853	0.815	0.853	0.849	0.853	0.872	0.858	0.966	0.658	0.891
52	6.525	0.257	0.855	0.818	0.855	0.849	0.853	0.873	0.860	0.969	0.648	0.897
55	6.854	0.251	0.857	0.821	0.857	0.854	0.859	0.875	0.864	0.965	0.674	0.892
58	6.978	0.264	0.854	0.817	0.854	0.849	0.855	0.882	0.856	0.970	0.659	0.877
61	6.844	0.259	0.855	0.817	0.855	0.851	0.855	0.874	0.858	0.966	0.669	0.888
64	7.136	0.261	0.855	0.818	0.855	0.849	0.855	0.879	0.864	0.970	0.652	0.882
67	7.072	0.261	0.858	0.822	0.858	0.852	0.858	0.884	0.861	0.966	0.668	0.884
70	7.394	0.266	0.856	0.819	0.856	0.852	0.856	0.876	0.863	0.967	0.666	0.887
73	7.629	0.260	0.856	0.820	0.856	0.851	0.856	0.877	0.865	0.971	0.661	0.878
76	7.573	0.260	0.857	0.821	0.857	0.853	0.858	0.874	0.866	0.967	0.666	0.890
79	7.904	0.265	0.855	0.818	0.855	0.849	0.855	0.875	0.860	0.974	0.658	0.880
82	7.842	0.269	0.859	0.823	0.859	0.854	0.859	0.880	0.865	0.966	0.673	0.887
85	7.578	0.264	0.859	0.824	0.859	0.855	0.860	0.886	0.860	0.965	0.678	0.885
88	8.029	0.269	0.857	0.821	0.857	0.852	0.857	0.879	0.864	0.965	0.670	0.884
91	7.795	0.267	0.861	0.826	0.861	0.857	0.861	0.881	0.872	0.970	0.676	0.885
94	8.254	0.269	0.863	0.828	0.863	0.859	0.863	0.883	0.865	0.971	0.677	0.898
97	8.154	0.265	0.859	0.822	0.859	0.855	0.859	0.878	0.863	0.973	0.668	0.893
100	7.999	0.269	0.853	0.815	0.853	0.848	0.851	0.870	0.862	0.966	0.649	0.893
103	7.951	0.275	0.858	0.822	0.858	0.853	0.857	0.877	0.865	0.970	0.667	0.886
106	7.955	0.281	0.858	0.822	0.858	0.853	0.857	0.878	0.865	0.962	0.673	0.885
109	8.226	0.271	0.860	0.824	0.860	0.855	0.859	0.879	0.861	0.969	0.670	0.897
112	8.250	0.270	0.854	0.817	0.854	0.849	0.853	0.878	0.854	0.963	0.658	0.891
115	8.330	0.277	0.859	0.823	0.859	0.853	0.856	0.884	0.865	0.968	0.660	0.886
118	8.358	0.277	0.862	0.827	0.862	0.857	0.860	0.883	0.866	0.966	0.676	0.894
121	8.320	0.275	0.857	0.821	0.857	0.851	0.856	0.883	0.861	0.967	0.661	0.882
124	8.419	0.280	0.858	0.822	0.858	0.853	0.858	0.877	0.870	0.970	0.664	0.886
127	8.745	0.280	0.863	0.827	0.863	0.858	0.862	0.887	0.863	0.971	0.678	0.890
130	8.832	0.283	0.855	0.818	0.855	0.849	0.854	0.874	0.865	0.969	0.651	0.889
133	8.611	0.275	0.865	0.830	0.865	0.858	0.862	0.888	0.873	0.965	0.673	0.892
136	8.846	0.278	0.866	0.832	0.866	0.862	0.865	0.884	0.868	0.969	0.682	0.905
139	8.856	0.282	0.861	0.825	0.861	0.857	0.861	0.878	0.864	0.973	0.671	0.901
142	9.003	0.275	0.856	0.819	0.856	0.850	0.854	0.880	0.861	0.967	0.654	0.891
145	9.143	0.283	0.859	0.823	0.859	0.855	0.858	0.881	0.859	0.968	0.669	0.895
148	8.957	0.289	0.861	0.826	0.861	0.856	0.860	0.877	0.873	0.969	0.668	0.894
151	9.350	0.288	0.862	0.827	0.862	0.859	0.864	0.886	0.860	0.967	0.685	0.895
154	8.991	0.287	0.863	0.828	0.863	0.859	0.864	0.880	0.865	0.968	0.687	0.896
157	9.360	0.293	0.857	0.821	0.857	0.851	0.855	0.871	0.866	0.967	0.663	0.891
160	9.452	0.295	0.858	0.821	0.858	0.852	0.855	0.878	0.860	0.968	0.664	0.890
163	9.233	0.287	0.855	0.818	0.855	0.850	0.854	0.880	0.853	0.967	0.656	0.893
166	9.431	0.293	0.862	0.826	0.862	0.857	0.860	0.881	0.865	0.973	0.679	0.886
169	9.637	0.288	0.862	0.826	0.862	0.858	0.862	0.878	0.864	0.975	0.675	0.897
172	9.504	0.295	0.857	0.820	0.857	0.851	0.855	0.883	0.859	0.965	0.665	0.885
175	9.693	0.297	0.861	0.826	0.861	0.857	0.861	0.884	0.867	0.966	0.679	0.887
178	9.810	0.291	0.861	0.826	0.861	0.857	0.862	0.883	0.863	0.970	0.679	0.892
181	9.624	0.302	0.864	0.829	0.864	0.860	0.864	0.881	0.869	0.971	0.687	0.893
184	9.791	0.296	0.855	0.818	0.855	0.848	0.852	0.871	0.872	0.970	0.649	0.877
187	9.846	0.306	0.859	0.823	0.859	0.853	0.857	0.879	0.865	0.970	0.668	0.883
190	9.875	0.297	0.863	0.829	0.863	0.858	0.863	0.885	0.865	0.969	0.679	0.891
193	9.575	0.295	0.861	0.826	0.861	0.856	0.861	0.878	0.875	0.970	0.666	0.892
196	9.931	0.302	0.861	0.825	0.861	0.857	0.861	0.884	0.864	0.968	0.673	0.895
199	10.108	0.305	0.858	0.822	0.858	0.853	0.857	0.881	0.864	0.967	0.662	0.893
202	9.731	0.305	0.861	0.825	0.861	0.856	0.859	0.878	0.867	0.971	0.674	0.890
205	10.059	0.306	0.859	0.823	0.859	0.854	0.859	0.882	0.860	0.971	0.667	0.892
208	9.934	0.309	0.859	0.824	0.859	0.853	0.857	0.883	0.864	0.969	0.663	0.887
211	10.210	0.310	0.860	0.824	0.860	0.855	0.859	0.881	0.861	0.970	0.673	0.891
214	10.276	0.309	0.853	0.815	0.853	0.849	0.854	0.870	0.860	0.975	0.657	0.884
217	10.048	0.289	0.857	0.820	0.857	0.851	0.855	0.879	0.866	0.970	0.661	0.879
220	10.291	0.256	0.859	0.823	0.859	0.854	0.858	0.875	0.865	0.968	0.669	0.894
223	10.452	0.245	0.858	0.822	0.858	0.853	0.857	0.877	0.870	0.967	0.668	0.885
226	10.066	0.243	0.867	0.833	0.867	0.862	0.865	0.884	0.877	0.970	0.688	0.889
229	10.253	0.242	0.861	0.825	0.861	0.856	0.861	0.882	0.863	0.969	0.677	0.890
232	10.386	0.246	0.862	0.827	0.862	0.857	0.861	0.884	0.864	0.971	0.670	0.895
235	10.332	0.246	0.856	0.820	0.856	0.853	0.858	0.877	0.857	0.972	0.671	0.886
238	10.310	0.236	0.863	0.828	0.863	0.857	0.861	0.885	0.868	0.969	0.673	0.891
241	10.325	0.244	0.862	0.827	0.862	0.858	0.862	0.879	0.865	0.974	0.677	0.894
244	10.445	0.245	0.863	0.828	0.863	0.856	0.859	0.882	0.872	0.973	0.662	0.890
247	10.496	0.241	0.863	0.828	0.863	0.857	0.862	0.890	0.865	0.968	0.675	0.889

Table B.34: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 3 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.635	0.232	0.846	0.806	0.846	0.842	0.847	0.869	0.846	0.960	0.655	0.881
16	5.702	0.242	0.849	0.810	0.849	0.844	0.848	0.870	0.860	0.963	0.647	0.879
19	5.458	0.233	0.853	0.815	0.853	0.848	0.854	0.877	0.859	0.957	0.667	0.882
22	5.377	0.232	0.850	0.812	0.850	0.847	0.851	0.874	0.854	0.961	0.650	0.894
25	6.102	0.237	0.854	0.818	0.854	0.849	0.854	0.873	0.867	0.959	0.658	0.887
28	5.863	0.231	0.856	0.820	0.856	0.851	0.855	0.879	0.865	0.965	0.658	0.888
31	5.752	0.236	0.858	0.822	0.858	0.854	0.858	0.881	0.856	0.968	0.682	0.881
34	6.184	0.236	0.856	0.819	0.856	0.852	0.858	0.874	0.860	0.970	0.669	0.886
37	6.532	0.238	0.857	0.820	0.857	0.852	0.856	0.874	0.873	0.960	0.669	0.885
40	6.431	0.239	0.854	0.817	0.854	0.850	0.855	0.873	0.864	0.967	0.659	0.886
43	6.246	0.242	0.859	0.823	0.859	0.855	0.859	0.879	0.867	0.968	0.677	0.887
46	6.591	0.244	0.853	0.815	0.853	0.848	0.852	0.873	0.858	0.960	0.657	0.891
49	6.257	0.242	0.855	0.819	0.855	0.850	0.855	0.875	0.862	0.966	0.655	0.893
52	6.407	0.242	0.855	0.818	0.855	0.850	0.855	0.878	0.858	0.968	0.660	0.885
55	6.863	0.238	0.855	0.818	0.855	0.851	0.855	0.881	0.859	0.964	0.664	0.886
58	7.187	0.255	0.852	0.814	0.852	0.846	0.851	0.870	0.864	0.961	0.653	0.884
61	7.267	0.247	0.853	0.815	0.853	0.848	0.853	0.874	0.864	0.961	0.650	0.889
64	6.889	0.243	0.855	0.818	0.855	0.850	0.855	0.878	0.861	0.961	0.662	0.889
67	7.284	0.247	0.857	0.820	0.857	0.852	0.854	0.874	0.873	0.963	0.658	0.891
70	7.242	0.243	0.855	0.818	0.855	0.850	0.855	0.878	0.861	0.966	0.661	0.886
73	7.263	0.251	0.850	0.812	0.850	0.845	0.849	0.871	0.860	0.959	0.647	0.886
76	7.218	0.245	0.858	0.821	0.858	0.853	0.858	0.877	0.862	0.963	0.676	0.886
79	7.461	0.249	0.863	0.828	0.863	0.859	0.863	0.880	0.867	0.969	0.681	0.896
82	7.496	0.251	0.854	0.817	0.854	0.850	0.855	0.876	0.857	0.962	0.660	0.894
85	7.561	0.249	0.855	0.818	0.855	0.849	0.853	0.872	0.870	0.960	0.658	0.887
88	7.605	0.246	0.854	0.817	0.854	0.849	0.853	0.879	0.855	0.967	0.658	0.884
91	7.587	0.257	0.862	0.827	0.862	0.858	0.861	0.881	0.865	0.968	0.675	0.900
94	8.077	0.254	0.858	0.822	0.858	0.853	0.856	0.877	0.871	0.962	0.662	0.891
97	8.197	0.263	0.852	0.814	0.852	0.848	0.852	0.875	0.857	0.963	0.658	0.887
100	7.848	0.255	0.851	0.813	0.851	0.846	0.851	0.878	0.852	0.963	0.654	0.883
103	7.991	0.256	0.862	0.827	0.862	0.858	0.861	0.877	0.873	0.970	0.674	0.895
106	7.841	0.255	0.857	0.820	0.857	0.853	0.857	0.875	0.863	0.970	0.666	0.892
109	7.955	0.259	0.861	0.825	0.861	0.855	0.859	0.881	0.867	0.965	0.679	0.884
112	7.094	0.251	0.859	0.823	0.859	0.854	0.857	0.879	0.866	0.973	0.667	0.882
115	8.335	0.266	0.858	0.821	0.858	0.853	0.857	0.875	0.869	0.968	0.667	0.884
118	8.209	0.254	0.855	0.818	0.855	0.849	0.853	0.885	0.858	0.959	0.653	0.888
121	8.212	0.256	0.856	0.819	0.856	0.851	0.856	0.875	0.864	0.965	0.658	0.895
124	8.409	0.263	0.859	0.823	0.859	0.856	0.861	0.876	0.867	0.966	0.675	0.894
127	8.412	0.259	0.855	0.818	0.855	0.849	0.854	0.879	0.869	0.962	0.657	0.881
130	8.452	0.261	0.856	0.820	0.856	0.851	0.856	0.877	0.865	0.966	0.663	0.884
133	8.560	0.266	0.856	0.819	0.856	0.849	0.854	0.877	0.865	0.968	0.656	0.882
136	8.763	0.268	0.857	0.821	0.857	0.853	0.858	0.880	0.862	0.963	0.671	0.887
139	8.714	0.259	0.861	0.825	0.861	0.856	0.860	0.880	0.867	0.968	0.668	0.898
142	8.865	0.264	0.854	0.817	0.854	0.848	0.854	0.873	0.866	0.961	0.658	0.883
145	8.856	0.269	0.861	0.826	0.861	0.856	0.860	0.883	0.866	0.963	0.678	0.890
148	8.924	0.271	0.855	0.819	0.855	0.851	0.856	0.869	0.870	0.965	0.663	0.887
151	8.891	0.267	0.856	0.819	0.856	0.849	0.852	0.879	0.862	0.969	0.642	0.893
154	8.980	0.268	0.854	0.817	0.854	0.849	0.853	0.873	0.868	0.963	0.653	0.887
157	8.994	0.272	0.856	0.820	0.856	0.851	0.856	0.877	0.860	0.960	0.662	0.897
160	9.329	0.265	0.857	0.821	0.857	0.850	0.855	0.876	0.866	0.967	0.653	0.887
163	9.436	0.266	0.854	0.817	0.854	0.849	0.853	0.876	0.863	0.964	0.653	0.887
166	9.242	0.257	0.858	0.822	0.858	0.851	0.855	0.881	0.864	0.960	0.657	0.891
169	9.240	0.264	0.857	0.820	0.857	0.851	0.855	0.882	0.865	0.961	0.660	0.888
172	9.523	0.274	0.859	0.823	0.859	0.854	0.858	0.884	0.865	0.964	0.672	0.883
175	9.262	0.277	0.858	0.822	0.858	0.852	0.857	0.885	0.867	0.961	0.661	0.886
178	9.409	0.274	0.863	0.827	0.863	0.858	0.862	0.881	0.871	0.969	0.678	0.892
181	9.395	0.277	0.857	0.821	0.857	0.851	0.855	0.881	0.863	0.967	0.657	0.889
184	9.325	0.265	0.854	0.817	0.854	0.848	0.853	0.879	0.851	0.964	0.657	0.889
187	9.727	0.272	0.858	0.823	0.858	0.855	0.860	0.883	0.860	0.962	0.680	0.888
190	9.786	0.273	0.859	0.824	0.859	0.855	0.858	0.878	0.865	0.969	0.670	0.892
193	9.638	0.269	0.857	0.820	0.857	0.852	0.856	0.879	0.868	0.968	0.650	0.893
196	9.935	0.280	0.862	0.827	0.862	0.856	0.860	0.881	0.869	0.964	0.670	0.897
199	9.401	0.278	0.860	0.824	0.860	0.854	0.859	0.887	0.865	0.962	0.669	0.889
202	9.660	0.284	0.861	0.826	0.861	0.855	0.860	0.886	0.867	0.966	0.670	0.886
205	9.957	0.280	0.857	0.820	0.857	0.853	0.857	0.877	0.859	0.963	0.671	0.892
208	9.955	0.274	0.855	0.818	0.855	0.849	0.854	0.872	0.865	0.961	0.665	0.882
211	10.216	0.271	0.859	0.823	0.859	0.854	0.859	0.881	0.855	0.970	0.673	0.892
214	10.164	0.280	0.861	0.826	0.861	0.856	0.861	0.885	0.861	0.971	0.670	0.896
217	10.014	0.287	0.858	0.822	0.858	0.851	0.857	0.883	0.864	0.963	0.664	0.882
220	10.081	0.284	0.857	0.821	0.857	0.851	0.857	0.882	0.864	0.966	0.660	0.885
223	10.113	0.281	0.854	0.817	0.854	0.848	0.852	0.879	0.863	0.967	0.640	0.890
226	9.930	0.286	0.859	0.823	0.859	0.854	0.859	0.881	0.861	0.969	0.676	0.885
229	10.318	0.280	0.861	0.826	0.861	0.856	0.860	0.880	0.869	0.959	0.680	0.892
232	10.325	0.284	0.857	0.820	0.857	0.851	0.855	0.877	0.868	0.964	0.651	0.892
235	10.285	0.283	0.863	0.827	0.863	0.858	0.862	0.890	0.862	0.966	0.678	0.893
238	10.316	0.288	0.860	0.825	0.860	0.855	0.860	0.888	0.857	0.969	0.678	0.886
241	10.512	0.288	0.858	0.822	0.858	0.852	0.855	0.878	0.863	0.967	0.652	0.899
244	9.971	0.283	0.859	0.822	0.859	0.854	0.857	0.880	0.860	0.967	0.670	0.893
247	10.229	0.284	0.859	0.823	0.859	0.853	0.857	0.881	0.871	0.962	0.663	0.887

Table B.35: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 3 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.757	0.236	0.852	0.814	0.852	0.848	0.853	0.873	0.857	0.961	0.658	0.888
16	5.242	0.232	0.855	0.818	0.855	0.851	0.857	0.883	0.856	0.957	0.669	0.892
19	5.221	0.236	0.841	0.800	0.841	0.836	0.840	0.862	0.849	0.953	0.633	0.884
22	5.628	0.231	0.843	0.803	0.843	0.840	0.846	0.870	0.838	0.958	0.644	0.889
25	5.631	0.234	0.845	0.806	0.845	0.842	0.846	0.867	0.846	0.954	0.654	0.889
28	5.325	0.225	0.848	0.809	0.848	0.843	0.849	0.873	0.848	0.957	0.652	0.887
31	6.283	0.241	0.850	0.812	0.850	0.847	0.851	0.869	0.852	0.965	0.657	0.890
34	5.713	0.238	0.857	0.821	0.857	0.853	0.858	0.878	0.868	0.957	0.673	0.889
37	6.143	0.239	0.856	0.819	0.856	0.852	0.857	0.882	0.852	0.966	0.675	0.886
40	5.668	0.233	0.851	0.813	0.851	0.846	0.851	0.871	0.859	0.960	0.647	0.894
43	6.120	0.239	0.855	0.818	0.855	0.850	0.854	0.874	0.863	0.962	0.657	0.897
46	6.622	0.237	0.858	0.822	0.858	0.853	0.859	0.881	0.869	0.964	0.669	0.883
49	6.223	0.233	0.847	0.808	0.847	0.842	0.847	0.868	0.860	0.959	0.646	0.879
52	6.493	0.238	0.856	0.819	0.856	0.850	0.855	0.878	0.872	0.956	0.666	0.876
55	6.949	0.241	0.850	0.812	0.850	0.844	0.849	0.872	0.854	0.954	0.651	0.890
58	6.993	0.241	0.855	0.818	0.855	0.851	0.857	0.880	0.860	0.959	0.668	0.885
61	6.925	0.238	0.854	0.817	0.854	0.850	0.854	0.878	0.861	0.958	0.661	0.890
64	7.279	0.241	0.853	0.815	0.853	0.847	0.851	0.874	0.859	0.957	0.654	0.888
67	7.086	0.242	0.847	0.808	0.847	0.843	0.848	0.877	0.843	0.954	0.651	0.888
70	7.390	0.242	0.856	0.819	0.856	0.852	0.856	0.882	0.854	0.956	0.663	0.901
73	7.482	0.245	0.852	0.815	0.852	0.848	0.853	0.867	0.860	0.963	0.654	0.899
76	7.611	0.238	0.853	0.816	0.853	0.849	0.853	0.877	0.856	0.960	0.657	0.895
79	7.085	0.241	0.856	0.819	0.856	0.851	0.855	0.873	0.860	0.958	0.665	0.900
82	7.687	0.250	0.853	0.816	0.853	0.847	0.853	0.874	0.864	0.963	0.650	0.887
85	7.506	0.242	0.852	0.814	0.852	0.847	0.851	0.875	0.854	0.957	0.658	0.891
88	7.857	0.242	0.860	0.824	0.860	0.854	0.859	0.884	0.857	0.964	0.674	0.890
91	7.728	0.245	0.854	0.817	0.854	0.848	0.853	0.873	0.867	0.955	0.660	0.887
94	7.968	0.247	0.856	0.819	0.856	0.851	0.854	0.882	0.859	0.953	0.668	0.891
97	8.166	0.248	0.853	0.816	0.853	0.848	0.854	0.879	0.860	0.958	0.665	0.876
100	8.037	0.249	0.863	0.828	0.863	0.858	0.863	0.888	0.868	0.963	0.678	0.893
103	8.067	0.249	0.858	0.822	0.858	0.852	0.857	0.881	0.864	0.961	0.665	0.889
106	8.446	0.252	0.855	0.818	0.855	0.849	0.853	0.880	0.863	0.958	0.656	0.889
109	8.292	0.247	0.855	0.818	0.855	0.850	0.854	0.882	0.859	0.957	0.659	0.892
112	8.217	0.249	0.851	0.814	0.851	0.846	0.849	0.876	0.861	0.956	0.644	0.890
115	8.472	0.242	0.853	0.816	0.853	0.847	0.851	0.877	0.858	0.963	0.648	0.887
118	8.321	0.253	0.858	0.822	0.858	0.854	0.859	0.872	0.871	0.957	0.671	0.897
121	8.232	0.246	0.851	0.813	0.851	0.845	0.850	0.883	0.851	0.960	0.651	0.878
124	8.528	0.255	0.855	0.818	0.855	0.850	0.855	0.875	0.860	0.965	0.654	0.895
127	8.469	0.250	0.851	0.814	0.851	0.845	0.849	0.881	0.856	0.953	0.648	0.888
130	8.567	0.256	0.851	0.814	0.851	0.843	0.849	0.878	0.863	0.949	0.648	0.878
133	8.791	0.252	0.855	0.818	0.855	0.849	0.853	0.879	0.863	0.959	0.661	0.883
136	8.960	0.255	0.857	0.821	0.857	0.852	0.857	0.877	0.869	0.962	0.671	0.883
139	8.442	0.256	0.861	0.825	0.861	0.856	0.860	0.883	0.863	0.964	0.676	0.894
142	8.869	0.260	0.855	0.818	0.855	0.848	0.854	0.877	0.863	0.961	0.654	0.886
145	8.763	0.254	0.851	0.813	0.851	0.846	0.850	0.878	0.856	0.954	0.656	0.887
148	8.576	0.248	0.858	0.822	0.858	0.853	0.858	0.882	0.860	0.960	0.666	0.898
151	9.147	0.255	0.857	0.822	0.857	0.850	0.854	0.885	0.864	0.956	0.648	0.895
154	8.909	0.256	0.856	0.820	0.856	0.852	0.857	0.880	0.859	0.961	0.670	0.891
157	9.019	0.253	0.862	0.826	0.862	0.857	0.861	0.886	0.873	0.960	0.673	0.893
160	9.035	0.263	0.857	0.821	0.857	0.851	0.856	0.877	0.871	0.960	0.660	0.888
163	8.955	0.263	0.851	0.813	0.851	0.844	0.849	0.879	0.856	0.953	0.644	0.889
166	9.227	0.254	0.857	0.821	0.857	0.850	0.855	0.880	0.867	0.962	0.656	0.886
169	9.243	0.258	0.856	0.819	0.856	0.850	0.855	0.881	0.858	0.953	0.658	0.901
172	9.250	0.258	0.855	0.818	0.855	0.850	0.854	0.875	0.866	0.955	0.660	0.893
175	9.236	0.261	0.858	0.822	0.858	0.853	0.857	0.884	0.869	0.955	0.672	0.883
178	9.347	0.263	0.853	0.816	0.853	0.845	0.850	0.875	0.863	0.952	0.642	0.894
181	9.219	0.253	0.854	0.817	0.854	0.847	0.852	0.877	0.856	0.964	0.650	0.889
184	8.948	0.261	0.852	0.814	0.852	0.847	0.851	0.879	0.858	0.959	0.653	0.884
187	9.491	0.262	0.854	0.818	0.854	0.848	0.852	0.877	0.869	0.954	0.655	0.884
190	9.483	0.271	0.862	0.827	0.862	0.856	0.861	0.883	0.870	0.958	0.675	0.892
193	9.386	0.264	0.857	0.820	0.857	0.851	0.855	0.883	0.856	0.952	0.677	0.887
196	9.627	0.258	0.861	0.826	0.861	0.856	0.860	0.881	0.869	0.961	0.676	0.893
199	9.744	0.266	0.858	0.821	0.858	0.853	0.857	0.878	0.860	0.961	0.671	0.897
202	9.527	0.270	0.855	0.818	0.855	0.850	0.854	0.883	0.854	0.956	0.662	0.894
205	9.613	0.270	0.850	0.812	0.850	0.842	0.847	0.880	0.855	0.952	0.643	0.881
208	9.766	0.255	0.855	0.819	0.855	0.847	0.853	0.880	0.859	0.961	0.650	0.884
211	9.739	0.269	0.853	0.816	0.853	0.848	0.852	0.874	0.861	0.959	0.652	0.893
214	9.892	0.263	0.856	0.819	0.856	0.850	0.854	0.882	0.857	0.957	0.660	0.893
217	9.666	0.266	0.850	0.811	0.850	0.844	0.849	0.875	0.856	0.961	0.642	0.886
220	10.195	0.271	0.848	0.809	0.848	0.843	0.848	0.872	0.852	0.955	0.646	0.891
223	10.280	0.267	0.856	0.819	0.856	0.850	0.855	0.874	0.870	0.960	0.666	0.879
226	10.358	0.268	0.861	0.826	0.861	0.856	0.861	0.888	0.859	0.950	0.680	0.904
229	10.245	0.280	0.858	0.822	0.858	0.852	0.857	0.882	0.868	0.955	0.666	0.890
232	10.264	0.269	0.855	0.818	0.855	0.849	0.854	0.874	0.870	0.956	0.654	0.893
235	10.207	0.267	0.855	0.818	0.855	0.849	0.852	0.879	0.862	0.951	0.660	0.891
238	10.172	0.268	0.854	0.817	0.854	0.849	0.853	0.874	0.868	0.954	0.664	0.884
241	10.310	0.266	0.855	0.818	0.855	0.850	0.855	0.878	0.860	0.963	0.662	0.888
244	10.246	0.279	0.851	0.813	0.851	0.845	0.850	0.879	0.859	0.957	0.645	0.885
247	10.432	0.276	0.862	0.828	0.862	0.856	0.861	0.886	0.865	0.966	0.672	0.893

