

Simulação do funcionamento de um torrador baseado em Deep Learning

JOSÉ MANUEL ALVES DA SILVA
Julho de 2022

POLITÉCNICO DO PORTO
INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO

Simulação do funcionamento de um torrador baseado em Deep Learning

José Manuel Alves da Silva

Mestrado em Engenharia Electrotécnica e de Computadores
Área de Especialização em Automação e Sistemas



DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA
Instituto Superior de Engenharia do Porto

Junho, 2022

*Esta dissertação satisfaz, parcialmente, os requisitos que constam da Ficha de
Unidade Curricular de Tese/Dissertação, do 2º ano, do Mestrado em
Engenharia Electrotécnica e de Computadores, Área de Especialização em
Automação e Sistemas.*

Candidato: José Manuel Alves da Silva, Nº 1151539, 1151539@isep.ipp.pt

Orientação Científica: Ramiro Barbosa, rsb@isep.ipp.pt

Empresa: M de Máquina II, Lda.

Orientador: Augusto Castilho, acastilho@mdemaquina.pt



DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA
Instituto Superior de Engenharia do Porto
Rua Dr. António Bernardino de Almeida, 431, 4200-072 Porto

Junho, 2022

Resumo

O processo de torrefação do café é bastante complexo, sendo até considerado por alguns como arte. Mesmo antes de iniciar a torrefação é necessário escolher a mistura dos tipos de café que serão torrados, posteriormente, é definido o grau de torra a realizar. De forma a replicar o café pretendido é criada a receita para a torra desse tipo de café. Condições ambientais como a temperatura ambiente e humidade do ar, interferem no processo de torrefação bem como a respetiva humidade dos grãos. De forma a entender o processo de torrefação, é necessário conhecer os vários tipos de café bem como as suas propriedades, conhecer os diferentes graus de torra, saber que alterações os grãos sofrem durante o processo de torrefação e conhecer o torrador e os seus componentes bem como a forma com que estes se correlacionam.

Dada a elevada complexidade do sistema, a criação de uma ferramenta capaz de recriar o funcionamento do torrador, necessita de, ser desenvolvida com algum tipo de inteligência artificial, de forma a adaptar-se ao funcionamento real do torrador. Neste sentido, foi realizado um estudo sobre inteligência artificial, mais especificamente *Machine Learning*, *Deep Learning* e redes neurais. Foram também abordados alguns algoritmos de redes neurais, que detinham a possibilidade de gerar resultados positivos.

Com recurso à ferramenta MATLAB foram treinados algoritmos de *Deep Learning*. De forma a avaliar que tipo de algoritmos se adaptava melhor, foi realizada uma primeira avaliação, com o objetivo de identificar aquele que apresentava um melhor desempenho e uma capacidade superior de melhoria. Após a análise dos resultados obtidos, foi possível identificar a rede que mais se adequava ao problema em questão. Posteriormente, foi necessário aferir qual seria a melhor formatação de dados e quais os parâmetros que melhor se ajustavam à rede definida. Foram realizados vários treinos, procedendo-se à recolha do RMSE para efetuar a comparação entre os diferentes tipos de dados e parâmetros. Analisando os resultados obtidos procedeu-se à seleção de um conjunto de parâmetros que traduziriam na melhor rede neuronal possível. Numa etapa final, foram realizados os treinos com os conjuntos de dados escolhidos. Finalizando os treinos e comparando resultados foi escolhida a rede neuronal capaz de replicar o funcionamento do torrador com o menor erro

possível.

Palavras-Chave: Café, Torrefação, Torrador, Inteligência Artificial, MATLAB, *Deep Learning*, LSTM.

Abstract

The coffee roasting process is quite complex, being even considered an art by some. Even before starting the roasting process, it is necessary to choose the mix of coffee types that will be roasted, and then the degree of roasting to be done. In order to replicate the desired coffee, a recipe is created for roasting it. Environmental conditions, such as ambient temperature and air humidity, interfere in the roasting process, as well as the respective humidity of the beans. In order to understand the roasting process, it is necessary to know the various types of coffee and their properties, the different roasting grades, know what changes the beans during the roasting process and to know the roaster and its components as well as how they correlate.

Given the high complexity of the system, the creation of a tool capable of recreating the roaster's functioning needs to be developed with some kind of artificial intelligence, in order to adapt to the real functioning of the roaster. In this sense, a study on artificial intelligence, more specifically Machine Learning, Deep Learning and Neural Networks was carried out. Some Neural Network algorithms, which had the possibility of generating positive results, were also discussed.

Using the MATLAB tool, Deep Learning algorithms were trained. In order to evaluate which type of algorithms were best suited, a first evaluation was performed, with the objective of identifying the one that presented the best performance and a superior capacity for improvement. After analyzing the obtained results, it was possible to identify the network that best suited the problem at hand. Subsequently, it was necessary to assess which would be the best data formatting and which parameters best fit the defined network. Several trainings were performed, and the RMSE was collected to compare the different types of data and parameters. Analyzing the obtained results, a set of parameters that would translate into the best possible neural network were selected. In a final step, training was performed with the chosen data sets. Finishing the trainings and comparing results it was chosen the neural network capable of replicating the roaster operation with the smallest

possible error.

Keywords: Coffee, Roasting, Toaster, Artificial Intelligence, MATLAB, Deep Learning, LSTM

Índice

Lista de Figuras	ix
Lista de Tabelas	xiii
Listagens	xv
Lista de Acrónimos	xvii
1 Introdução	1
1.1 Contextualização	1
1.2 Empresa	2
1.3 Definição do Problema	4
1.4 Objetivos	4
1.5 Plano de Trabalho	5
1.6 Organização da Dissertação	5
2 Estado da Arte	7
2.1 A Origem do café	7
2.2 Tipos de café	11
2.2.1 Sabor	12
2.2.2 Planta	12
2.2.3 Grão	12
2.3 Processamento do café	12
2.3.1 Colheita	13
2.3.2 Descascagem	14
2.3.3 Processamentos	15
2.4 Alterações no grão durante o processo de torrefação	16
2.4.1 Secagem	16
2.4.2 Reação de Mailard	16
2.4.3 Primeira racha	17
2.4.4 Caramelização	17
2.4.5 Segunda racha	17
2.5 Tipos de torras	17
2.5.1 Torra clara	18

2.5.2	Torra média	19
2.5.3	Torra média-escura	19
2.5.4	Torra escura	20
2.6	Tipos de torradores	21
2.7	Constituição dos torradores industriais	21
2.7.1	Hopper de alimentação	21
2.7.2	Tambor de torra	23
2.7.3	Coletor de partículas	23
2.7.4	Fonte de aquecimento	23
2.7.5	Tabuleiro de arrefecimento	25
2.8	Controlo da torra	25
2.9	Processo de torrefação	26
3	Inteligência Artificial	29
3.1	Definição	29
3.2	História da inteligência artificial	31
3.3	Tipos de AI	35
3.4	Aplicações da Inteligência Artificial	35
3.5	Machine Learning	36
3.5.1	Tipos de Machine Learning	37
3.6	Deep Learning	38
3.7	Redes Neurais	38
3.7.1	Funções de ativação	40
3.7.2	Recurrent Neural Networks	41
	Tipos de RNN	42
3.7.3	Long Short-term Memory	43
3.8	Diferenças entre Deep Learning e Redes Neurais	43
4	Implementação de Redes Neurais em MATLAB	45
4.1	Dados	45
4.2	Tratamento dos Dados	46
4.3	Implementação da rede	49
4.3.1	Avaliação do desempenho de diferentes tipos de redes neurais	52
	Feed-Forward	52
	NARX	54
	LSTM	58
4.3.2	Comparação de resultados das redes	60
4.4	Treino da LSTM e Resultados	62
4.4.1	Avaliação do tipo de dados	63
4.4.2	Avaliação dos parâmetros	67
4.5	Rede final	73

4.6	Conclusões	77
5	Conclusões	79
	Referências	81
A	Códigos de programação	85
A.1	Código Python para filtragem de ficheiros	85
A.2	Código MATLAB de importação dos dados com tempo	86
A.3	Código MATLAB de importação dos dados sem tempo	88
A.4	Código MATLAB para uniformização dos dados	90
A.5	Código MATLAB para normalização dos dados	93
B	Gráficos do RMSE médio dos treinos da rede LSTM	97
B.1	Análise do parâmetro <i>hidden units</i>	97
B.2	Análise do parâmetro <i>Epochs</i>	100
B.3	Análise do parâmetro <i>Batch</i>	102
B.4	Análise do parâmetro <i>Gradient treshold</i>	104
B.5	Análise do parâmetro <i>Initial learning rate</i>	106
B.6	Análise do parâmetro <i>Validation frequency</i>	108
B.7	Análise do parâmetro <i>Validation patiente</i>	110

Lista de Figuras

1.1	Logótipo da empresa M de Máquina II	2
2.1	Kaldi a dançar com as suas cabras [1]	8
2.2	Cafeeiro com fruto [2]	8
2.3	Uma representação do século XVII de uma casa de café em Londres [3]	9
2.4	<i>Boston tea party</i> [4]	10
2.5	Árvore da família botânica Rubiaceae [5]	11
2.6	Grão de café arábica e grão de café robusta [6]	11
2.7	Plantação de café [7]	13
2.8	Flor do cafeeiro [8]	13
2.9	Separação do grão de café da polpa [9]	14
2.10	Método da via seca [9]	15
2.11	Do café verde ao torrado [10]	16
2.12	Os 4 graus de torra [11]	18
2.13	Grãos de café de torra clara [11]	19
2.14	Grãos de café de torra média [11]	19
2.15	Grãos de café de torra média-escura [11]	20
2.16	Grãos de café de torra escura [11]	21
2.17	Uma figura com duas sub-figuras.	22
2.18	Diagrama de um torrador industrial [12]	22
2.19	Hopper de alimentação [13]	23
2.20	Tambor de um torrador [14]	24
2.21	Coletor de partículas	24
2.22	Tabuleiro de arrefecimento [15]	25
2.23	Coletor de amostras de um torrador [12]	26
2.24	Uma figura com duas sub-figuras.	26
3.1	Alan Turing [16]	30
3.2	Livro Runaround de Isaac Asimov [17]	31
3.3	ELIZA [18]	32
3.4	DARPA [19]	33
3.5	Deep Blue [20]	34
3.6	Subcampos da AI [21]	37

3.7	Neurónio artificial [22]	39
3.8	Camada de NN [22]	39
3.9	NN de múltiplas camadas [22]	40
3.10	Funções de ativação[22]	41
3.11	RNN <i>One-to-one</i> [23]	42
3.12	Uma figura com duas sub-figuras.	42
3.13	RNN <i>Many-to-many</i> [23]	43
3.14	Camada de uma LSTM [23]	43
4.1	Gráfico dos dados de um ficheiro removido	46
4.2	Gráfico dos dados de um ficheiro removido	47
4.3	Gráfico dos dados de um ficheiro utilizado	47
4.4	Fluxograma geral das redes neuronais	50
4.5	Exemplo de imagem exportada com os gráficos relativos a um treino	51
4.6	Estrutura de uma rede Feed-Forward	52
4.7	Arquitetura de uma rede NARX [24]	55
4.8	Análise do desempenho das redes	61
4.9	Análise do desempenho das redes (RMSE<20)	62
4.10	Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 301 a 306	76
4.11	Gráficos dos 4 primeiros resultados do treino 301	77
B.1	Gráfico de linhas dos resultados dos treinos relativos ao treinos 101 a 106	97
B.2	Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 101 a 106	98
B.3	Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 101 a 106	99
B.4	Gráfico de linhas dos resultados dos treinos relativos ao treinos 111 a 115	100
B.5	Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 111 a 115	100
B.6	Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 111 a 115	101
B.7	Gráfico de linhas dos resultados dos treinos relativos ao treinos 121 a 125	102
B.8	Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 121 a 125	102
B.9	Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 121 a 125	103