Table B.36: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 3 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	6.586	0.256	0.847	0.808	0.847	0.842	0.846	0.867	0.855	0.963	0.646	0.878
16	6.507	0.257	0.842	0.801	0.842	0.837	0.842	0.869	0.847	0.957	0.637	0.875
19	6.281	0.255	0.846	0.806	0.846	0.841	0.845	0.866	0.860	0.961	0.644	0.873
22	6.484	0.256	0.847	0.807	0.847	0.842	0.848	0.864	0.854	0.962	0.657	0.876
25	6.415	0.264	0.849	0.811	0.849	0.845	0.849	0.870	0.858	0.971	0.650	0.874
28	6.737	0.261	0.847	0.808	0.847	0.842	0.846	0.871	0.853	0.963	0.641	0.883
31	6.700	0.264	0.846	0.806	0.846	0.840	0.843	0.860	0.864	0.968	0.636	0.872
34	7.188	0.265	0.852	0.814	0.852	0.847	0.852	0.877	0.857	0.964	0.653	0.886
37	7.244	0.273	0.853	0.816	0.853	0.849	0.854	0.867	0.861	0.966	0.663	0.887
40	6.538	0.271	0.857	0.821	0.857	0.852	0.857	0.886	0.856	0.969	0.670	0.880
43	6.881	0.267	0.857	0.820	0.857	0.852	0.856	0.882	0.859	0.969	0.667	0.885
46	7.007	0.272	0.860	0.824	0.860	0.857	0.861	0.878	0.866	0.966	0.676	0.897
49	7.015	0.275	0.853	0.815	0.853	0.847	0.852	0.878	0.848	0.969	0.660	0.882
52	7.282	0.275	0.860	0.824	0.860	0.856	0.859	0.880	0.867	0.966	0.671	0.893
55	7.447	0.276	0.848	0.809	0.848	0.844	0.851	0.874	0.853	0.965	0.655	0.872
58	7.641	0.280	0.854	0.817	0.854	0.849	0.854	0.875	0.865	0.970	0.659	0.877
61	7.633	0.286	0.853	0.815	0.853	0.849	0.853	0.871	0.858	0.974	0.657	0.883
64	7.775	0.277	0.851	0.812	0.851	0.846	0.851	0.874	0.856	0.966	0.651	0.882
67	8.070	0.293	0.860	0.824	0.860	0.856	0.861	0.879	0.869	0.970	0.680	0.881
70	8.261	0.279	0.860	0.824	0.860	0.856	0.859	0.871	0.876	0.968	0.670	0.894
73	8.365	0.295	0.856	0.819	0.856	0.853	0.857	0.873	0.860	0.969	0.665	0.898
76	8.158	0.296	0.856	0.820	0.856	0.851	0.856	0.877	0.864	0.967	0.674	0.876
79	8.233	0.290	0.855	0.817	0.855	0.849	0.854	0.882	0.856	0.961	0.663	0.883
82	8.446	0.295	0.855	0.818	0.855	0.850	0.854	0.871	0.871	0.969	0.661	0.879
85	8.302	0.300	0.858	0.821	0.858	0.853	0.857	0.879	0.865	0.969	0.665	0.887
88	8.400	0.301	0.861	0.825	0.861	0.856	0.859	0.881	0.867	0.969	0.674	0.886
91	8.402	0.298	0.857	0.820	0.857	0.852	0.857	0.884	0.854	0.972	0.677	0.872
94	8.583	0.293	0.863	0.827	0.863	0.858	0.862	0.883	0.871	0.969	0.684	0.882
97	8.889	0.303	0.861	0.825	0.861	0.857	0.862	0.882	0.863	0.973	0.677	0.891
100	8.572	0.308	0.855	0.818	0.855	0.850	0.856	0.877	0.865	0.964	0.663	0.881
103	8.934	0.302	0.858	0.821	0.858	0.854	0.860	0.880	0.863	0.972	0.668	0.885
106	8.607	0.308	0.856	0.819	0.856	0.851	0.857	0.884	0.856	0.964	0.666	0.886
109	8.970	0.311	0.861	0.826	0.861	0.857	0.861	0.879	0.865	0.968	0.675	0.898
112	9.297	0.311	0.863	0.828	0.863	0.858	0.862	0.879	0.876	0.964	0.683	0.889
115	8.943	0.319	0.862	0.826	0.862	0.859	0.864	0.877	0.871	0.973	0.682	0.891
118	8.892	0.250	0.858	0.822	0.858	0.852	0.856	0.883	0.861	0.967	0.668	0.879
121	9.052	0.245	0.859	0.823	0.859	0.853	0.858	0.882	0.866	0.970	0.669	0.879
124	9.295	0.248	0.864	0.829	0.864	0.859	0.863	0.882	0.873	0.967	0.680	0.894
127	9.284	0.241	0.858	0.821	0.858	0.854	0.859	0.876	0.863	0.970	0.672	0.889
130	9.452	0.252	0.865	0.831	0.865	0.861	0.866	0.883	0.870	0.969	0.696	0.889
133	9.449	0.247	0.855	0.818	0.855	0.851	0.856	0.873	0.865	0.964	0.674	0.879
136	9.600	0.247	0.854	0.817	0.854	0.850	0.856	0.877	0.858	0.967	0.667	0.880
139	9.621	0.248	0.856	0.819	0.856	0.852	0.855	0.874	0.865	0.968	0.667	0.884
142	9.692	0.245	0.857	0.820	0.857	0.851	0.855	0.885	0.856	0.970	0.664	0.882
145	9.722	0.245	0.856	0.818	0.856	0.852	0.856	0.865	0.872	0.965	0.670	0.889
148	9.849	0.250	0.859	0.823	0.859	0.855	0.859	0.880	0.864	0.968	0.673	0.888
151	9.844	0.248	0.864	0.829	0.864	0.859	0.863	0.884	0.874	0.968	0.681	0.886
154	9.764	0.244	0.863	0.828	0.863	0.857	0.862	0.885	0.866	0.968	0.681	0.886
157	9.677	0.245	0.855	0.818	0.855	0.850	0.855	0.877	0.856	0.969	0.666	0.883
160	9.901	0.244	0.862	0.827	0.862	0.858	0.864	0.882	0.870	0.972	0.682	0.885
163	9.756	0.248	0.862	0.827	0.862	0.858	0.862	0.881	0.868	0.965	0.682	0.894
166	9.951	0.249	0.861	0.826	0.861	0.856	0.861	0.879	0.870	0.972	0.676	0.885
169	10.007	0.246	0.863	0.828	0.863	0.858	0.862	0.885	0.866	0.970	0.683	0.886
172	9.817	0.258	0.858	0.822	0.858	0.854	0.859	0.874	0.871	0.964	0.677	0.886
175	10.161	0.254	0.860	0.825	0.860	0.857	0.861	0.884	0.861	0.971	0.675	0.891
178	10.095	0.253	0.864	0.829	0.864	0.858	0.862	0.887	0.868	0.968	0.679	0.889
181	10.113	0.250	0.860	0.824	0.860	0.855	0.860	0.884	0.862	0.967	0.672	0.891
184	10.243	0.252	0.859	0.823	0.859	0.855	0.860	0.871	0.872	0.971	0.671	0.893
187	10.437	0.249	0.862	0.826	0.862	0.856	0.859	0.887	0.864	0.973	0.667	0.888
190	10.309	0.246	0.863	0.828	0.863	0.856	0.861	0.888	0.873	0.973	0.669	0.877
193	10.357	0.248	0.864	0.829	0.864	0.858	0.863	0.884	0.871	0.970	0.683	0.884
196	10.564	0.252	0.861	0.826	0.861	0.856	0.860	0.883	0.869	0.969	0.673	0.889
199	10.420	0.255	0.866	0.832	0.866	0.861	0.865	0.893	0.865	0.967	0.689	0.890
202	10.517	0.250	0.861	0.826	0.861	0.857	0.863	0.881	0.864	0.969	0.689	0.885
205	10.574	0.252	0.858	0.821	0.858	0.851	0.857	0.882	0.864	0.967	0.663	0.879
208	10.657	0.245	0.862	0.826	0.862	0.856	0.860	0.883	0.869	0.971	0.676	0.882
211	10.703	0.252	0.848	0.809	0.848	0.843	0.849	0.879	0.841	0.970	0.643	0.884
214	10.422	0.248	0.864	0.829	0.864	0.859	0.862	0.880	0.873	0.972	0.676	0.891
217	10.752	0.251	0.858	0.822	0.858	0.854	0.858	0.877	0.864	0.969	0.674	0.884
220	10.712	0.250	0.862	0.827	0.862	0.857	0.861	0.884	0.870	0.966	0.680	0.887
223	10.615	0.248	0.865	0.830	0.865	0.860	0.864	0.887	0.865	0.971	0.688	0.889
226	10.790	0.250	0.868	0.834	0.868	0.862	0.866	0.894	0.873	0.972	0.690	0.882
229	10.951	0.252	0.863	0.828	0.863	0.858	0.862	0.883	0.860	0.970	0.684	0.892
232	10.921	0.244	0.864	0.829	0.864	0.860	0.863	0.881	0.866	0.972	0.681	0.900
235	10.811	0.249	0.867	0.834	0.867	0.864	0.870	0.885	0.873	0.973	0.694	0.897
238	11.184	0.255	0.864	0.829	0.864	0.859	0.863	0.885	0.866	0.972	0.684	0.890
241	11.131	0.249	0.862	0.827	0.862	0.857	0.861	0.885	0.870	0.967	0.675	0.886
244	11.227	0.245	0.867	0.832	0.867	0.862	0.865	0.883	0.877	0.974	0.688	0.887
247	10.972	0.252	0.857	0.820	0.857	0.852	0.856	0.880	0.862	0.970	0.665	0.883

Table B.37: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 4 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.674	0.242	0.850	0.812	0.850	0.846	0.851	0.869	0.864	0.957	0.662	0.879
16	5.538	0.252	0.850	0.811	0.850	0.846	0.852	0.870	0.863	0.963	0.659	0.874
19	5.766	0.242	0.850	0.812	0.850	0.846	0.850	0.874	0.854	0.963	0.652	0.887
22	5.227	0.233	0.861	0.825	0.861	0.856	0.860	0.887	0.860	0.965	0.683	0.885
25	5.659	0.242	0.852	0.814	0.852	0.847	0.851	0.876	0.859	0.962	0.663	0.875
28	6.515	0.246	0.846	0.807	0.846	0.842	0.846	0.865	0.849	0.966	0.646	0.881
31	5.976	0.239	0.851	0.813	0.851	0.847	0.850	0.867	0.865	0.962	0.652	0.888
34	5.780	0.250	0.847	0.807	0.847	0.840	0.845	0.875	0.847	0.963	0.640	0.877
37	5.961	0.243	0.852	0.814	0.852	0.849	0.854	0.864	0.859	0.972	0.663	0.888
40	6.212	0.250	0.855	0.818	0.855	0.851	0.854	0.879	0.854	0.968	0.665	0.887
43	6.285	0.255	0.856	0.820	0.856	0.851	0.856	0.881	0.861	0.966	0.665	0.884
46	6.502	0.251	0.852	0.814	0.852	0.847	0.852	0.874	0.857	0.965	0.655	0.885
49	5.931	0.246	0.850	0.812	0.850	0.845	0.850	0.870	0.864	0.960	0.650	0.883
52	6.750	0.255	0.857	0.820	0.857	0.853	0.858	0.882	0.857	0.965	0.675	0.887
55	6.517	0.258	0.860	0.824	0.860	0.856	0.862	0.883	0.864	0.968	0.678	0.888
58	7.321	0.256	0.854	0.816	0.854	0.849	0.854	0.874	0.858	0.969	0.668	0.876
61	7.079	0.257	0.855	0.817	0.855	0.850	0.855	0.874	0.861	0.965	0.666	0.886
64	7.157	0.256	0.857	0.821	0.857	0.853	0.857	0.879	0.868	0.967	0.666	0.883
67	7.337	0.267	0.856	0.819	0.856	0.850	0.855	0.882	0.858	0.963	0.664	0.885
70	6.989	0.264	0.859	0.823	0.859	0.854	0.859	0.880	0.867	0.966	0.675	0.884
73	7.500	0.264	0.860	0.824	0.860	0.856	0.859	0.879	0.870	0.968	0.672	0.889
76	7.566	0.258	0.859	0.823	0.859	0.855	0.859	0.881	0.865	0.967	0.678	0.884
79	7.570	0.263	0.856	0.818	0.856	0.852	0.857	0.873	0.870	0.966	0.666	0.886
82	7.610	0.257	0.852	0.814	0.852	0.848	0.852	0.874	0.860	0.960	0.658	0.887
85	7.868	0.270	0.853	0.815	0.853	0.846	0.851	0.880	0.858	0.964	0.657	0.873
88	8.037	0.268	0.856	0.819	0.856	0.852	0.856	0.877	0.855	0.967	0.668	0.895
91	7.586	0.271	0.857	0.821	0.857	0.853	0.856	0.877	0.862	0.964	0.667	0.894
94	7.928	0.265	0.859	0.823	0.859	0.854	0.859	0.883	0.860	0.969	0.671	0.887
97	7.968	0.275	0.857	0.821	0.857	0.851	0.855	0.879	0.864	0.972	0.660	0.881
100	8.513	0.274	0.863	0.828	0.863	0.859	0.863	0.879	0.872	0.971	0.685	0.887
103	7.925	0.275	0.853	0.816	0.853	0.847	0.852	0.877	0.859	0.967	0.653	0.881
106	8.120	0.270	0.859	0.823	0.859	0.854	0.858	0.881	0.864	0.967	0.665	0.893
109	8.427	0.278	0.865	0.830	0.865	0.861	0.865	0.882	0.873	0.971	0.688	0.889
112	8.309	0.271	0.860	0.825	0.860	0.856	0.861	0.880	0.868	0.969	0.677	0.886
115	5.760	0.263	0.860	0.825	0.860	0.855	0.860	0.888	0.860	0.968	0.678	0.882
118	6.438	0.257	0.862	0.827	0.862	0.857	0.861	0.874	0.874	0.964	0.679	0.893
121	8.048	0.268	0.859	0.824	0.859	0.854	0.858	0.885	0.858	0.969	0.665	0.890
124	7.059	0.272	0.867	0.833	0.867	0.861	0.865	0.888	0.874	0.970	0.690	0.886
127	6.505	0.268	0.856	0.818	0.856	0.851	0.856	0.880	0.863	0.967	0.663	0.883
130	7.219	0.273	0.859	0.823	0.859	0.855	0.860	0.883	0.857	0.966	0.673	0.896
133	7.673	0.276	0.860	0.824	0.860	0.855	0.860	0.878	0.872	0.969	0.675	0.882
136	5.447	0.260	0.862	0.827	0.862	0.857	0.862	0.889	0.859	0.972	0.674	0.892
139	6.847	0.260	0.864	0.829	0.864	0.861	0.865	0.882	0.871	0.971	0.687	0.891
142	6.150	0.262	0.862	0.827	0.862	0.859	0.864	0.880	0.867	0.969	0.687	0.894
145	6.035	0.261	0.868	0.834	0.868	0.864	0.867	0.884	0.878	0.967	0.692	0.897
148	7.683	0.273	0.865	0.831	0.865	0.861	0.867	0.885	0.873	0.970	0.697	0.880
151	6.595	0.269	0.856	0.819	0.856	0.852	0.856	0.874	0.865	0.968	0.663	0.888
154	7.299	0.279	0.859	0.823	0.859	0.854	0.858	0.881	0.868	0.967	0.671	0.880
157	6.975	0.261	0.862	0.827	0.862	0.858	0.862	0.881	0.864	0.968	0.684	0.895
160	7.007	0.284	0.857	0.820	0.857	0.852	0.855	0.875	0.867	0.967	0.663	0.888
163	7.820	0.273	0.857	0.820	0.857	0.850	0.854	0.884	0.861	0.960	0.666	0.878
166	6.274	0.268	0.862	0.827	0.862	0.857	0.861	0.886	0.863	0.969	0.678	0.890
169	6.726	0.276	0.855	0.818	0.855	0.850	0.854	0.881	0.855	0.967	0.661	0.886
172	6.835	0.265	0.863	0.828	0.863	0.859	0.863	0.887	0.864	0.966	0.680	0.898
175	6.420	0.275	0.859	0.823	0.859	0.853	0.857	0.880	0.866	0.968	0.667	0.881
178	5.890	0.264	0.864	0.829	0.864	0.859	0.862	0.884	0.862	0.971	0.679	0.897
181	7.105	0.276	0.855	0.818	0.855	0.851	0.855	0.877	0.861	0.962	0.673	0.881
184	6.341	0.267	0.855	0.819	0.855	0.849	0.855	0.879	0.865	0.968	0.659	0.877
187	7.608	0.288	0.862	0.827	0.862	0.857	0.863	0.885	0.865	0.967	0.692	0.877
190	6.472	0.275	0.858	0.822	0.858	0.852	0.857	0.883	0.858	0.963	0.673	0.881
193	5.666	0.267	0.864	0.830	0.864	0.860	0.865	0.885	0.871	0.968	0.681	0.894
196	5.616	0.266	0.856	0.819	0.856	0.850	0.854	0.877	0.862	0.973	0.652	0.885
199	5.591	0.267	0.863	0.828	0.863	0.858	0.862	0.886	0.865	0.969	0.682	0.887
202	5.857	0.270	0.859	0.823	0.859	0.856	0.860	0.880	0.866	0.972	0.674	0.887
205	5.780	0.266	0.860	0.825	0.860	0.856	0.861	0.881	0.866	0.964	0.682	0.889
208	5.787	0.271	0.861	0.825	0.861	0.857	0.861	0.879	0.865	0.965	0.683	0.896
211	5.854	0.275	0.859	0.823	0.859	0.854	0.858	0.877	0.861	0.970	0.666	0.895
214	5.876	0.275	0.870	0.837	0.870	0.865	0.870	0.894	0.871	0.970	0.698	0.894
217	6.065	0.259	0.860	0.824	0.860	0.853	0.857	0.884	0.867	0.964	0.668	0.883
220	6.016	0.223	0.864	0.829	0.864	0.858	0.861	0.882	0.871	0.968	0.678	0.889
223	5.999	0.203	0.859	0.823	0.859	0.853	0.858	0.888	0.860	0.962	0.672	0.881
226	6.142	0.202	0.865	0.831	0.865	0.859	0.863	0.885	0.875	0.969	0.682	0.885
229	6.164	0.200	0.864	0.829	0.864	0.859	0.864	0.886	0.875	0.967	0.677	0.891
232	6.094	0.201	0.862	0.827	0.862	0.855	0.860	0.886	0.868	0.966	0.670	0.888
235	6.258	0.207	0.861	0.825	0.861	0.856	0.860	0.880	0.861	0.972	0.674	0.894
238	7.124	0.220	0.859	0.823	0.859	0.854	0.857	0.879	0.869	0.968	0.670	0.884
241	7.531	0.230	0.860	0.825	0.860	0.856	0.861	0.880	0.870	0.970	0.676	0.883
244	8.341	0.236	0.870	0.836	0.870	0.863	0.868	0.893	0.877	0.971	0.695	0.881
247	8.732	0.235	0.864	0.830	0.864	0.859	0.863	0.885	0.869	0.971	0.680	0.888

Table B.38: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 4 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	3.539	0.206	0.837	0.795	0.837	0.832	0.837	0.861	0.832	0.954	0.634	0.880
16	3.392	0.202	0.848	0.809	0.848	0.844	0.849	0.876	0.838	0.961	0.655	0.889
19	3.374	0.205	0.852	0.814	0.852	0.848	0.853	0.874	0.860	0.963	0.660	0.884
22	3.785	0.215	0.850	0.812	0.850	0.844	0.851	0.880	0.847	0.966	0.654	0.875
25	4.985	0.236	0.850	0.811	0.850	0.846	0.850	0.873	0.854	0.957	0.656	0.886
28	5.768	0.241	0.851	0.812	0.851	0.846	0.850	0.873	0.855	0.955	0.658	0.887
31	5.927	0.237	0.850	0.812	0.850	0.846	0.852	0.874	0.855	0.962	0.651	0.889
34	5.711	0.234	0.854	0.817	0.854	0.848	0.853	0.880	0.854	0.967	0.657	0.883
37	6.035	0.241	0.856	0.819	0.856	0.852	0.857	0.876	0.861	0.968	0.663	0.892
40	6.368	0.242	0.847	0.807	0.847	0.841	0.845	0.875	0.855	0.957	0.634	0.882
43	6.205	0.235	0.847	0.808	0.847	0.843	0.847	0.865	0.851	0.964	0.653	0.881
46	6.416	0.240	0.853	0.816	0.853	0.850	0.854	0.874	0.857	0.963	0.661	0.894
49	6.293	0.238	0.857	0.821	0.857	0.853	0.858	0.883	0.858	0.961	0.684	0.879
52	6.450	0.243	0.859	0.823	0.859	0.855	0.859	0.876	0.866	0.966	0.681	0.887
55	6.849	0.243	0.854	0.816	0.854	0.848	0.852	0.872	0.873	0.963	0.656	0.876
58	6.628	0.240	0.852	0.814	0.852	0.848	0.853	0.875	0.858	0.963	0.664	0.879
61	7.074	0.247	0.855	0.818	0.855	0.849	0.854	0.879	0.862	0.956	0.670	0.880
64	7.516	0.249	0.850	0.811	0.850	0.844	0.848	0.868	0.858	0.966	0.636	0.891
67	7.385	0.249	0.855	0.818	0.855	0.850	0.854	0.878	0.859	0.962	0.669	0.884
70	6.814	0.241	0.857	0.820	0.857	0.852	0.856	0.882	0.860	0.968	0.664	0.884
73	7.681	0.250	0.855	0.818	0.855	0.850	0.854	0.875	0.864	0.957	0.663	0.890
76	7.570	0.253	0.856	0.819	0.856	0.851	0.857	0.874	0.862	0.967	0.662	0.891
79	7.492	0.255	0.851	0.814	0.851	0.847	0.853	0.873	0.853	0.962	0.657	0.892
82	7.541	0.249	0.858	0.822	0.858	0.853	0.858	0.883	0.862	0.963	0.672	0.888
85	7.661	0.251	0.856	0.819	0.856	0.851	0.854	0.872	0.869	0.966	0.653	0.896
88	7.765	0.255	0.852	0.815	0.852	0.850	0.854	0.872	0.851	0.966	0.664	0.894
91	7.463	0.253	0.862	0.827	0.862	0.857	0.861	0.886	0.865	0.964	0.676	0.892
94	7.789	0.259	0.861	0.826	0.861	0.857	0.862	0.885	0.861	0.967	0.679	0.891
97	7.908	0.260	0.854	0.816	0.854	0.849	0.852	0.876	0.858	0.964	0.659	0.886
100	8.203	0.258	0.856	0.820	0.856	0.852	0.857	0.885	0.855	0.961	0.669	0.887
103	7.949	0.264	0.858	0.822	0.858	0.853	0.858	0.882	0.862	0.965	0.665	0.891
106	8.077	0.252	0.858	0.821	0.858	0.854	0.859	0.875	0.872	0.961	0.672	0.887
109	7.898	0.259	0.863	0.828	0.863	0.858	0.862	0.886	0.866	0.970	0.678	0.888
112	8.620	0.263	0.858	0.822	0.858	0.854	0.859	0.875	0.865	0.968	0.673	0.889
115	8.220	0.261	0.857	0.821	0.857	0.853	0.857	0.881	0.862	0.965	0.671	0.889
118	8.503	0.260	0.856	0.820	0.856	0.852	0.858	0.875	0.857	0.966	0.669	0.893
121	8.681	0.259	0.859	0.823	0.859	0.854	0.858	0.881	0.864	0.965	0.674	0.886
124	8.238	0.265	0.853	0.816	0.853	0.849	0.854	0.878	0.856	0.960	0.663	0.889
127	8.484	0.262	0.860	0.824	0.860	0.855	0.859	0.881	0.864	0.966	0.674	0.889
130	8.840	0.267	0.857	0.820	0.857	0.853	0.857	0.878	0.864	0.964	0.671	0.887
133	8.502	0.259	0.861	0.826	0.861	0.858	0.863	0.883	0.860	0.966	0.688	0.889
136	8.726	0.256	0.860	0.825	0.860	0.856	0.860	0.885	0.860	0.965	0.680	0.895
139	8.733	0.268	0.861	0.826	0.861	0.856	0.861	0.892	0.856	0.962	0.681	0.889
142	8.645	0.261	0.864	0.829	0.864	0.860	0.864	0.887	0.864	0.966	0.688	0.896
145	8.861	0.264	0.854	0.817	0.854	0.849	0.853	0.881	0.859	0.957	0.661	0.888
148	8.806	0.265	0.862	0.827	0.862	0.857	0.861	0.885	0.867	0.965	0.678	0.890
151	9.205	0.270	0.857	0.820	0.857	0.851	0.855	0.878	0.865	0.960	0.665	0.886
154	9.059	0.269	0.858	0.822	0.858	0.853	0.858	0.880	0.862	0.966	0.675	0.881
157	8.805	0.269	0.860	0.824	0.860	0.854	0.859	0.889	0.859	0.963	0.673	0.888
160	9.367	0.277	0.862	0.827	0.862	0.857	0.860	0.887	0.866	0.963	0.673	0.893
163	9.275	0.268	0.861	0.826	0.861	0.857	0.861	0.880	0.868	0.963	0.678	0.895
166	9.307	0.274	0.860	0.825	0.860	0.856	0.860	0.881	0.862	0.965	0.677	0.894
169	9.446	0.266	0.861	0.825	0.861	0.855	0.860	0.885	0.860	0.970	0.671	0.887
172	9.531	0.271	0.859	0.823	0.859	0.853	0.858	0.884	0.855	0.958	0.681	0.890
175	9.372	0.274	0.860	0.824	0.860	0.855	0.860	0.886	0.863	0.966	0.682	0.881
178	9.630	0.275	0.860	0.825	0.860	0.856	0.861	0.883	0.858	0.963	0.682	0.895
181	9.526	0.277	0.861	0.826	0.861	0.855	0.859	0.880	0.870	0.966	0.670	0.888
184	9.868	0.276	0.861	0.826	0.861	0.857	0.861	0.888	0.865	0.961	0.679	0.893
187	9.773	0.274	0.861	0.825	0.861	0.856	0.859	0.881	0.864	0.970	0.672	0.891
190	9.684	0.274	0.861	0.825	0.861	0.854	0.859	0.889	0.858	0.963	0.674	0.886
193	9.632	0.279	0.857	0.821	0.857	0.853	0.858	0.877	0.867	0.967	0.668	0.887
196	9.586	0.286	0.858	0.822	0.858	0.853	0.856	0.878	0.862	0.960	0.669	0.894
199	9.646	0.279	0.858	0.822	0.858	0.852	0.857	0.886	0.856	0.962	0.673	0.885
202	9.690	0.281	0.859	0.823	0.859	0.852	0.857	0.881	0.868	0.968	0.669	0.875
205	9.822	0.270	0.859	0.823	0.859	0.853	0.857	0.876	0.868	0.960	0.667	0.893
208	10.152	0.276	0.858	0.821	0.858	0.852	0.856	0.884	0.859	0.961	0.664	0.892
211	9.844	0.271	0.860	0.824	0.860	0.854	0.858	0.884	0.864	0.958	0.674	0.889
214	10.339	0.280	0.864	0.829	0.864	0.860	0.864	0.885	0.868	0.968	0.683	0.893
217	10.148	0.283	0.861	0.825	0.861	0.855	0.859	0.886	0.867	0.964	0.673	0.885
220	10.258	0.280	0.856	0.820	0.856	0.851	0.855	0.879	0.861	0.962	0.669	0.885
223	10.461	0.288	0.859	0.823	0.859	0.853	0.858	0.881	0.867	0.968	0.666	0.885
226	10.319	0.289	0.853	0.817	0.853	0.845	0.852	0.883	0.856	0.960	0.643	0.884
229	9.955	0.284	0.858	0.822	0.858	0.851	0.857	0.885	0.858	0.963	0.667	0.884
232	10.104	0.281	0.861	0.825	0.861	0.855	0.860	0.884	0.866	0.968	0.670	0.889
235	10.115	0.290	0.864	0.829	0.864	0.859	0.864	0.889	0.863	0.964	0.693	0.888
238	10.399	0.287	0.866	0.831	0.866	0.860	0.864	0.889	0.868	0.967	0.684	0.890
241	10.474	0.285	0.850	0.811	0.850	0.844	0.848	0.874	0.855	0.957	0.650	0.883
244	10.570	0.288	0.866	0.832	0.866	0.860	0.864	0.887	0.880	0.964	0.683	0.886
247	10.458	0.283	0.859	0.823	0.859	0.855	0.859	0.876	0.865	0.965	0.670	0.896

Table B.39: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 4 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.315	0.233	0.849	0.811	0.849	0.844	0.851	0.871	0.861	0.956	0.653	0.881
16	5.808	0.236	0.844	0.804	0.844	0.840	0.844	0.869	0.858	0.948	0.646	0.876
19	5.150	0.231	0.841	0.801	0.841	0.836	0.842	0.872	0.841	0.952	0.636	0.880
22	5.706	0.227	0.852	0.814	0.852	0.848	0.852	0.878	0.857	0.954	0.658	0.890
25	5.676	0.239	0.846	0.806	0.846	0.840	0.845	0.873	0.850	0.952	0.644	0.882
28	6.020	0.231	0.851	0.813	0.851	0.846	0.852	0.876	0.856	0.957	0.658	0.884
31	5.669	0.230	0.861	0.826	0.861	0.857	0.862	0.883	0.861	0.963	0.688	0.888
34	5.586	0.234	0.849	0.811	0.849	0.846	0.852	0.876	0.850	0.958	0.657	0.889
37	5.680	0.234	0.852	0.814	0.852	0.848	0.852	0.872	0.860	0.957	0.655	0.894
40	6.193	0.236	0.845	0.806	0.845	0.839	0.844	0.869	0.854	0.953	0.638	0.883
43	6.034	0.235	0.849	0.810	0.849	0.844	0.847	0.870	0.861	0.955	0.647	0.886
46	6.219	0.240	0.849	0.811	0.849	0.846	0.850	0.868	0.857	0.959	0.653	0.892
49	6.289	0.239	0.858	0.821	0.858	0.854	0.858	0.878	0.860	0.959	0.680	0.890
52	6.716	0.238	0.850	0.812	0.850	0.845	0.849	0.872	0.858	0.961	0.642	0.891
55	6.759	0.243	0.851	0.813	0.851	0.846	0.851	0.879	0.856	0.957	0.659	0.876
58	7.379	0.243	0.853	0.815	0.853	0.849	0.854	0.876	0.864	0.955	0.661	0.887
61	6.980	0.243	0.854	0.817	0.854	0.849	0.853	0.878	0.857	0.959	0.662	0.890
64	7.104	0.246	0.845	0.805	0.845	0.839	0.844	0.872	0.850	0.953	0.635	0.887
67	6.966	0.243	0.857	0.821	0.857	0.852	0.857	0.881	0.863	0.959	0.674	0.885
70	7.159	0.245	0.852	0.815	0.852	0.847	0.853	0.877	0.853	0.965	0.659	0.883
73	7.095	0.242	0.855	0.818	0.855	0.851	0.856	0.877	0.857	0.957	0.674	0.887
76	7.123	0.244	0.858	0.821	0.858	0.853	0.859	0.891	0.849	0.965	0.671	0.888
79	7.511	0.244	0.853	0.815	0.853	0.847	0.852	0.882	0.855	0.952	0.662	0.887
82	7.510	0.243	0.852	0.814	0.852	0.847	0.853	0.881	0.848	0.957	0.665	0.886
85	7.599	0.247	0.860	0.824	0.860	0.855	0.858	0.880	0.862	0.962	0.674	0.897
88	7.679	0.244	0.850	0.811	0.850	0.844	0.849	0.871	0.862	0.957	0.641	0.889
91	7.693	0.252	0.855	0.817	0.855	0.849	0.854	0.882	0.859	0.959	0.663	0.884
94	7.815	0.252	0.854	0.816	0.854	0.849	0.853	0.877	0.855	0.965	0.660	0.886
97	8.302	0.243	0.858	0.822	0.858	0.853	0.858	0.884	0.866	0.960	0.668	0.886
100	8.000	0.246	0.854	0.817	0.854	0.849	0.855	0.876	0.862	0.958	0.657	0.892
103	7.867	0.248	0.852	0.814	0.852	0.846	0.851	0.878	0.858	0.959	0.648	0.887
106	8.269	0.248	0.849	0.811	0.849	0.843	0.848	0.876	0.854	0.947	0.647	0.889
109	8.074	0.253	0.859	0.823	0.859	0.856	0.862	0.879	0.862	0.959	0.688	0.893
112	8.298	0.253	0.851	0.813	0.851	0.846	0.851	0.877	0.856	0.954	0.656	0.885
115	8.413	0.251	0.854	0.817	0.854	0.849	0.854	0.875	0.858	0.957	0.664	0.891
118	8.490	0.254	0.853	0.815	0.853	0.848	0.852	0.877	0.854	0.956	0.661	0.893
121	8.397	0.253	0.856	0.820	0.856	0.851	0.856	0.886	0.863	0.955	0.665	0.885
124	8.312	0.255	0.857	0.820	0.857	0.850	0.855	0.876	0.869	0.962	0.659	0.886
127	8.469	0.252	0.857	0.821	0.857	0.851	0.856	0.883	0.862	0.959	0.662	0.891
130	8.326	0.257	0.857	0.820	0.857	0.852	0.856	0.881	0.858	0.955	0.668	0.896
133	8.435	0.255	0.855	0.818	0.855	0.851	0.855	0.875	0.858	0.962	0.666	0.891
136	8.726	0.253	0.853	0.816	0.853	0.848	0.853	0.876	0.862	0.959	0.657	0.885
139	8.766	0.255	0.856	0.819	0.856	0.850	0.854	0.872	0.866	0.962	0.657	0.892
142	8.974	0.259	0.856	0.820	0.856	0.851	0.855	0.884	0.855	0.957	0.668	0.889
145	8.714	0.259	0.851	0.813	0.851	0.843	0.849	0.882	0.855	0.946	0.646	0.884
148	8.931	0.257	0.863	0.828	0.863	0.859	0.863	0.884	0.867	0.966	0.681	0.899
151	8.744	0.255	0.854	0.817	0.854	0.849	0.855	0.880	0.857	0.949	0.667	0.892
154	8.696	0.261	0.857	0.821	0.857	0.851	0.857	0.880	0.861	0.965	0.662	0.889
157	8.788	0.264	0.854	0.817	0.854	0.849	0.853	0.876	0.866	0.957	0.661	0.884
160	8.948	0.271	0.852	0.815	0.852	0.847	0.852	0.879	0.857	0.958	0.648	0.891
163	9.241	0.267	0.852	0.815	0.852	0.846	0.851	0.878	0.861	0.958	0.640	0.895
166	9.521	0.259	0.856	0.820	0.856	0.852	0.858	0.887	0.860	0.958	0.667	0.885
169	8.986	0.261	0.854	0.817	0.854	0.847	0.852	0.883	0.861	0.963	0.652	0.877
172	9.173	0.261	0.856	0.819	0.856	0.850	0.854	0.881	0.855	0.957	0.671	0.888
175	9.158	0.263	0.857	0.821	0.857	0.851	0.856	0.879	0.866	0.956	0.665	0.890
178	9.435	0.260	0.860	0.825	0.860	0.854	0.859	0.887	0.862	0.953	0.669	0.898
181	9.431	0.259	0.855	0.818	0.855	0.849	0.854	0.881	0.855	0.955	0.668	0.889
184	9.316	0.267	0.855	0.819	0.855	0.850	0.855	0.882	0.860	0.957	0.668	0.882
187	9.744	0.267	0.862	0.826	0.862	0.856	0.860	0.883	0.864	0.963	0.676	0.894
190	9.428	0.259	0.854	0.818	0.854	0.849	0.855	0.878	0.864	0.964	0.654	0.884
193	9.490	0.268	0.860	0.825	0.860	0.854	0.859	0.889	0.862	0.953	0.672	0.896
196	9.884	0.263	0.861	0.825	0.861	0.854	0.859	0.888	0.863	0.960	0.665	0.893
199	9.503	0.262	0.855	0.818	0.855	0.850	0.853	0.872	0.868	0.961	0.654	0.895
202	9.868	0.266	0.857	0.821	0.857	0.852	0.856	0.871	0.875	0.958	0.666	0.889
205	9.783	0.264	0.858	0.822	0.858	0.852	0.857	0.886	0.864	0.956	0.667	0.889
208	9.904	0.270	0.857	0.821	0.857	0.852	0.856	0.882	0.863	0.958	0.668	0.888
211	9.727	0.272	0.850	0.811	0.850	0.844	0.847	0.870	0.855	0.960	0.642	0.892
214	10.163	0.264	0.855	0.819	0.855	0.850	0.855	0.877	0.855	0.958	0.668	0.894
217	10.249	0.270	0.853	0.817	0.853	0.846	0.852	0.875	0.873	0.951	0.647	0.885
220	10.138	0.265	0.858	0.821	0.858	0.852	0.856	0.876	0.870	0.953	0.674	0.887
223	10.074	0.270	0.856	0.820	0.856	0.849	0.854	0.882	0.862	0.956	0.660	0.888
226	10.236	0.271	0.853	0.816	0.853	0.846	0.852	0.880	0.864	0.958	0.652	0.879
229	10.244	0.270	0.856	0.819	0.856	0.850	0.855	0.882	0.853	0.954	0.675	0.885
232	10.147	0.270	0.851	0.813	0.851	0.847	0.850	0.870	0.861	0.956	0.652	0.894
235	10.049	0.268	0.859	0.823	0.859	0.854	0.859	0.882	0.865	0.963	0.664	0.895
238	10.483	0.265	0.850	0.813	0.850	0.843	0.849	0.875	0.862	0.953	0.641	0.883
241	10.231	0.273	0.855	0.819	0.855	0.847	0.852	0.884	0.863	0.955	0.650	0.884
244	10.434	0.270	0.856	0.820	0.856	0.851	0.856	0.883	0.853	0.961	0.667	0.890
247	10.684	0.278	0.846	0.807	0.846	0.838	0.844	0.873	0.861	0.946	0.632	0.878

Table B.40: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 4 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.941	0.240	0.838	0.797	0.838	0.834	0.840	0.859	0.834	0.968	0.642	0.864
16	5.031	0.243	0.841	0.800	0.841	0.837	0.844	0.864	0.842	0.968	0.645	0.868
19	4.940	0.248	0.848	0.809	0.848	0.845	0.851	0.862	0.853	0.970	0.657	0.884
22	5.095	0.248	0.850	0.811	0.850	0.847	0.852	0.870	0.852	0.973	0.650	0.888
25	5.015	0.254	0.850	0.811	0.850	0.845	0.852	0.874	0.847	0.972	0.662	0.871
28	5.170	0.255	0.854	0.817	0.854	0.850	0.854	0.877	0.850	0.972	0.674	0.876
31	5.409	0.260	0.852	0.814	0.852	0.848	0.853	0.872	0.843	0.972	0.669	0.886
34	5.456	0.259	0.854	0.816	0.854	0.850	0.854	0.872	0.851	0.977	0.658	0.889
37	5.620	0.262	0.859	0.822	0.859	0.855	0.861	0.882	0.853	0.976	0.685	0.882
40	5.685	0.262	0.849	0.810	0.849	0.844	0.848	0.870	0.852	0.970	0.657	0.870
43	5.872	0.258	0.857	0.820	0.857	0.852	0.857	0.883	0.856	0.974	0.674	0.871
46	6.024	0.265	0.859	0.823	0.859	0.856	0.861	0.871	0.865	0.977	0.686	0.880
49	6.021	0.263	0.856	0.820	0.856	0.853	0.859	0.878	0.858	0.972	0.681	0.878
52	6.279	0.281	0.858	0.821	0.858	0.854	0.858	0.872	0.862	0.977	0.675	0.883
55	6.284	0.270	0.859	0.823	0.859	0.855	0.860	0.879	0.862	0.976	0.682	0.876
58	6.473	0.279	0.859	0.824	0.859	0.857	0.863	0.877	0.861	0.975	0.691	0.880
61	6.404	0.276	0.857	0.821	0.857	0.854	0.861	0.875	0.867	0.976	0.673	0.879
64	6.498	0.295	0.859	0.823	0.859	0.855	0.861	0.878	0.854	0.977	0.681	0.884
67	6.717	0.282	0.863	0.828	0.863	0.860	0.866	0.885	0.861	0.977	0.691	0.886
70	6.671	0.290	0.858	0.822	0.858	0.855	0.859	0.878	0.856	0.972	0.676	0.891
73	6.925	0.292	0.858	0.822	0.858	0.856	0.863	0.875	0.856	0.978	0.682	0.887
76	6.995	0.291	0.855	0.818	0.855	0.853	0.858	0.876	0.852	0.976	0.678	0.881
79	7.089	0.300	0.864	0.829	0.864	0.861	0.866	0.885	0.859	0.979	0.692	0.890
82	7.227	0.307	0.857	0.820	0.857	0.854	0.860	0.878	0.858	0.974	0.674	0.884
85	7.163	0.303	0.858	0.821	0.858	0.854	0.860	0.881	0.852	0.976	0.681	0.881
88	7.115	0.302	0.863	0.828	0.863	0.859	0.865	0.885	0.860	0.977	0.692	0.883
91	7.312	0.300	0.856	0.819	0.856	0.853	0.857	0.880	0.852	0.967	0.678	0.886
94	7.376	0.299	0.857	0.821	0.857	0.853	0.859	0.880	0.848	0.979	0.677	0.882
97	7.370	0.306	0.855	0.818	0.855	0.850	0.856	0.877	0.859	0.971	0.670	0.875
100	7.506	0.312	0.863	0.828	0.863	0.860	0.866	0.883	0.859	0.976	0.697	0.884
103	7.599	0.318	0.851	0.813	0.851	0.848	0.853	0.872	0.848	0.967	0.666	0.885
106	7.716	0.311	0.862	0.826	0.862	0.860	0.866	0.883	0.856	0.976	0.696	0.887
109	7.647	0.306	0.863	0.828	0.863	0.858	0.863	0.882	0.864	0.974	0.681	0.888
112	7.714	0.315	0.861	0.825	0.861	0.858	0.863	0.878	0.861	0.974	0.692	0.886
115	7.804	0.318	0.864	0.830	0.864	0.862	0.868	0.880	0.870	0.977	0.693	0.889
118	7.678	0.240	0.856	0.819	0.856	0.853	0.858	0.876	0.856	0.975	0.672	0.884
121	7.904	0.235	0.856	0.820	0.856	0.853	0.858	0.875	0.854	0.976	0.677	0.881
124	7.838	0.242	0.859	0.823	0.859	0.856	0.861	0.875	0.860	0.980	0.682	0.883
127	8.003	0.234	0.863	0.828	0.863	0.859	0.866	0.884	0.865	0.976	0.692	0.879
130	8.280	0.245	0.863	0.828	0.863	0.860	0.866	0.882	0.856	0.976	0.697	0.889
133	8.217	0.237	0.862	0.826	0.862	0.858	0.864	0.878	0.865	0.975	0.689	0.884
136	8.253	0.226	0.864	0.829	0.864	0.861	0.866	0.884	0.857	0.975	0.696	0.892
139	8.296	0.234	0.865	0.830	0.865	0.861	0.866	0.886	0.870	0.975	0.698	0.873
142	8.559	0.240	0.861	0.825	0.861	0.857	0.862	0.882	0.859	0.972	0.684	0.888
145	9.717	0.250	0.863	0.828	0.863	0.859	0.865	0.884	0.862	0.975	0.692	0.884
148	9.764	0.246	0.858	0.821	0.858	0.854	0.860	0.879	0.857	0.974	0.679	0.883
151	9.878	0.245	0.858	0.822	0.858	0.854	0.860	0.873	0.864	0.976	0.675	0.881
154	9.920	0.249	0.863	0.827	0.863	0.859	0.865	0.885	0.865	0.975	0.690	0.882
157	9.874	0.255	0.859	0.823	0.859	0.855	0.860	0.875	0.869	0.972	0.683	0.879
160	10.002	0.252	0.867	0.832	0.867	0.863	0.868	0.885	0.862	0.977	0.705	0.888
163	10.279	0.252	0.861	0.825	0.861	0.857	0.861	0.875	0.867	0.973	0.686	0.887
166	10.051	0.257	0.860	0.825	0.860	0.856	0.860	0.877	0.860	0.974	0.683	0.886
169	10.078	0.249	0.869	0.836	0.869	0.867	0.873	0.883	0.873	0.978	0.703	0.898
172	10.064	0.247	0.856	0.819	0.856	0.853	0.858	0.880	0.851	0.974	0.669	0.890
175	10.206	0.247	0.864	0.829	0.864	0.859	0.863	0.884	0.861	0.977	0.687	0.888
178	10.259	0.253	0.866	0.832	0.866	0.862	0.866	0.878	0.872	0.977	0.696	0.889
181	10.436	0.254	0.864	0.829	0.864	0.859	0.865	0.887	0.866	0.976	0.682	0.886
184	10.404	0.258	0.870	0.836	0.870	0.866	0.871	0.893	0.860	0.979	0.704	0.896
187	10.365	0.241	0.861	0.826	0.861	0.858	0.864	0.882	0.857	0.976	0.687	0.889
190	10.563	0.250	0.863	0.828	0.863	0.861	0.867	0.879	0.862	0.976	0.695	0.892
193	10.774	0.256	0.862	0.827	0.862	0.858	0.862	0.883	0.863	0.974	0.686	0.885
196	10.517	0.252	0.868	0.834	0.868	0.864	0.870	0.890	0.865	0.976	0.700	0.890
199	10.765	0.259	0.867	0.833	0.867	0.863	0.869	0.885	0.868	0.980	0.697	0.887
202	11.141	0.250	0.865	0.830	0.865	0.861	0.867	0.885	0.865	0.974	0.704	0.879
205	11.051	0.264	0.863	0.828	0.863	0.859	0.863	0.883	0.862	0.975	0.686	0.888
208	11.083	0.258	0.865	0.831	0.865	0.861	0.866	0.889	0.866	0.974	0.691	0.884
211	11.036	0.260	0.862	0.827	0.862	0.859	0.864	0.885	0.860	0.973	0.694	0.882
214	11.321	0.256	0.864	0.830	0.864	0.862	0.867	0.884	0.854	0.976	0.701	0.893
217	11.355	0.250	0.867	0.832	0.867	0.862	0.868	0.888	0.867	0.975	0.696	0.885
220	11.163	0.258	0.861	0.826	0.861	0.857	0.864	0.881	0.862	0.975	0.680	0.888
223	11.215	0.258	0.873	0.840	0.873	0.868	0.873	0.896	0.870	0.978	0.706	0.889
226	11.469	0.259	0.866	0.832	0.866	0.862	0.867	0.887	0.862	0.976	0.699	0.886
229	11.384	0.251	0.857	0.821	0.857	0.854	0.860	0.882	0.846	0.974	0.686	0.881
232	11.380	0.256	0.872	0.840	0.872	0.869	0.873	0.889	0.870	0.975	0.716	0.893
235	11.228	0.253	0.866	0.832	0.866	0.862	0.868	0.888	0.861	0.978	0.697	0.887
238	11.329	0.256	0.862	0.827	0.862	0.858	0.864	0.888	0.856	0.975	0.687	0.887
241	11.615	0.259	0.865	0.831	0.865	0.861	0.866	0.884	0.867	0.973	0.694	0.887
244	11.588	0.261	0.867	0.833	0.867	0.864	0.868	0.887	0.870	0.978	0.698	0.887
247	11.505	0.251	0.860	0.824	0.860	0.855	0.860	0.883	0.850	0.977	0.680	0.883

Table B.41: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 6 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.407	0.236	0.844	0.804	0.844	0.841	0.846	0.865	0.842	0.971	0.646	0.882
16	4.768	0.237	0.838	0.797	0.838	0.836	0.841	0.851	0.840	0.967	0.642	0.881
19	4.696	0.223	0.842	0.802	0.842	0.840	0.846	0.861	0.843	0.964	0.658	0.874
22	5.637	0.245	0.848	0.809	0.848	0.845	0.850	0.867	0.851	0.970	0.658	0.877
25	5.613	0.242	0.850	0.812	0.850	0.846	0.851	0.869	0.856	0.974	0.650	0.881
28	5.681	0.239	0.853	0.816	0.853	0.850	0.857	0.874	0.848	0.976	0.664	0.889
31	5.553	0.254	0.855	0.818	0.855	0.853	0.858	0.876	0.844	0.974	0.688	0.883
34	6.219	0.258	0.851	0.814	0.851	0.848	0.855	0.874	0.851	0.972	0.668	0.875
37	6.135	0.258	0.854	0.817	0.854	0.849	0.854	0.875	0.855	0.974	0.663	0.879
40	5.689	0.256	0.848	0.809	0.848	0.846	0.850	0.866	0.845	0.971	0.662	0.885
43	6.390	0.264	0.851	0.813	0.851	0.846	0.850	0.866	0.854	0.972	0.655	0.883
46	6.303	0.262	0.852	0.814	0.852	0.848	0.853	0.876	0.842	0.972	0.669	0.880
49	6.128	0.255	0.854	0.817	0.854	0.851	0.855	0.878	0.846	0.968	0.675	0.886
52	6.424	0.262	0.855	0.818	0.855	0.852	0.859	0.880	0.846	0.979	0.683	0.871
55	6.546	0.261	0.857	0.821	0.857	0.855	0.859	0.871	0.858	0.974	0.683	0.888
58	7.213	0.270	0.853	0.815	0.853	0.849	0.854	0.878	0.842	0.968	0.666	0.891
61	6.434	0.262	0.858	0.821	0.858	0.854	0.858	0.873	0.861	0.974	0.673	0.890
64	6.973	0.261	0.859	0.823	0.859	0.856	0.862	0.877	0.858	0.969	0.679	0.897
67	6.945	0.265	0.856	0.819	0.856	0.851	0.857	0.883	0.850	0.969	0.672	0.882
70	7.142	0.264	0.861	0.825	0.861	0.857	0.862	0.879	0.868	0.975	0.690	0.875
73	6.830	0.258	0.855	0.819	0.855	0.853	0.861	0.876	0.854	0.974	0.678	0.883
76	6.956	0.267	0.857	0.821	0.857	0.852	0.858	0.881	0.858	0.977	0.672	0.873
79	7.010	0.273	0.860	0.824	0.860	0.856	0.861	0.882	0.856	0.973	0.686	0.884
82	6.320	0.265	0.858	0.822	0.858	0.854	0.859	0.877	0.850	0.972	0.679	0.894
85	7.355	0.278	0.858	0.822	0.858	0.855	0.860	0.878	0.862	0.976	0.675	0.883
88	7.787	0.273	0.861	0.826	0.861	0.858	0.864	0.881	0.864	0.975	0.688	0.883
91	7.808	0.287	0.862	0.827	0.862	0.858	0.863	0.884	0.860	0.976	0.683	0.887
94	8.088	0.276	0.855	0.818	0.855	0.850	0.856	0.882	0.857	0.975	0.670	0.869
97	7.991	0.275	0.860	0.825	0.860	0.856	0.861	0.881	0.860	0.973	0.680	0.888
100	7.773	0.284	0.861	0.825	0.861	0.858	0.864	0.876	0.859	0.977	0.690	0.889
103	6.919	0.269	0.858	0.822	0.858	0.855	0.861	0.880	0.856	0.973	0.681	0.885
106	6.798	0.275	0.856	0.819	0.856	0.852	0.859	0.884	0.849	0.971	0.677	0.881
109	6.638	0.282	0.859	0.824	0.859	0.856	0.861	0.878	0.862	0.970	0.685	0.882
112	6.857	0.277	0.862	0.826	0.862	0.858	0.863	0.882	0.860	0.975	0.683	0.890
115	6.931	0.274	0.859	0.823	0.859	0.856	0.862	0.877	0.861	0.975	0.689	0.878
118	6.573	0.268	0.852	0.814	0.852	0.849	0.854	0.875	0.842	0.970	0.672	0.886
121	6.750	0.289	0.856	0.819	0.856	0.851	0.856	0.878	0.857	0.972	0.661	0.886
124	6.954	0.261	0.863	0.828	0.863	0.859	0.864	0.882	0.867	0.976	0.687	0.884
127	7.134	0.276	0.863	0.828	0.863	0.860	0.864	0.883	0.865	0.970	0.688	0.892
130	7.225	0.279	0.858	0.822	0.858	0.855	0.860	0.876	0.857	0.971	0.683	0.887
133	7.377	0.278	0.862	0.827	0.862	0.858	0.864	0.880	0.867	0.974	0.683	0.888
136	7.366	0.274	0.861	0.826	0.861	0.857	0.862	0.879	0.863	0.980	0.676	0.889
139	7.341	0.280	0.855	0.818	0.855	0.852	0.857	0.873	0.854	0.971	0.677	0.885
142	7.448	0.296	0.859	0.823	0.859	0.855	0.860	0.881	0.850	0.976	0.672	0.896
145	7.328	0.279	0.862	0.827	0.862	0.859	0.865	0.883	0.860	0.977	0.695	0.881
148	7.467	0.287	0.862	0.826	0.862	0.858	0.864	0.886	0.857	0.975	0.688	0.883
151	7.637	0.297	0.861	0.826	0.861	0.860	0.865	0.874	0.860	0.972	0.696	0.897
154	7.766	0.284	0.861	0.825	0.861	0.858	0.862	0.878	0.855	0.973	0.687	0.896
157	7.763	0.273	0.863	0.827	0.863	0.858	0.862	0.880	0.862	0.978	0.687	0.885
160	8.291	0.297	0.864	0.829	0.864	0.859	0.864	0.884	0.861	0.977	0.687	0.889
163	9.564	0.309	0.860	0.824	0.860	0.856	0.860	0.879	0.859	0.973	0.683	0.884
166	9.377	0.310	0.861	0.825	0.861	0.857	0.863	0.886	0.853	0.975	0.683	0.889
169	9.603	0.303	0.862	0.827	0.862	0.860	0.865	0.880	0.860	0.977	0.694	0.887
172	9.774	0.305	0.861	0.825	0.861	0.858	0.863	0.878	0.856	0.980	0.686	0.889
175	9.634	0.312	0.860	0.824	0.860	0.857	0.861	0.879	0.859	0.970	0.686	0.891
178	9.617	0.300	0.864	0.829	0.864	0.861	0.866	0.884	0.856	0.978	0.689	0.896
181	9.698	0.311	0.861	0.825	0.861	0.857	0.862	0.881	0.862	0.973	0.682	0.888
184	9.961	0.307	0.862	0.826	0.862	0.859	0.863	0.877	0.862	0.975	0.687	0.892
187	9.518	0.315	0.856	0.819	0.856	0.851	0.855	0.882	0.854	0.968	0.662	0.889
190	10.009	0.317	0.865	0.831	0.865	0.862	0.867	0.877	0.866	0.976	0.700	0.892
193	9.954	0.316	0.862	0.827	0.862	0.858	0.862	0.878	0.868	0.975	0.683	0.885
196	10.087	0.309	0.860	0.824	0.860	0.855	0.860	0.881	0.859	0.972	0.679	0.886
199	10.053	0.323	0.867	0.833	0.867	0.863	0.868	0.884	0.871	0.977	0.702	0.881
202	10.197	0.321	0.867	0.833	0.867	0.864	0.870	0.885	0.868	0.976	0.699	0.893
205	9.987	0.316	0.872	0.839	0.872	0.869	0.874	0.887	0.867	0.979	0.718	0.896
208	10.279	0.320	0.863	0.827	0.863	0.858	0.863	0.885	0.862	0.975	0.692	0.877
211	10.267	0.318	0.857	0.821	0.857	0.853	0.858	0.884	0.850	0.972	0.671	0.889
214	10.391	0.328	0.865	0.830	0.865	0.860	0.864	0.884	0.870	0.970	0.691	0.884
217	10.254	0.302	0.862	0.827	0.862	0.858	0.864	0.888	0.858	0.976	0.686	0.884
220	10.277	0.270	0.868	0.835	0.868	0.865	0.870	0.891	0.862	0.977	0.705	0.890
223	10.158	0.248	0.863	0.828	0.863	0.857	0.862	0.884	0.870	0.972	0.678	0.883
226	10.539	0.249	0.864	0.829	0.864	0.860	0.866	0.885	0.856	0.975	0.693	0.891
229	10.370	0.245	0.865	0.831	0.865	0.861	0.866	0.888	0.866	0.977	0.690	0.884
232	10.320	0.245	0.868	0.834	0.868	0.864	0.869	0.892	0.861	0.978	0.708	0.881
235	10.347	0.249	0.863	0.828	0.863	0.860	0.864	0.882	0.855	0.976	0.694	0.891
238	10.666	0.249	0.869	0.835	0.869	0.865	0.869	0.885	0.870	0.979	0.701	0.890
241	10.603	0.236	0.865	0.830	0.865	0.861	0.866	0.886	0.861	0.977	0.692	0.889
244	10.698	0.247	0.864	0.829	0.864	0.860	0.865	0.887	0.860	0.977	0.689	0.885
247	10.494	0.238	0.859	0.823	0.859	0.856	0.861	0.880	0.859	0.974	0.682	0.884

Table B.42: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 6 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.751	0.230	0.840	0.800	0.840	0.837	0.843	0.865	0.832	0.970	0.641	0.876
16	5.287	0.233	0.846	0.807	0.846	0.843	0.851	0.873	0.843	0.972	0.651	0.877
19	5.338	0.230	0.839	0.798	0.839	0.835	0.841	0.862	0.836	0.965	0.631	0.884
22	4.872	0.227	0.845	0.806	0.845	0.842	0.847	0.866	0.848	0.964	0.659	0.873
25	4.255	0.216	0.849	0.811	0.849	0.845	0.850	0.867	0.859	0.973	0.653	0.871
28	4.679	0.224	0.849	0.810	0.849	0.846	0.854	0.867	0.851	0.970	0.665	0.879
31	4.282	0.216	0.848	0.809	0.848	0.844	0.848	0.865	0.853	0.969	0.652	0.879
34	4.704	0.227	0.845	0.805	0.845	0.841	0.845	0.863	0.844	0.967	0.655	0.874
37	4.770	0.222	0.856	0.819	0.856	0.852	0.857	0.876	0.859	0.969	0.679	0.879
40	4.881	0.216	0.848	0.809	0.848	0.844	0.848	0.871	0.852	0.967	0.656	0.872
43	4.938	0.226	0.845	0.806	0.845	0.842	0.847	0.870	0.841	0.970	0.650	0.879
46	5.119	0.226	0.852	0.814	0.852	0.849	0.855	0.869	0.854	0.969	0.671	0.881
49	5.259	0.244	0.854	0.817	0.854	0.849	0.855	0.880	0.859	0.964	0.671	0.870
52	5.223	0.230	0.852	0.814	0.852	0.848	0.853	0.871	0.860	0.965	0.669	0.874
55	5.468	0.240	0.851	0.812	0.851	0.846	0.851	0.878	0.853	0.967	0.658	0.873
58	5.500	0.237	0.853	0.816	0.853	0.851	0.857	0.873	0.851	0.976	0.670	0.884
61	5.520	0.242	0.853	0.815	0.853	0.849	0.853	0.875	0.848	0.972	0.659	0.889
64	5.607	0.248	0.853	0.815	0.853	0.849	0.854	0.874	0.854	0.970	0.669	0.879
67	5.696	0.238	0.850	0.812	0.850	0.846	0.851	0.870	0.850	0.971	0.660	0.878
70	5.588	0.241	0.853	0.816	0.853	0.851	0.856	0.872	0.857	0.970	0.672	0.882
73	5.672	0.243	0.853	0.816	0.853	0.851	0.857	0.874	0.859	0.970	0.669	0.883
76	5.919	0.232	0.855	0.818	0.855	0.851	0.857	0.883	0.857	0.964	0.665	0.883
79	5.864	0.246	0.857	0.821	0.857	0.854	0.859	0.874	0.856	0.976	0.678	0.887
82	6.120	0.240	0.858	0.821	0.858	0.854	0.859	0.879	0.848	0.977	0.686	0.880
85	6.083	0.238	0.862	0.826	0.862	0.858	0.864	0.881	0.863	0.973	0.690	0.885
88	5.985	0.242	0.860	0.824	0.860	0.857	0.861	0.880	0.857	0.972	0.684	0.890
91	6.060	0.248	0.861	0.825	0.861	0.857	0.861	0.884	0.863	0.968	0.682	0.885
94	6.231	0.240	0.850	0.812	0.850	0.846	0.852	0.877	0.840	0.973	0.660	0.878
97	6.246	0.249	0.856	0.820	0.856	0.853	0.860	0.875	0.860	0.972	0.679	0.880
100	6.233	0.248	0.861	0.825	0.861	0.858	0.863	0.874	0.860	0.976	0.689	0.892
103	6.612	0.254	0.852	0.815	0.852	0.851	0.859	0.869	0.850	0.975	0.673	0.889
106	6.354	0.241	0.853	0.816	0.853	0.849	0.855	0.876	0.846	0.970	0.666	0.889
109	6.322	0.254	0.853	0.815	0.853	0.848	0.853	0.874	0.851	0.962	0.665	0.889
112	6.864	0.238	0.853	0.816	0.853	0.849	0.854	0.872	0.852	0.971	0.670	0.882
115	7.344	0.243	0.857	0.821	0.857	0.853	0.859	0.884	0.847	0.975	0.678	0.883
118	7.102	0.257	0.862	0.826	0.862	0.857	0.862	0.881	0.857	0.976	0.692	0.880
121	7.851	0.266	0.855	0.818	0.855	0.853	0.859	0.873	0.851	0.974	0.677	0.890
124	8.344	0.269	0.860	0.824	0.860	0.856	0.862	0.882	0.858	0.974	0.684	0.882
127	8.249	0.270	0.859	0.823	0.859	0.854	0.862	0.889	0.855	0.971	0.679	0.878
130	8.345	0.257	0.857	0.820	0.857	0.854	0.859	0.872	0.865	0.969	0.682	0.883
133	7.062	0.256	0.856	0.819	0.856	0.853	0.858	0.870	0.860	0.974	0.678	0.882
136	7.304	0.259	0.862	0.826	0.862	0.857	0.861	0.880	0.862	0.971	0.683	0.888
139	8.390	0.266	0.857	0.820	0.857	0.853	0.859	0.880	0.862	0.969	0.684	0.872
142	8.543	0.277	0.859	0.823	0.859	0.854	0.860	0.884	0.857	0.964	0.685	0.882
145	7.248	0.250	0.861	0.826	0.861	0.858	0.863	0.884	0.862	0.974	0.684	0.885
148	7.159	0.274	0.859	0.822	0.859	0.855	0.858	0.878	0.854	0.972	0.681	0.888
151	7.751	0.253	0.861	0.826	0.861	0.857	0.861	0.877	0.866	0.970	0.687	0.886
154	8.830	0.274	0.858	0.821	0.858	0.853	0.859	0.887	0.855	0.972	0.681	0.869
157	9.110	0.279	0.859	0.823	0.859	0.854	0.858	0.874	0.869	0.964	0.673	0.890
160	8.834	0.282	0.854	0.817	0.854	0.850	0.855	0.876	0.856	0.971	0.663	0.883
163	9.237	0.284	0.862	0.827	0.862	0.858	0.863	0.887	0.857	0.970	0.691	0.885
166	9.136	0.281	0.861	0.826	0.861	0.857	0.862	0.884	0.855	0.970	0.682	0.892
169	9.008	0.274	0.862	0.827	0.862	0.858	0.864	0.885	0.857	0.973	0.688	0.889
172	9.019	0.278	0.861	0.826	0.861	0.857	0.864	0.883	0.857	0.974	0.689	0.881
175	8.929	0.280	0.859	0.823	0.859	0.855	0.861	0.883	0.850	0.974	0.685	0.885
178	9.561	0.279	0.859	0.823	0.859	0.854	0.859	0.882	0.862	0.964	0.682	0.882
181	8.694	0.279	0.851	0.813	0.851	0.848	0.855	0.873	0.843	0.971	0.669	0.886
184	8.847	0.279	0.858	0.822	0.858	0.854	0.859	0.883	0.854	0.971	0.676	0.885
187	8.417	0.268	0.857	0.820	0.857	0.854	0.860	0.878	0.852	0.975	0.680	0.885
190	8.314	0.279	0.861	0.826	0.861	0.858	0.865	0.881	0.855	0.974	0.692	0.891
193	8.171	0.284	0.856	0.818	0.856	0.852	0.857	0.880	0.848	0.976	0.667	0.888
196	8.345	0.274	0.861	0.826	0.861	0.857	0.861	0.881	0.862	0.974	0.676	0.891
199	8.307	0.276	0.859	0.823	0.859	0.855	0.860	0.878	0.862	0.976	0.681	0.880
202	8.375	0.279	0.862	0.827	0.862	0.858	0.863	0.881	0.861	0.974	0.689	0.887
205	8.483	0.282	0.857	0.821	0.857	0.853	0.858	0.884	0.846	0.976	0.676	0.881
208	8.526	0.285	0.858	0.822	0.858	0.853	0.858	0.881	0.861	0.975	0.673	0.875
210	9.844	0.282	0.863	0.828	0.863	0.859	0.862	0.884	0.864	0.975	0.683	0.886
211	8.361	0.287	0.861	0.825	0.861	0.857	0.863	0.882	0.856	0.975	0.683	0.888
214	9.309	0.274	0.857	0.820	0.857	0.853	0.858	0.878	0.858	0.972	0.668	0.889
217	8.880	0.284	0.862	0.826	0.862	0.858	0.862	0.882	0.861	0.970	0.689	0.887
220	9.822	0.298	0.860	0.824	0.860	0.857	0.862	0.881	0.863	0.972	0.681	0.888
223	8.732	0.290	0.860	0.824	0.860	0.857	0.862	0.878	0.861	0.967	0.683	0.894
226	8.866	0.278	0.864	0.829	0.864	0.860	0.864	0.883	0.868	0.967	0.697	0.884
229	8.900	0.281	0.868	0.834	0.868	0.863	0.867	0.890	0.865	0.972	0.704	0.885
232	10.089	0.286	0.861	0.826	0.861	0.857	0.862	0.887	0.858	0.968	0.683	0.887
235	9.062	0.298	0.859	0.823	0.859	0.854	0.858	0.878	0.863	0.971	0.673	0.885
238	8.958	0.300	0.867	0.833	0.867	0.862	0.867	0.887	0.867	0.971	0.695	0.891
241	9.082	0.282	0.861	0.826	0.861	0.857	0.862	0.882	0.868	0.970	0.688	0.877
244	9.513	0.275	0.867	0.833	0.867	0.864	0.869	0.884	0.866	0.975	0.699	0.896
247	9.942	0.305	0.859	0.823	0.859	0.856	0.862	0.879	0.854	0.968	0.689	0.892