B.10 Gráfico de linhas dos resultados dos treinos relativos ao treinos 131 a 135	104
B.11 Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 131 a 135	104
B.12 Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 131 a 135	105
B.13 Gráfico de linhas dos resultados dos treinos relativos ao treinos 141 a 146	106
B.14 Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 141 a 146	106
B.15 Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 141 a 146	107
B.16 Gráfico de linhas dos resultados dos treinos relativos ao treinos 151 a 155	108
B.17 Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 151 a 155	108
B.18 Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 151 a 155	109
B.19 Gráfico de linhas dos resultados dos treinos relativos ao treinos 161 a 166	110
B.20 Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 161 a 166	110
B.21 Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 161 a 166	111

Lista de Tabelas

4.1	Valores RMSE Feed-Forward-Análise do tipo de dados	53
4.2	Valores RMSE Feed-Forward-Análise dos parâmetros	53
4.3	Parâmetros para rede Feed-Forward	54
4.4	Parâmetros de treino para a rede NARX	55
4.5	Valores RMSE NARX-Análise do tipo de dados	56
4.6	Valores RMSE NARX-Análise dos parâmetros	56
4.7	Parâmetros de treino para a rede NARX	57
4.8	Valores RMSE NARX-Análise do tipo de dados	58
4.9	Valores RMSE NARX-Análise dos parâmetros	58
4.10	Parâmetros de treino para a rede LSTM	59
4.11	Valores RMSE LSTM-Análise do tipo de dados	60
4.12	Valores RMSE LSTM-Análise dos parâmetros	60
4.13	Parâmetros LSTM	63
4.14	Valores RMSE-Parâmetros <i>Hidden units</i> -Análise dos dados	64
4.15	Valores RMSE-Parâmetros <i>Epochs</i> -Análise dos dados	64
4.16	Valores RMSE-Parâmetros <i>Batch size</i> -Análise dos dados	65
4.17	Valores RMSE-Parâmetros <i>Gradient treshold</i> -Análise dos dados	65
4.18	Valores RMSE-Parâmetros <i>Initial learning rate</i> -Análise dos dados	66
4.19	Valores RMSE-Parâmetros <i>Validation frequency</i> -Análise dos dados	66
4.20	Valores RMSE-Parâmetros <i>Validation Patiente</i> -Análise dos dados	67
4.21	Valores RMSE-Parâmetro <i>Hidden units</i> -Análise dos parâmetros	67
4.22	Valores RMSE-Parâmetro <i>Epochs</i> -Análise dos parâmetros	68
4.23	Valores RMSE-Parâmetro <i>Batch size</i> -Análise dos parâmetros	69
4.24	Valores RMSE-Parâmetro <i>Gradient treshold</i> -Análise dos parâmetros	70
4.25	Valores RMSE-Parâmetro <i>Initial learning rate</i> -Análise dos parâmetros	71
4.26	Valores RMSE-Parâmetro <i>Validation frequency</i> -Análise dos parâmetros	72
4.27	Valores RMSE-Parâmetro <i>Validation patiente</i> -Análise dos parâmetros	72
4.28	Parâmetros de treino finais para LSTM	73
4.29	Valores RMSE-Treinos Finais-Análise dos parâmetros	74
4.30	Valores RMSE-Treinos finais-Análise dos parâmetros	75

Listagens

files/excel_edit.py	85
files/import_com_tempo.m	86
files/import_s_tempo.m	88
files/manual_padding.m	90
files/normalisation.m	93

Lista de Acrónimos

AGI	<i>Artificial General Intelligence</i>
AI	<i>Artificial Intelligence</i>
ANI	<i>Artificial Narrow Intelligence</i>
ANN	<i>Artificial Neural Networks</i>
ASI	<i>Artificial Super Intelligence</i>
DARPA	<i>Defense Advanced Research Projects Agency</i>
DSRPAI	<i>Dartmouth Summer Research Project on Artificial Intelligence</i>
ETA	Estação de Tratamento de Águas
ETAR	Estação de Tratamento de Águas Residuais
EUA	Estados Unidos da América
FEUP	Faculdade de Engenharia da Universidade do Porto
HMI	<i>Human-Machine Interface</i>
IBM	<i>International Business Machines Corporation</i>
IP	<i>Internet Protocol</i>
ISEP	Instituto Superior de Engenharia do Porto
LSTM	<i>Long Short-Term Memory</i>
MIT	<i>Massachusetts Institute of Technology</i>
ML	<i>Machine Learning</i>
NARX	<i>Nonlinear Autoregressive Network with Exogenous Inputs</i>
NLP	<i>Natural Language processing</i>
PLC	<i>Programmable Logic Controller</i>
RMSE	<i>Root Mean Square Error</i>
RNN	<i>Recurrent Neural Networks</i>
RoR	<i>Rate of Rise</i>
SCADA	<i>Supervisory Control And Data Acquisition</i>
TCP	<i>Transmission Control Protocol</i>

Capítulo 1

Introdução

Neste capítulo será primeiramente exposta uma breve contextualização do projeto. De seguida é apresentada uma breve descrição da empresa onde o projeto foi desenvolvido. É também realizada a definição do problema, definição dos objetivos que se pretendem obter com este projeto e realizada uma planificação para o desenvolvimento das várias etapas do mesmo. Por fim é referida qual será a organização do relatório.

1.1 Contextualização

Este projeto surgiu no âmbito da unidade curricular Tese/Dissertação do Mestrado de Engenharia Eletrotécnica e Computadores ramo de Automação e Sistemas. Esta unidade curricular tem como objetivo aprofundar e implementar em aplicações reais, os conhecimentos obtidos ao longo do curso.

Ao longo do tempo a evolução das tecnologias de Inteligência Artificial (*AI-Artificial Intelligence*), proporcionou uma maior procura de implementação de sistemas inteligentes. O aumento da acessibilidade, a componentes computacionais avançados às empresas e a particulares, facilitou a implementação destes sistemas inteligentes nos seus produtos e processos de fabrico. Atualmente sistemas inteligentes estão presentes na indústria bem como em elementos que são utilizados diariamente, tais como *smartphones*, *web browsers*, computadores, eletrodomésticos, veículos, etc.

A necessidade de integrar sistemas inteligentes tem aumentado de uma forma significativa. Estes sistemas são altamente requisitados pois possuem a capacidade de analisar dados, e consecutivamente, tomar decisões. São normalmente sistemas com elevada adaptabilidade e eficiência, capazes de melhorar os consumos energéticos, consumos de matérias primas, a organização de *stocks*, prever avarias, etc.

1.2 Empresa

Desde o seu início, há vinte e cinco anos, a MdeMáquina (logótipo na Figura 1.1) tem focalizado as suas competências em automação em vários setores de atividade: indústria, infraestruturas, ambiente, energia. A fidelização dos clientes são o reconhecimento da qualidade e êxito dos serviços prestados e o comprovativo da eficácia das soluções implementadas pela MdeMáquina.



Figura 1.1: Logótipo da empresa M de Máquina II

Apoiada num corpo técnico de formação superior, predominantemente das escolas de engenharia FEUP e ISEP, e na confiança depositada pelos seus clientes, a MdeMáquina apostou numa capacidade pluridisciplinar:

Eletricidade

Projeto, fornecimento e instalação de quadros elétricos permitindo a satisfação, tipo chave-na-mão, das necessidades do cliente.

Automação e Controlo de Processo

Larga experiência e competência com várias marcas de autómatos e HMI, tais como Rockwell, Siemens, Schneider ou Omron.

Monitorização

Associados aos sistemas mais complexos a monitorização, o comando e o controlo, centralizados ou em telegestão, são profusamente utilizados com recurso a sistemas SCADA (*Supervisory Control and Data Acquisition*). Esta é outra área de atividade da MdeMáquina, recorrendo predominantemente às ferramentas das marcas dos autómatos utilizados.

Comunicações

Ethernet IP, ModBus TCP/IP, Profinet, DeviceNet são algumas das redes de campo e de tráfego de dados utilizadas.

Aplicações Informáticas

A MdeMáquina desenvolve aplicações informáticas de monitorização e condução de processos, de base de dados e de tratamento de informação, onde o sistema SCADA, pelas suas características não é solução.

Toda a experiência da MdeMáquina, nas vertentes acima referidas tem sido aplicada em áreas como, entre outras:

- ETA e ETAR;
- Tratamento de Resíduos;
- Indústria de Vidro;
- Indústria Alimentar;
- Indústria Corticeira;
- Cimenteiras;
- Armazéns Automáticos;
- Gestão Técnica Centralizada de Edifícios.

Enquanto fornecedor seja do cliente final, seja de fabricantes de máquinas ou de instaladores.

1.3 Definição do Problema

Atualmente, o Brigus, é um *software* desenvolvido pela empresa que é responsável pelas receitas usadas nos processos de torrefação de café, tanto pelo armazenamento dos dados obtidos durante a torra, como pelo processamento e armazenamento dos mesmos para a criação de receitas e por os enviar para a unidade de controlo (PLC) do torrador. O PLC é programado de forma a controlar vários componentes dos torradores de forma a replicar a receita pretendida.

Um dos obstáculos frequentemente encontrado é a impossibilidade de efetuar testes nos torradores de forma a validar os programas desenvolvidos. Uma possível solução para a resolução deste problema foi o desenvolvimento de uma ferramenta capaz de replicar o funcionamento real do torrador. Após uma análise aos dados que são recolhidos pelo mesmo concluiu-se que não seria possível criar tal ferramenta pela falta de dados de determinadas variáveis essenciais à construção do modelo de simulação.


No entanto, surgiu a ideia de criar uma ferramenta, que seja capaz de ajudar o utilizador do *software*, a acertar as curvas presentes numa receita, de forma a que estas se aproximem da curva real que seria criada pelo sistema real. O utilizador iria inserir as curvas de funcionamento dos componentes do torrador sendo gerada a curva de temperatura do grão.

1.4 Objetivos

Para este projeto, o objetivo principal é a criação de uma Rede Neuronal (NN-*Neural Network*) capaz de, simular a curva de temperatura do café de um processo de torrefação. Para tal foram definidos os seguintes objetivos:

- Estudo do café e do respetivo processo de torrefação;
- Estudo dos torradores, componentes e respetivo funcionamento;
- Estudo da área da Inteligência Artificial, com foco nas redes neuronais;
- Implementação e treino das redes neuronais em MATLAB;
- Análise dos resultados e retificação das redes neuronais.

1.5 Plano de Trabalho



1.6 Organização da Dissertação

No Capítulo 1 é apresentada uma breve introdução ao trabalho, contendo uma breve contextualização do projeto, uma descrição da empresa onde o mesmo foi desenvolvido e uma calendarização e objetivos planejados.

No decorrer do Capítulo 2 é apresentado o estado da arte relativo ao café e aos torradores. Inicialmente, é explorado com mais detalhe a história do aparecimento do café no mundo, seguido da diferenciação entre os diferentes tipos de café e as suas características. É explicado o processo de tratamento do café, desde o fruto até ao grão, bem como o seu processo de torrefação contemplando também os seus diferentes tipos. Finalmente são apresentados os torradores e os diferentes tipos. Mais especificamente é descrita a composição dos torradores industriais bem como o funcionamento dos mesmos.

No Capítulo 3, é apresentada a definição da AI, a história do seu aparecimento e evolução, bem como as aplicações possíveis da mesma. É também explicado o *Machine Learning* (ML) bem como o *Deep Learning* (DL) e as redes neurais.

No Capítulo 4 é explicado o processo de implementação das redes neurais no MATLAB. Neste capítulo são também apresentados testes e resultados necessários

à criação das redes. Por fim é apresentada a rede neuronal final, os seus respetivos parâmetros de treino e os resultados finais.