Table B.43: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 6 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.671	0.235	0.851	0.813	0.851	0.847	0.851	0.874	0.851	0.969	0.657	0.881
16	5.180	0.231	0.841	0.801	0.841	0.835	0.840	0.866	0.844	0.968	0.631	0.865
19	5.133	0.225	0.841	0.801	0.841	0.838	0.844	0.865	0.837	0.967	0.643	0.880
22	5.263	0.234	0.846	0.807	0.846	0.843	0.848	0.869	0.847	0.965	0.653	0.879
25	5.282	0.227	0.850	0.811	0.850	0.848	0.853	0.870	0.849	0.974	0.654	0.891
28	5.855	0.233	0.850	0.812	0.850	0.845	0.850	0.873	0.854	0.960	0.662	0.878
31	5.356	0.228	0.847	0.808	0.847	0.843	0.849	0.873	0.841	0.967	0.651	0.884
34	5.852	0.230	0.850	0.812	0.850	0.847	0.853	0.871	0.846	0.973	0.659	0.885
37	5.436	0.227	0.850	0.812	0.850	0.846	0.851	0.872	0.851	0.965	0.657	0.887
40	5.550	0.229	0.845	0.805	0.845	0.841	0.846	0.869	0.843	0.963	0.650	0.879
43	4.678	0.221	0.854	0.817	0.854	0.849	0.854	0.886	0.844	0.972	0.671	0.870
46	5.335	0.217	0.850	0.811	0.850	0.845	0.850	0.873	0.850	0.961	0.661	0.881
49	4.904	0.219	0.851	0.813	0.851	0.847	0.852	0.871	0.856	0.964	0.663	0.879
52	4.955	0.219	0.849	0.810	0.849	0.844	0.850	0.871	0.848	0.970	0.648	0.884
55	5.226	0.225	0.855	0.818	0.855	0.853	0.859	0.878	0.855	0.969	0.680	0.882
58	5.703	0.225	0.849	0.810	0.849	0.845	0.850	0.873	0.847	0.964	0.659	0.881
61	6.681	0.241	0.854	0.817	0.854	0.850	0.856	0.875	0.854	0.968	0.667	0.887
64	6.515	0.240	0.856	0.819	0.856	0.851	0.856	0.880	0.856	0.968	0.674	0.878
67	6.117	0.243	0.851	0.813	0.851	0.846	0.851	0.878	0.858	0.958	0.666	0.872
70	5.489	0.228	0.852	0.815	0.852	0.848	0.853	0.879	0.848	0.965	0.668	0.879
73	5.498	0.238	0.851	0.813	0.851	0.845	0.850	0.879	0.853	0.960	0.656	0.878
76	5.730	0.227	0.850	0.812	0.850	0.846	0.854	0.878	0.842	0.963	0.665	0.882
79	5.746	0.234	0.850	0.811	0.850	0.847	0.852	0.867	0.849	0.972	0.663	0.883
82	5.754	0.233	0.847	0.808	0.847	0.843	0.849	0.869	0.849	0.960	0.662	0.875
85	5.991	0.231	0.854	0.817	0.854	0.850	0.856	0.876	0.842	0.967	0.678	0.885
88	5.947	0.235	0.857	0.820	0.857	0.854	0.860	0.875	0.852	0.971	0.681	0.891
91	5.959	0.238	0.852	0.814	0.852	0.845	0.850	0.877	0.852	0.963	0.649	0.883
94	6.032	0.228	0.856	0.819	0.856	0.852	0.857	0.873	0.862	0.968	0.675	0.881
97	6.136	0.242	0.852	0.814	0.852	0.848	0.854	0.876	0.853	0.961	0.675	0.875
100	6.198	0.239	0.853	0.816	0.853	0.849	0.855	0.877	0.846	0.968	0.668	0.886
103	6.340	0.242	0.854	0.817	0.854	0.850	0.856	0.882	0.847	0.969	0.672	0.881
106	6.350	0.242	0.848	0.809	0.848	0.843	0.848	0.874	0.845	0.964	0.650	0.881
109	6.532	0.239	0.852	0.814	0.852	0.847	0.852	0.879	0.851	0.955	0.666	0.883
112	6.346	0.240	0.857	0.820	0.857	0.852	0.857	0.884	0.852	0.967	0.675	0.881
115	6.495	0.239	0.852	0.814	0.852	0.847	0.853	0.871	0.851	0.968	0.665	0.880
118	6.395	0.235	0.853	0.816	0.853	0.849	0.855	0.877	0.854	0.965	0.663	0.885
121	6.502	0.245	0.842	0.802	0.842	0.836	0.842	0.866	0.850	0.955	0.629	0.881
124	6.684	0.243	0.854	0.817	0.854	0.851	0.857	0.869	0.854	0.967	0.675	0.890
127	6.677	0.256	0.851	0.813	0.851	0.844	0.849	0.882	0.844	0.960	0.657	0.875
130	6.672	0.242	0.854	0.817	0.854	0.849	0.854	0.873	0.858	0.965	0.662	0.889
133	6.841	0.243	0.852	0.814	0.852	0.846	0.852	0.879	0.855	0.961	0.665	0.871
136	6.669	0.262	0.851	0.813	0.851	0.847	0.851	0.872	0.859	0.960	0.656	0.888
139	6.982	0.254	0.855	0.818	0.855	0.851	0.855	0.878	0.855	0.969	0.672	0.881
142	7.032	0.247	0.853	0.816	0.853	0.850	0.856	0.870	0.855	0.966	0.675	0.883
145	6.983	0.243	0.851	0.813	0.851	0.845	0.850	0.878	0.852	0.965	0.667	0.863
148	7.104	0.254	0.853	0.816	0.853	0.849	0.853	0.877	0.854	0.964	0.663	0.886
151	7.296	0.253	0.860	0.824	0.860	0.856	0.859	0.880	0.852	0.973	0.683	0.892
154	7.349	0.239	0.848	0.809	0.848	0.844	0.851	0.875	0.833	0.968	0.659	0.885
157	7.273	0.257	0.855	0.818	0.855	0.851	0.856	0.881	0.855	0.963	0.672	0.882
160	7.148	0.250	0.852	0.815	0.852	0.847	0.852	0.880	0.852	0.966	0.659	0.878
163	7.498	0.247	0.858	0.822	0.858	0.855	0.860	0.877	0.858	0.969	0.682	0.887
166	7.355	0.239	0.855	0.818	0.855	0.851	0.857	0.877	0.857	0.963	0.669	0.890
169	7.523	0.254	0.853	0.815	0.853	0.848	0.852	0.877	0.846	0.965	0.665	0.890
172	7.515	0.266	0.852	0.814	0.852	0.848	0.854	0.872	0.859	0.960	0.669	0.880
175	7.618	0.253	0.856	0.820	0.856	0.851	0.856	0.879	0.855	0.963	0.670	0.890
178	7.695	0.267	0.856	0.820	0.856	0.853	0.858	0.875	0.858	0.968	0.672	0.893
181	7.617	0.269	0.860	0.824	0.860	0.856	0.861	0.885	0.855	0.966	0.689	0.885
184	7.879	0.255	0.855	0.818	0.855	0.850	0.855	0.879	0.843	0.963	0.667	0.899
187	7.866	0.255	0.853	0.816	0.853	0.848	0.853	0.881	0.849	0.959	0.666	0.885
190	7.907	0.266	0.851	0.813	0.851	0.846	0.852	0.875	0.846	0.964	0.658	0.888
193	7.862	0.260	0.849	0.811	0.849	0.845	0.850	0.868	0.849	0.967	0.657	0.882
196	8.029	0.255	0.853	0.816	0.853	0.848	0.854	0.877	0.849	0.969	0.665	0.882
199	8.037	0.267	0.859	0.823	0.859	0.853	0.858	0.880	0.865	0.960	0.674	0.887
202	8.094	0.263	0.862	0.826	0.862	0.857	0.862	0.884	0.865	0.965	0.687	0.884
205	8.316	0.262	0.857	0.821	0.857	0.853	0.859	0.887	0.842	0.962	0.683	0.892
208	8.147	0.271	0.852	0.814	0.852	0.847	0.852	0.878	0.847	0.971	0.665	0.874
211	8.356	0.279	0.855	0.818	0.855	0.851	0.856	0.874	0.853	0.966	0.669	0.892
214	8.217	0.273	0.858	0.822	0.858	0.854	0.859	0.885	0.850	0.963	0.682	0.888
217	8.312	0.273	0.859	0.823	0.859	0.854	0.860	0.879	0.860	0.972	0.670	0.890
220	8.448	0.261	0.854	0.817	0.854	0.848	0.851	0.875	0.864	0.957	0.662	0.882
223	8.516	0.260	0.854	0.817	0.854	0.851	0.856	0.879	0.844	0.955	0.681	0.898
226	8.576	0.256	0.852	0.814	0.852	0.848	0.853	0.876	0.840	0.972	0.660	0.890
229	8.450	0.271	0.858	0.822	0.858	0.853	0.858	0.885	0.855	0.960	0.679	0.885
232	8.512	0.266	0.856	0.820	0.856	0.853	0.858	0.874	0.858	0.962	0.676	0.895
235	8.905	0.269	0.861	0.826	0.861	0.856	0.860	0.883	0.855	0.971	0.674	0.894
238	8.722	0.274	0.858	0.822	0.858	0.854	0.860	0.879	0.857	0.972	0.681	0.881
241	8.781	0.282	0.859	0.824	0.859	0.855	0.861	0.878	0.861	0.965	0.679	0.891
244	8.981	0.273	0.859	0.822	0.859	0.853	0.857	0.886	0.858	0.962	0.670	0.888
247	9.000	0.259	0.862	0.827	0.862	0.858	0.863	0.878	0.867	0.973	0.692	0.880

Table B.44: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 6 and pooling size = 2

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	5.684	0.247	0.838	0.797	0.838	0.834	0.842	0.868	0.832	0.960	0.647	0.865
16	5.334	0.243	0.840	0.800	0.840	0.836	0.843	0.859	0.838	0.967	0.644	0.873
19	5.767	0.249	0.854	0.816	0.854	0.850	0.856	0.880	0.852	0.969	0.673	0.878
22	5.552	0.248	0.848	0.809	0.848	0.844	0.849	0.879	0.840	0.963	0.648	0.888
25	5.799	0.253	0.851	0.813	0.851	0.848	0.855	0.877	0.849	0.968	0.666	0.879
28	5.202	0.244	0.847	0.807	0.847	0.841	0.847	0.878	0.847	0.957	0.654	0.871
31	5.890	0.254	0.855	0.818	0.855	0.850	0.855	0.879	0.855	0.963	0.668	0.887
34	6.225	0.258	0.853	0.816	0.853	0.848	0.855	0.880	0.854	0.966	0.667	0.873
37	6.262	0.259	0.855	0.817	0.855	0.850	0.855	0.883	0.851	0.963	0.668	0.886
40	6.644	0.266	0.860	0.824	0.860	0.856	0.861	0.887	0.856	0.971	0.682	0.884
43	6.572	0.264	0.853	0.815	0.853	0.849	0.855	0.876	0.855	0.963	0.672	0.880
46	6.850	0.268	0.858	0.821	0.858	0.853	0.858	0.879	0.861	0.968	0.680	0.876
49	7.226	0.269	0.858	0.821	0.858	0.853	0.858	0.878	0.866	0.970	0.670	0.884
52	6.913	0.278	0.859	0.823	0.859	0.856	0.861	0.880	0.860	0.966	0.685	0.890
55	6.581	0.277	0.855	0.818	0.855	0.852	0.858	0.881	0.851	0.966	0.672	0.888
58	7.042	0.279	0.852	0.815	0.852	0.847	0.853	0.877	0.853	0.971	0.660	0.874
61	7.238	0.281	0.856	0.819	0.856	0.852	0.857	0.880	0.857	0.967	0.675	0.880
64	7.639	0.282	0.860	0.824	0.860	0.857	0.862	0.883	0.856	0.962	0.693	0.892
67	7.930	0.284	0.858	0.822	0.858	0.854	0.859	0.882	0.856	0.969	0.680	0.882
70	7.737	0.284	0.856	0.820	0.856	0.851	0.856	0.876	0.864	0.965	0.666	0.886
73	7.842	0.286	0.855	0.818	0.855	0.852	0.858	0.871	0.859	0.968	0.678	0.882
76	7.693	0.288	0.857	0.821	0.857	0.853	0.859	0.881	0.863	0.970	0.678	0.871
79	6.969	0.281	0.858	0.822	0.858	0.853	0.859	0.883	0.856	0.971	0.675	0.881
82	7.621	0.297	0.857	0.821	0.857	0.854	0.859	0.876	0.864	0.966	0.681	0.883
85	8.046	0.285	0.861	0.825	0.861	0.857	0.861	0.885	0.862	0.967	0.685	0.884
88	8.177	0.297	0.857	0.820	0.857	0.853	0.857	0.883	0.861	0.966	0.674	0.879
91	8.160	0.294	0.856	0.819	0.856	0.852	0.857	0.880	0.855	0.970	0.665	0.889
94	8.212	0.299	0.859	0.823	0.859	0.854	0.860	0.889	0.851	0.969	0.682	0.879
97	8.423	0.297	0.861	0.826	0.861	0.857	0.861	0.886	0.860	0.960	0.694	0.884
100	8.570	0.303	0.862	0.827	0.862	0.859	0.865	0.886	0.857	0.969	0.695	0.886
103	7.571	0.305	0.857	0.821	0.857	0.852	0.859	0.881	0.859	0.970	0.668	0.884
106	7.834	0.296	0.861	0.825	0.861	0.857	0.861	0.880	0.863	0.972	0.682	0.887
109	8.433	0.303	0.864	0.829	0.864	0.859	0.864	0.887	0.863	0.970	0.697	0.881
112	8.805	0.310	0.861	0.826	0.861	0.856	0.863	0.888	0.859	0.971	0.683	0.878
115	8.592	0.313	0.867	0.833	0.867	0.863	0.868	0.889	0.869	0.969	0.700	0.889
118	8.902	0.242	0.864	0.829	0.864	0.859	0.866	0.889	0.864	0.969	0.691	0.884
121	9.070	0.241	0.859	0.823	0.859	0.855	0.860	0.883	0.857	0.970	0.677	0.891
124	8.712	0.236	0.863	0.827	0.863	0.858	0.862	0.890	0.863	0.969	0.687	0.878
127	8.949	0.248	0.862	0.827	0.862	0.858	0.862	0.887	0.858	0.972	0.687	0.886
130	9.254	0.246	0.860	0.824	0.860	0.856	0.860	0.887	0.856	0.970	0.679	0.885
133	9.231	0.242	0.862	0.827	0.862	0.857	0.862	0.885	0.864	0.965	0.687	0.884
136	9.249	0.246	0.867	0.833	0.867	0.862	0.866	0.889	0.869	0.972	0.692	0.889
139	9.309	0.244	0.863	0.828	0.863	0.859	0.864	0.886	0.870	0.969	0.690	0.880
142	9.396	0.248	0.863	0.828	0.863	0.859	0.863	0.888	0.861	0.968	0.693	0.883
145	9.613	0.240	0.863	0.827	0.863	0.858	0.864	0.892	0.854	0.970	0.691	0.885
148	9.665	0.244	0.857	0.821	0.857	0.851	0.856	0.886	0.860	0.966	0.666	0.876
151	9.720	0.240	0.858	0.822	0.858	0.855	0.861	0.871	0.874	0.967	0.673	0.888
154	9.771	0.250	0.860	0.824	0.860	0.855	0.861	0.879	0.871	0.966	0.682	0.879
157	9.505	0.245	0.861	0.826	0.861	0.856	0.861	0.886	0.866	0.967	0.683	0.879
160	9.777	0.249	0.861	0.826	0.861	0.856	0.862	0.889	0.862	0.965	0.683	0.882
163	10.070	0.245	0.864	0.830	0.864	0.859	0.863	0.885	0.862	0.975	0.692	0.881
166	9.993	0.252	0.862	0.826	0.862	0.857	0.862	0.887	0.859	0.972	0.683	0.885
169	10.181	0.245	0.861	0.825	0.861	0.857	0.862	0.884	0.856	0.971	0.685	0.887
172	10.186	0.251	0.858	0.822	0.858	0.854	0.861	0.888	0.853	0.965	0.679	0.885
175	10.253	0.245	0.859	0.822	0.859	0.854	0.859	0.881	0.864	0.968	0.678	0.880
178	10.134	0.246	0.864	0.829	0.864	0.860	0.866	0.889	0.852	0.968	0.702	0.891
181	10.388	0.254	0.862	0.827	0.862	0.857	0.862	0.884	0.861	0.970	0.682	0.889
184	10.199	0.251	0.858	0.822	0.858	0.855	0.860	0.881	0.854	0.968	0.689	0.882
187	10.295	0.247	0.861	0.826	0.861	0.857	0.863	0.890	0.854	0.972	0.687	0.881
190	10.358	0.255	0.866	0.832	0.866	0.863	0.868	0.887	0.863	0.972	0.703	0.889
193	10.533	0.248	0.863	0.828	0.863	0.860	0.865	0.889	0.858	0.969	0.688	0.896
196	10.517	0.253	0.862	0.826	0.862	0.857	0.863	0.889	0.863	0.964	0.685	0.885
199	10.706	0.250	0.865	0.830	0.865	0.860	0.865	0.889	0.866	0.969	0.691	0.887
202	10.744	0.251	0.858	0.822	0.858	0.853	0.858	0.880	0.860	0.972	0.678	0.877
205	10.698	0.256	0.866	0.831	0.866	0.861	0.865	0.889	0.867	0.969	0.689	0.891
208	10.757	0.249	0.858	0.821	0.858	0.853	0.858	0.879	0.861	0.967	0.680	0.880
211	10.891	0.254	0.864	0.829	0.864	0.860	0.866	0.887	0.863	0.972	0.694	0.886
214	11.113	0.254	0.856	0.819	0.856	0.851	0.856	0.879	0.856	0.969	0.674	0.877
217	10.911	0.256	0.861	0.825	0.861	0.857	0.862	0.887	0.855	0.967	0.691	0.883
220	10.941	0.252	0.861	0.825	0.861	0.855	0.860	0.889	0.862	0.970	0.679	0.877
223	11.156	0.248	0.864	0.829	0.864	0.860	0.865	0.890	0.864	0.967	0.694	0.886
226	11.131	0.258	0.865	0.831	0.865	0.861	0.866	0.887	0.865	0.972	0.694	0.890
229	11.156	0.258	0.859	0.823	0.859	0.852	0.857	0.888	0.862	0.966	0.671	0.873
232	11.117	0.245	0.861	0.825	0.861	0.857	0.862	0.884	0.860	0.972	0.682	0.885
235	11.196	0.250	0.859	0.823	0.859	0.856	0.861	0.878	0.863	0.976	0.683	0.878
238	11.182	0.251	0.869	0.835	0.869	0.864	0.869	0.892	0.871	0.972	0.700	0.886
241	11.343	0.253	0.865	0.830	0.865	0.860	0.864	0.887	0.861	0.968	0.702	0.881
244	11.426	0.256	0.860	0.824	0.860	0.855	0.859	0.877	0.863	0.973	0.674	0.888
247	11.362	0.253	0.867	0.833	0.867	0.864	0.868	0.889	0.866	0.970	0.698	0.896

Table B.45: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 256, Kernel size = 8 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.227	0.227	0.848	0.809	0.848	0.844	0.849	0.869	0.846	0.961	0.669	0.875
16	3.701	0.210	0.852	0.814	0.852	0.848	0.855	0.875	0.848	0.964	0.672	0.882
19	4.941	0.228	0.850	0.812	0.850	0.846	0.852	0.876	0.853	0.961	0.657	0.883
22	4.725	0.229	0.854	0.817	0.854	0.850	0.856	0.876	0.854	0.965	0.671	0.886
25	4.730	0.228	0.847	0.808	0.847	0.843	0.848	0.871	0.849	0.962	0.647	0.885
28	4.610	0.230	0.853	0.815	0.853	0.849	0.854	0.874	0.855	0.963	0.675	0.878
31	5.415	0.240	0.850	0.811	0.850	0.845	0.851	0.879	0.848	0.958	0.664	0.877
34	5.169	0.235	0.858	0.821	0.858	0.853	0.858	0.885	0.853	0.967	0.680	0.882
37	5.605	0.237	0.858	0.822	0.858	0.853	0.859	0.884	0.862	0.961	0.679	0.880
40	5.467	0.239	0.856	0.819	0.856	0.851	0.858	0.887	0.847	0.967	0.673	0.882
43	5.537	0.242	0.846	0.806	0.846	0.843	0.847	0.866	0.844	0.962	0.658	0.882
46	6.026	0.251	0.855	0.818	0.855	0.850	0.856	0.879	0.852	0.965	0.665	0.889
49	5.845	0.245	0.855	0.818	0.855	0.851	0.857	0.876	0.856	0.965	0.676	0.883
52	5.511	0.245	0.856	0.819	0.856	0.851	0.857	0.881	0.851	0.967	0.684	0.874
55	6.256	0.248	0.859	0.823	0.859	0.855	0.860	0.887	0.857	0.961	0.681	0.888
58	6.182	0.252	0.854	0.816	0.854	0.850	0.855	0.879	0.850	0.956	0.677	0.886
61	6.379	0.253	0.857	0.821	0.857	0.853	0.859	0.888	0.850	0.970	0.676	0.879
64	6.552	0.254	0.863	0.828	0.863	0.859	0.864	0.886	0.867	0.965	0.689	0.887
67	6.687	0.257	0.852	0.814	0.852	0.848	0.853	0.881	0.852	0.965	0.668	0.872
70	6.849	0.259	0.855	0.818	0.855	0.851	0.858	0.885	0.844	0.965	0.676	0.884
73	7.005	0.257	0.855	0.818	0.855	0.850	0.855	0.881	0.848	0.968	0.667	0.886
76	6.796	0.256	0.851	0.813	0.851	0.846	0.852	0.876	0.852	0.970	0.654	0.877
79	6.596	0.255	0.854	0.816	0.854	0.850	0.854	0.875	0.848	0.965	0.669	0.893
82	6.588	0.258	0.868	0.834	0.868	0.864	0.868	0.892	0.864	0.967	0.698	0.897
85	7.206	0.255	0.855	0.818	0.855	0.852	0.858	0.878	0.848	0.971	0.676	0.887
88	7.436	0.266	0.855	0.818	0.855	0.850	0.855	0.883	0.859	0.960	0.667	0.881
91	7.418	0.267	0.865	0.831	0.865	0.861	0.867	0.892	0.863	0.964	0.705	0.882
94	7.406	0.270	0.858	0.822	0.858	0.854	0.859	0.879	0.859	0.971	0.676	0.885
97	7.696	0.268	0.860	0.824	0.860	0.855	0.859	0.886	0.855	0.967	0.681	0.884
100	7.612	0.267	0.856	0.819	0.856	0.851	0.855	0.881	0.855	0.965	0.671	0.882
103	6.976	0.268	0.856	0.819	0.856	0.854	0.860	0.878	0.853	0.964	0.680	0.894
106	7.670	0.269	0.858	0.822	0.858	0.853	0.859	0.881	0.860	0.970	0.680	0.874
109	7.929	0.275	0.858	0.823	0.858	0.855	0.861	0.882	0.857	0.971	0.682	0.881
112	7.953	0.268	0.860	0.824	0.860	0.856	0.862	0.881	0.864	0.966	0.685	0.887
115	8.185	0.276	0.857	0.820	0.857	0.852	0.856	0.884	0.855	0.964	0.673	0.885
118	8.251	0.281	0.860	0.824	0.860	0.855	0.859	0.883	0.864	0.967	0.675	0.885
121	8.407	0.279	0.860	0.825	0.860	0.857	0.862	0.881	0.865	0.970	0.687	0.880
124	7.632	0.274	0.854	0.817	0.854	0.850	0.857	0.880	0.848	0.967	0.674	0.881
127	8.010	0.278	0.857	0.820	0.857	0.852	0.858	0.887	0.854	0.961	0.678	0.881
130	8.158	0.283	0.861	0.825	0.861	0.858	0.864	0.887	0.855	0.966	0.690	0.892
133	8.503	0.282	0.861	0.826	0.861	0.858	0.861	0.881	0.862	0.971	0.682	0.892
136	8.466	0.279	0.865	0.830	0.865	0.862	0.867	0.883	0.867	0.970	0.704	0.886
139	8.718	0.278	0.866	0.831	0.866	0.862	0.868	0.891	0.868	0.961	0.701	0.892
142	8.389	0.283	0.861	0.826	0.861	0.859	0.865	0.883	0.859	0.970	0.692	0.889
145	8.193	0.284	0.864	0.829	0.864	0.861	0.865	0.881	0.872	0.965	0.691	0.895
148	8.457	0.279	0.860	0.824	0.860	0.856	0.861	0.879	0.858	0.971	0.682	0.892
151	8.831	0.283	0.862	0.827	0.862	0.858	0.863	0.889	0.859	0.967	0.688	0.889
154	8.715	0.279	0.868	0.834	0.868	0.863	0.869	0.892	0.867	0.971	0.702	0.885
157	8.911	0.286	0.860	0.825	0.860	0.856	0.860	0.886	0.860	0.967	0.676	0.889
160	8.794	0.282	0.862	0.827	0.862	0.859	0.866	0.890	0.852	0.970	0.698	0.884
163	9.352	0.292	0.864	0.829	0.864	0.859	0.864	0.888	0.870	0.967	0.690	0.881
166	8.639	0.282	0.865	0.831	0.865	0.860	0.865	0.886	0.867	0.973	0.685	0.888
169	8.896	0.285	0.862	0.827	0.862	0.857	0.862	0.886	0.862	0.965	0.684	0.887
172	9.112	0.288	0.864	0.829	0.864	0.859	0.863	0.889	0.861	0.971	0.691	0.884
175	9.447	0.303	0.863	0.827	0.863	0.857	0.862	0.886	0.872	0.963	0.685	0.880
178	9.423	0.295	0.854	0.816	0.854	0.849	0.855	0.882	0.842	0.971	0.664	0.884
181	9.094	0.294	0.865	0.831	0.865	0.860	0.865	0.894	0.865	0.965	0.689	0.887
184	9.332	0.293	0.866	0.831	0.866	0.861	0.866	0.890	0.863	0.972	0.692	0.889
187	8.797	0.293	0.866	0.832	0.866	0.862	0.867	0.889	0.868	0.971	0.695	0.889
190	9.170	0.298	0.861	0.826	0.861	0.857	0.862	0.888	0.856	0.967	0.688	0.887
193	9.296	0.297	0.857	0.821	0.857	0.852	0.859	0.887	0.857	0.964	0.673	0.880
196	9.840	0.312	0.860	0.824	0.860	0.856	0.860	0.882	0.858	0.971	0.684	0.882
199	9.463	0.305	0.856	0.820	0.856	0.852	0.858	0.881	0.857	0.967	0.672	0.882
202	9.457	0.307	0.863	0.828	0.863	0.858	0.863	0.881	0.870	0.970	0.677	0.892
205	9.315	0.297	0.860	0.824	0.860	0.855	0.860	0.885	0.861	0.969	0.681	0.880
208	9.539	0.307	0.863	0.828	0.863	0.859	0.864	0.887	0.858	0.969	0.695	0.885
211	10.263	0.308	0.859	0.823	0.859	0.855	0.859	0.881	0.860	0.966	0.683	0.882
214	10.017	0.312	0.862	0.826	0.862	0.857	0.862	0.885	0.858	0.962	0.692	0.890
217	9.856	0.290	0.868	0.834	0.868	0.864	0.868	0.892	0.864	0.968	0.702	0.893
220	10.091	0.255	0.867	0.833	0.867	0.862	0.867	0.888	0.873	0.973	0.701	0.876
223	9.767	0.245	0.862	0.826	0.862	0.857	0.861	0.883	0.863	0.972	0.683	0.886
226	9.983	0.239	0.862	0.827	0.862	0.858	0.863	0.886	0.865	0.966	0.690	0.883
229	10.161	0.241	0.858	0.822	0.858	0.853	0.857	0.882	0.859	0.970	0.670	0.881
232	10.125	0.245	0.868	0.834	0.868	0.864	0.868	0.891	0.862	0.976	0.697	0.892
235	9.962	0.247	0.864	0.830	0.864	0.858	0.865	0.889	0.866	0.968	0.689	0.880
238	10.106	0.244	0.860	0.824	0.860	0.856	0.860	0.886	0.853	0.966	0.681	0.892
241	9.760	0.232	0.863	0.828	0.863	0.858	0.863	0.889	0.866	0.969	0.685	0.880
244	10.022	0.235	0.864	0.829	0.864	0.859	0.865	0.890	0.857	0.973	0.687	0.891
247	10.256	0.243	0.864	0.830	0.864	0.860	0.865	0.889	0.866	0.969	0.693	0.883