No Capítulo 5 é realizada a conclusão do trabalho, indicando quais os problemas e dificuldades que surgiram ao longo do projeto, bem como algumas considerações e descrição de possíveis trabalhos futuros.

Capítulo 2

Estado da Arte

Neste capítulo será abordado o café, quais os tipos de café existentes bem como as características de cada, como se processa o mesmo desde a sua colheita até o grão pronto para torrar, que alterações ocorrem no grão durante processo de torrefação e por fim quais os tipos de torras existentes.

2.1 A Origem do café

A história da origem do café não é conhecida com certeza, esta baseia-se em lendas que relatam uma possível história.

A história da origem do café mais divulgada e aceita é a lenda da Etiópia. O café cultivado em todo o mundo pode traçar a sua herança até às antigas florestas de café no planalto etíope séculos atrás. Kaldi (representado na Figura 2.1), pastor de cabras, descobriu pela primeira vez na história o potencial do café, este notou que após as cabras se alimentarem deste fruto amarelo-avermelhado (Figura 2.2), ficavam extremamente energéticas e caminhavam bastante mais, bem como ficavam sem dormir de noite.

Kaldi decidiu então contar a sua descoberta junto dos monges locais, que decidiram experimentar o tal fruto. Estes fizeram uma bebida com infusão dos frutos e notaram que a bebida os deixava mais despertos durante as longas horas de orações. O conhecimento desta fruta começou a espalhar-se.



Figura 2.1: Kaldi a dançar com as suas cabras [1]



Figura 2.2: Cafeeiro com fruto [2]

O cultivo e comércio do café tiveram início na Península Arábica. No século XV, o café estava a ser cultivado no distrito Yemeni da Arábia, no século XVI passou a ser conhecido na Pérsia, Egito, Síria e Turquia.

O café não era apenas apreciado em casa, mas também em cafetarias públicas (Figura 2.3) que começaram a aparecer em cidades do Oriente próximo chamadas *qahveh khaneh*. Estas cafetarias eram frequentadas para variados tipo de atividades sociais, para além de apenas beber café, os clientes jogavam xadrez assistiam a artistas e mantinham-se atualizados nas notícias, tanto que rapidamente passaram a ser referidas como *Schools of the wise*.



Figura 2.3: Uma representação do século XVII de uma casa de café em Londres [3]

A visita de milhares de peregrinos anualmente fez com que o conhecimento do “wine of araby” se espalhasse pelo mundo.

No século XVII o café começou a se tornar popular na Europa, espalhando-se rapidamente por todo o continente.

Inicialmente esta nova bebida negra, o café, não foi aceite por todos, sendo esta chamada por alguns como a “bitter invention of Satan”. Em 1615 o café chegou a Veneza sendo condenado pelo clero local. Uma enorme controvérsia foi gerada levando a que o Papa Clemente VIII interviesse, este decidiu provar a bebida e achou-a bastante satisfatória o que o levou a dar a aprovação papal.

Apesar da enorme controvérsia ainda existente, as cafetarias rapidamente se espalharam nas grandes cidades dos países, tais como, Inglaterra, Áustria, França, Alemanha e Holanda tornando-se centros de atividade social.

O café começa a substituir bebidas comuns da época, tais como, o vinho e a cerveja, levando a que estes que tomam café ao invés do álcool sentiam-se muito mais energizados, tornando a qualidade do seu trabalho melhor.

Em meados de 1600, o café chegou a Nova York (conhecida como Nova Amsterdã na altura). Apesar do crescimento das cafetarias, o chá continuava a ser a bebida favorecida até 1773. O pesado imposto sobre o chá criado pelo Rei Jorge II levou a uma revolta dos colonos, conhecida como *Boston Tea Party* (Figura 2.4). Esta revolta mudou completamente a preferência americana de beber chá para o café.



Figura 2.4: *Boston tea party* [4]

À medida que a procura pela bebida continuava a aumentar, havia uma concorrência feroz para plantar café fora da Arábia. Na segunda metade do século XVII os holandeses conseguiram plantas. As primeiras plantações na Índia falharam, no entanto foram bem sucedidos na Batavia, ilha de Java que agora é Indonésia. As plantas prosperaram e os Holandeses tiveram um comércio produtivo e crescente de café.

Em 1714, o presidente de Amsterdã ofereceu uma planta de café (cafeeiro) ao rei Francês Luís XIV, que foi plantada no jardim Botânico Real em Paris. Em 1723 um oficial naval conseguiu obter uma planta que transportou para plantar em Martinique, esta planta levou a que mais de 18 milhões de cafeeiros nascessem na ilha nos seguintes 50 anos. Esta planta foi também a origem de todos os cafeeiros na América do Sul e Central bem como das Caraíbas.

Missionários, viajantes, comerciantes e colonos transportaram sementes de café por novas terras levando a que estas fossem plantadas por todo o mundo. Algumas plantações deram frutos enquanto outras foram de curta duração. Novas nações entraram na economia do café. No século XVIII o café era uma das culturas e exportação mais rentáveis do mundo, sendo a mercadoria mais procurada após o crude [25].

2.2 Tipos de café

O café pertence à família botânica Rubiaceae, representada na Figura 2.5, esta possui cerca de 500 gêneros e mais de 6000 espécies, sendo a maioria árvores tropicais e arbustos que crescem mais junto ao chão nas florestas. Na família também estão incluídas as gardênias e plantas que produzem quinino e outras substâncias úteis, no entanto o gênero *Coffea* é o membro mais economicamente importante da família. As espécies de café mais comercializadas são a Arábica e a Robusta, apresentando entre si diferenças marcantes [4].




Figura 2.5: Árvore da família botânica Rubiaceae [5]

Apesar de existirem muitas espécies do gênero *Coffea*, as duas espécies mais conhecidas e importantes economicamente são o Arabica *Coffea* (café arábica), representando mais de 70% do café mundial, e o *Coffea canephora* (café robusta), estando representados os grãos de cada na Figura 2.6. Existem também outras duas espécies de café com produções muito inferiores sendo estas a *Coffea liberica* e *Coffea dewevrei* (café excelsea). Relativamente aos dois cafés mais produzidos, estes podem ser distinguidos pelo sabor, condições de crescimento, diferenças físicas do grão, cultivo, preço, idade e composição química.



Figura 2.6: Grão de café arábica e grão de café robusta [6]

2.2.1 Sabor

Relativamente ao sabor o café robusta é amargo e com um intenso sabor. Este possui uma elevada quantidade de cafeína e de ácido clorogénico que enfatizam o sabor amargo durante o processo de torrefação.

No entanto o café Arábica é conhecido pelo seu sabor e complexidade, comparado com o robusta este café possui quase o dobro de açúcares e lípidos. Uma chávena de café arábica possui um sabor mais suave e doce quando comparado com o robusta, o seu sabor é complexo possuindo notas de açúcar, frutas e bagas bem como sendo menos ácido.

2.2.2 Planta

A planta do café Robusta cresce até uma altura máxima de 10 metros. Foi descoberta no Congo Belga em 1800, esta planta é muito resistente a alterações climáticas, logo não requer tantos cuidados como as plantas do café arábica, geralmente cresce entre 200 m e 800 m acima do nível do mar. Uma das razões pelas quais esta planta possui uma elevada robustez é a elevada quantidade de cafeína existente na mesma que serve de inseticida natural.

A planta do café Arábica cresce até uma altura entre 2,5 e 4,4 metros. É originária das regiões montanhosas da Etiópia. A planta desenvolve-se normalmente em ambientes subtropicais, onde existe elevados níveis de humidade, solo rico em nutrientes, sol, sombra e temperaturas constantes a alturas entre os 500 m e os 2000 m acima do nível do mar. A planta requer bastante atenção pois é sensível a pestes de doenças. Como o cultivo desta planta é efetuado em altitudes mais elevadas a colheita dos grãos é mais complicada e dispendiosa.

2.2.3 Grão

Os grãos do café Arábica possuem uma cor castanho-clara, bem como uma forma oval. Os grãos do café Robusta possuem uma cor mais escura bem como uma forma circular.

2.3 Processamento do café

O cafeeiro é um arbusto (Figura 2.7) que pode atingir, no estado selvagem, entre 8 a 10 metros de altura. No entanto, e de forma a permitir um melhor manuseamento, o arbusto é podado, ficando apenas com 2,5 a 3 metros de altura [8].

As flores do cafeeiro (Figura 2.8) têm 5 pétalas brancas e assemelham-se, em aspeto e fragrância, às do jasmim e da laranjeira. Um arbusto pode dar 30.000 flores que duram apenas 3 dias. O fruto do cafeeiro é uma drupa, mais conhecida na linguagem comum como cereja. Cada cereja agrupa duas sementes. No entanto,



Figura 2.7: Plantação de café [7]

por vezes quando um dos óvulos da semente aborta, a cereja apresenta apenas uma semente. Esta é arredondada, visto não ter encontrado oposição que a obrigue a desenvolver outra forma. Neste caso o café chama-se MOKA [8].



Figura 2.8: Flor do cafeeiro [8]

Dependendo da variedade do café, pode demorar aproximadamente 3 a 4 anos para um arbusto novo produzir o fruto. Normalmente existe apenas uma colheita durante o ano, no entanto em países como a Colômbia onde acontecem duas florações existe uma segunda colheita no ano [26].

2.3.1 Colheita

Na maioria dos países o café é colhido manualmente por pessoas, este é um trabalho bastante intensivo e difícil, no entanto, em países como o Brasil onde os terrenos são maioritariamente planos e com plantações de café imensas, o processo de colheita é

maquinizado. Independentemente da colheita ser manual ou maquinada, esta pode ser realizada das duas seguintes formas [26].

Colheita seletiva (*picking*), é um processo manual que envolve trabalhadores que vão passando de planta em planta colhendo apenas as bagas vermelhas e brilhantes já maduras (cerejas), uma por uma. Os apanhadores passam pelas árvores a cada 8 a 10 dias de forma a apanhar o fruto no seu melhor estado. Este método é dispendioso, mas a qualidade do café verde (café que ainda não foi torrado) é excelente. Este é o melhor método, mas também o mais lento, laborioso e intenso [27].

Colheita indiferenciada (*stripping*), neste caso a safra inteira é colhida de uma só vez. É um processo que pode ser tanto manual como mecânico. Em ambos os casos, todas as cerejas são colhidas ao mesmo tempo [27].

2.3.2 Descascagem

A etapa seguinte da preparação do café nas origens é a separação do grão da polpa (Figura 2.9) de forma a evitar que se estrague. Dependendo da localização de processamento ou apenas por escolha este tratamento pode ser realizado das seguintes formas. A via húmida exige maiores investimentos e cuidados. Todavia, este mé-



Figura 2.9: Separação do grão de café da polpa [9]

todo ajuda a preservar as qualidades intrínsecas dos grãos de café, originando menos desperdícios. A principal característica deste método consiste no facto da polpa ser extraída logo após a colheita das cerejas, não permitindo que estas sequem, como acontece na via seca [8]. Após a separação da maioria da polpa os grãos passam por canais de água. Os grãos mais leves flutuam enquanto os mais maduros e pesados afundam. São também passados por tambores que os separam por tamanhos. Após a separação são colocados em tanques de fermentação para remover a cama lisa de mucilagem, posteriormente estes grãos são lavados e colocados a secar até atingirem aproximadamente 11% de humidade [26].

A via seca (Figura 2.10) é um método mais simples e menos dispendioso. Depois de colhidas, as cerejas são espalhadas sobre uma superfície de cimento, tijolo ou tapetes de palha e, preferencialmente, expostas aos raios solares. Periodicamente, as cerejas são revolvidas impedindo que haja a fermentação das mesmas. No caso de descidas de temperatura ou de ocorrência de chuva, estas devem de ser cobertas para sua proteção. Este processo de seca do grão é realizado até este possuir apenas 11% de humidade no grão [8].



Figura 2.10: Método da via seca [9]

2.3.3 Processamentos

Antes de ser exportado o café passa ainda por outras etapas de processamento.

Descascamento do café, este passa por uma máquina que procede à remoção da “parchment layer” (endocarp) do café processado pela via húmida. O descascamento do café processado pela via seca remove a casca total do café (exocarp, mesocarp e endocarp).

Polimento, este é um processo opcional em que uma máquina remove qualquer pele remanescente no grão. Embora os grãos polidos sejam considerados superiores aos não polidos, existe pouca diferença entre os dois.

Classificação, esta é feita por tamanho e peso do grão, sendo também detetados grãos com falhas de cor e imperfeições. A separação dos grãos por tamanho é realizada com recurso a telas perfuradas, relativamente ao peso estes são separados por um jato de ar.

O tamanho dos grãos é representado numa escala entre 10 a 20, o número representa o tamanho do diâmetro de um orifício redondo de 1/64 polegada. Um grão numero 10 teria o tamanho de aproximadamente 10/64 polegadas de diâmetro. O grãos defeituosos são removidos com recurso a máquinas ou manualmente, garantindo assim que apenas o café de melhor qualidade é exportado [26].

2.4 Alterações no grão durante o processo de torrefação

Durante o processo de torrefação o café passa por transformações físicas e químicas (Figura 2.11) para se tornar no café que conhecemos. O processo de torrefação pode ser dividido em etapas sendo estas secagem, reação Maillard, primeira racha, caramelização, segunda racha.



Figura 2.11: Do café verde ao torrado [10]

2.4.1 Secagem

Esta etapa inicia-se imediatamente após a entrada dos grãos no torrador previamente aquecido. Na entrada do torrador, os grãos encontram-se à temperatura ambiente, absorvendo cerca de metade da temperatura do torrador. Nesta fase endotérmica do grão este inicia a alteração das suas características. A principal transformação é o aumento do volume do grão derivada da passagem de água para vapor, perda de massa bem como alteração da cor verde para amarela. Uma fase de secagem demasiado rápida pode levar a que a temperatura interna do grão não seja uniforme e um aumento do risco de queimar o grão, por outro lado uma secagem demasiado lenta provoca uma torra pouco desenvolvida resultando em grãos com sabor amargo e terroso.

2.4.2 Reação de Maillard

Tal como o nome indica, nesta fase ocorre uma reação chamada Maillard, é uma reação desencadeada pelo calor entre amino ácidos e açúcares que produzem o escurecimento e dão ao café a sua cor e sabores. Nesta fase o café expande o que leva a que a sua casca comece a partir e a separar-se do café. Esta casca como representa um elevado risco de incêndio, leva a que no torrador possua constantemente ar quente a passar pelos grãos de forma a transportar a casca para o respetivo coletor.

2.4.3 Primeira racha

Durante o processo de torrefação, o grão acumula gases e vapor de água no seu interior e quando a pressão é libertada é possível ouvir um pequeno estouro semelhante ao das pipocas no entanto mais baixo. No final desta etapa o grão já torrou o suficiente para produzir café, no entanto cabe ao responsável da torra decidir qual o ponto de torrefação que pretende.

2.4.4 Caramelização

Nesta fase os açúcares e ácidos são caramelizados levando a uma redução no sabor e acidez consoante o tempo a que o grão se mantém a torrar após a primeira racha. O grão adquire uma cor mais escura e a sua superfície torna-se mais suave.

2.4.5 Segunda racha

No final da fase de caramelização o grão torna a estourar, desta vez mais silenciosamente, o que significa que a estrutura do grão se encontra a quebrar. O grão escurece ainda mais e óleos aparecem na superfície do mesmo deixando-o mais brilhante. Neste ponto o café deixa o seu sabor e aroma no óleo libertado, sendo, no entanto, um café bastante amargo, este ponto de torra é conhecido como torra francesa ou italiana.

2.5 Tipos de torras

Apesar do tipo e qualidade do grão, o processo de torrefação proporciona o aroma e sabor que o grão de café possui. A duração do processo de torrefação afeta vários parâmetros, tais como, corpo, acidez e sabor dos grãos de café.

Existem quatro tipos de torra do café, representadas na Figura 2.12, torra clara, torra média, torra média-escura e torra escura. Cada um destes tipos possui diferente aroma, aspeto e sabor.



Figura 2.12: Os 4 graus de torra [11]

2.5.1 Torra clara

A torra clara (Figura 2.13) é o grau de torra onde a torrefação é a mais rápida. Durante o processo de torrefação os grãos atingem temperaturas internas entre 180 °C e 205 °C, imediatamente após a primeira racha.

Geralmente estes grãos não possuem os óleos pois não foram torrados a uma temperatura suficientemente alta para a libertação dos mesmos. Quanto mais tempo os grãos de café se encontram a torrar, mais o calor remove a cafeína e a acidez do mesmo, o que leva a que, este tipo de torra, proporcione ao café uma maior quantidade de cafeína bem como um perfil mais ácido. As torras claras possuem um perfil de sabor diferente, pelo facto de ser uma torra curta levando a que certas alterações químicas não ocorram. Os sabores originais do grão são mais reconhecíveis neste tipo que nos restantes. A acidez acompanhada com notas cítricas são características deste tipo de café [11].



Figura 2.13: Grãos de café de torra clara [11]

2.5.2 Torra média

O café de torra média (Figura 2.14) atinge temperaturas internas entre 210 e 220 °C. Isto é depois da primeira rachadura e pouco antes da segunda ocorrer. Eles têm um pouco mais de corpo do que um assado leve e menos acidez.

Esta torra possui sabores equilibrados, a acidez e o corpo deste tipo de café possuem intensidade média. Alguns exemplos e cafés de torra média são: House Blend, Breakfast roast e American Roast [11].



Figura 2.14: Grãos de café de torra média [11]

2.5.3 Torra média-escura

Os grãos submetidos a torra média-escura (Figura 2.15) durante o processo atingem temperaturas internas entre 225 e 230 °C. Isto é durante ou depois da segunda rachadura.

Esta torra faz com que o óleo comece a aparecer na superfície dos grãos de café derivado das altas temperaturas atingidas. Os sabores são mais ricos e cheios, com um maior corpo e menor acidez [11].



Figura 2.15: Grãos de café de torra média-escura [11]

2.5.4 Torra escura

A temperatura interna dos grãos da torra escura (Figura 2.16) atinge entre os 240 e os 250 °C. Os grãos possuem óleos visíveis na sua superfície, tipicamente neste grau de torra não é possível sentir qualquer sabor original dos grãos.

A torra escura possui um sabor doce, pois os açúcares nos grãos tiveram tempo de caramelizar. Quanto mais longo for o processo de torrefação mais facilmente é desenvolvido um sabor rico e um corpo completo, que normalmente leva a um acabamento amanteigado. Este café possui a menor acidez bem como a menor quantidade de cafeína. A torra francesa é considerada a torra mais escura possuindo um sabor esfumaçado. Caso a torra possua uma duração superior à da torra francesa os óleos e açúcares presentes nos grãos começam a queimar. Geralmente as torras escuras possuem nomes europeus pela sua popularidade na Europa [11].



Figura 2.16: Grãos de café de torra escura [11]

2.6 Tipos de torradores

Atualmente existem torradores de café domésticos e torradores industriais, encontrando-se representados na Figura 2.17. Os torradores domésticos apresentam capacidades de torração baixas e o controlo é limitado. Os torradores industriais são mais complexos e possuem uma maior capacidade.

Os torradores industriais podem ser encontrados divididos em 3 categorias, manuais (o torrador é totalmente manuseado por um operador) semiautomáticos (o torrador tanto pode funcionar em modo automático, controlo por perfil, ou manuseado por um operador) e automáticos (o torrador funciona totalmente em modo automático).

Existem vários tipos de torradores, no entanto todos possuem construções semelhantes. Os elementos presentes nos torradores de seguida apresentados podem variar consoante o tipo de torrador, capacidade e fabricante do mesmo.

2.7 Constituição dos torradores industriais

Os torradores industriais (representado na Figura 2.18) são geralmente constituídos por Hopper de alimentação, tambor de torra, coletor de partículas, fonte de aquecimento e tabuleiro de arrefecimento.

2.7.1 Hopper de alimentação

Compartimento para os grãos de café verdes, também designado de Hopper de alimentação, representado na Figura 2.19.

Este componente tem como funcionalidade carregar o torrador com o café verde.



(a)



(b)

Figura 2.17: (a)Torrador doméstico [28]; (b)Torrador industrial [29]




Figura 2.18: Diagrama de um torrador industrial [12]

Para iniciar a torra, a válvula presente no Hopper muda de posição fechando a exaustão do ar, e consequentemente, permite a queda dos grãos para o tambor do torrador.

Finalizada a carga do mesmo a válvula troca de posição permitindo a exaustão do ar e fechando a ligação entre o Hopper e o torrador.



Figura 2.19: Hopper de alimentação [13]

2.7.2 Tambor de torra

O tambor de torra (Figura 2.20) é onde o café se encontra durante o processo de torrefação. Para fazer com o café seja torrado uniformemente o tambor possui pás giratórias que fazem com que o café seja revolido durante o processo de torrefação.

2.7.3 Coletor de partículas

O coletor de partículas (Figura 2.21) é utilizado para remover as cascas e pó durante o processo de torrefação. A remoção das cascas e pó é feita durante o processo de torrefação visto que estas representam um elevado risco de incêndio.

2.7.4 Fonte de aquecimento

A fonte de aquecimento pode variar consoante o tipo, tamanho e fabricante do torrador, no entanto apresentam todos a mesma funcionalidade. Este componente é responsável pelo aquecimento dos grãos de café.

A transferência de calor nos torradores geralmente pode ser feita de 3 formas diferentes:


- Transferência por condução: Ocorre através do contato físico do grão com a parede aquecida do tambor de torra.



Figura 2.20: Tambor de um torrador [14]



(a) Fotografia [30]



(b) Desenho [31]

Figura 2.21: Coletor de partículas

- Transferência por convecção: Este tipo de transferência ocorre através do aquecimento do ar na parte inferior do tambor, este ar aquecido sobe e o ar mais frio de cima desce, ocorrendo um processo circular. Geralmente os tambores de torra são perfurados para aumentar a eficácia deste tipo de transferência, considerada a mais eficiente.
- Transferência por radiação: Ocorre por meio de ondas eletromagnéticas, é uma fonte secundária de calor.

2.7.5 Tabuleiro de arrefecimento

O tabuleiro de arrefecimento (Figura 2.22) tem como função arrefecer o café após a torra, este arrefecedor possui um ventilador na parte inferior que suga o ar do tabuleiro perfurado. O café após a torra é despejado para o tabuleiro perfurado onde este é arrefecido com o auxílio de pás giratórias que mexem o café para este arrefecer de uma forma mais uniforme e rápida.



Figura 2.22: Tabuleiro de arrefecimento [15]

2.8 Controlo da torra

Para controlar o ponto de torra pretendido são utilizadas duas técnicas de controlo, controlo por cor/visual ou controlo por perfil.

O controlo por cor/visual consiste no acompanhamento da evolução da cor do grão do café por parte do mestre torrador usando um coletor de amostras (Figura 2.23). Quando o café atinge a coloração pretendida este interrompe a torra. Neste tipo de controlo podem ocorrer variações no ponto de torra devido a interferências na deteção da cor do grão por parte do olho humano. Essas interferências

podem depender da diferença de luminosidade, claridade do dia e diferença de visão entre pessoas.





Figura 2.23: Coletor de amostras de um torrador [12]

O controlo da torrefação por perfil é uma técnica mais moderna e precisa que proporciona maior reprodutibilidade de um determinado ponto de torra. Perfil de torra é o gráfico que descreve a temperatura em relação ao tempo de torra (Figura 2.24).