Table B.46: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 128, Kernel size = 8 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.546	0.227	0.846	0.807	0.846	0.841	0.847	0.877	0.841	0.956	0.655	0.877
16	4.700	0.221	0.844	0.804	0.844	0.840	0.845	0.862	0.853	0.965	0.643	0.878
19	5.185	0.228	0.849	0.810	0.849	0.843	0.849	0.878	0.851	0.963	0.647	0.878
22	4.392	0.220	0.846	0.807	0.846	0.843	0.851	0.873	0.842	0.963	0.662	0.875
25	4.552	0.222	0.850	0.812	0.850	0.847	0.852	0.875	0.852	0.961	0.665	0.880
28	5.097	0.218	0.847	0.808	0.847	0.843	0.848	0.868	0.855	0.959	0.659	0.874
31	4.774	0.220	0.850	0.812	0.850	0.847	0.853	0.874	0.847	0.963	0.667	0.883
34	4.267	0.208	0.848	0.809	0.848	0.844	0.849	0.872	0.849	0.962	0.655	0.883
37	5.017	0.223	0.850	0.812	0.850	0.847	0.854	0.876	0.851	0.961	0.661	0.888
40	5.587	0.234	0.849	0.811	0.849	0.846	0.852	0.874	0.845	0.962	0.661	0.888
43	5.598	0.237	0.849	0.811	0.849	0.843	0.848	0.882	0.848	0.952	0.655	0.878
46	5.834	0.242	0.850	0.811	0.850	0.845	0.851	0.878	0.848	0.965	0.661	0.874
49	5.981	0.241	0.854	0.816	0.854	0.849	0.855	0.877	0.858	0.965	0.671	0.876
52	5.942	0.239	0.856	0.819	0.856	0.851	0.856	0.886	0.858	0.959	0.673	0.878
55	6.154	0.245	0.852	0.815	0.852	0.847	0.852	0.877	0.857	0.961	0.655	0.885
58	6.490	0.238	0.856	0.819	0.856	0.853	0.859	0.881	0.854	0.965	0.674	0.890
61	6.180	0.233	0.855	0.819	0.855	0.851	0.858	0.885	0.850	0.962	0.677	0.883
64	5.902	0.233	0.850	0.811	0.850	0.845	0.849	0.872	0.852	0.962	0.653	0.887
67	6.321	0.251	0.852	0.814	0.852	0.848	0.853	0.876	0.855	0.954	0.671	0.882
70	6.637	0.247	0.859	0.823	0.859	0.855	0.860	0.883	0.863	0.959	0.688	0.880
73	6.700	0.246	0.852	0.814	0.852	0.849	0.853	0.875	0.855	0.954	0.669	0.889
76	6.624	0.239	0.858	0.821	0.858	0.854	0.859	0.884	0.859	0.961	0.678	0.887
79	6.884	0.246	0.855	0.818	0.855	0.850	0.856	0.888	0.852	0.965	0.668	0.876
82	6.790	0.248	0.852	0.814	0.852	0.848	0.854	0.881	0.849	0.966	0.667	0.876
85	7.253	0.247	0.855	0.818	0.855	0.851	0.855	0.877	0.858	0.962	0.674	0.883
88	7.128	0.251	0.857	0.821	0.857	0.854	0.859	0.876	0.859	0.963	0.683	0.888
91	5.993	0.233	0.857	0.820	0.857	0.853	0.857	0.879	0.857	0.963	0.674	0.892
94	6.954	0.245	0.862	0.827	0.862	0.858	0.865	0.889	0.865	0.958	0.689	0.891
97	7.077	0.252	0.861	0.825	0.861	0.857	0.861	0.886	0.857	0.962	0.686	0.893
100	6.988	0.248	0.856	0.819	0.856	0.849	0.855	0.885	0.860	0.960	0.669	0.874
103	7.263	0.251	0.856	0.820	0.856	0.850	0.856	0.883	0.859	0.961	0.670	0.879
106	7.364	0.252	0.853	0.815	0.853	0.848	0.854	0.876	0.856	0.960	0.669	0.881
109	7.445	0.251	0.853	0.816	0.853	0.851	0.857	0.871	0.852	0.968	0.678	0.886
112	7.741	0.255	0.856	0.819	0.856	0.851	0.857	0.882	0.859	0.954	0.677	0.885
115	6.974	0.250	0.856	0.819	0.856	0.852	0.858	0.887	0.847	0.962	0.672	0.893
118	7.514	0.233	0.854	0.817	0.854	0.850	0.855	0.881	0.856	0.964	0.676	0.872
121	7.634	0.256	0.855	0.818	0.855	0.851	0.859	0.880	0.853	0.967	0.670	0.887
124	7.929	0.254	0.858	0.822	0.858	0.854	0.860	0.886	0.856	0.971	0.677	0.880
127	8.023	0.254	0.859	0.823	0.859	0.854	0.858	0.884	0.861	0.961	0.677	0.889
130	8.148	0.261	0.858	0.822	0.858	0.854	0.860	0.890	0.855	0.959	0.679	0.885
133	8.125	0.258	0.856	0.820	0.856	0.853	0.859	0.880	0.854	0.970	0.676	0.884
136	7.877	0.261	0.858	0.822	0.858	0.853	0.859	0.887	0.859	0.963	0.670	0.885
139	7.456	0.257	0.864	0.829	0.864	0.859	0.863	0.891	0.860	0.968	0.691	0.886
142	8.372	0.266	0.861	0.825	0.861	0.856	0.862	0.887	0.858	0.963	0.687	0.886
145	8.739	0.264	0.854	0.817	0.854	0.848	0.853	0.881	0.857	0.962	0.657	0.883
148	8.577	0.264	0.857	0.821	0.857	0.852	0.856	0.885	0.857	0.966	0.672	0.882
151	8.390	0.254	0.858	0.822	0.858	0.854	0.859	0.882	0.860	0.954	0.676	0.898
154	8.676	0.268	0.861	0.825	0.861	0.858	0.863	0.881	0.866	0.970	0.686	0.886
157	8.789	0.270	0.857	0.821	0.857	0.853	0.858	0.883	0.854	0.965	0.675	0.885
160	8.072	0.259	0.857	0.820	0.857	0.853	0.859	0.885	0.849	0.967	0.679	0.888
163	8.219	0.268	0.861	0.826	0.861	0.858	0.862	0.885	0.858	0.965	0.686	0.895
166	8.927	0.271	0.862	0.827	0.862	0.858	0.863	0.882	0.863	0.966	0.691	0.886
169	8.926	0.270	0.862	0.827	0.862	0.858	0.863	0.884	0.860	0.960	0.694	0.894
172	8.880	0.275	0.858	0.822	0.858	0.854	0.858	0.880	0.863	0.968	0.676	0.881
175	8.891	0.271	0.858	0.822	0.858	0.853	0.858	0.883	0.868	0.958	0.677	0.880
178	8.850	0.268	0.863	0.828	0.863	0.858	0.862	0.886	0.866	0.966	0.689	0.884
181	8.442	0.260	0.857	0.820	0.857	0.853	0.861	0.884	0.849	0.970	0.679	0.885
184	9.032	0.269	0.859	0.823	0.859	0.853	0.857	0.887	0.863	0.959	0.672	0.883
187	8.905	0.270	0.864	0.829	0.864	0.860	0.864	0.890	0.863	0.960	0.692	0.894
190	9.189	0.279	0.853	0.815	0.853	0.847	0.852	0.882	0.854	0.957	0.661	0.882
193	9.187	0.277	0.862	0.827	0.862	0.857	0.863	0.887	0.858	0.969	0.683	0.886
196	9.315	0.273	0.860	0.824	0.860	0.855	0.860	0.888	0.858	0.964	0.679	0.888
199	9.361	0.266	0.864	0.829	0.864	0.860	0.865	0.891	0.860	0.966	0.695	0.890
202	8.671	0.272	0.859	0.822	0.859	0.854	0.858	0.881	0.860	0.963	0.679	0.889
205	9.402	0.276	0.864	0.829	0.864	0.859	0.863	0.889	0.866	0.967	0.689	0.885
208	9.362	0.275	0.859	0.823	0.859	0.855	0.859	0.881	0.856	0.968	0.680	0.891
211	9.570	0.277	0.858	0.822	0.858	0.854	0.860	0.881	0.854	0.966	0.685	0.887
214	9.688	0.276	0.858	0.823	0.858	0.854	0.860	0.879	0.867	0.959	0.678	0.888
217	9.608	0.284	0.862	0.827	0.862	0.858	0.862	0.887	0.861	0.967	0.684	0.889
220	9.017	0.269	0.864	0.830	0.864	0.861	0.865	0.886	0.862	0.967	0.695	0.895
223	9.881	0.278	0.859	0.823	0.859	0.854	0.859	0.887	0.855	0.960	0.682	0.885
226	9.825	0.278	0.860	0.824	0.860	0.856	0.860	0.887	0.861	0.957	0.689	0.885
229	9.727	0.281	0.861	0.826	0.861	0.858	0.865	0.889	0.849	0.961	0.700	0.890
232	9.914	0.280	0.867	0.833	0.867	0.864	0.869	0.891	0.861	0.970	0.704	0.892
235	9.872	0.279	0.864	0.830	0.864	0.861	0.866	0.891	0.857	0.972	0.693	0.892
238	9.369	0.280	0.862	0.827	0.862	0.858	0.866	0.886	0.861	0.967	0.688	0.885
241	9.730	0.286	0.862	0.827	0.862	0.855	0.863	0.888	0.863	0.962	0.677	0.887
244	9.851	0.290	0.853	0.815	0.853	0.847	0.851	0.876	0.859	0.965	0.655	0.879
247	9.972	0.285	0.862	0.826	0.862	0.857	0.862	0.885	0.863	0.961	0.692	0.885

Table B.47: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 64, Kernel size = 8 and pooling size = 4

Para Embedding dim	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	4.849	0.226	0.840	0.799	0.840	0.836	0.842	0.871	0.838	0.962	0.633	0.879
16	4.721	0.225	0.843	0.803	0.843	0.839	0.844	0.873	0.843	0.953	0.644	0.882
19	4.654	0.227	0.843	0.803	0.843	0.840	0.847	0.865	0.843	0.956	0.655	0.882
22	4.705	0.218	0.849	0.810	0.849	0.845	0.851	0.880	0.853	0.948	0.660	0.884
25	4.493	0.215	0.847	0.808	0.847	0.844	0.849	0.869	0.849	0.964	0.653	0.885
28	4.148	0.207	0.843	0.803	0.843	0.841	0.847	0.868	0.839	0.955	0.658	0.884
31	4.981	0.232	0.841	0.801	0.841	0.837	0.843	0.867	0.842	0.957	0.632	0.887
34	5.433	0.229	0.849	0.810	0.849	0.845	0.852	0.877	0.846	0.956	0.666	0.881
37	5.092	0.231	0.849	0.810	0.849	0.844	0.849	0.870	0.858	0.956	0.658	0.880
40	5.841	0.231	0.846	0.807	0.846	0.841	0.847	0.877	0.845	0.949	0.658	0.878
43	5.455	0.227	0.848	0.810	0.848	0.843	0.849	0.876	0.846	0.957	0.655	0.882
46	5.665	0.229	0.851	0.813	0.851	0.846	0.850	0.877	0.857	0.960	0.659	0.878
49	5.757	0.231	0.848	0.809	0.848	0.843	0.848	0.881	0.840	0.948	0.659	0.887
52	5.961	0.230	0.850	0.812	0.850	0.847	0.852	0.880	0.848	0.951	0.656	0.897
55	6.078	0.233	0.849	0.810	0.849	0.844	0.848	0.875	0.850	0.950	0.658	0.885
58	5.612	0.232	0.848	0.810	0.848	0.845	0.852	0.874	0.847	0.953	0.659	0.891
61	5.472	0.235	0.854	0.817	0.854	0.851	0.856	0.878	0.856	0.955	0.674	0.891
64	6.336	0.238	0.848	0.809	0.848	0.844	0.851	0.878	0.846	0.952	0.664	0.881
67	6.559	0.238	0.846	0.806	0.846	0.842	0.847	0.872	0.850	0.952	0.656	0.877
70	6.572	0.242	0.852	0.814	0.852	0.848	0.854	0.874	0.856	0.959	0.667	0.886
73	6.686	0.241	0.848	0.810	0.848	0.843	0.849	0.871	0.853	0.959	0.644	0.889
76	6.779	0.237	0.855	0.819	0.855	0.852	0.858	0.880	0.850	0.961	0.674	0.895
79	7.189	0.246	0.852	0.814	0.852	0.847	0.851	0.881	0.845	0.955	0.668	0.885
82	6.649	0.239	0.860	0.824	0.860	0.855	0.860	0.887	0.863	0.962	0.680	0.883
85	6.558	0.239	0.849	0.810	0.849	0.845	0.851	0.877	0.842	0.953	0.665	0.888
88	6.357	0.238	0.851	0.813	0.851	0.846	0.851	0.876	0.853	0.962	0.660	0.880
91	6.473	0.241	0.854	0.817	0.854	0.850	0.855	0.883	0.857	0.957	0.666	0.885
94	7.408	0.241	0.847	0.809	0.847	0.841	0.848	0.876	0.851	0.950	0.648	0.882
97	7.633	0.249	0.845	0.805	0.845	0.837	0.841	0.881	0.846	0.950	0.630	0.878
100	7.371	0.238	0.855	0.818	0.855	0.851	0.856	0.880	0.853	0.959	0.672	0.890
103	7.484	0.247	0.853	0.816	0.853	0.850	0.855	0.874	0.854	0.961	0.672	0.886
106	7.481	0.242	0.854	0.817	0.854	0.850	0.854	0.878	0.856	0.951	0.678	0.887
109	7.525	0.240	0.857	0.821	0.857	0.854	0.860	0.885	0.859	0.960	0.683	0.881
112	6.708	0.241	0.856	0.819	0.856	0.851	0.855	0.887	0.859	0.953	0.666	0.889
115	7.431	0.244	0.852	0.814	0.852	0.847	0.853	0.883	0.848	0.959	0.669	0.877
118	7.517	0.246	0.859	0.824	0.859	0.854	0.859	0.883	0.871	0.951	0.679	0.887
121	7.848	0.251	0.851	0.813	0.851	0.845	0.852	0.885	0.844	0.951	0.664	0.881
124	7.619	0.244	0.848	0.809	0.848	0.842	0.846	0.882	0.845	0.954	0.650	0.881
127	7.562	0.258	0.849	0.811	0.849	0.844	0.850	0.881	0.851	0.956	0.650	0.879
130	8.109	0.253	0.858	0.822	0.858	0.853	0.858	0.880	0.863	0.959	0.679	0.886
133	7.658	0.255	0.853	0.815	0.853	0.847	0.852	0.887	0.850	0.955	0.666	0.879
136	7.640	0.248	0.856	0.819	0.856	0.851	0.857	0.885	0.855	0.955	0.671	0.889
139	7.344	0.248	0.857	0.820	0.857	0.852	0.857	0.884	0.857	0.961	0.668	0.890
142	7.935	0.253	0.856	0.819	0.856	0.851	0.856	0.878	0.867	0.955	0.670	0.883
145	8.019	0.257	0.859	0.823	0.859	0.854	0.859	0.884	0.864	0.956	0.682	0.883
148	8.393	0.250	0.854	0.817	0.854	0.849	0.853	0.880	0.860	0.952	0.663	0.888
151	8.429	0.254	0.852	0.814	0.852	0.847	0.853	0.880	0.851	0.956	0.664	0.885
154	8.295	0.260	0.852	0.815	0.852	0.846	0.852	0.875	0.860	0.951	0.662	0.883
157	8.205	0.252	0.849	0.811	0.849	0.845	0.851	0.882	0.842	0.949	0.662	0.889
160	7.636	0.243	0.853	0.816	0.853	0.850	0.855	0.876	0.857	0.957	0.666	0.893
163	8.203	0.251	0.857	0.821	0.857	0.852	0.858	0.883	0.867	0.956	0.671	0.881
166	8.800	0.250	0.860	0.824	0.860	0.855	0.860	0.886	0.861	0.960	0.683	0.885
169	8.676	0.259	0.858	0.822	0.858	0.852	0.858	0.887	0.862	0.956	0.677	0.878
172	8.755	0.261	0.854	0.816	0.854	0.848	0.853	0.880	0.862	0.950	0.663	0.883
175	8.676	0.254	0.857	0.820	0.857	0.852	0.857	0.882	0.853	0.954	0.674	0.898
178	8.602	0.258	0.854	0.817	0.854	0.850	0.856	0.882	0.854	0.957	0.675	0.883
181	8.004	0.246	0.853	0.815	0.853	0.848	0.853	0.882	0.853	0.953	0.663	0.887
184	8.740	0.263	0.859	0.824	0.859	0.855	0.860	0.886	0.867	0.958	0.679	0.882
187	8.791	0.248	0.850	0.812	0.850	0.844	0.850	0.877	0.852	0.959	0.654	0.878
190	8.742	0.259	0.853	0.816	0.853	0.847	0.853	0.885	0.852	0.954	0.660	0.885
193	8.959	0.260	0.848	0.809	0.848	0.842	0.847	0.876	0.852	0.943	0.648	0.891
196	9.120	0.253	0.861	0.826	0.861	0.856	0.861	0.879	0.865	0.962	0.682	0.894
199	9.276	0.265	0.859	0.824	0.859	0.854	0.858	0.890	0.861	0.942	0.689	0.886
202	8.492	0.259	0.854	0.818	0.854	0.847	0.855	0.887	0.855	0.954	0.660	0.881
205	9.256	0.265	0.853	0.816	0.853	0.848	0.852	0.877	0.864	0.950	0.663	0.887
208	9.665	0.261	0.857	0.821	0.857	0.851	0.856	0.890	0.858	0.950	0.664	0.890
211	9.735	0.269	0.852	0.814	0.852	0.845	0.851	0.878	0.856	0.955	0.652	0.886
214	9.199	0.263	0.856	0.819	0.856	0.850	0.854	0.884	0.858	0.957	0.669	0.884
217	9.300	0.268	0.848	0.810	0.848	0.843	0.850	0.869	0.859	0.956	0.654	0.878
220	9.050	0.257	0.855	0.818	0.855	0.850	0.854	0.879	0.851	0.960	0.665	0.893
223	8.596	0.269	0.857	0.820	0.857	0.852	0.857	0.880	0.862	0.959	0.681	0.880
226	9.261	0.263	0.856	0.819	0.856	0.852	0.857	0.877	0.859	0.959	0.679	0.884
229	9.774	0.267	0.859	0.823	0.859	0.855	0.859	0.887	0.857	0.959	0.681	0.890
232	9.164	0.264	0.853	0.816	0.853	0.847	0.853	0.886	0.849	0.958	0.666	0.876
235	9.512	0.268	0.861	0.825	0.861	0.855	0.859	0.880	0.866	0.962	0.678	0.889
238	9.460	0.269	0.854	0.817	0.854	0.849	0.854	0.873	0.864	0.962	0.663	0.882
241	9.520	0.268	0.850	0.812	0.850	0.846	0.853	0.882	0.839	0.954	0.667	0.888
244	9.426	0.266	0.864	0.829	0.864	0.860	0.863	0.887	0.861	0.965	0.682	0.903
247	9.979	0.272	0.855	0.817	0.855	0.852	0.857	0.875	0.854	0.957	0.676	0.897

Table B.48: Performances and execution times for CNN on different embedding dimensions, when filter sizes = 32, Kernel size = 8 and pooling size = 4

Parameter Filter Size	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
13	9.313	0.254	0.846	0.807	0.846	0.840	0.844	0.869	0.853	0.963	0.638	0.879
16	9.422	0.261	0.848	0.810	0.848	0.841	0.847	0.872	0.855	0.959	0.639	0.880
19	9.596	0.253	0.850	0.813	0.850	0.847	0.852	0.869	0.866	0.952	0.666	0.881
22	9.800	0.251	0.847	0.808	0.847	0.840	0.846	0.876	0.850	0.964	0.633	0.879
25	9.507	0.261	0.850	0.812	0.850	0.845	0.850	0.868	0.853	0.965	0.660	0.876
28	9.729	0.268	0.857	0.821	0.857	0.853	0.858	0.877	0.860	0.971	0.680	0.875
31	9.592	0.262	0.851	0.813	0.851	0.845	0.850	0.873	0.856	0.963	0.654	0.879
34	9.951	0.273	0.857	0.820	0.857	0.851	0.855	0.878	0.863	0.967	0.662	0.887
37	10.083	0.274	0.864	0.830	0.864	0.861	0.865	0.877	0.878	0.973	0.687	0.888
40	9.974	0.267	0.860	0.824	0.860	0.855	0.859	0.876	0.867	0.970	0.676	0.885
43	9.672	0.271	0.857	0.821	0.857	0.851	0.856	0.879	0.858	0.962	0.671	0.885
46	9.572	0.274	0.856	0.819	0.856	0.851	0.856	0.876	0.859	0.967	0.673	0.881
49	9.282	0.272	0.857	0.820	0.857	0.852	0.857	0.876	0.857	0.969	0.667	0.889
52	9.921	0.278	0.855	0.818	0.855	0.851	0.856	0.873	0.860	0.972	0.665	0.886
55	9.560	0.276	0.864	0.829	0.864	0.859	0.863	0.883	0.871	0.972	0.684	0.886
58	9.782	0.282	0.859	0.824	0.859	0.857	0.861	0.870	0.867	0.972	0.684	0.890
61	10.143	0.280	0.856	0.819	0.856	0.851	0.855	0.878	0.855	0.972	0.664	0.885
64	9.844	0.282	0.863	0.828	0.863	0.859	0.862	0.884	0.864	0.975	0.683	0.886
67	10.143	0.287	0.859	0.823	0.859	0.855	0.859	0.879	0.864	0.971	0.680	0.880
70	9.901	0.284	0.867	0.833	0.867	0.862	0.867	0.883	0.871	0.974	0.696	0.887
73	9.791	0.279	0.862	0.827	0.862	0.856	0.862	0.886	0.858	0.977	0.683	0.877
76	9.675	0.292	0.861	0.826	0.861	0.857	0.861	0.877	0.862	0.972	0.686	0.888
79	9.932	0.294	0.861	0.825	0.861	0.857	0.861	0.878	0.862	0.971	0.679	0.892
82	9.962	0.293	0.861	0.826	0.861	0.857	0.862	0.882	0.859	0.973	0.682	0.888
85	10.141	0.299	0.864	0.829	0.864	0.859	0.865	0.886	0.858	0.974	0.690	0.885
88	9.964	0.294	0.859	0.823	0.859	0.853	0.859	0.883	0.858	0.969	0.675	0.881
91	10.174	0.288	0.859	0.822	0.859	0.853	0.859	0.881	0.858	0.975	0.671	0.881
94	9.974	0.296	0.866	0.832	0.866	0.860	0.865	0.885	0.866	0.977	0.688	0.885
97	10.308	0.296	0.861	0.826	0.861	0.857	0.862	0.876	0.864	0.977	0.681	0.888
100	10.006	0.302	0.860	0.824	0.860	0.856	0.861	0.878	0.860	0.976	0.677	0.888
103	9.901	0.298	0.855	0.818	0.855	0.851	0.857	0.869	0.859	0.976	0.670	0.881
106	9.770	0.298	0.863	0.828	0.863	0.859	0.863	0.881	0.862	0.977	0.686	0.887
109	10.154	0.301	0.857	0.821	0.857	0.853	0.858	0.877	0.859	0.975	0.674	0.879
112	10.098	0.309	0.863	0.829	0.863	0.859	0.865	0.883	0.863	0.977	0.687	0.884
115	10.119	0.303	0.857	0.820	0.857	0.854	0.858	0.873	0.857	0.978	0.675	0.887
118	10.166	0.294	0.862	0.827	0.862	0.858	0.863	0.882	0.859	0.970	0.682	0.897
121	10.104	0.313	0.857	0.821	0.857	0.852	0.857	0.884	0.857	0.971	0.665	0.881
124	10.077	0.307	0.862	0.827	0.862	0.857	0.862	0.880	0.870	0.973	0.676	0.886
127	10.071	0.311	0.862	0.827	0.862	0.858	0.864	0.880	0.864	0.977	0.689	0.880
130	10.130	0.323	0.863	0.828	0.863	0.858	0.863	0.880	0.862	0.975	0.679	0.896
133	10.202	0.290	0.865	0.830	0.865	0.861	0.865	0.880	0.867	0.974	0.693	0.887
136	10.406	0.243	0.866	0.832	0.866	0.861	0.866	0.888	0.866	0.975	0.689	0.886
139	10.361	0.254	0.853	0.816	0.853	0.850	0.857	0.873	0.841	0.975	0.673	0.889
142	10.290	0.242	0.861	0.825	0.861	0.856	0.861	0.882	0.866	0.972	0.676	0.882
145	10.625	0.253	0.860	0.825	0.860	0.856	0.860	0.879	0.868	0.972	0.678	0.881
148	10.536	0.247	0.865	0.831	0.865	0.862	0.866	0.882	0.865	0.977	0.694	0.891
151	10.510	0.255	0.864	0.829	0.864	0.861	0.866	0.888	0.855	0.979	0.683	0.899
154	10.172	0.243	0.859	0.824	0.859	0.855	0.862	0.878	0.858	0.978	0.677	0.886
157	10.427	0.242	0.862	0.827	0.862	0.859	0.863	0.883	0.864	0.978	0.686	0.882
160	10.339	0.252	0.865	0.831	0.865	0.861	0.865	0.887	0.867	0.973	0.688	0.889
163	10.539	0.248	0.859	0.822	0.859	0.855	0.860	0.875	0.864	0.975	0.677	0.885
166	10.586	0.247	0.864	0.829	0.864	0.859	0.864	0.888	0.868	0.976	0.686	0.878
169	10.504	0.254	0.863	0.828	0.863	0.859	0.865	0.880	0.865	0.975	0.692	0.885
172	10.492	0.250	0.867	0.833	0.867	0.865	0.870	0.881	0.867	0.979	0.701	0.896
175	10.327	0.246	0.865	0.830	0.865	0.861	0.865	0.882	0.860	0.979	0.690	0.894
178	10.556	0.250	0.862	0.827	0.862	0.859	0.863	0.879	0.865	0.974	0.686	0.889
181	10.534	0.250	0.865	0.830	0.865	0.862	0.867	0.882	0.869	0.976	0.692	0.890
182	10.288	0.249	0.863	0.828	0.863	0.861	0.866	0.878	0.866	0.977	0.703	0.879
184	10.411	0.252	0.859	0.824	0.859	0.855	0.861	0.879	0.866	0.974	0.674	0.884
187	10.543	0.247	0.860	0.825	0.860	0.857	0.863	0.874	0.867	0.978	0.687	0.881
190	10.554	0.250	0.863	0.828	0.863	0.860	0.865	0.882	0.858	0.975	0.696	0.887
193	10.914	0.244	0.864	0.830	0.864	0.860	0.866	0.883	0.866	0.976	0.686	0.891
196	10.694	0.257	0.862	0.827	0.862	0.859	0.865	0.876	0.870	0.979	0.682	0.888
199	10.424	0.249	0.872	0.839	0.872	0.867	0.871	0.888	0.875	0.976	0.710	0.888
202	10.668	0.249	0.865	0.830	0.865	0.861	0.866	0.882	0.868	0.977	0.694	0.886
205	10.834	0.255	0.861	0.825	0.861	0.857	0.862	0.876	0.869	0.975	0.682	0.883
208	10.892	0.247	0.866	0.832	0.866	0.862	0.868	0.881	0.870	0.975	0.703	0.881
211	10.650	0.248	0.864	0.828	0.864	0.860	0.864	0.882	0.872	0.973	0.688	0.885
214	10.749	0.255	0.861	0.826	0.861	0.857	0.862	0.883	0.863	0.975	0.678	0.886
217	10.685	0.254	0.867	0.833	0.867	0.863	0.868	0.884	0.870	0.977	0.697	0.887
220	10.947	0.249	0.862	0.826	0.862	0.858	0.862	0.874	0.871	0.975	0.681	0.886
223	10.859	0.255	0.858	0.822	0.858	0.853	0.858	0.878	0.859	0.976	0.670	0.882
226	10.696	0.248	0.860	0.825	0.860	0.855	0.862	0.884	0.862	0.974	0.677	0.881
229	10.978	0.250	0.859	0.823	0.859	0.855	0.860	0.880	0.855	0.977	0.675	0.890
232	10.624	0.246	0.866	0.832	0.866	0.864	0.868	0.883	0.864	0.977	0.705	0.890
235	10.799	0.257	0.865	0.830	0.865	0.862	0.867	0.880	0.866	0.978	0.693	0.893
238	11.014	0.254	0.865	0.831	0.865	0.862	0.868	0.882	0.867	0.979	0.690	0.892
241	10.893	0.253	0.859	0.824	0.859	0.855	0.860	0.877	0.858	0.976	0.678	0.887
244	11.128	0.254	0.861	0.826	0.861	0.855	0.860	0.883	0.865	0.978	0.670	0.880
247	10.842	0.258	0.864	0.830	0.864	0.861	0.864	0.883	0.869	0.975	0.689	0.886
250	11.049	0.255	0.867	0.833	0.867	0.864	0.868	0.882	0.871	0.979	0.695	0.892
253	10.761	0.258	0.862	0.826	0.862	0.858	0.863	0.880	0.861	0.976	0.685	0.886