(a) manual [32]



(b) automático [33]

Figura 2.24: Controlador de um torrador

2.9 Processo de torrefação

Para iniciar a torra, o torrador necessita de ser pré-aquecido, o elemento de aquecimento é ligado bem como os sistemas e exaustão de gases. Estando o torrador na temperatura pretendida o café é transferido do Hopper de alimentação para o tambor de torra.

Durante a torrefação é necessário ajustar a potência do elemento de aquecimento, do ventilador e a posição da válvula de exaustão de forma a manter a temperatura do grão conforme o pretendido.

Após o término da torra a porta do torrador abre e o café é transferido para o tabuleiro de arrefecimento, neste os motores iniciam o funcionamento rodando as pás e a aspiração do ar.

Capítulo 3

Inteligência Artificial

Neste capítulo é abordada a AI. Primeiramente é realizada uma breve definição da AI, seguindo-se da história do aparecimento e evolução da mesma. Seguidamente apresenta-se que tipos de AI existem e quais as aplicações atuais. É explicado o conceito de ML e os seus respetivos tipos, bem como, explicação do DL. Está também presente no capítulo uma descrição das NN referindo as funções de ativação utilizadas, assim como uma explicação das Redes Neurais Recorrentes (*RNN-
Recurrent Neural Networks*) e *Long Short-Term Memory* (LSTM). Finalmente é esclarecida a diferença entre DL e NN.

3.1 Definição

Inteligência artificial é a ciência e engenharia de criar máquinas inteligentes, especialmente programas computacionais. Esta está relacionada com a tarefa de usar computadores para entender a inteligência humana, no entanto AI não tem necessariamente que se confinar a métodos que são biologicamente observáveis. Inteligência pode ser definida como sendo a parte computacional da habilidade de atingir objetivos no mundo. Vários tipos e graus de inteligência existem em pessoas, vários animais e em algumas máquinas [34].

Décadas antes desta definição, o nascimento da AI foi denotado pelo trabalho de Alan Turing (Figura 3.1), "Máquinas de Computação e Inteligência", publicado em 1950. Neste artigo, Turing, argumenta que se uma máquina conseguisse pretender com sucesso ser um humano para com um determinado observador, esta poderia ser

considerada inteligente. Este teste é denominado teste de Turing. Durante o teste o observador interage com a máquina e com um humano por *teletype* (de forma a que a máquina não tenha de imitar a aparência ou voz de um humano), o humano e a máquina tentariam persuadir o observador de que eram humanos. Apesar de este teste satisfazer a maioria das pessoas, os filósofos continuavam cépticos [34][35].




Figura 3.1: Alan Turing [16]

Stuart Russell e Peter Norvig publicaram "Artificial Intelligence: A Modern Approach", tornando-se um dos principais livros didáticos no estudo da AI. Neste a AI é dividida em quatro objetivos ou definições, que diferencia sistemas computacionais com base na racionalidade e no pensamento contra atuação.

Abordagem humana:

- Sistemas que pensam como humanos
- Sistemas que agem como humanos

Abordagem ideal:

- Sistemas que pensam racionalmente
- Sistemas que agem racionalmente

Na sua forma mais básica, AI é um campo, que combina ciência computacional e conjuntos de dados robustos, para permitir a resolução de problemas. Também engloba sub-campos de ML e DL, normalmente mencionados em conjunto com a AI. Estas disciplinas são compostas por algoritmos de AI que procuram criar sistemas capazes de efetuar predições e classificações baseada em dados de entrada.

3.2 História da inteligência artificial

A identificação precisa do nascimento da AI é difícil, no entanto, o seu início pode ser remetido aos anos 40, mais precisamente a 1942, quando Isac Asimov, escritor de ficção científica publicou a sua história "Runaround" (Figura 3.2). Em 2004 foi realizado um filme baseado nesse livro chamado "I Robot".




Figura 3.2: Livro Runaround de Isac Asimov [17]

Na mesma época, o matemático inglês Alan Turing trabalhou em questões menos fictícias desenvolvendo uma máquina para quebrar códigos, chamada The Bombe, usada pelo governo Britânico com o objetivo de decifrar o código Enigma usado pelo exército alemão durante a segunda guerra Mundial. The Bombe foi considerado o primeiro computador eletro-mecânico funcional, pesando cerca de uma tonelada. O código Enigma com esta máquina passou a ser possível de decifrar, tarefa esta previamente impossível mesmo pelos melhores matemáticos, o que levou Turing a indagar-se sobre a inteligência destas máquinas. Em 1950 Turing publicou o artigo "Computing Machinery and Intelligence" onde descreve como criar máquinas inteligentes e como testar a sua inteligência. A forma de testar as máquinas é designada de teste de Turing sendo ainda atualmente considerado um marco para a identificação da inteligência de um sistema artificial.

A expressão inteligência artificial foi oficialmente aceite em 1956 quando Marvin Minsky e John McCarthy lecionaram o *Dartmouth Summer Research Project on Artificial Intelligence* (DSRPAI) no Dartmouth College em New Hampshire. Este *workshop* reuniu as pessoas que mais tarde foram consideradas os pais da AI. Sendo o cientista da computação Nathaniel Rochester, que mais tarde projetou o IBM 701,

o primeiro computador científico comercial, e o matemático Claude Shannon, que fundou a teoria da informação. O objetivo do DSRPAI era reunir investigadores de diversas áreas para criar uma nova área de pesquisa orientada para a construção de máquinas capazes de simular inteligência humana.

Os dois anos posteriores, foram de bastante sucesso no ramo da AI. Um dos exemplos é o programa de computador ELIZA (Figura 3.3), criado entre 1964 e 1966 por Joseph Weizenbaum no MIT. ELIZA era uma ferramenta de processamento de linguagem natural capaz de simular uma conversa com um humano sendo um dos primeiros programas capazes de passar no teste de Turing. O programa "General Problem Solver" foi desenvolvido pelo Herbet Simon, vencedor de um prêmio Nobel, e por cientistas da Rand Corporation, nomeadamente, Clif Shaw e Allen Newell. Este programa era capaz de resolver automaticamente problemas simples, tal como Towers of Hanoi.




Figura 3.3: ELIZA [18]

EM 1967 Frank Rosenblatt constrói o Mark 1 Perceptron, sendo o primeiro computador baseado em redes neurais em que o seu método de aprendizagem era realizado por tentativa e erro. Apenas um ano depois, Marvin Minsky e Seymour Papert publicam o livro "Perceptrons", tornando-se uma referência para redes neurais e, por um período de tempo, um argumento contra futuros projetos de investigação de redes neurais [35].

Estes sucessos, bem como a argumentação de pesquisadores de renome (nomeadamente os participantes do DSRPAI) convenceram agências governamentais, como a *Defense Advanced Research Projects Agency* (DARPA) a financiar a investigação de AI em várias instituições (Figura 3.4). O governo estava particularmente interessado numa máquina com a capacidade de transcrever e traduzir a linguagem falada, bem como uma elevada capacidade de processamento de dados. O otimismo era alto e as expectativas eram ainda maiores.



Figura 3.4: DARPA [19]

Em 1970, Marvin Minsky deu uma entrevista à Life Magazine na qual afirmou que uma máquina com a inteligência geral de um ser humano médio poderia ser desenvolvido dentro de três a oito anos. No entanto apenas 3 anos depois, no ano 1973, o congresso dos EUA criticou fortemente os gastos elevados na investigação da AI. No mesmo ano, James Lighthill, matemático britânico, publicou um relatório pelo British Science Research Council no qual indagava a perspectiva otimista dos investigadores da AI. Este afirmou que as máquinas apenas iriam atingir um nível de experiência amadora em jogos como o xadrez e que a capacidade de raciocínio relativamente ao bom-senso estaria além das suas habilidades. Em resposta o governo britânico extinguiu o suporte para investigação de AI exceto em 3 universidades, nomeadamente, Edinburgh, Sussex, e Essex. O governo americano logo seguiu o exemplo britânico. Estas ações iniciaram o Inverno da AI, período em que a sua investigação ficou em pausa. Apesar de, em 1980, o governo japonês investir em massa na investigação de AI, e de a DARPA americana aumentar os fundos para a investigação, não foram realizados avanços nos anos consecutivos.

Uma razão para a falta de progresso inicial na AI e o facto da realidade não corresponder às expectativas reside na forma de como os primeiros sistemas, tais como ELIZA e General Problem Solver, tentaram replicar a inteligência humana. Estes eram todos *expert systems*, ou seja, conjuntos de regras que assumem que a inteligência humana pode ser descrita e reconstruída numa forma linear como uma série de condições "if-then". Os *expert systems* podem funcionar com uma elevada precisão em certas áreas o que pode levar a serem considerados sistemas inteligentes. Um exemplo é o programa de jogo de xadrez Deep Blue da IBM (Figura 3.5), onde em 1997 foi capaz de derrotar o campeão mundial Gary Kasparov revelando ser um fantástico *expert systems*. Este jogo provou que uma das declarações realizadas por James Lighthill 25 anos antes estava errada. O Deep Blue era capaz de processar 200 milhões de movimentos possíveis por segundo e capaz de determinar o próximo movimento ótimo prevendo os 20 movimentos seguintes usando um método denominado pesquisa em árvore.



Figura 3.5: Deep Blue [20]

No mesmo ano, foi desenvolvido pela Dragons systems um *software* de reconhecimento de fala que posteriormente foi implementado no Windows. Este foi mais um grande avanço no esforço da interpretação da língua falada. Foi também desenvolvido um robô por Cynthia Breazeal, com capacidade de reconhecer e exibir emoções humanas [36].

Apesar da popularidade dos *experts systems* a eficiência destes em problemas não formalizados é muito baixa. Um exemplo onde os *expert systems* não podem ser facilmente treinado é no reconhecimento facial, ou de distinção de imagens. Para tal é necessário que o sistema possua capacidade de interpretar dados externos, aprender com os mesmos e utilizar a aprendizagem de forma a alcançar determinados objetivos e tarefas através de adaptação flexível, sendo estas características que definem a AI.

Os métodos estatísticos para alcançar a verdadeira AI já tinham sido discutidos nos anos 40, quando Donal Hebb, psicólogo Canadano, desenvolveu uma teoria de aprendizagem denominada Hebbian Learning que consiste no processo de replicação do funcionamento dos neurónios no cérebro humano. Esta levou ao início da investigação sobre Redes Neurais Artificiais. O trabalho em redes neurais acabou por estagnar em 1969 quando Marvin Minsky e Seymour Papert demonstraram a falta de poder de processamento dos computadores da altura para poderem lidar com a carga de trabalho exigido pelas redes.

As redes neurais retornaram sob a forma de DL em 2015 com AlphaGo, programa desenvolvido pela Google, em que este foi capaz de superar o campeão mundial no jogo de tabuleiro Go. Este jogo é extremamente complexo, no xadrez existem

apenas cerca de 20 movimentos para abertura de jogo, enquanto que, no Go existem 361. Durante muito tempo acreditou-se que nenhum computador teria a capacidade de vencer um humano neste jogo.

3.3 Tipos de AI

A AI pode ser dividida em 2 tipos.

A AI fraca, também chamada de *Narrow AI* ou *Artificial Narrow Intelligence* (ANI), é treinada e focada para executar tarefas específicas. A AI fraca impulsiona a maior parte da AI implementada atualmente. O descritivo 'Narrow' pode ser mais adequado para este tipo de AI. Esta AI não é fraca de todo, ela é capaz de ser usada em aplicações bastante robustas, tais como Siri da Apple, Alexa da Amazon, IBM Watson e veículos autônomos [35].