Table B.49: Performances and execution times for CNN on different filter sizes, when embedding dimension is 210

Parameter	Time		Metrics					f1 score for each class				
	Dense Layer	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir
13	10.482	0.253	0.861	0.825	0.861	0.857	0.862	0.878	0.863	0.974	0.681	0.890
16	10.675	0.249	0.869	0.835	0.869	0.865	0.869	0.892	0.868	0.976	0.698	0.889
19	10.623	0.251	0.859	0.822	0.859	0.855	0.860	0.883	0.858	0.972	0.679	0.882
22	10.444	0.246	0.867	0.833	0.867	0.863	0.867	0.889	0.860	0.979	0.697	0.889
25	10.288	0.249	0.863	0.828	0.863	0.861	0.866	0.878	0.866	0.977	0.703	0.879
28	10.177	0.253	0.861	0.826	0.861	0.858	0.863	0.879	0.860	0.975	0.684	0.890
31	10.842	0.252	0.862	0.827	0.862	0.857	0.863	0.878	0.870	0.974	0.688	0.875
34	10.494	0.250	0.868	0.834	0.868	0.864	0.869	0.889	0.866	0.979	0.703	0.883
37	10.501	0.246	0.870	0.837	0.870	0.867	0.872	0.893	0.867	0.976	0.708	0.889
40	10.634	0.250	0.869	0.836	0.869	0.865	0.870	0.893	0.864	0.979	0.702	0.887
43	10.410	0.249	0.866	0.832	0.866	0.862	0.867	0.886	0.871	0.971	0.696	0.886
46	10.273	0.253	0.872	0.839	0.872	0.868	0.873	0.889	0.877	0.978	0.712	0.884
49	10.636	0.253	0.864	0.829	0.864	0.861	0.868	0.881	0.864	0.978	0.701	0.882
52	10.640	0.254	0.863	0.828	0.863	0.859	0.866	0.887	0.853	0.978	0.692	0.888
55	10.515	0.249	0.868	0.834	0.868	0.863	0.868	0.892	0.867	0.976	0.695	0.883
58	10.405	0.248	0.871	0.838	0.871	0.869	0.875	0.892	0.866	0.976	0.717	0.893
61	10.652	0.253	0.869	0.835	0.869	0.865	0.871	0.894	0.863	0.980	0.701	0.886
64	10.659	0.250	0.874	0.841	0.874	0.870	0.876	0.896	0.868	0.979	0.715	0.892
67	10.403	0.254	0.870	0.837	0.870	0.867	0.872	0.892	0.866	0.973	0.707	0.895
70	10.529	0.251	0.873	0.840	0.873	0.870	0.875	0.892	0.869	0.977	0.721	0.889
73	11.092	0.249	0.868	0.834	0.868	0.864	0.869	0.890	0.863	0.978	0.699	0.890
76	10.419	0.251	0.866	0.831	0.866	0.862	0.867	0.888	0.862	0.980	0.697	0.882
79	10.314	0.253	0.866	0.832	0.866	0.862	0.867	0.893	0.857	0.976	0.698	0.885
82	10.411	0.256	0.870	0.837	0.870	0.867	0.873	0.889	0.867	0.978	0.711	0.891
85	10.728	0.249	0.875	0.843	0.875	0.872	0.877	0.899	0.864	0.980	0.722	0.893
88	10.527	0.252	0.867	0.834	0.867	0.864	0.868	0.886	0.871	0.977	0.701	0.883
91	10.577	0.251	0.872	0.840	0.872	0.869	0.875	0.896	0.861	0.978	0.717	0.893
94	10.595	0.252	0.869	0.836	0.869	0.867	0.872	0.891	0.862	0.979	0.706	0.894
97	10.645	0.253	0.869	0.836	0.869	0.862	0.869	0.891	0.865	0.976	0.689	0.890
100	10.726	0.250	0.873	0.840	0.873	0.869	0.874	0.892	0.873	0.980	0.715	0.886
103	10.590	0.249	0.868	0.834	0.868	0.865	0.870	0.884	0.866	0.979	0.705	0.891
106	10.619	0.246	0.864	0.829	0.864	0.860	0.867	0.884	0.865	0.977	0.694	0.881
109	10.529	0.254	0.873	0.840	0.873	0.869	0.873	0.894	0.870	0.978	0.714	0.889
112	10.814	0.250	0.870	0.837	0.870	0.867	0.872	0.889	0.867	0.979	0.711	0.890
115	10.691	0.253	0.870	0.837	0.870	0.865	0.870	0.898	0.862	0.978	0.702	0.886
118	10.917	0.252	0.873	0.840	0.873	0.869	0.873	0.893	0.875	0.980	0.708	0.887
121	10.628	0.251	0.870	0.837	0.870	0.867	0.872	0.889	0.869	0.979	0.715	0.882
124	10.654	0.256	0.870	0.837	0.870	0.867	0.873	0.889	0.867	0.980	0.709	0.892
127	10.632	0.252	0.873	0.840	0.873	0.869	0.873	0.889	0.876	0.981	0.709	0.891
130	10.507	0.250	0.869	0.835	0.869	0.866	0.872	0.887	0.868	0.980	0.707	0.891
133	10.683	0.254	0.871	0.838	0.871	0.868	0.873	0.890	0.871	0.978	0.711	0.889
136	10.626	0.247	0.872	0.839	0.872	0.867	0.872	0.894	0.870	0.977	0.707	0.890
139	10.789	0.254	0.873	0.841	0.873	0.870	0.876	0.896	0.865	0.980	0.718	0.892
142	10.560	0.250	0.872	0.839	0.872	0.869	0.874	0.892	0.867	0.976	0.712	0.896
145	10.665	0.259	0.873	0.840	0.873	0.869	0.874	0.895	0.869	0.979	0.708	0.894
148	10.883	0.256	0.866	0.832	0.866	0.861	0.866	0.888	0.863	0.973	0.701	0.882
151	10.879	0.246	0.871	0.838	0.871	0.868	0.872	0.887	0.868	0.981	0.715	0.890
154	10.827	0.250	0.870	0.837	0.870	0.867	0.872	0.887	0.868	0.978	0.711	0.894
157	10.945	0.252	0.869	0.836	0.869	0.865	0.870	0.889	0.867	0.981	0.704	0.885
160	10.666	0.249	0.871	0.838	0.871	0.867	0.872	0.892	0.876	0.978	0.703	0.884
163	10.713	0.249	0.874	0.842	0.874	0.870	0.875	0.895	0.871	0.980	0.716	0.890
166	10.711	0.247	0.871	0.838	0.871	0.868	0.873	0.891	0.866	0.979	0.711	0.896
169	10.679	0.244	0.876	0.845	0.876	0.874	0.879	0.894	0.879	0.979	0.727	0.891
172	10.716	0.256	0.874	0.841	0.874	0.870	0.876	0.892	0.877	0.979	0.717	0.885
175	10.878	0.243	0.866	0.832	0.866	0.861	0.865	0.885	0.867	0.977	0.691	0.888
178	10.865	0.256	0.875	0.842	0.875	0.871	0.876	0.893	0.875	0.978	0.720	0.891
181	10.830	0.257	0.874	0.842	0.874	0.870	0.875	0.897	0.870	0.979	0.712	0.893
184	10.722	0.249	0.871	0.838	0.871	0.867	0.873	0.897	0.866	0.979	0.716	0.879
187	11.090	0.251	0.876	0.844	0.876	0.873	0.878	0.895	0.873	0.981	0.722	0.893
190	10.930	0.246	0.871	0.838	0.871	0.869	0.873	0.889	0.867	0.976	0.719	0.892
193	10.709	0.248	0.868	0.834	0.868	0.864	0.868	0.890	0.866	0.975	0.704	0.884
196	10.780	0.251	0.871	0.838	0.871	0.869	0.874	0.889	0.874	0.976	0.710	0.894
199	10.779	0.245	0.871	0.838	0.871	0.867	0.871	0.895	0.866	0.980	0.706	0.887
202	11.033	0.248	0.870	0.837	0.870	0.866	0.872	0.888	0.877	0.979	0.708	0.881
205	10.865	0.251	0.869	0.836	0.869	0.865	0.871	0.888	0.872	0.980	0.697	0.891
208	10.784	0.248	0.872	0.839	0.872	0.869	0.874	0.891	0.871	0.981	0.714	0.885
211	11.108	0.255	0.875	0.843	0.875	0.871	0.876	0.899	0.876	0.981	0.708	0.889
214	10.812	0.254	0.874	0.842	0.874	0.870	0.875	0.892	0.870	0.980	0.711	0.899
217	11.140	0.248	0.872	0.839	0.872	0.869	0.875	0.892	0.863	0.979	0.717	0.897
220	11.027	0.252	0.872	0.839	0.872	0.869	0.874	0.890	0.871	0.980	0.714	0.890
223	11.136	0.247	0.872	0.839	0.872	0.868	0.872	0.893	0.867	0.979	0.712	0.887
226	10.889	0.251	0.874	0.842	0.874	0.872	0.878	0.893	0.870	0.980	0.719	0.895
229	10.926	0.253	0.872	0.839	0.872	0.868	0.874	0.892	0.871	0.978	0.709	0.893
232	10.802	0.252	0.873	0.841	0.873	0.870	0.875	0.898	0.865	0.981	0.708	0.895
235	11.017	0.245	0.871	0.838	0.871	0.868	0.874	0.891	0.871	0.975	0.706	0.898
238	11.014	0.250	0.878	0.847	0.878	0.874	0.878	0.896	0.878	0.980	0.726	0.890
241	11.328	0.258	0.871	0.838	0.871	0.868	0.874	0.892	0.855	0.980	0.712	0.901
244	11.370	0.252	0.871	0.838	0.871	0.868	0.873	0.888	0.872	0.978	0.714	0.889
247	11.172	0.253	0.870	0.836	0.870	0.866	0.871	0.888	0.865	0.980	0.709	0.890

Table B.50: Performances and execution times for CNN on different dense layers, when embedding dimension is 210 and filter size is 182

Parameter	Time		Metrics					f1 score for each class				
	Train	Pred	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
0.0225	7.307	0.201	0.875	0.843	0.875	0.872	0.878	0.896	0.869	0.977	0.719	0.898
0.035	7.268	0.207	0.869	0.836	0.869	0.867	0.876	0.894	0.859	0.979	0.709	0.893
0.0475	7.316	0.211	0.875	0.843	0.875	0.872	0.878	0.897	0.870	0.979	0.720	0.893
0.06	7.278	0.208	0.873	0.841	0.873	0.871	0.876	0.892	0.876	0.975	0.719	0.893
0.0725	7.757	0.215	0.872	0.840	0.872	0.869	0.876	0.894	0.867	0.979	0.712	0.892
0.085	9.374	0.242	0.873	0.841	0.873	0.870	0.877	0.892	0.872	0.980	0.717	0.890
0.0975	10.280	0.244	0.869	0.836	0.869	0.866	0.872	0.890	0.866	0.977	0.707	0.889
0.11	10.410	0.246	0.871	0.838	0.871	0.869	0.876	0.889	0.870	0.977	0.716	0.891
0.1225	10.098	0.249	0.876	0.844	0.876	0.872	0.878	0.892	0.880	0.981	0.721	0.889
0.135	10.156	0.249	0.877	0.846	0.877	0.873	0.880	0.902	0.867	0.982	0.726	0.891
0.1475	10.067	0.247	0.871	0.838	0.871	0.868	0.874	0.894	0.863	0.981	0.705	0.896
0.16	10.296	0.246	0.879	0.849	0.879	0.876	0.882	0.900	0.879	0.979	0.732	0.888
0.1725	10.345	0.243	0.866	0.832	0.866	0.863	0.869	0.883	0.864	0.980	0.697	0.890
0.185	10.107	0.244	0.871	0.838	0.871	0.868	0.874	0.887	0.869	0.979	0.716	0.891
0.1975	9.726	0.238	0.870	0.836	0.870	0.867	0.872	0.887	0.869	0.980	0.704	0.894
0.21	10.897	0.253	0.868	0.834	0.868	0.865	0.872	0.889	0.859	0.979	0.704	0.894
0.2225	10.765	0.250	0.874	0.842	0.874	0.870	0.875	0.891	0.871	0.975	0.719	0.897
0.235	11.017	0.253	0.869	0.836	0.869	0.865	0.870	0.889	0.866	0.978	0.709	0.885
0.2475	10.869	0.253	0.873	0.840	0.873	0.870	0.875	0.891	0.867	0.980	0.711	0.900
0.26	10.859	0.247	0.869	0.836	0.869	0.866	0.872	0.888	0.866	0.979	0.711	0.885
0.2725	10.874	0.252	0.866	0.832	0.866	0.863	0.870	0.884	0.861	0.979	0.697	0.896
0.285	11.000	0.255	0.872	0.839	0.872	0.868	0.874	0.893	0.866	0.979	0.710	0.894
0.2975	10.860	0.256	0.867	0.834	0.867	0.864	0.872	0.891	0.863	0.978	0.702	0.887
0.31	10.954	0.252	0.871	0.838	0.871	0.867	0.872	0.893	0.868	0.977	0.706	0.893
0.3225	10.890	0.250	0.870	0.837	0.870	0.866	0.873	0.893	0.868	0.977	0.710	0.882
0.335	10.925	0.252	0.874	0.841	0.874	0.870	0.876	0.898	0.866	0.981	0.713	0.893
0.3475	10.822	0.246	0.868	0.834	0.868	0.865	0.871	0.889	0.864	0.977	0.705	0.891
0.36	11.141	0.247	0.872	0.839	0.872	0.869	0.874	0.891	0.876	0.977	0.712	0.887
0.3725	10.742	0.250	0.867	0.833	0.867	0.863	0.867	0.886	0.865	0.981	0.694	0.889
0.385	10.946	0.254	0.873	0.841	0.873	0.870	0.876	0.891	0.873	0.978	0.720	0.891
0.3975	10.979	0.255	0.871	0.838	0.871	0.866	0.873	0.890	0.876	0.979	0.703	0.884
0.41	10.954	0.253	0.869	0.835	0.869	0.866	0.870	0.887	0.862	0.981	0.705	0.893
0.4225	10.898	0.255	0.873	0.840	0.873	0.869	0.874	0.895	0.868	0.977	0.709	0.897
0.435	11.007	0.242	0.874	0.842	0.874	0.870	0.877	0.903	0.865	0.980	0.713	0.888
0.4475	10.974	0.255	0.872	0.839	0.872	0.869	0.875	0.885	0.872	0.979	0.716	0.893
0.46	10.669	0.246	0.866	0.832	0.866	0.862	0.867	0.883	0.869	0.975	0.703	0.881
0.4725	11.019	0.248	0.875	0.842	0.875	0.872	0.877	0.892	0.875	0.980	0.721	0.890
0.485	10.866	0.257	0.870	0.836	0.870	0.866	0.871	0.893	0.865	0.978	0.702	0.891
0.4975	11.082	0.254	0.874	0.842	0.874	0.870	0.876	0.902	0.864	0.977	0.719	0.890
0.5	10.865	0.256	0.875	0.842	0.875	0.871	0.876	0.893	0.875	0.978	0.720	0.891
0.51	11.075	0.252	0.872	0.839	0.872	0.868	0.872	0.890	0.870	0.977	0.708	0.894
0.5225	10.971	0.246	0.874	0.841	0.874	0.870	0.876	0.895	0.873	0.975	0.719	0.887
0.535	10.944	0.254	0.872	0.839	0.872	0.867	0.872	0.898	0.866	0.974	0.711	0.888
0.5475	11.037	0.249	0.867	0.833	0.867	0.863	0.869	0.884	0.868	0.980	0.700	0.884
0.56	10.953	0.246	0.863	0.828	0.863	0.858	0.863	0.882	0.863	0.974	0.684	0.888
0.5725	10.939	0.254	0.866	0.832	0.866	0.861	0.866	0.886	0.860	0.973	0.703	0.883
0.585	11.024	0.249	0.863	0.828	0.863	0.858	0.864	0.884	0.857	0.979	0.685	0.887
0.5975	11.201	0.253	0.871	0.838	0.871	0.867	0.872	0.892	0.866	0.974	0.709	0.892
0.61	11.054	0.252	0.865	0.830	0.865	0.860	0.865	0.886	0.862	0.979	0.687	0.888
0.6225	10.845	0.242	0.870	0.837	0.870	0.866	0.872	0.892	0.862	0.979	0.708	0.890
0.635	10.982	0.242	0.868	0.835	0.868	0.864	0.869	0.894	0.858	0.978	0.697	0.891
0.6475	11.196	0.261	0.863	0.828	0.863	0.858	0.864	0.883	0.860	0.975	0.685	0.888
0.66	10.865	0.253	0.860	0.825	0.860	0.857	0.865	0.884	0.848	0.973	0.691	0.887
0.6725	10.886	0.252	0.858	0.823	0.858	0.854	0.861	0.880	0.854	0.974	0.683	0.880
0.685	10.803	0.248	0.860	0.825	0.860	0.855	0.863	0.878	0.861	0.975	0.678	0.885
0.6975	10.778	0.247	0.856	0.820	0.856	0.852	0.863	0.880	0.846	0.970	0.681	0.885
0.71	10.902	0.253	0.862	0.828	0.862	0.857	0.864	0.885	0.860	0.973	0.677	0.888
0.7225	10.963	0.249	0.862	0.827	0.862	0.858	0.864	0.885	0.857	0.976	0.684	0.890
0.735	10.905	0.250	0.856	0.820	0.856	0.851	0.857	0.878	0.854	0.963	0.672	0.888
0.7475	11.007	0.253	0.861	0.826	0.861	0.856	0.861	0.884	0.853	0.975	0.672	0.896
0.76	10.706	0.236	0.849	0.811	0.849	0.843	0.852	0.872	0.837	0.964	0.660	0.885
0.7725	10.958	0.251	0.849	0.811	0.849	0.843	0.849	0.869	0.853	0.972	0.643	0.879
0.785	10.932	0.254	0.857	0.821	0.857	0.853	0.859	0.877	0.859	0.976	0.664	0.888
0.7975	10.857	0.247	0.854	0.818	0.854	0.850	0.857	0.875	0.855	0.975	0.669	0.876
0.81	11.024	0.249	0.859	0.824	0.859	0.853	0.860	0.884	0.848	0.973	0.673	0.889
0.8225	10.948	0.254	0.858	0.822	0.858	0.854	0.860	0.882	0.848	0.972	0.676	0.890
0.835	10.878	0.246	0.859	0.824	0.859	0.856	0.861	0.879	0.861	0.969	0.683	0.887
0.8475	10.966	0.250	0.856	0.819	0.856	0.852	0.859	0.880	0.847	0.970	0.679	0.884
0.86	10.703	0.246	0.852	0.815	0.852	0.849	0.856	0.865	0.853	0.968	0.672	0.888
0.8725	11.109	0.250	0.853	0.816	0.853	0.851	0.860	0.871	0.853	0.972	0.678	0.880
0.885	10.689	0.251	0.857	0.821	0.857	0.853	0.861	0.886	0.852	0.976	0.670	0.884
0.8975	10.869	0.248	0.854	0.817	0.854	0.852	0.861	0.873	0.849	0.971	0.680	0.887
0.91	11.188	0.257	0.861	0.826	0.861	0.858	0.867	0.884	0.858	0.972	0.691	0.886
0.9225	10.986	0.244	0.860	0.825	0.860	0.857	0.863	0.887	0.851	0.969	0.685	0.894
0.935	10.779	0.256	0.864	0.829	0.864	0.862	0.870	0.888	0.861	0.974	0.699	0.888
0.9475	10.945	0.253	0.856	0.819	0.856	0.854	0.862	0.877	0.851	0.971	0.680	0.891
0.96	10.852	0.250	0.846	0.807	0.846	0.845	0.853	0.871	0.850	0.956	0.660	0.885
0.9725	10.929	0.247	0.844	0.805	0.844	0.841	0.850	0.879	0.851	0.951	0.649	0.876
0.985	10.942	0.251	0.817	0.770	0.817	0.805	0.812	0.858	0.836	0.931	0.536	0.862
0.9975	10.863	0.259	0.520	0.420	0.520	0.472	0.543	0.821	0.434	0.195	0.256	0.653

Table B.51: Performances and execution times for CNN on different dropout rates, when embedding dimension is 210, filter size is 182 and dense layer is 178

B.6.2 All Application Results

Tottenhams Harry Winks sørget for seier etter overtidsdrama.

Dele Alli utlignet med et hodestøt i andreomgang og Harry Winks fikk seieren med scoring i siste minutt på overtid.

Etter elleve minutter viste Fulham-debutant Ryan Babel seg frem. Den tidligere Liverpool-vingen fikk med seg ballen fra midtbanen og kom alene mot Hugo Lloris. Davinson Sanchez klarte å ta igjen hollenderen som får avsluttet, men Lloris får stoppet skuddet til hjørnespark.

Fulham kom inn i en god periode og etter et annet hjørnespark ble Alexandar Mitrovic dratt ned i feltet av Jan Verthongen.

Claudio Ranieries menn fortsatte å presse Tottenham, og etter nytt hjørnespark satte Harry Kanes erstatter, Fernando Llorente, ballen i eget mål. Spanjolen klarte ikke å stokke beina og Lloris var sjanseløs etter 16 minutter.

Minuttet senere skjedde det som Tottenham-fansen fryktet. Dele Alli jaget en ball ut mot sidelinjen og i forsøket på å nå ballen holdt 22-åringen seg til hamstringen og måtte legge seg ned utenfor banen. Engelskmannen klarte ikke å komme seg på beina igjen og ble byttet ut. Alli så tydelig preget ut på benken etter byttet.

På overtid svingte innbytter Nkoudou ballen inn i feltet der Harry Winks headet ballen i mål i siste minutt av overtiden. Dermed vant Tottenham 2-1 på Craven Cottage.

Tottenham uten Harry Kane (skadet) og Heung-Min Son (Asiamesterskapet) slet lenge mot Fulham. Fernando Llorente, som erstattet Kane, satte ballen i eget mål etter et kvarter.

Fernando Llorente fikk den store sjansen til å bli helten igjen for Tottenham. Med ti minutt igjen slo Eriksen et frispark inn i feltet. Ballen skled av hodet til spanjolen og like utenfor mål. Til Llorente og Tottenham-fansens store fortvilelse.

Spurs løftet seg etter pause - kampen avgjort på straffesparkkonkurranse Like etter pause reduserte Tottenham. Harry Kane-erstatteren Fernando Llorente headet inn 1-2-reduseringen seks minutter ut i omgangen, og dermed trengte Tottenham kun ett mål for å ta seg videre til ligacupens finale.

Christian Eriksen scoret sikkert på Tottenhams første straffespark. Willian satte sikkert Chelseas første, før Erik Lamela like sikkert scoret på Tottenhams andre straffespark.

Azpilicueta satte 2-2 for Chelsea. Så blåste Eric Dier ballen over for Tottenham, og Chelsea var i førerretet. Jorginho satte arrogant inn 3-2-ledelse med et frekt straffespark.

Lucas Moura bommet for Tottenham, og David Luiz kunne avgjøre straffesparkkonkurransen for Chelsea. Brasilianeren dundret inn scoringen og dermed er Chelsea klar for finalen med 4-2-seier i straffesparkkonkurransen.

Tottenham styrte mye av banespillet, men slet med å komme til de store sjansene. Der var Fulham farligere. Ryan Babel var nær å doble ledelsen fem minutter før pause. Hodestøtet fra fem meter gikk over mål.

Fulham skapte enda mer. To minutter senere la Babel inn til Andre Schurrle som banket til på hel volley fra kort avstand. Lloris vartet opp med en mesterlig redning, men ballen endte hos Mitrovic som headet ballen i mål. Serberen var imidlertid i offside og scoringen ble annullert.

I andreomgang slo Tottenham tilbake. Seks minutter ut i omgangen slo Christian Eriksen et perfekt innlegg til Dele Alli som headet ballen i mål fra kloss hold. 1-1 og kamp igjen på Craven Cottage.

Tottenham tok mer over spillet i London-derbyet. Etter rundt en time spilt fikk Danny Rose sjansen til å sende Spurs i ledelsen. Skuddet gikk via Denis Odoi og i tverrliggeren.

Dier bommet for Spurs N'golo Kanté og Eden Hazards scoret målene for Chelsea på Stamford Bridge, mens Tottenhams reduseringsmål ble satt inn av Fernando Llorente.

Der ble David Luiz Chelseas store helt da han satte inn det avgjørende straffesparket etter at Tottenham hadde bommet to ganger.

Eric Dier scoret et viktig straffemål for England i fotball-VM sist sommer, men denne gangen gikk skuddet langt over. Skuddet til Lucas Moura ble reddet av Chelseas keeper Kepa.

Midtbanespilleren dundret løs fra 16 meters hold. Ballen føk gjennom beina på et par Spurs-spillere, og i mål via Tottenhams keeper Paolo Gazzaniga. Paolo Gazzaniga fikk tillit fra start på bekostning av Hugo Lloris.

Figure B.49: CNN application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Ti minutter før slutt måtte forøvrig Tottenhams Moussa Sissoko gi seg på grunn av skade. Davinson Sánchez kom inn. Skadeproblemene fortsetter dermed for Tottenham.

– Det er en fantastisk følelse. I den første omgangen kunne vi scoret tre eller fire. Vi kontrollerte kampen også etter pause. Spurs fikk sin mulighet, og scoret. Reaksjonen til spillerne og viljen vi viste gjør meg svært glad. For det var frustrerende at vi risikerte å tape på straffer etter å kontrollert kampen fullstendig. I straffesparkkonkurranser vet man aldri hva som skjer. Men laget gjorde det strålende. Vi skapte mange sjanser og presset Tottenham hele kampen, sa Chelseas straffeheft David Luiz til Sky Sports etter kampen.

– Gazzaniga hadde ingen sjanse og det var virkelig et mål med klasse av hjemmelaget. Det der er smart fotball. De angrep raskt og avsluttet vidunderlig, beskrev Andy Townsend etter scoringen som sørget for at Chelsea kunne gå til pause med 2-0.

Etter 60 minutter var det slutt for Lucas Moura. Inn kom Fernando Llorente. Spanjolen kom tidlig til flere store muligheter. Tottenham presset på for scoring, og etter 82 minutter var det en hjemvendt Son som reddet dagen.

Først vant Llorente duellen, før Son dro seg fri og sendte i vei et skudd fra 18 meter. Skuddet gikk rett på Dubravka, men keeperen klarte likevel ikke å stoppe det.

Heung-min Son sørget for tre Tottenham-poeng med sen scoring.

Newcastle var på vei mot nok et krittsterkt resultat mot et topplag, men Heung-min Son ville det annerledes. Med åtte minutter igjen av ordinær tid scoret sørkoreaneren sitt tiende ligamål for sesongen.

Slik var kampen Det var Tottenham som var nærmest scoring i den første omgangen. Lucas Moura fikk en enorm mulighet etter et kvarter, men brasilianerens heading gikk utenfor mål.

Christian Eriksen, Son Heung-min (to), Lucas Moura og Harry Kane scoret målene for Tottenham, som altså er ett poeng foran Manchester City. Ekstra gledelig var det for Spurs-fansen at backvikaren Kyle Walker-Peters var nest sist på tre av scoringene.

Mål: 0–1 Yerry Mina (2), 0–2 Lucas Digne (13), 0–3 Gyfi Sigurdsson (str. 22), 1–3 Ben Gibson (37), 1–4 Digne (72), 1–5 Richarlison (90).

Mål: 1–0 Ryan Sessegnon (74), 1–1 Romain Saïss (85).

Mål: 1–0 Nemanja Matic (28), 2–0 Paul Pogba (64), 3–0 Pogba (78), 3–1 Mathias Jørgensen (88).

Sist Liverpool tapt en ligakamp på Anfield, var da Crystal Palace vant 2–1 23. april i fjor. Siden da har det blitt ni uavgjorte, og 21 seirer. Denne sesongen har det blitt bare seirer, med unntak av 0–0-kampen mot Manchester City.

Son, som også scoret i midtukekampen mot Watford, har nå scoret i begge kampene etter sin hjemkomst fra Asiamesterskapet.

Angriperen fyrte løs fra 18 meter. Skuddet gikk rett Martin Dubravka, men keeperen klarte ikke å stoppe skuddet.

Midtveis i omgangen var det Erik Lamela som fikk en sjanse. Innlegget fra Jan Vertonghen var av det presise slaget, men headingen fra Lamela var akkurat ikke god nok. Ballen smalt i tverrliggeren. Returen falt til Moura, men heller ikke denne gang traff angriperen mål.

Sissoko prøvde seg med et brukbar volleyforsøk kort tid før pause, men Dubravka stoppet skuddet. Dermed gikk lagene til pause på 0-0.

Nytt stolpetreff Rondon var et uromoment også i førsteomgang, og kort tid etter hvilen var han frempå igjen. Spydspissen var både sterk og lur da han fikk headet mot mål fra fem meter, men forsøket gikk i stolpen og ut.

Midtstopper Dejan Lovren banket lekkert inn det eneste målet i første omgang, da han traff perfekt på halvsprett etter en corner som ble svakt halvklarert.

Tidlig i andre omgang økte Mohamed Salah til 2–0 fra straffemerket etter at han selv ble dratt i armen av Paul Dummett. Straffen var likevel billig, og Salah blir fra flere holdt beskyldt for å filme. Uansett var det svakt av Dummett å bruke armen i duellen, og straffen satte Salah sikkert forbi keeper Martin Dubravka.

På tampen ordnet Xherdan Shaqiri 3–0 fra kloss hold, før innbytter Fabinho skallet inn en corner fra Salah, og sørget for 4–0.

Tottenham knuste Bournemouth 5–0, og tok over annenplassen på tabellen – seks poeng bak Liverpool. Mauricio Pochettinos lag har scoret vanvittige 11 mål på få dager, etter 6–2-seieren borte mot Everton lille julaften.

Bernardo Silva sendte Manchester City i ledelsen, men Marc Albrighton og Ricardo Pereira scoret i hver sin omgang og sørget for 2–1-seier til Leicester. Vinnermålet til Pereira var et herlig langskudd, og Fabian Delph pådro seg rødt kort på tampen av kampen.

Mål: 1–0 Dejan Lovren (11), 2–0 Mohamed Salah (str. 48), 3–0 Xherdan Shaqiri (79), 4–0 Fabinho (85).

Men etter pause hevet Tottenham seg, og Fernando Llorente utlignet den sammenlagte ledelsen rett etter pause med et kontant hodestøt.

I straffesparkkonkurransen scoret Willian, Azpilicueta, Jorginho og David Luiz, mens Eric Dier banket ballen langt opp på tribunen, og Lucas Moura rett i fanget på Kepa, dermed hjalp det lite at Christian Eriksen og Erik Lamela scoret på de to første forsøkene.

N'Golo Kanté banket inn 1–0 mellom bena på to Tottenham-forsvarer og keeper Paulo Gazzaniga, dermed var ledelsen fra første kamp utlignet. Rett før pause satte en toneangivende Hazard inn 2–0 mot et tamt Tottenham, som tydelig savnet nøkkelspillere som Harry Kane, Dele Alli (begge skadet) og Heung-min Son (i Asiamesterskapet).

Figure B.50: CNN application results on the "Goal/Assist" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Jeg kan ikke huske hva som skjedde. Det er litt tåkete. Det var et stort øyeblikk og en seier som vi trengte, sier Harry Winks til Sky Sports etter kampen.
 - Kanskje ikke Dele Alli, men vi kan ha Lucas Moura på benken eller fra start mot Chelsea, sier Tottenham-manageren ifølge BBC.
 - Han er uheldig, men jeg mener også han er udyktig. Ja, den kommer ganske brått på, men han må forvente at ballen kan falle ned der. Med den kroppstillingen mener jeg man kan forvente at han skal å få den ballen utenfor mål, sier TV 2-ekspert Petter Myhre.
 - Det er alltid godt å slå tilbake etter en tøff kamp. I dag gjorde vi det i 90 minutter. Vi kontrollerte kampen. Tottenham hadde en sjanse, og scoret. Til slutt så kom vi oss til finalen, og det er vi glade for, sa Hazard, som spår en tøff finale mot Manchester City.
 - Vi vant mot dem på Wembley. De slo oss her. Jeg foretrekker å tape på straffer fremfor etter fulltid. Gratulerer til Chelsea. Nå skal vi gjøre alt og være klar for FA-cupkampen mot Crystal Palace på søndag, sa Tottenhams suksessjef etter kampen.
 - Ballen snek seg gjennom, men du bør forvente at keeperen reddet det skuddet der. Keeperen burde gjort mer for å forhindre scoring, sa BBC-ekspert Andy Townsend om scoringen.
 - Han har vært en av Newcastles beste spillere denne sesongen. Han har reddet laget så mange ganger. Det er brutalt, sier TV 2-kommentator Endre Olav Osnes.
 - Det er en stor, stor sjanse, men headingen er ikke i nærheten av god nok, sa Trevor Morley.
 - Det er en ball som skal være mulig å ta for Dubravka. Det er dårlig keeperspill, sa Simen Stamsø-Møller.
 - Manchester City er sammen med Liverpool det beste laget i Premier League. De har vunnet mange troféer, og har et strålende lag. Det er en 50-50-kamp, slo han fast.
 - Hazard: – Jeg bryr meg ikkeMaurizio Sarri kritiserte som kjent Chelsea-spillerne etter 0-2-tapet mot Arsenal i Premier League. Manageren sa blant annet at Hazard ikke var en leder på banen.
 - Jeg bryr meg ikke. Jeg spiller bare fotball. Det har ingenting å si hva manageren sier, jeg fokuserer bare på fotballen og vil gjøre det best mulig for laget, svarte Hazard på spørsmål om hva han mente om Sarris kritikk.
 - Jeg gikk aldri til angrep på mine spillere. Jeg sa vi hadde et problem. Problemet var motivasjonen. I denne kampen var responsen veldig, veldig god. Nå må vi bare vise kontinuitet fremover, sa Sarri.
 - Både City og Liverpool sviktet i forrige runde. Nå starter Tottenham denne helgen med å vinne. Det er tre lag som kjemper om tittelen nå, sier Osnes.
 - Vi møter Manchester City om en uke, og hvis jeg var i Manchester City ville jeg fokusert på at de bare er fire poeng bak. Vi skal også møte Arsenal i mellomtiden, så det som først og fremst betydde noe for oss i dag var prestasjonen, og nivået vi er i stand til å holde for tiden, sa en fornøyd Klopp etter kampen.
 - Tottenham er i kjempeform nå, og er i form. Chelsea vil trolig vinne mye fremover, Arsenal vil vinne og dette blir et race til siste dag. Vi er med i racet, og det er det aller viktigste, la han til.
- Burnley – Everton 1–5 (1–3)
- Fulham – Wolverhampton 1–1 (0–0)
- Leicester – Manchester C. 2–1 (1–1)
- Liverpool – Newcastle 4–0 (1–0)
- Tottenham – Bournemouth 5–0 (3–0)
- Brighton – Arsenal 1–1 (1–1)
- Chelsea har vært et av de mest suksessrike lagene i England de siste årene. Å vinne titler er det eneste som gjelder i denne klubben, så vi er glade for å være i finalen, oppsummerte Chelsea-kaptein Cesar Azpilicueta til Viasat 4.
 - Det er deilig å se spillere leke fotball på den måten, sa Ronny Deila om Jorginhos arrogante straffe, hvor midtbanespilleren ventet ut keeper og trillet ballen nonchalant i mål.
 - Vi er de første som ønsker å vinne og slå tilbake etter en sånn prestasjon, sa Azpilicueta til Viasat på spørsmål om managerens kritikk.

Figure B.51: CNN application results on the "Quotes" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Tottenham seiret etter overtidsdrama</p> <p>Tottenhams Dele Alli måtte forlate banen haltende med det som så ut som en hamstring-skade åtte minutter før slutt. Alli var tydelig preget på benken etter skaden, noe som er svært dårlige nyheter for Spurs og Mauricio Pochettino.</p> <p>Argentineren kunne imidlertid komme med en aldri så liten gladmelding etter kampen. Brasilianske Lucas Moura mistet de seneste kampene med en skade, men ifølge Pochettino vil han være tilbake til returoppgjøret i Ligacupens semifinale mot Chelsea i midtuken.</p> <p>Etter 22 minutter fikk Llorente sjansen til å rette opp feilen, men traff ikke på headingen fra kloss hold og ballen gikk rett på Fulham-keeper Sergio Rico.</p> <p>Fulham var flere ganger frempå og skapte problemer på tampen av omgangen. Ranieris menn ledet fortjent 1-0 til pause.</p> <p>Dermed endte det 2-2 sammenlagt etter to kamper, og kampen måtte avgjøres på straffesparkkonkurranse.</p> <p>– Vidunderlig fotball av Chelsea Etter en tett og jevn start på kampen presenterte N'golo Kanté seg etter 27 minutters spill.</p> <p>I det 38. minutt viste Chelsea frem vidunderlig fotball. Eden Hazard startet det vakre angrepet, og avsluttet selv i boksen. Plutselig stod det 2-0 og Chelsea stormet mot en ny cupfinale.</p> <p>Tottenham skapte en rekke sjanser det siste kvarteret. Chelsea skapte også sine sjanser og hadde ingen planer om å parkere bussen.</p> <p>Flere scoringer ble det imidlertid ikke i kampen, og kampen måtte avgjøres på straffer.</p>	<p>Etter 72 minutter kokte det over for Mitrovic og Sánchez. Begge kamphanene hadde ved flere anledninger hakket på hverandre, og i denne situasjonen dro de hverandre ned i bakken. Begge ble straffet med gult kort.</p> <p>Motstander i finalen på Wembley blir Manchester City. Finalen spilles 24. februar.</p> <p>Chelsea-manager Maurizio Sarri fikk dermed den responsen fra spillerne han ønsket seg etter 0-2-tapet mot Arsenal i den forrige serierunden i Premier League.</p> <p>Chelsea-stjernen Eden Hazard var høyt oppe etter straffeseieren.</p> <p>Sarri ble også spurt om kritikken han kom med etter Arsenal-tapet.</p> <p>Tottenhams manager Mauricio Pochettino hevdet at han ikke var særlig skuffet etter nederlaget.</p> <p>Argentineren rakk ikke å bli spilleklar til Tottenham-kampen.</p> <p>Fernando Llorente startet på topp for Tottenham i fraværet av Harry Kane, mens Olivier Giroud ledet Chelsea-angrepet.</p> <p>Slik startet lagene:</p> <p>Benken: Caballero, Ampadu, Alonso, Kovacic, Hudson-Odoi, Willian, Piazon.</p> <p>Tottenham Hotspur: Gazzaniga, Aurier, Alderweireld, Vertonghen, Davies, Dier, Winks, Sissoko, Eriksen, Lamela, Llorente.</p> <p>Subs: Lloris, Rose, Sanchez, Nkoudou, Walker-Peters, Lucas Moura, Skipp.</p> <p>Chelsea til finale etter seier mot Tottenham i straffesparkkonkurranse</p>
--	--

Figure B.52: CNN application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Maurizio Sarri øyner sitt første trofé som manager for Chelsea etter at blåtrøyene slo Tottenham på straffer torsdag kveld.</p> <p>Scoringen gjorde at Spurs nok en gang dro i land en seier i sluttminuttene. Det betyr at Tottenham nå er oppe på en andreplass, men med én kamp mer spilt enn Manchester City.</p> <p>Det var det som skulle til for at Spurs dro i land nok en sen seier på eget gress. Resultatet gjør at Tottenham nå har sneket seg forbi Manchester City, riktignok med én kamp mer spilt.</p> <p>Hjemvendte Son reddet dagen for Spurs</p> <p>For øyeblikket bunnsolide Liverpool gikk sin 30. strake hjemmekamp i ligaen uten tap. Selv om farlig utsatte Newcastle hang med lenge, så ble det stygge sifre til slutt. Den antatt argeste gullrivalen, Manchester City, ligger nå syv poeng bak.</p> <p>(Liverpool-Newcastle 4-0, Leicester – Manchester City 2-1) Mens Liverpool cruiset inn til en ny storseier mot Newcastle, så tapte Manchester City sin andre strake kamp. Dermed har Jürgen Klopps menn fått seks poengs forsprang på toppen av tabellen, og Tottenham er oppe på annenplass.</p> <p>For nå er det syv poeng ned til Manchester City, som snublet igjen.</p> <p>For få dager siden tapte de 2-3 hjemme mot Crystal Palace, og i kveld ble Leicester for sterke.</p> <p>Mål: 0-1 Pierre-Émerick Aubameyang (7), 1-1 Jürgen Locadia (35).</p> <p>Det ble klart etter seier i straffesparkkonkurranse mot Tottenham torsdag kveld.</p> <p>I returoppgjøret mot Tottenham i Ligacupen fikk han svar på tiltale.</p>	<p>Men de to siste rundene har gjort Liverpool til storfavoritter når det gjelder ligagullet.</p> <p>PS! Førstkommende lørdag spiller Tottenham hjemme mot Wolverhampton, og Liverpool får besøk av Arsenal. Manchester City spiller borte mot Southampton søndag.</p> <p>Crystal Palace – Cardiff 0-0</p> <p>Mål: 0-1 Bernardo Silva (14), 1-1 Marc Albrighton (19), 2-1 Ricardo Pereira (81).</p> <p>Manchester U. – Huddersfield 3-1 (1-0)</p> <p>Gult kort: Martin Montoya (45), Glenn Murray (58), Brighton, Sead Kolasinac (81), Arsenal.</p> <p>Drømmejul for Liverpool – ny gavepakke fra Manchester City</p> <p>I finalen venter Manchester City. Seier vil bety Sarris første trofé som Chelsea-manager. Mauricio Pochettino derimot må vente enda lenger på sitt første som Tottenham-sjef.</p> <p>Finalen spilles på Wembley siste helgen i februar.</p> <p>Chelsea til ligacupfinale etter straffeseier</p> <p>(Chelsea - Tottenham 2-1, 2-2 sammenlagt, 6-4 etter straffer) Kun Pep Guardiola og Manchester City står mellom Maurizio Sarri og hans første trofé som Chelsea-manager.</p> <p>Chelsea-manager Sarri raste mot eget lag etter helgens tap mot Arsenal.</p>
--	--

Figure B.53: CNN application results on the "Irrelevant" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Se seiersmålet og høydepunktene i videovinduet øverst!</p> <p>Chelsea – Tottenham 2-1 (2-2 sammenlagt, 4-2 etter straffer):</p> <p>Se sammendrag i Sportsnyhetene øverst!</p> <p>Chelsea: Kepa, Azpilicueta, Luiz, Rudiger, Emerson, Jorginho, Kante, Barkley, Pedro, Giroud, Hazard.</p> <p>Dommer: Martin Atkinson, West Yorkshire</p> <p>Tottenham - Newcastle 1-0</p> <p>Se scoringen i videovinduet øverst!</p> <p>Live: Brighton tok poeng mot Arsenal - referat fra dagens runde</p> <p>21.484 tilskuere.</p> <p>25.206 tilskuere</p>	<p>24.382 tilskuere.</p> <p>32.090 tilskuere.</p> <p>Rødt kort: Fabian Delph (89), Manchester C.</p> <p>53.318 tilskuere.</p> <p>74.523 tilskuere.</p> <p>Mål: 1-0 Christian Eriksen (16), 2-0 Son Heung-min (23), 3-0 Lucas Moura (35), 4-0 Harry Kane (61), 5-0 Son (70).</p> <p>45.154 tilskuere.</p> <p>Joshua King spilte 16 minutter som innbytter for Bournemouth.</p> <p>30.608 tilskuere</p> <p>Senere kampstart: Watford – Chelsea 20.30.</p> <p>Der bommet Eric Dier og Lucas Moura for Tottenham, mens Chelsea-spillerne alle var sikre, og David Luiz satte inn den avgjørende ballen.</p>
---	--

Figure B.54: CNN application results on the "Ignore" class, for Lucas Moura. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Da 31-åringen ble byttet ut fem minutter før slutt, ble han møtt med stående ovasjoner fra Chelsea-fansen. Så brast han ut i gråt.

Davide Zappacosta fikk slått inn til Álvaro Morata som headet midt på mål fra tre meter. Men keeper Luke Steele sto i veien og fikk reddet for Nottingham.

Chelsea var nære scoring flere ganger i førsteomgang uten å få uttelling, men fire minutter ut i andreomgang kom scoringen for vertene.

Callum Hudson-Odoi la inn foran mål hvor Morata ventet. Etter flere forsøk satt den endelig for Chelsea-spissen, og hjemmelaget ledet 1-0.

Like etter var Hudson-Odoi nære å øke ledelsen for Chelsea, men Steele serverte nok en god redning.

Men den siste sesongene har han slitt. Morata har scoret ni mål i alle turneringer for London-klubben. Den hittil siste kampen i blått ble 2-0-seieren i FA-cupen over Nottingham Forest 5. januar, hvor den utskjelte spissen scoret begge.

Higuaín kommer til Chelsea med et rykte som en notorisk målscorer. Kun fem spillere har scoret mer enn argentineren i topp fem-ligaene siden starten av 2006/07-sesongen.

I Chelsea er Higuaín gjenforent med manager Maurizio Sarri, som han spilte under i sin mest målrike sesong, da han scoret 36 ligamål på 35 kamper for Napoli i 2015/16-sesongen. Ingen har noen gang scoret flere i en Serie A-sesong.

Sarri ønsket Higuaín inn allerede i sommer, men Chelsea-ledelsen var skeptisk, noe som fikk argentineren til heller å velge Milan. Styreleder i Chelseas norske supporterklubb Øystein Vinje var i utgangspunktet skeptisk til signeringen av Higuaín.

Utskjelte Morata sendte Chelsea videre da Fabregas tok farvel med Stamford Bridge

(Chelsea – Nottingham Forest 2–0) Cesc Fàbregas (31) spilte trolig sin siste Chelsea-kamp mot Nottingham Forest, men fikk ikke noen drømmeavskjed. I stedet var det landsmannen Álvaro Morata (26) som ble Chelseas redningsmann.

Bare når ettertraktede Callum Hudson-Odoi serverte fra høyre fikk Morata til å score. Først med en tap-in, deretter med et pent hodestøt, hvor han knuste Claudio Yacob i lufta.

Angrepene fra hjemmelaget kom som perler på snor utover, og Morata burde økt ledelsen til Chelsea etter 58 minutter, men på åpent mål presterte spissen å skyte over.

Men den bommen ble raskt glemt, for minuttet senere fikk Morata sin revansje da han headet inn 2-0 etter nytt innlegg fra Hudson-Odoi. Nok et strøket angrep av samme duo som lagde 1-0 målet.

Cesc Fàbregas gikk fram til straffemerket og sendte skuddet mot venstre hjørnet. Den veien gikk også Steele, og Nottingham-keeperen svarte med enda en viktig redning for gjestene. Dermed sto det fremdeles 0-0 på Stamford Bridge.

Antoine Griezmann er storklubbens toppscorer med ti mål i serien. Bak ham har ingen scoret mer enn to. Blant dem som har slitt, er tidligere Chelsea-stjerne Diego Costa. Spansk-brasilianeren har bare funnet nettmaskene én gang i ligasammenheng.

Spanjolen fikk en pangstart på Chelsea-karrieren da han scoret sju mål på sine åtte første kamper for klubben.

Huddersfield-kampen forrige helg, der Higuaín scoret to mål, ga også TV 2s Premier League-ekspert Erik Thorstvedt større tro på at argentineren blir en suksess.

Morata misbrukte en rekke store muligheter, men det ble likevel en gledens dag for den tidligere Juventus- og Real Madrid-spissen. Han scoret begge målene da Chelsea tok seg videre fra FA-cupkampen mot Nottingham Forest.

Chelsea ble tildelt straffe i 1. omgang, og 31-åringen gikk frem for å ta det. Han stoppet opp i tilløpet og la straffen til sin venstre, men keeper Jason Steele gikk riktig – og reddet straffen.

Sparket fra ellevemetersmerket burde nok blitt tatt opp igjen, da en hel haug av spillere fra både Nottingham Forest og Chelsea var innenfor 16-meteren før Fabregas' avslutning:

Hudson-Odoi - som jaktet av Bayern München - ble dermed den første tenåringen til å levere to målgivende i en og samme kamp for Chelsea siden Scott Sinclair i oktober 2007. Det melder Opta.

Figure B.55: CNN application results on the "Goal/Assist" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Den spanske playmakeren er ifølge dem på det nærmeste klar for Thierry Henrys Monaco.</p> <p>Totalt ble det 500 kamper i engelsk fotball for Fábregas, som fikk gjennombruddet for Arsenal som tenåring.</p> <p>Stortalentet Hudson-Odoi (18) leverte varene for Chelsea i oppkjøringen av sesongen, men har kun fått ett innhopp i Premier League hittil. Han tok vare på sjansen da han fikk den i FA-cupen.</p> <p>Chelsea-spiss klar for La Liga-gigant</p> <p>Atlético Madrid bekrefter låneavtalen på sine nettsider. Den strekker seg ut 2019/20-sesongen.</p> <p>Moratas overgang til Atlético Madrid skjer like etter at Chelsea sikret seg Gonzalo Higuain på lån fra AC Milan ut sesongen.</p> <p>Morata kom til Chelsea fra Real Madrid for 600 millioner kroner i juli 2017. Han skrev da under på en femårskontrakt med London-klubben.</p> <p>PSG har vært koblet til Evertons midtbanespiller Idrissa Gueye en stund. Ifølge Liverpool Echo har de imidlertid ikke lagt inn noe formelt bud enda.</p> <p>Marcelo ønsker å gjenforenes med Cristiano Ronaldo i Juventus, skriver Marca. De to var lagkamerater i Real Madrid fra 2009 til sistnevnte dro til Italia i sommer. Ifølge avisen har 30-åringen sagt til sjefene på Bernabeu at de skal godta det dersom det kommer et bud fra italienerne.</p> <p>Watford føler seg sikre på at midtbanespilleren Abdoulaye Doucoure blir i klubben i alle fall til slutten av sesongen, skriver Evening Standard. 26-åringen har vært koblet til PSG de siste ukene.</p> <p>Newcastle ønsker å signere to spillere på lån innen slutten av uken, skriver The Telegraph. Avisen hevder klubben har lagt inn bud på Monacos italienske forsvarsspiller Antonio Barreca, og Atletico Madrids portugisiske ving Gelson Martins.</p> <p>Med sommerens signering av Jorginho, og Higuain inn i januarvinduet, har Sarri hentet inn to viktige brikker fra tiden sin i Napoli, som vet hvordan italieneren ønsker å spille.</p> <p>På søndag møter en meget tøff utfordring for Higuain og Chelsea, når de gjester Manchester City på Etihad. Supporterleder Vinje forventer en svært tøff kamp mot de regjerende mesterne.</p> <p>Siden Roman Abramovitsjs inntog i Chelsea har stjernespiessene vært mange, men få har lyktes. Den siste til å prøve seg i den blå drakta er Gonzalo Higuain.</p> <p>Den engelske kanalen hevder at han nå forlater London til fordel for fyrstedømmet Monaco, hvor han skal spille under ledelsen av sin gamle Arsenal-kollega Thierry Henry.</p>	<p>Álvaro Morata (26) lånes ut fra Chelsea til Atlético Madrid.</p> <p>Alvaro Morata er nær ved å forlate Chelsea. Her er dagens fotballrykter!</p> <p>Ifølge Daily Mirror signerer Alvaro Morata for Atletico Madrid i dag. Den spanske hovedstadsklubben betaler 50 millioner kroner for et lån ut sesongen og avtalen inneholder også en opsjon på kjøp for 489 millioner kroner.</p> <p>Onsdag ble Fenerbache koblet til Stefan Johansen. Torsdag melder Goal at Chelseas Victor Moses nærmer seg et lån til klubben.</p> <p>Det ser ut til at den spanske midtbanespilleren Denis Suarez blir i Barcelona ut sesongen etter at samtalene med Arsenal gikk i stå, skriver ESPN.</p> <p>Chelsea har lenge vært koblet til Zenits argentinske midtbanespiller Leandro Paredes, men nå har Paris Saint-Germain seilet opp som favoritt til å signere 24-åringen, skriver The Telegraph.</p> <p>Aaron Ramsey nærmer seg en overgang til Juventus. I den forbindelse benytter walisersens landslagssjef og tidligere Manchester United-spiller Ryan Giggs sjansen til å sende et stikk i retning Arsenal. Giggs mener Ramsey vil bli bedre av å komme seg til en «toppklasseklubb» som Juventus, skriver Sky Sports.</p> <p>Chelsea har en lang tradisjon for å hente stjernespiesser, men få har levd opp til forventningene på Stamford Bridge.</p> <p>Siden den gang har Higuain spilt to suksessfulle sesonger i Juventus, før han før denne sesongen ble lånt ut til AC Milan. Tiden i Milan ble ingen suksess, og det ble med åtte mål på 22 kamper for de svarte og røde. Chelsea-fansen håper nå de får Napoli-versjonen av Higuain, og ikke den som mislyktes i Milano.</p>
--	---

Figure B.56: CNN application results on the "Transfer" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

- Med det blikket for spillet og timingen på pasningene, er han unik i sin posisjon, slår Chelsea-assistent Carlo Cudicini fast etter kampen.
- Fortid er fortid. Den kan ikke endres. Jeg er stolt av den. Jeg ser frem til at alt går i orden, slik at jeg kan trene med mine nye lagkamerater. Jeg begynte karrieren min i Atletico. De som kjenner meg, vet hva det betyr for meg, sa Morata til reportere i Spania søndag etter at han fikk godkjent legesjekken, ifølge BBC.
- Fotballryktene: – Morata bare timer unna overgang**
- Jeg vil ikke sette et krav til antall mål eller noe, men han må bidra til at vi blir topp fire. Blir han som Morata og begynner å furte og ikke bidrar positivt, ser jeg han ikke som en suksess selv om han scorer ti mål.
- Den første kampen hans var grusom, men det var bedre sist. Mot Huddersfield var det mange gode tegn på at han og Hazard kan finne hverandre bra, og at begge kan få noe positivt ut av samarbeidet, mener Thorstvedt.
- Det er en av de to-tre vanskeligste kampene som er. Men toppkamper lever sitt eget liv, og Chelsea har ofte vært bedre borte mot topplagene enn mot de antatt svakere lagene.
- Chelsea sliter ofte med å bryte ned lag som ligger lavt og tetter igjen. På søndag møter vi et City som nok vil ha ballen klart mest. Da gjelder det å ta overgangene når vi får muligheten. Det har vi klart tidligere, sier Vinje.
- Higuaín kan ikke bare måles på antall scoringer
- Jeg har fått større tro på ham nå etter kampen mot Huddersfield enn jeg hadde da han ble hentet. Om han blir en suksess eller ikke tror jeg avhenger av om resten av stallen klarer å bruke ham mer enn de har klart med Morata og Giroud.
- Utdfordringen er at Chelsea har vinger som liker å føre ballen langt inn i banen, og da har Higuaín ofte allerede løpt i offside før pasningen kommer, sier Vinje.
- Jeg har mer troa etter kampen mot Huddersfield. Han er jo en målscorer, men han har slitt denne sesongen. Spørsmålet er om Chelsea får den Higuaín som scoret 36 ligamål på en sesong i Napoli, eller den som slet i Milan denne sesongen.
- Var det ett lag som virkelig trengte en signering i januar, var det Chelsea som trengte en spiss. Det har funket veldig dårlig med Hazard på topp, så de trengte sårt å få inn en bra spiss.
- Han kan ikke bare måles på antall scoringer. Det viktigste er at han bidrar til at Chelsea klarer topp fire, mener TV 2s Premier League-ekspert Erik Thorstvedt, som får støtte fra styreleder i Chelseas norske supporterklubb, Øystein Vinje:
- I Jorginho og Higuaín har Sarri fått inn to spillere som han kjente godt fra før. Det kan slå positivt ut, men samtidig er fallhøyden større for Sarri dersom disse ikke lykkes. Da henger mer på manageren, mener TV 2-eksperten.
- Jeg er litt forbauset over at en så rutinert spiller gjør en så dårlig vurdering. Kanskje han ombestemte seg underveis, spøkte Åge Hareide i Viasats studio.