A AI forte é composta por *Artificial General Intelligence* (AGI) e *Artificial Super Intelligence* (ASI). A AGI é uma AI teórica onde uma máquina teria uma inteligência igual a humanos, seria auto-consciente, tendo a capacidade de resolver problemas, aprender e planejar o futuro. A ASI, também conhecida como super-inteligência, superaria a inteligência e a capacidade do cérebro humano. Embora a AI forte ainda seja inteiramente teórica e atualmente sem exemplos práticos, a pesquisa e desenvolvimento da mesma continua nos interesses dos investigadores [35].

3.4 Aplicações da Inteligência Artificial

Atualmente vivemos na era do "big data", onde elevadas quantidades de dados são adquiridas. A aplicação da AI para o processamento de elevadas quantidades de dados já demonstrou ser bastante produtiva em diversos setores. Uma das principais aplicações da AI é *software* de AI, ou seja, programas de computador que usam vários mecanismos para simular o comportamento humano pela aprendizagem de vários padrões de dados. Existem quatro tipos principais de *software* de AI:

- Plataformas de AI: Fornecem ferramentas e ambientes para o desenvolvimento de *software* de AI, tais como, algoritmos embutidos, modelos e ferramentas "drag-and-drop".
- Chatbots: Programas de conversação AI com o objetivo de realizar um diálogo realista em tempo real com o utilizador.
- Aplicações ML: programas generalizados capazes de aprender com dados e interações com *software* anteriores.
- Aplicações DL: Programas que efetuam reconhecimento de fala, imagem e outras funções complexas, baseadas em algoritmos complexos.

Exemplos de *software* de AI para os mercados empresariais e consumidores são: Cortana, Google assistant, H2O.AI, Masdima e Sisense.

Estes exemplos do uso de AI, são apenas uma amostra do volume total de aplicações existentes na atualidade. Atualmente, em diversos setores é possível notar o uso de AI, tais como, transportes, finanças, saúde, educação, produção e planejamento urbano. Nos transportes, sistemas como o Google Maps têm a capacidade de analisar a velocidade e movimento do trânsito a qualquer momento, incorporando relatos de incidentes de trânsito, como obras ou acidentes. Na indústria são implementados sistemas de manutenção preditivos e preventivos, de forma a reduzir os períodos de inatividade, também são incorporados sistemas de controle de qualidade AI que melhoram a produção. A AI e ML desempenham um papel extremamente importante no processo de pagamentos, depósito de cheques móveis, seguro e recomendações de opções de investimento. A prestação e administração dos cuidados de saúde foram melhorados com a implementação de AI e *smart conectad systems*, através de diagnósticos remotos e tele-medicina. Na educação a leitura automatizada de documentos, classificação e plágio reduziu bastante a carga de trabalho dos professores. Nas urbanizações, o desenvolvimento das tecnologias "smart city" vieram melhorar o controle de tráfego, gestão de resíduos e outros serviços essenciais.

3.5 Machine Learning

Machine learning é um subcampo da AI, tal como representado na Figura 3.6, com a capacidade de aprender com dados sem ser explicitamente programados. Evuindo a partir do estudo do reconhecimento de padrões e da teoria de aprendizagem computacional na AI, o *Machine Learning*, explora o estudo e a construção de algoritmos capazes de aprender e fazer previsões usando dados[37].

Machine Learning usa uma variedade de algoritmos que aprendem constantemente com dados de forma a melhorar, descrever dados e prever resultados. À medida que os algoritmos recebem dados de treino, é então possível criar modelos mais precisos baseados nesses dados. Um modelo de ML é a saída gerada do treino do algoritmo com os dados [21].

Atualmente é altamente provável a utilização de aplicações baseadas em algoritmos de ML sem saber. Um exemplo, é nos *sites* de *e-commerce*, quando um utilizador vê produtos e avaliações é muito provável que seja apresentado com produtos semelhantes que possa considerar interessantes. Estas recomendações não são programadas por um exército de programadores, mas sim criadas por um modelo de ML. Este modelo recebe o histórico de pesquisa dos utilizadores e compras realizadas com o objetivo de apresentar produtos que o utilizador possa ter interesse em comprar [21].




Figura 3.6: Subcampos da AI [21]

3.5.1 Tipos de Machine Learning

Tipos de ML são necessárias para melhorar a precisão dos modelos preditivos. Dependendo da natureza do problema, existem diferentes métodos a ser aplicados consoante o tipo e quantidade de dados. Os dois tipos de ML mais utilizados são: *supervised learning* e *unsupervised learning*. O tipo *supervised learning* é utilizado por cerca de 70% dos algoritmos, *unsupervised learning* tem uma utilização entre os 10 e os 20%. Os tipos *Semi-supervised* e *reinforcement learning* são usados ocasionalmente. De seguida será apresentada a explicação para cada tipo referido.

- *Supervised learning*: são algoritmos onde os dados utilizados para o treino são legendados, tal como, uma entrada onde a saída desejada é conhecida. O algoritmo em treino recebe um conjunto de entradas juntamente com as correspondentes saídas corretas, este aprende comparando a sua saída real com as saídas corretas para encontrar erros. Modificando o algoritmo, através de métodos como classificação, regressão, previsão e aumento de gradiente, a aprendizagem supervisionada utiliza padrões para prever a legenda dos dados não catalogados. Esta é normalmente utilizada em aplicações que com o histórico de dados prevêem prováveis eventos futuros.
- *Unsupervised learning*: são algoritmos onde os dados utilizados para o treino não possuem qualquer tipo de legenda, tendo este que descobrir que dados é que está a receber. O objetivo é explorar os dados e encontrar alguma estrutura nos mesmos. A aprendizagem não supervisionada funciona bem com dados transacionais. Por exemplo, pode identificar segmentos de clientes com atributos semelhantes que podem depois ser tratados de forma semelhante em campanhas de *marketing*. Ou pode encontrar os principais atributos que separam segmentos de clientes uns dos outros.

- *Semi-supervised learning*: neste tipo de algoritmos são usados tantos dados legendados como não legendados para o treino, normalmente neste tipo a quantidade de dados legendados é baixa pelo facto de estes serem mais dispendiosos e difíceis de obter face aos não legendados. Este tipo de algoritmos pode ser utilizado com métodos tais como classificação, regressão e previsão. Este método é útil quando o custo da legendagem (rotulação-catalogação) dos dados é demasiado elevado.
- *Reinforcement learning*: neste tipo de algoritmos o treino é baseado numa aprendizagem de reforço, ou seja, tentativa e erro. Este tipo de algoritmo é bastante utilizado na robótica, jogos e navegação. Ao invés de ser fornecido ao algoritmos pares de entradas e saídas, é apenas indicado o estado atual do sistema, qual o objetivo pretendido, uma lista das potenciais soluções bem como as restrições que cada resultado possui. O modelo é deixado a treinar, por tentativa e erro, até alcançar o seu objetivo de forma a maximizar a recompensa.

3.6 Deep Learning

Deep Learning é um subconjunto de ML, tal como representado na Figura 3.6, esta incorpora redes neurais em camadas sucessivas, com o objetivo de aprender iterativamente com os dados. DL é especialmente útil para a aprendizagem de padrões em dados não estruturados [21]. DL também designado de *complex neural networks*, são algoritmos desenvolvidos com o objetivo de simular o funcionamento do cérebro humano de forma a que os computadores possam ser treinados de forma a possuírem as capacidades necessárias para lidar com abstrações e problemas mal definidos [21].

DL utiliza uma cascata de unidades de processamento não lineares de múltiplas camadas para a extração e transformação de características. As camadas mais baixas, junto dos dados de entrada aprendem características simples, enquanto que as camadas mais altas, junto da saída aprendem características mais complexas [38].

3.7 Redes Neurais

As NN, também conhecidas como *Artificial Neural Networks* (ANN), procuram replicar o funcionamento do cérebro humano através de um conjunto de algoritmos. Tal como o cérebro humano é constituído por neurónios, as NN são compostas pelo equivalente matemático de um neurónio que se encontra representado na Figura 3.7. O neurónio é composto pelas entradas e os respetivos pesos, pelo *bias*, pela função de ativação e pela saída [39].




Figura 3.7: Neurónio artificial [22]

A representação matemática do neurónio artificial pode ser realizada de acordo com as equações (3.1) e (3.2).

$$\sum_{i=1}^m w_{ki}x_i = w_{k1}x_1 + w_{k2}x_2 + \dots + w_{km}x_m \quad (3.1)$$

$$y_k = \varphi\left(\sum_{i=1}^m w_{ki}x_i + b_k\right) \quad (3.2)$$

Uma camada de uma NN é constituída por múltiplos neurónios distribuídos verticalmente, tal como representado na Figura 3.8.




Figura 3.8: Camada de NN [22]

Para determinadas aplicações, uma NN de apenas uma camada não é suficiente, pelo que é necessário múltiplas camadas de neurónios. A disposição e ligação entre camadas encontra-se representada na Figura 3.9.




Figura 3.9: NN de múltiplas camadas [22]

3.7.1 Funções de ativação

A função de ativação, representada por $\varphi()$ na Figura 3.7, é usada com a finalidade de simular a resposta de um neurónio biológico. As funções de ativação podem ser divididas em 2 categorias, as funções lineares e as funções não-lineares. Uma função de ativação é escolhida de forma a resolver certas especificações do problema que o neurónio se encontra a tentar resolver. Na Figura 3.10 encontra-se uma tabela com algumas das funções de ativação mais utilizadas.

Name	Input/Output Relation	Icon	MATLAB Function
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Linear	$a = n$		purelin
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Symmetric Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$		logsig
Hyperbolic Tangent Sigmoid	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		poslin
Competitive	$a = 1 \quad \text{neuron with max } n$ $a = 0 \quad \text{all other neurons}$		compet

Figura 3.10: Funções de ativação[22]

3.7.2 Recurrent Neural Networks

As RNN, é um tipo de NN artificial que usa dados sequenciais ou dados de séries temporais. Este tipo de algoritmos são especialmente usados para problemas temporais ou normais, tais como tradutores, processadores de linguagem natural, reconhecimento da fala e processamento de imagem. Tal como outros tipos de redes, o treino das redes recorrentes são baseados em dados para a sua aprendizagem [23].

Este tipo de redes são distinguidas das demais pela sua capacidade de memória, estas têm em conta informações obtidas de entradas anteriores para influenciar a saída da entrada atual. Enquanto que as NN tradicionais assumem que as entradas e saídas são diferentes umas das outras, as saídas das RNN dependem de elementos

anteriores da sequência. Apesar de os eventos futuros também serem úteis para a previsão da saída de uma determinada sequência, as RNN unidirecionais não possuem tal capacidade [23].

Tipos de RNN

Existem vários tipos deste algoritmo em que a quantidade de entradas e saídas varia, bem como a forma com que estas se interligam entre si e com as camadas da rede. Os diferentes tipos de RNN são geralmente representados pelos diagramas nas Figuras 3.11, 3.12 e 3.13 [23].



Figura 3.11: RNN *One-to-one* [23]





Figura 3.12: (a) RNN *Many-to-One*; (b) RNN *One-to-many* [23]

Figura 3.13: RNN *Many-to-many* [23]

3.7.3 Long Short-term Memory

A rede neuronal LSTM é uma derivação da RNN. Este tipo de redes são usadas em situações em que o algoritmo necessita de ter memória e relembrar acontecimentos passados. Para tal as LSTM possuem células nas camadas, que contêm três *gates*, uma *gate* de entrada, uma de saída e uma de esquecimento. Estas *gates* controlam o fluxo de informação necessário para prever a saída da rede [23].




Figura 3.14: Camada de uma LSTM [23]

3.8 Diferenças entre Deep Learning e Redes Neurais

Os termos DL e NN tendem a ser utilizados de uma forma permutável, o que normalmente leva a dúvidas relativamente às suas diferenças. De notar que o termo "deep" em *Deep Learning* se refere apenas à profundidade das camadas de uma NN. Uma NN que possua mais de três camadas, incluindo a de entrada e a de saída, pode ser considerada um algoritmo de DL. Caso seja uma NN com apenas duas ou três camadas é considerada uma NN básica [39].

Capítulo 4

Implementação de Redes Neuronais em MATLAB

Neste capítulo será abordada a implementação das redes neuronais em MATLAB. Inicialmente é referido como é que se obtiveram os dados utilizados seguido de como se concretizou o processo de tratamento dos mesmos. Posteriormente é tratado o processo de implementação das redes neuronais, foram implementadas 3 redes diferentes sendo que para cada uma foram realizados testes preliminares de forma a escolher a rede mais adequada ao problema.

4.1 Dados

Os dados recolhidos para o treino das redes é realizado pelo Brigus. O Brigus é um *software* desenvolvido pela empresa M de Máquina II .Lda que corre no sistema operativo Windows. Este *software* tem como funcionalidade a criação, edição e gestão das receitas de torrefação de café, a obtenção de dados de certos elementos do torrador durante os processos de torrefação e o envio dos dados necessários para o PLC do torrador controlar o mesmo para a torra pretendida. Os dados recolhidos pelo torrador durante o processo de torrefação são: tempo, temperatura do grão, temperatura do ar de exaustão, potência do queimador, potência do ventilador e o *Rate Of Rise* (ROR). Os dados recolhidos são armazenados na base de dados do programa.

Os dados utilizados neste projeto foram exportados de uma base de dados de uma fábrica. Os dados encontram-se em formato .csv sendo que cada ficheiro é relativo a uma torra. Na Figura 4.1 encontra-se representado um ficheiro de dados, no total a base de dados possui cerca de 1224 ficheiros.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	Encoding: System.Text.SBCSCodePageEncoding													
2	INSTANT; BEAN (°C); ROR (°C/min); BURNER (%); FAN (%); AIR (°C)													
3	00:00:01; 189.4; 20; 40; 174.3													
4	00:00:02; 188.6; 20; 40; 171.7													
5	00:00:03; 187.9; 20; 40; 169.1													
6	00:00:04; 187; 20; 40; 166.4													
7	00:00:05; 186.3; 20; 40; 163.9													
8	00:00:06; 186.4; 20; 40; 162.3													
9	00:00:07; 186.4; 20; 40; 161.8													
10	00:00:08; 186.5; 20; 40; 161.9													
11	00:00:09; 186.6; 20; 40; 162.5													
12	00:00:10; 186.6; 13; 40; 163.3													
13	00:00:11; 186.5; 11.7; 40; 164.2													
14	00:00:12; 186.4; 10.4; 40; 165.2													
15	00:00:13; 186.2; 9.2; 40; 166.1													
16	00:00:14; 186; 7.9; 40; 167													
17	00:00:15; 185.8; 6.7; 40; 167.7													
18	00:00:16; 185.7; 5.3; 40; 168.3													
19	00:00:17; 185.7; 4; 40; 168.9													
20	00:00:18; 185.5; 2.7; 40; 169.4													
21	00:00:19; 185.3; 1.4; 40; 169.8													
22	00:00:20; 185.1; 0.2; 40; 170.1													
23	00:00:21; 184.9; 0; 40; 170.3													
24	00:00:22; 184.6; 0; 40; 170.5													
25	00:00:23; 184; 0; 40; 170.6													
26	00:00:24; 183; 0; 40; 170.4													
27	00:00:25; 181.9; 0; 40; 170													
28	00:00:26; 181.1; 0; 40; 169.5													
29	00:00:27; 180.3; 0; 40; 168.9													
30	00:00:28; 179.4; 0; 40; 168.3													
31	00:00:29; 178.6; 0; 40; 167.6													
32	00:00:30; 177.8; 0; 40; 166.9													
33	00:00:31; 177.1; 0; 40; 166.3													
34	00:00:32; 176.3; 0; 40; 165.7													
35	00:00:33; 175.6; 0; 40; 165.2													
36	00:00:34; 175; 0; 40; 164.6													

Figura 4.1: Gráfico dos dados de um ficheiro removido

4.2 Tratamento dos Dados

Antes de os dados serem usados para treino das redes é necessário efetuar uma organização dos mesmos de forma a estarem no formato necessário. Inicialmente foi necessário realizar uma filtragem dos ficheiros, tendo em conta que a base de dados usada reflete todas as torras realizadas na fábrica, incluindo testes, calibração e torras manuais. Foi desenvolvido um *script* em Python, código no Anexo A.1, com a finalidade de separar os ficheiros baseados nas curvas de potência do queimador. A filtragem consistia na remoção dos ficheiros que na curva de potência do queimador possuísem valores constantes de potência durante 120 segundos consecutivos, com a exceção de quando a potência do queimador se encontra nos 100%. Na Figura 4.2 encontra-se apresentado o gráfico de um ficheiro removido.




Figura 4.2: Gráfico dos dados de um ficheiro removido

Na Figura 4.2 é possível observar que a linha vermelha, que neste caso representa a potência do queimador possui períodos, de potência de funcionamento constantes, elevados e que a temperatura do grão também possui uma curva anômala, o que permite concluir que estes dados não representam sequer um processo de torrefação. Com esta filtragem 224 ficheiros foram removidos, ficando 1000 ficheiros para o treino e teste das redes. Na Figura 4.3 é possível observar um gráfico de um ficheiro considerado correto, onde a curva de temperatura do grão e a curva de potência do queimador apresentam a forma correta.




Figura 4.3: Gráfico dos dados de um ficheiro utilizado

Após a filtragem é necessário organizar os dados e eliminar informações desnecessárias de forma a ser possível a utilização dos dados no treino das redes, esse

tratamento foi realizado no MATLAB. Foram criados 4 ficheiros para tratamento de dados.

No código presente no Anexo A.2 são lidos os ficheiros de dados, onde os dados relativos ao ROR e temperatura do ar de exaustão são removidos e os dados relativos ao tempo são formatados para segundos. É criada uma variável para os dados de entrada onde são colocados os dados tempo, potência do queimador e potência do ventilador, e outra para os dados de saída onde são colocados os dados relativos à temperatura do grão. Para o treino e teste das redes neuronais é então necessário dividir os dados, neste caso 15% dos dados serão usados para teste ficando os restantes 85% para o treino das redes. As variáveis com os dados presentes no *workspace* são posteriormente exportadas para uso futuro.

No código presente no Anexo A.3 a lógica de processamento de dados é igual ao anterior, referindo no entanto, que a escala de tempo neste caso é eliminada. Os dados de entrada são a potência do queimador e potência do ventilador e os dados de saída são a temperatura. Tal como no anterior os dados também são separados para treino e teste e posteriormente igualmente exportados.

O código presente no Anexo A.4 tem como funcionalidade uniformizar o tamanho de cada torra. Carregando os dados anteriormente tratados (dados resultantes do código nos Anexos A.2 e A.3), é adicionado a cada torra zeros no final de forma a que cada uma possua um tamanho de 1230. Tal como nos anteriores os dados são também exportados.

No código do Anexo A.5 é efetuado a normalização dos dados anteriormente tratados pelos 3 programas anteriormente referidos. A normalização dos dados segue a seguinte equação:

$$X_{norm} = \frac{X - \bar{x}}{\sigma} \quad (4.1)$$

Onde X é o valor atual, $\bar{x}$ é a média dos valores e σ é o desvio padrão. Neste caso para além dos dados necessários para o treino, os valores média e desvio padrão também são exportados pois são necessários para a desnormalização dos dados.

Os programas acima descritos geram os seguintes ficheiros de dados:

- Dados com tempo
- Dados sem tempo
- Dados com tempo uniformizados
- Dados sem tempo uniformizados
- Dados com tempo normalizados
- Dados sem tempo normalizados
- Dados com tempo uniformizados normalizados

- Dados sem tempo uniformizados normalizados

4.3 Implementação da rede

Para este projeto foram inicialmente analisados 3 tipos de redes neuronais implementadas no seu formato básico de forma a avaliar o desempenho de cada uma nesta situação. Após a avaliação da melhor rede para ser implementada, foram feitos diferentes treinos com diferentes parâmetros de forma a conseguir obter o melhor desempenho possível da mesma. O fluxograma da Figura 4.4 descreve o funcionamento geral do treino e teste das redes neuronais programadas.




Figura 4.4: Fluxograma geral das redes neuronais

Todas as redes foram programadas com a mesma ideologia base, diferenciando-se apenas pelos parâmetros de treino, parametrização da rede e treino da mesma. Inicialmente é executado o tratamento dos dados recorrendo às funções descritas no Capítulo 4.2, estas são apenas executadas uma vez no decorrer do programa. Cada programa tem a capacidade de efetuar vários treinos com diferentes parâmetros bem como com diferentes dados. Para tal, foram utilizados ciclos em que no primeiro são definidos os parâmetros de treino, ainda dentro deste, encontra-se outro ciclo para a seleção dos dados a utilizar. Com os parâmetros e dados definidos a rede é configurada, treinada e testada. Caso os dados usados para o treino e teste estejam normalizados é realizada a desnormalização dos mesmos. O cálculo do RMSE é realizado para cada um dos dados de teste, bem como, a média de todos os valores calculados, sendo todos estes valores exportados para um ficheiro Excel. No final são gerados os gráficos dos primeiros 4 dados de teste, cada gráfico possui 2 curvas, a curva original (curva azul) e a curva gerada pela rede (curva vermelha), bem como o respetivo valor de RMSE. Os gráficos e o valor médio do RMSE são exportados numa única imagem, estando na Figura 4.5 representado um exemplo.




Figura 4.5: Exemplo de imagem exportada com os gráficos relativos a um treino

Para cada parametrização é criada uma pasta para a exportação dos gráficos, o nome da imagem exportada é igual ao nome dos dados utilizados. O cálculo do RMSE é efetuado com recurso à seguinte expressão:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (p_i - r_i)^2}{n}} \quad (4.2)$$

Onde p_i representa os valores simulados pela rede, r_i os valores originais e n o número total de valores.

4.3.1 Avaliação do desempenho de diferentes tipos de redes neurais

Inicialmente foram testadas 3 redes neurais diferentes, sendo estas, Feed-Forward, NARX e LSTM.

Feed-Forward

As redes neurais Feed-Forward, são redes relativamente simples. Estas são geralmente constituídas pela camada de entrada, saída e camada escondida, tal como representada na Figura 4.6.




Figura 4.6: Estrutura de uma rede Feed-Forward

Para o treino desta rede, a parametrização baseou-se apenas no número de neurónios na camada escondida. No sentido de perceber a influência dos mesmos no desempenho da rede, foram treinadas com 5, 10, 15, 20 e 50 neurónios na camada escondida. Os dados utilizados foram apenas os dados uniformizados e os uniformizados normalizados, visto que a rede só aceita dados de treino com dimensões iguais. Tal como referido anteriormente o valor do RMSE foi calculado. De seguida são apresentadas as Tabelas 4.1 e 4.2 com os valores de RMSE obtidos.