Figure B.57: CNN application results on the "Quotes" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

<p>Chelsea-stjerne forlot banen i tårer</p> <p>Før ettermiddagens cupkamp på Stamford Bridge, meldte Sky Sports om at dette antageligvis kom til å Fábregas' siste kamp i blå drakt.</p> <p>Chelsea hadde stort sett kontroll på Nottingham Forest i FA-cupens tredje runde. Men det var duoen Álvaro Morata og Callum Hudson-Odoi som utgjorde forskjellen i 2-0 seieren.</p> <p>Chelsea tok raskt dominansen på Stamford Bridge og etter 12 minutter fikk hjemmelaget en sjanse av det virkelig store slaget.</p> <p>Etter de første 20 minuttene hadde gjestene hatt mer enn nok med å forsvare seg mot Chelseas intense offensive spill.</p> <p>Etter halvtimen spilt sendte Zappacosta ballen til Ruben Loftus-Cheek som ventet innenfor Nottinghams 16-meter. Chelsea-midtbanemann ble taklet så det sang av Danny Fox, og Chelsea ble tildelt et soleklart straffespark.</p> <p>Morata har slitt med å få spilletid på Stamford Bridge denne sesongen. Manager Maurizio Sarri har foretrukket å bruke Eden Hazard i en «falsk nier-rolle» på topp. Også Olivier Giroud har til tider vært foran Morata i køen i Chelsea.</p> <p>Spillere som Andrij Sjevtsjenko, Fernando Torres, Romelu Lukaku, og nå sist Alvaro Morata, har ikledd seg den blå drakten uten nevneverdig suksess.</p> <p>Blant alle skuffelsene har det likevel vært lyspunkter, og storspisser som Didier Drogba, Nicolas Anelka og Diego Costa har vært direkte avgjørende for Chelsea-suksess i Abramovitsj-æraen.</p> <p>Det er denne rekken Higuaín nå håper å føye seg inn i, men det finnes en annen målestokk for suksess enn antall mål fra argentineren.</p> <p>Thorstvedt mener likevel Higuaín-overgangen var en sårt tiltrengt forsterkning i Chelsea-stallen.</p> <p>Vondt ble til verre for Fabregas, da han forlot banen kort tid etter at han pådro seg en smell, og ble erstattet av N'Golo Kanté.</p> <p>Fabregas tok seg god tid på vei av benen, delte ut flere varme klemmer til lagkameratene og takket fansen.</p> <p>Men da en spanjol mislykkes, var det en annen som fikk det til – etter noen forsøk.</p> <p>Chelsea unngikk dermed cupbomben, og er klare for 4. runde i FA-cupen.</p>	<p>Mot slutten av omgangen viste Nottingham mer selvtillit og utfordret Chelsea. Noen helt store sjanser ble det ikke, men etter å ha tilbragt store deler av omgangen på egen banehalvdel, var det i hvert fall et steg i riktig retning for gjestene.</p> <p>Etter intense første 45 minutter gikk lagene til pause på 0-0, noe Nottingham trolig var mer fornøyd med enn Chelsea.</p> <p>Etter drøye timen spilt begynte sjansene å bli større for Nottingham. Nærmest redusering var Joe Lolley, men spissen måtte nøye seg med nettveggen denne gang.</p> <p>Det ble ikke mer enn nesten for Nottingham og regjerende mester Chelsea tok seg greit videre til FA-cupens fjerde runde.</p> <p>Álvaro Morata og Callum Hudson-Odoi sikret Chelsea-seier mot Nottingham Forest. Samtidig tok Cesc Fábregas farvel med engelsk fotball.</p> <p>Higuaín fikk ingen god start på Premier League-karrieren da han startet i Chelseas 0-4-tap mot Bournemouth forrige uke. Heldigvis for argentineren ble hjemmedebuten betydelig bedre.</p> <p>Chelsea vant kampen 2–0, og fansen tok dermed ikke farvel med FA-cupen.</p> <p>De tok imidlertid trolig farvel med den spanske midtbanespilleren Cesc Fábregas. Ifølge Sky Sports spilte han lørdag sin aller siste kamp for Chelsea.</p> <p>Det var dermed passende at Maurizio Sarri ga Fabregas kapteinsbindet, men det ble ingen fantastisk avskjed for Fabregas – selv om det kunne blitt det.</p>
---	--

Figure B.58: CNN application results on the "Irrelevant" class, for Morata. Where red indicates paragraphs that classified wrongly and green indicates paragraphs that classified correctly

Appendix C

Submitted Paper

Soccer news data collection, labelling and classification using machine learning

1st Aanund Jupskås Nordskog
Simula
University of Oslo
Oslo, Norway
aanundjn@ifi.uio.no

2nd Pål Halvorsen
SimulaMet
Oslo Metropolitan University
Oslo, Norway
paalh@simula.no

2nd Steven Hicks
SimulaMet
Oslo Metropolitan University
Oslo, Norway
steven@simula.no

3rd Håkon K. Stensland
Simula
Oslo, Norway
haakons@simula.no

3rd Hugo L. Hammer
Oslo Metropolitan University
Oslo, Norway
hugoh@oslomet.no

3rd Michael A. Riegler
SimulaMet
Oslo, Norway
michael@simula.no

Abstract—In the today’s Internet we are overwhelmed with information. One important part of these information are news. Within news sport news are very popular in within sport news soccer takes a large amount of the coverage. For users it can be hard to find the really interesting news and it can even end up as a tedious and time consuming task. In this paper we present different machine learning approaches that are applied to soccer news from Norwegian news papers. We present a system to collect, index, label, analyse and present the collected news articles based on the content. In addition we compare different algorithms ranging from more traditional machine learning approaches to deep learning. In addition, the collected dataset is also made public available for other researchers.

Index Terms—News, Soccer, Sport, Machine Learning.

I. INTRODUCTION

The world wide web is almost an endless source of information, and a lot of this information comes in the form of text. From 2015 to 2018 the total number of websites have doubled, reaching 1.63 billion sites in 2018 [1]. With this amount of data available the need to categorize, index and label information is more important than ever.

Along with the increase in data the popularity of machine learning has also increased. The search term from google trends for machine learning and deep learning over the past five years shows that the popularity has grown significantly [2].

The popularity of deep learning is not without reason, for it has shown extraordinary results in many different application. In image classification CNN have shown high performance [3], Google translate is using recurrent neural networks (RNN) to translate from one language to another [4], and in natural language processing both RNN and convolutional neural networks (CNN) have seen a rise in popularity and state-of-the-art performance [5].

The main goal of this paper is to evaluate how deep learning and traditional machine learning methods perform on text classification, more specifically how the methods perform when classifying paragraphs in football articles. The goal is to train

a wide range of deep learning and traditional machine learning models and see how they perform compared to each other. The models will be compared on classification performance, training time and setup complexity. Two methods will be used to determine the classification performance of the different models. The first method will compare the performance during training, i.e., metrics will be calculated during training and analysed. The second method will use the models created in method one and test how they perform in an application on new data. The application will present a visual result of how the models perform.

The data used for all experiments was extracted from VG.no and TV2.no (two large Norwegian newspapers), and paragraphs from these articles are labelled and stored in a database. An application is presented that was used to make the labelling of the paragraphs easier. In addition, an application is presented that displays a visual representation of the paragraphs that have been classified by the different algorithms.

The research question of this work was: How does deep learning compare to traditional machine learning on soccer news classification when it comes to classification performance, training time and setup complexity? Thus, main contributions of this paper to provide an answer to the research question are:

- A thorough comparison between deep learning and traditional machine learning algorithms on text classification.
- A public dataset for football news collected from two newspapers that can be used to train and test machine learning algorithms.
- An application that can help to extend the dataset and provides a visual representation of how different models perform on the data.

II. RELATED WORK

Natural language processing has seen state-of-the-art performance in many application over the last few years [5].

Dataset	c	l	N	V	Test
SST-1	5	18	11855	17836	2210
TREC	6	10	5952	9592	500

TABLE I: Summary of the dataset SST-1 and TREC. c: number of different classes. l: average number of word per sentence. N: Dataset size. |V|: Vocabulary size. Test: Test set size [8]

Much research has been tested on different text-based datasets with different deep learning and traditional machine learning models. We will see how the models mentioned above have performed on the Stanford Sentiment Treebank dataset (SST-1) and the TREC question dataset (TREC). There is a summary of the two datasets in table I.

The SST-1¹ dataset is a collection of movie reviews, and the objective of the classifier is to detect sentiment. There are five labels, very positive, positive, neutral, negative and very negative. One thing to note with this dataset is that the training set is provided at the parse-level, meaning that the training set consists of phrases and sentences. Therefore, the training set is an order of magnitude larger than what is shown in table I. The test set, on the other hand, consists only of sentences [6].

The TREC² dataset is a collection of questions, and the objective of the classifier is to classify the questions to different question types. For example, questions about location will classify to the location class. There are six labels, Abbrev., Entity, Description, Human, Location and Numeric. [7]

Table II shows the accuracy the different models have on the SST-1 and TREC datasets. The results are collected from different research papers that have used Naive Bayes, SVM, CNN and RNN on the two datasets.

The CNN-rand model is from Yoon Kim paper [8] where he tests different CNN models on different text datasets among them SST-1 and TREC. The CNN-rand model is the only model that does not use pre-trained vectors with word2vec. The vectors are instead randomly initialised and modified during training. This model is chosen because word2vec is beyond the scope of this thesis.

The Bi-LSTM model is used as a comparison to C-LSTM neural networks presented in Chunting Zhou paper [9], and it is tested on the SST-1 and TREC dataset. The Bi-LSTM is a one layered bidirectional recurrent network with the LSTM architecture.

Socher presents the SVM and Naive Bayes model used on the SST-1 in the paper [6] where he presents the SST-1 dataset. They are both implemented with bag-of-words features. Zhang presents the SVM and Naive Bayes model used on the TREC dataset in the paper [10] where he tests SVM on question classification. Both models are implemented with bag-of-words features and default values for the parameters (e.g. C value in SVM). The SVM model that is shown in the table use a linear kernel, but there were the same results for

Model	SST-1	TREC
Naive Bayes	41.0	77.4
SVM	40.7	85.8
BiLSTM	47.8	93.0
CNN-rand	45.0	91.2

TABLE II: Accuracy score for the different models on the SST-1 and TREC dataset

Article_id	content_order	content	html_type	class
yvdVOJ	0	To ml av Espen Ruud - og Sarpsborg gikk p sitt fjerde strake tap	h1	
yvdVOJ	1	(Sarpsborg-Odd 12) Odd-backen Espen Ruud (34) har laget fem ml p de	p	
yvdVOJ	2	Mens stfoldingene presterer med bravur i Europa, gr det alt annet	p	
yvdVOJ	3	Espen Ruud headet Odd i ledelsen, en annen back, Joachim Thomassen Ronaldo denne hsten).	p	

TABLE III: View of ow the data is stored in the database

the polynomial, RBF and sigmoid kernel. Another thing to mention is that Silva [11] managed to get 95% accuracy on the TREC dataset with SVM. However, that implementation of the SVM model had highly engineered features.

The results show that the deep learning models outperform the traditional machine learning models by a good margin. The bidirectional LSTM has the highest performance closely followed by the CNN model; there is a small jump down to SVM and Naive Bayes. They perform about the same on the SST-1 dataset, but the SVM model has higher performance on the TREC dataset.

III. DATA

A. Retrieving Data

To collect the data we created a python program to fetch and process the HTML code from the web pages of VG and TV2. First, the program uses Request to fetch the HTML code of all the football articles on 'www.vg.no/fotball' and 'www.tv2.no/fotball'. Next, the relevant information from the HTML code is extracted using beautiful soup and the result is stored in the database. There are four columns in the database table containing the extracted information and one containing the class label (see table III):

- **article_id** - This is the id of the article given by TV2 and VG.
- **content_order** - This is the order of the paragraphs in the article. Zero is the headline, and the highest number is the last paragraph.
- **Content** - The content in the paragraph.
- **html_type** - The type of the HTML tag used by VG and TV2. For example p for paragraph and h1 for the headline.
- **class** - the label of the paragraph.

¹<http://nlp.stanford.edu/sentiment>

²<http://cogcomp.cs.illinois.edu/Data/QA/QC/>



Fig. 1: Example of how the labelling is done with Arx. The first step is to click an article, the second step is to locate a paragraph, and the third step is to determine which label to give the chosen paragraph.

The database contains approximately 1000 articles and 20,000 paragraphs and 1,000 labelled paragraphs from each class.

B. Labelling Data

After the data was stored in the database, we created a web app called Arx to label the data. The purpose of Arx was to help with the labelling, making the process much quicker. Arx displays the content of each article in a structured way with a labelling option for each paragraph (see figure 1). It is also possible to fetch all paragraphs or articles containing keywords (see figure 2). For example, one can fetch all articles or paragraphs containing the word "mlscorer", "overgang" or "vinnermlet". This option is beneficial since there are a lot of football articles that do not contain relevant paragraphs. Labelling is possible on both computers and mobile devices.

Arx was made with Django as the RESTful API server and React as the frontend web page. There are two possible HTTP commands to the Django API, GET and PUT. React calls GET to fetches articles and paragraphs from the database, and PUT to update a paragraph with the correct label in the database. There are in general only five labels, however, to make the labelling easier there are several more options to choose from than just five, for example, club detail, player detail and chances to name a few.

C. The Dataset

The dataset contains 5,526 labelled data samples. The dataset can be found online here [12]. In table IV there is an overview of how many data samples there are of each class. There are eight classes, but only five will be used because the last three classes have too few samples. The dataset is split with satisfied 10-fold cross-validation during training.

IV. EXPERIMENTS

The football articles are collected from Norwegian newspapers, and there are no libraries for pre-processing Norwegian text. As a result, there will be no pre-processing of the text in the dataset, except for removing special characters.

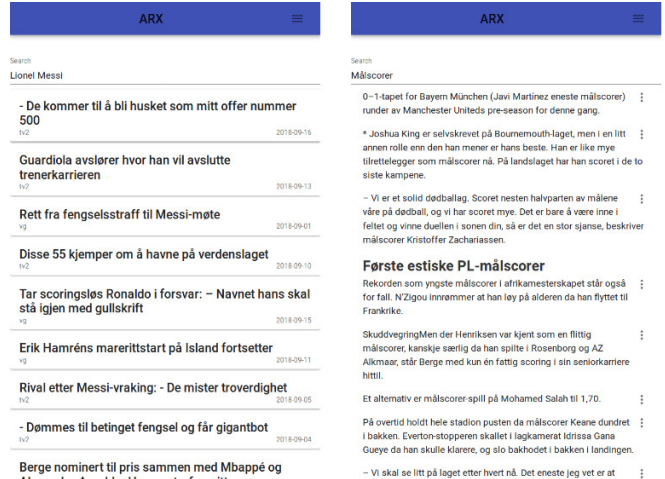


Fig. 2: Example of how to fetch articles and paragraphs with a keyword in Arx. The left figure finds all articles that contain "Lionel Messi". The right figure finds all paragraphs that contain the word "Mlscorer"

Class Label	Count
Goal/Assist	1117
Quotes	975
Transfer	887
Irrelevant	812
Ignore	663
Player Detail	340
Club Detail	315
Chances	300

TABLE IV: Number of data samples per class.

In table V there is an overview of the hardware used to train the different machine learning algorithms.

The traditional machine learning algorithms Navie Bayes, Linear SVC and SVC are all created with the Scikit-learn library. With Scikit-learn the algorithm is imported and initiated with the relevant hyperparameters. All the algorithms choose between two vectorizers to transform the paragraphs into vectors of numbers. The first method is term frequency-inverse document frequency (TFIDF), and the other method is a count vectorizer.

The deep learning models RNN and CNN are both created with the python library Keras. Keras [13] is a high-level neural network API written in python, that runs on top of Tensorflow

Component	Model	Description
CPU	Intel i7-8700K ³	Cores: 6 Clock spees: 3.7-4.7GHz Catch: 12MB
GPU	Nvidia GTX1070 Ti ⁴	Memory: 8GB DDR5 Cuda cores: 2432 Boost clock: 1683 MHz
RAM	na	16 GB DDR4
OS	Ubuntu 18.04	na

TABLE V: Hardware specifications

[14], Theano [15] or CNTK [16]. We use the tokeniser from Keras to convert words to numbers. The input to the models is fixed, and the paragraph with the most words determine the input length. All other paragraphs are padded to match the max size.

The RNN model is a composition of the following layers, embedding layer, dropout layer, bidirectional LSTM layer, and a dense layer. To find the optimal RNN model three experiments will be executed. The first experiment will find the optimal embedding dimension for four different LSTM layers, with the other parameters set to the default values. For the second experiment, the optimal embedding dimension will be used to find the optimal number of LSTM neurons in the LSTM layer, with the other parameters set to the default value. The third experiments will use the optimal embedding dimension and the optimal number of LSTM neurons, to find the optimal dropout rate when the dropout layer is before and after the LSTM layer.

The CNN model is a composition of these layers, embedding layer, convolutional layer, dropout layer, pooling layer, flattening layer and two dense layers.

To find the optimal CNN model four experiments will be executed. The first experiment will find the optimal embedding dimension with different filter sizes, pooling sizes and kernel sizes. The second experiment will use the optimal embedding dimension, kernel size and pooling size to find the optimal filter size. The third experiment will use the optimal values found in experiment one and two to find the optimal number of neurons in the dense layer. The fourth experiment will find the optimal dropout rate when the optimal values are used for all parameters.

After the training experiments, each model will use the optimal parameters and train on the entire dataset. The models will then be used in the application to classify articles about football players. The result from the models will be compared and analysed. The articles used in the application is collected in the period between December 2018 and February 2019, three months after the training set was made.

Figure 3 shows the user interface of the classification program. The application takes a player name and a machine learning type as input. It then searches the database for all articles where that player is mentioned two times. The paragraphs in these articles are run through the machine learning algorithm, and the result is presented in five different tags shown in figure 3.

Each model will classify articles for five players. Two players will test the models on how well they classify "Goal/Assist" paragraphs. The two players are Lucas Moura and Marcus Rashford, both of these players scored goals and performed well in the period from December 2018 to February 2019. Two players will test the models on how well they classify "Transfer" paragraphs. The two players are Higuain and Morata, these players were sold in the 2019 January transfer window. The last player to test the models is Martin degaard, he performed well and was speculated in the transfer marked in the period December 2018 to February 2019.

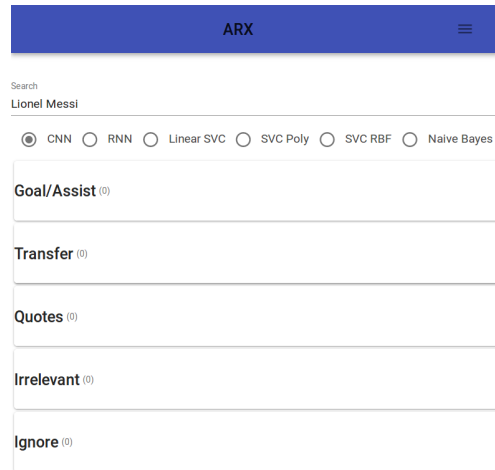


Fig. 3: An example of the classification of Lionel Messi with the CNN model. Each paragraph in articles about Lione Messi will be classified in one of the five tabs.

Metric values and confusion matrix are calculated for each player on all the different models. In addition, for Lucas Moura and Morata the paragraphs will be shown and the result will be analysed. Five articles will be classified for Lucas Moura.

The following metrics are used to determine the performance of a classifier: Accuracy, recall, precision, f-measure and MCC. To get the result of the classifiers as general as possible the metrics are calculated as an average over 10-fold cross-validation.

A. Results

The performance of Linear SVC, SVC RBF and SVC poly are almost identical during training, with an MCC of 82% and an accuracy of 85.5%. The Naive Bayes model performs 4% lower than the others. All the algorithms have the same pattern, where the f1 score of the "Irrelevant" class has low performance, and the other classes have high performance. Especially for Naive Bayes the f1 score of the "Irrelevant" class is 17% lower than the other algorithms, but for the other four classes, the performance is only 2% lower. The training time for SVC poly and SVC RBF is 2.7 seconds, that is 30 times higher than what it is for Naive Bayes and Linear SVC. And the prediction time is 0.4 ms per paragraph, and that is 25 times higher than what it is for Linear SVC and Naive Bayes.

When running the optimal model for all the algorithms in the application, the results show a 20% drop in MCC for all the models. The SVC poly and SVC RBF have the best performance, with an MCC of 62%, beating Linear SVC with 2% and Naive Bayes with 6%. Then Naive Bayes classifier has a 5-7% higher f1 score on the "Transfer" class than the others. On the other hand, the f1 score of the "Ignore" class is 13-15% lower than the other models.

The performance of the RNN and CNN classifier is very similar during training. The RNN model has an MCC of 85.3% and an accuracy of 88.3%, which is 1% better than CNN. The

Parameter	Metrics					f1 score for each class				
Model Name	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
RNN	0.887	0.859	0.887	0.885	0.892	0.907	0.884	0.982	0.74	0.912
CNN	0.879	0.849	0.879	0.876	0.882	0.9	0.879	0.979	0.732	0.888
SVM RBF	0.859	0.823	0.859	0.857	0.864	0.903	0.876	0.903	0.701	0.9
SVM Poly	0.859	0.822	0.859	0.855	0.861	0.904	0.882	0.903	0.694	0.891
Linear SVM	0.853	0.815	0.853	0.848	0.854	0.907	0.877	0.893	0.68	0.883
Naive Bayes	0.818	0.775	0.818	0.798	0.814	0.873	0.868	0.87	0.528	0.851

TABLE VI: Shows the result of the training experiments

Parameter	Metrics					f1 score for each class				
Model Name	Acc	MCC	Rec	F1	Prec	Go/As	Tr	Qu	Ir	Ig
RNN	0.733	0.647	0.733	0.717	0.778	0.611	0.672	0.936	0.718	0.65
CNN	0.703	0.625	0.703	0.696	0.776	0.558	0.684	0.881	0.699	0.659
SVM Poly	0.703	0.624	0.703	0.72	0.768	0.567	0.661	0.868	0.667	0.835
SVM RBF	0.697	0.618	0.697	0.711	0.767	0.563	0.65	0.872	0.663	0.809
Linear SVM	0.69	0.609	0.69	0.704	0.758	0.566	0.633	0.85	0.657	0.819
Naive Bayes	0.613	0.564	0.613	0.645	0.738	0.515	0.711	0.855	0.467	0.677

TABLE VII: Shows the result of the application experiments

two models have the same pattern, where the f1 score of the "Irrelevant" class is low, and the other classes f1 score is high. The training time for CNN is between 4 and 11 seconds, and for RNN it is between 7 and 15 seconds. The predictions time for CNN is 0.22 ms per paragraphs, which is about half of what it is for RNN.

When running the optimal model for RNN and CNN in the application, the results show a 20% drop in MCC score. The RNN classifier has the best performance, with an MCC of 64.7%, which is 2% higher than what it is for CNN. The f1 score of the different classes is very similar between the two models.

V. DISCUSSION

The performance of the algorithms during training was overall very high. There is an overview of the top results in table VI. Naive Bayes is at the low end with an MCC of 75% and RNN at the high end with an MCC of 85.3%. The MCC of the deep learning models was around 85%, while for the SVM models the MCC was around 82%. Thus, the performance is overall better for the deep learning algorithms, but not with a large margin. After the training, each model was used in the application with the optimal parameters. The first thing to note from the results in the application is that all the algorithms suffered a $\sim 20\%$ drop in MCC. This drop might indicate that the models are overfitting, or that the training set does not represent the data good enough. Since all the algorithms are affected the same, the problem most likely lies with the training set. The results from the application show that the deep learning models have a better performance than the traditional machine learning models; there is an overview of the results in table VII. Same as during training, RNN has the highest MCC with 64.7%, and Naive Bayes has the lowest MCC with 56.4%. The SVM model with polynomial kernel was closest with an MCC of 62.4%. The difference in performance is marginal, with RNN performing slightly better than SVM models.

The training time can be divided into three brackets, where Naive Bayes and linear SVM have a very low training time, SVM with polynomial and RBF kernel have a high training time, and RNN and CNN have a very high training time. In table VIII there is an overview of the approximate time for

Model Name	Expression	ttt
Naive Bayes	$4 * 80 * 0.063 * 10$	3 min
Linear SVM	$3 * 80 * 0.084 * 10$	3.36 min
SVM RBF	$4 * 80 * 2.7 * 10$	2.4 h
SVM Poly	$6 * 80 * 2.6 * 10$	3.46 h
RNN	$7 * 80 * 11 * 10$	17 h
CNN	$27 * 80 * 8 * 10$	48 h

TABLE VIII: Show the total training time for each algorithm

the different models. Where the time is calculated with the function 1 and where the different parameters are as follow:

- Experiments (exp) - Number of experiments that were executed.
- Parameters per experiment (ppe) - Number of values that were tested for each experiment.
- Average training time (att) - The average training time for each model.
- Number of folds in cross-validation (fcv) - Number of folds that were used during training.

$$Total\ training\ time\ (ttt) = exp * ppe * att * fcv \quad (1)$$

SVM with RBF and polynomial kernel have a lower training time then what is shown in table VIII. The implementation from Sklearn does not support multi-threading, so each of them only ran on one processor core. However, during training, the task was split up to use the six cores available. Therefore, the time shown in the table can roughly be divided by six. The linear SVM model has a lower training time than the other SVM models because Sklearn uses a different multi-class implementation. For linear SVM Sklearn uses one-vs-rest, and for the other two, it uses one-vs-one, which is more computationally expensive. The total training time is much higher for the deep learning algorithms than it is for the traditional machine learning models. One reason for the high training time is that there are more parameters to optimise for the deep learning models, combined with higher training time in general. Despite the high training time compared to the other models, it is not unreasonable high and still very manageable.

A. Failure Analysis

The algorithms have some common performance problems. The "Irrelevant" class have a low f1 score compared to the other classes. Moreover, paragraphs classify to the "Goal/Assist" class instead of the "Irrelevant" class. There is also a significant drop in performance from the training results to the application results.

The "Irrelevant" class contains many different types of paragraphs, for example, goal chances, team lineups and general trivial information. In other words, the "Irrelevant" class is many classes put into one class, and this makes it difficult for the models to generalise what belongs to this class. One solution to increase the performance of the different models can be to change the "Irrelevant" class. For example, one of the main problems in the application is that paragraphs about

goal chances get classified to the "Goal/Assist" class instead of to the "Irrelevant" class. Renaming the "Goal/Assist" class to "Situation" class, and changing the content from being about goals and assists to goals, assists and chances would simplify the "Irrelevant" class. Another problem in the application is that paragraphs about team line-ups get classified to the "Ignore" class instead of to the "Irrelevant" class. Moving these paragraphs to the "Ignore" class makes sense, maybe that is where they should have been from the start. These two measures would reduce the size of the "Irrelevant" class without complicating the "Goal/Assist" and "Ignore" class.

One possible reason for the big difference between the training experiment result and the application result can be the labelling method used on the training set and the test set. There are three ways to label data samples (1) label paragraphs in random articles, (2) label paragraphs in articles that contain a keyword, for example, articles that contain a certain player name, or (3) label paragraphs from a list of paragraphs containing a keyword, for example, a list of all paragraphs that contain the word "Mlscorer". When making the training set, all three methods were used, but the third method was used the most. On the other hand, when making the test set, only the second method was used, which means that the training set has a less diverse set of paragraphs compared to the test set.

RNN and CNN are data hungry algorithms compared to Naive Bayes and SVM, and the training set used in this research contains approximately 5,500 data samples, which is considered to be few when it comes to deep learning. However, even with a limited training set, the deep learning algorithms outperformed the traditional machine learning algorithms, and if this dataset is a working progress, meaning that it will grow over time, it is reasonable to think that CNN and RNN will benefit more from this than SVM and Naive Bayes.

VI. CONCLUSION AND FUTURE WORK

The research question raised was: "**How does deep learning compare to traditional machine learning on text classification when it comes to classification performance, training time and setup complexity?**". To answer this question different machine learning and deep learning models were created, and then compared against each other.

There is no clear answer to whether deep learning or traditional machine learning algorithms are preferred on text classification, based on the research done in this paper. On the one hand, the deep learning models did perform slightly better overall compared to the traditional machine learning algorithms. However, on the other hand, for the deep learning models, the training time is much higher and the setup is more challenging.

To conclude, if the dataset is limited as it is in this work the traditional machine learning models are the better choice. The easy setup, low training time and limited maintenance outweigh the small performance gain given by deep learning. However, if the dataset is growing over time and have the potential to become much bigger than it is now, the deep

learning models are the better choice. The overhead would then be worth the potential performance gain that is given by deep learning.

For future work we are planing the following improvements. First, to get a more thorough comparison between deep learning and traditional machine learning, more algorithms can be tested. For example, add decision trees, k-nearest neighbours and other machine learning algorithms. Also, test different architectures for RNN and CNN. Furthermore, pre-processing of the dataset was almost non-existent in this research; only special characters were removed. Therefore, more advanced pre-processing could be tested on the dataset. One way to do this is to use the Google Translate API, and translate the dataset into English for so to apply pre-processing tools available in English. Second, improve the dataset, by adding more data samples. See how the different models perform when given fewer data samples compared to more. Third, We plan to make the application so general that the only thing it needs is an unlabeled dataset, and eventually machine learning models to classify data samples.

REFERENCES

- [1] Total number of websites - internet live stats. [Online]. Available: <http://www.internetlivesstats.com/total-number-of-websites/>
- [2] Google trends. [Online]. Available: <https://trends.google.com/trends/explore?date=today>
- [3] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [4] G. Lewis-Kraus, "The great ai awakening," *The New York Times Magazine*, vol. 14, 2016.
- [5] T. Young, D. Hazarika, S. Poria, and E. Cambria, "Recent trends in deep learning based natural language processing," *IEEE Computational Intelligence Magazine*, vol. 13, no. 3, pp. 55–75, 2018.
- [6] R. Socher, A. Perelygin, J. Wu, J. Chuang, C. D. Manning, A. Ng, and C. Potts, "Recursive deep models for semantic compositionality over a sentiment treebank," in *Proceedings of the 2013 conference on empirical methods in natural language processing*, 2013, pp. 1631–1642.
- [7] X. Li and D. Roth, "Learning question classifiers," in *Proceedings of the 19th international conference on Computational linguistics-Volume 1*. Association for Computational Linguistics, 2002, pp. 1–7.
- [8] Y. Kim, "Convolutional neural networks for sentence classification," *arXiv preprint arXiv:1408.5882*, 2014.
- [9] C. Zhou, C. Sun, Z. Liu, and F. Lau, "A c-lstm neural network for text classification," *arXiv preprint arXiv:1511.08630*, 2015.
- [10] D. Zhang and W. S. Lee, "Question classification using support vector machines," in *Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval*. ACM, 2003, pp. 26–32.
- [11] J. Silva, L. Coheur, A. C. Mendes, and A. Wichert, "From symbolic to sub-symbolic information in question classification," *Artificial Intelligence Review*, vol. 35, no. 2, pp. 137–154, 2011.
- [12] A. Nordskog, "Text classification project," original-date: 2019-05-16T06:12:33Z. [Online]. Available: <https://github.com/Halflingen/Text-Classification-Project>
- [13] F. Chollet *et al.*, "Keras," 2015. [Online]. Available: <https://keras.io/>
- [14] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard *et al.*, "Tensorflow: a system for large-scale machine learning," in *OSDI*, vol. 16, 2016, pp. 265–283.
- [15] J. Bergstra, O. Breuleux, F. Bastien, P. Lamblin, R. Pascanu, G. Desjardins, J. Turian, D. Warde-Farley, and Y. Bengio, "Theano: A cpu and gpu math compiler in python," in *Proc. 9th Python in Science Conf*, vol. 1, 2010.
- [16] F. Seide and A. Agarwal, "Cntk: Microsoft's open-source deep-learning toolkit," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2016, pp. 2135–2135.