Tabela 4.1: Valores RMSE Feed-Forward-Análise do tipo de dados

Dados Parâmetros		Dados com tempo normalizados	Dados sem tempo normalizados	Dados com tempo	Dados sem tempo	Dados com tempo uniformizados normalizados	Dados sem tempo uniformizados normalizados	Dados com tempo uniformizados	Dados sem tempo uniformizados
2	a	-	-	-	-	9.2224	33.942	13.3894	24.962
	b	-	-	-	-	7.3404	19.0611	8.325	18.8102
	c	-	-	-	-	4.7488	20.7524	8.6486	23.5663
	d	-	-	-	-	8.7062	30.8988	10.2821	35.324
	médio	-	-	-	-	8.0636	21.9589	10.9076	22.8323
3	a	-	-	-	-	8.1584	29.6941	6.5519	33.791
	b	-	-	-	-	6.2165	18.0746	5.0324	18.9853
	c	-	-	-	-	3.9397	21.5948	4.6554	19.0107
	d	-	-	-	-	8.9942	36.6382	8.5034	28.3606
	médio	-	-	-	-	7.6083	21.7864	7.3872	20.9842
4	a	-	-	-	-	6.7788	42.231	7.2114	38.1359
	b	-	-	-	-	5.7	18.1589	6.1447	18.4019
	c	-	-	-	-	3.6397	18.8987	3.7872	19.2025
	d	-	-	-	-	6.9176	27.0521	8.908	31.045
	médio	-	-	-	-	6.9665	20.6373	7.2114	21.1196
5	a	-	-	-	-	5.959	40.821	6.3561	40.9346
	b	-	-	-	-	5.7986	17.4195	5.3124	18.2554
	c	-	-	-	-	2.7737	18.7913	3.9916	19.9097
	d	-	-	-	-	6.9767	24.306	7.2277	24.4415
	médio	-	-	-	-	6.7477	20.3176	6.776	20.6048
6	a	-	-	-	-	4.2415	42.2265	4.7821	42.9823
	b	-	-	-	-	5.099	16.9822	5.3189	17.1258
	c	-	-	-	-	2.4303	17.8787	3.166	18.7117
	d	-	-	-	-	5.7505	19.9882	6.1455	23.3845
	médio	-	-	-	-	6.4047	19.5834	6.5008	19.663

Tabela 4.2: Valores RMSE Feed-Forward-Análise dos parâmetros

Dados Parâmetros		Dados com tempo normalizados	Dados sem tempo normalizados	Dados com tempo	Dados sem tempo	Dados com tempo uniformizados normalizados	Dados sem tempo uniformizados normalizados	Dados com tempo uniformizados	Dados sem tempo uniformizados
2	a	-	-	-	-	9.2224	33.942	13.3894	24.962
	b	-	-	-	-	7.3404	19.0611	8.325	18.8102
	c	-	-	-	-	4.7488	20.7524	8.6486	23.5663
	d	-	-	-	-	8.7062	30.8988	10.2821	35.324
	médio	-	-	-	-	8.0636	21.9589	10.9076	22.8323
3	a	-	-	-	-	8.1584	29.6941	6.5519	33.791
	b	-	-	-	-	6.2165	18.0746	5.0324	18.9853
	c	-	-	-	-	3.9397	21.5948	4.6554	19.0107
	d	-	-	-	-	8.9942	36.6382	8.5034	28.3606
	médio	-	-	-	-	7.6083	21.7864	7.3872	20.9842
4	a	-	-	-	-	6.7788	42.231	7.2114	38.1359
	b	-	-	-	-	5.7	18.1589	6.1447	18.4019
	c	-	-	-	-	3.6397	18.8987	3.7872	19.2025
	d	-	-	-	-	6.9176	27.0521	8.908	31.045
	médio	-	-	-	-	6.9665	20.6373	7.2114	21.1196
5	a	-	-	-	-	5.959	40.821	6.3561	40.9346
	b	-	-	-	-	5.7986	17.4195	5.3124	18.2554
	c	-	-	-	-	2.7737	18.7913	3.9916	19.9097
	d	-	-	-	-	6.9767	24.306	7.2277	24.4415
	médio	-	-	-	-	6.7477	20.3176	6.776	20.6048
6	a	-	-	-	-	4.2415	42.2265	4.7821	42.9823
	b	-	-	-	-	5.099	16.9822	5.3189	17.1258
	c	-	-	-	-	2.4303	17.8787	3.166	18.7117
	d	-	-	-	-	5.7505	19.9882	6.1455	23.3845
	médio	-	-	-	-	6.4047	19.5834	6.5008	19.663

As Tabelas 4.1 e 4.2 apresentadas foram formatadas condicionalmente segundo uma escala de cores de forma a facilitar a análise dos dados. Os números na primeira coluna à esquerda representam um índice que corresponde aos parâmetros de treino usados. Os parâmetros são apresentados na Tabela 4.3.

Tabela 4.3: Parâmetros para rede Feed-Forward

Índice	Parâmetros
2	Neurónios na Camada escondida= 5
3	Neurónios na Camada escondida= 10
4	Neurónios na Camada escondida= 15
5	Neurónios na Camada escondida= 20
6	Neurónios na Camada escondida= 50

A Tabela 4.1 foi formatada de forma a comparar os valores entre os tipos de dados usados. É possível visualizar duas colunas a verde, o que significa que esses dois tipos de dados, Dados com tempo uniformizados normalizados e Dados com tempo uniformizados, foram os dados que obtiveram valores de RMSE mais baixos, o que representa um desempenho superior da rede. Entre os dois, os valores do RMSE relativos aos dados com tempo uniformizados normalizados são ligeiramente inferiores aos valores dos dados com tempo uniformizados.

Na Tabela 4.2 os dados foram formatados para comparar os valores entre os parâmetros de treino usados. Neste caso é possível visualizar um gradiente de cores de cima para baixo, isto traduz num aumento do desempenho do treino da rede (diminuição do RMSE) à medida que o número de neurónios aumentou.

NARX

A rede neuronal NARX (*Non-Linear Autoregressive Network with Exogenous Inputs*) foi também utilizada, pelo facto, de esta ser utilizada para resolver problemas instáveis e não-lineares. A capacidade de esta rede se basear em instantes anteriores tanto das saídas como das entradas foi também umas das características tidas como relevantes para a resolução deste problema. Na Figura 4.7 encontra-se representada a arquitetura de uma rede NARX.




Figura 4.7: Arquitetura de uma rede NARX [24]

Para uma primeira análise, foram alterados os parâmetros de treino relativos às camadas escondidas de forma a avaliar como é que estes influenciam o desempenho da rede. Os parâmetros usados para cada índice são os representados na Tabela 4.4.

Tabela 4.4: Parâmetros de treino para a rede NARX

Índice	Parâmetros
31	Neurónios na Camada escondida= 5 Atraso entradas= 1 Atraso saídas= 1
32	Neurónios na Camada escondida= 10 Atraso entradas= 1 Atraso saídas= 1
33	Neurónios na Camada escondida= 15 Atraso entradas= 1 Atraso saídas= 1
34	Neurónios na Camada escondida= 20 Atraso entradas= 1 Atraso saídas= 1
35	Neurónios na Camada escondida= 50 Atraso entradas= 1 Atraso saídas= 1
36	Neurónios na Camada escondida= 100 Atraso entradas= 1 Atraso saídas= 1

À semelhança da rede anterior, os procedimentos seguiram as mesmas diretrizes. Para cada conjunto de parâmetros de treino foi analisado o valor médio do RMSE bem como o respetivo valor dos primeiros 4 testes da rede. A formatação condicional das cores presentes nas tabelas seguem a mesma ideologia da rede anterior. Esses valores estão representados nas Tabelas 4.5 e 4.6.

Tabela 4.5: Valores RMSE NARX-Análise do tipo de dados

Dados	Parâmetros	Dados							
		Dados com tempo normalizados	Dados sem tempo normalizados	Dados com tempo	Dados sem tempo	Dados com tempo uniformizados normalizados	Dados sem tempo uniformizados normalizados	Dados com tempo uniformizados	Dados sem tempo uniformizados
31	a	-	-	-	-	58.737	51.6881	58.4336	51.7527
	b	-	-	-	-	56.7512	56.3471	68.8102	61.4901
	c	-	-	-	-	32.7226	81.6461	32.6107	72.707
	d	-	-	-	-	35.5446	58.8118	40.5759	84.0974
	médio	-	-	-	-	54.7076	57.0468	75.8263	64.0745
32	a	-	-	-	-	58.9328	52.4163	58.7965	51.7389
	b	-	-	-	-	60.6025	59.7461	59.2306	62.6094
	c	-	-	-	-	32.1935	76.6964	31.5249	80.6555
	d	-	-	-	-	41.6424	60.371	41.8804	58.3456
	médio	-	-	-	-	63.4417	87.0384	59.514	79.2153
33	a	-	-	-	-	58.93278747	52.41631468	58.79645092	51.7389031
	b	-	-	-	-	60.60247204	59.74605857	59.23062238	62.60940418
	c	-	-	-	-	32.19347338	76.69642126	31.52490922	80.65553277
	d	-	-	-	-	41.64240786	60.37096706	41.88043917	58.34555124
	médio	-	-	-	-	111.4981	59.5428	102.6115	79.7383
34	a	-	-	-	-	58.2794	52.3761	59.2199	52.1067
	b	-	-	-	-	144.4408	64.1312	84.0864	57.4917
	c	-	-	-	-	103.7422	76.874	71.9913	82.2079
	d	-	-	-	-	135.0419	79.1045	40.7266	61.6196
	médio	-	-	-	-	137.5194	56.02	114.5615	80.4805
35	a	-	-	-	-	58.7084	51.6484	58.9876	52.089
	b	-	-	-	-	38.5443	55.3865	97.4396	73.5574
	c	-	-	-	-	55.0888	78.3932	88.2282	77.1321
	d	-	-	-	-	55.1027	59.9671	56.6872	83.6896
	médio	-	-	-	-	64.981	73.0439	137.6503	61.9924
36	a	-	-	-	-	59.8909	51.8276	59.3072	51.8352
	b	-	-	-	-	62.6549	61.9694	54.2531	72.8155
	c	-	-	-	-	80.8788	80.1994	61.2105	78.65
	d	-	-	-	-	46.2949	78.3847	64.9029	51.6573
	médio	-	-	-	-	91.6781	69.6474	76.3267	80.3754

Tabela 4.6: Valores RMSE NARX-Análise dos parâmetros

Dados	Parâmetros	Dados							
		Dados com tempo normalizados	Dados sem tempo normalizados	Dados com tempo	Dados sem tempo	Dados com tempo uniformizados normalizados	Dados sem tempo uniformizados normalizados	Dados com tempo uniformizados	Dados sem tempo uniformizados
31	a	-	-	-	-	58.737	51.6881	58.4336	51.7527
	b	-	-	-	-	56.7512	56.3471	68.8102	61.4901
	c	-	-	-	-	32.7226	81.6461	32.6107	72.707
	d	-	-	-	-	35.5446	58.8118	40.5759	84.0974
	médio	-	-	-	-	54.7076	57.0468	75.8263	64.0745
32	a	-	-	-	-	58.9328	52.4163	58.7965	51.7389
	b	-	-	-	-	60.6025	59.7461	59.2306	62.6094
	c	-	-	-	-	32.1935	76.6964	31.5249	80.6555
	d	-	-	-	-	41.6424	60.371	41.8804	58.3456
	médio	-	-	-	-	63.4417	87.0384	59.514	79.2153
33	a	-	-	-	-	58.93278747	52.41631468	58.79645092	51.7389031
	b	-	-	-	-	60.60247204	59.74605857	59.23062238	62.60940418
	c	-	-	-	-	32.19347338	76.69642126	31.52490922	80.65553277
	d	-	-	-	-	41.64240786	60.37096706	41.88043917	58.34555124
	médio	-	-	-	-	111.4981	59.5428	102.6115	79.7383
34	a	-	-	-	-	58.2794	52.3761	59.2199	52.1067
	b	-	-	-	-	144.4408	64.1312	84.0864	57.4917
	c	-	-	-	-	103.7422	76.874	71.9913	82.2079
	d	-	-	-	-	135.0419	79.1045	40.7266	61.6196
	médio	-	-	-	-	137.5194	56.02	114.5615	80.4805
35	a	-	-	-	-	58.7084	51.6484	58.9876	52.089
	b	-	-	-	-	38.5443	55.3865	97.4396	73.5574
	c	-	-	-	-	55.0888	78.3932	88.2282	77.1321
	d	-	-	-	-	55.1027	59.9671	56.6872	83.6896
	médio	-	-	-	-	64.981	73.0439	137.6503	61.9924
36	a	-	-	-	-	59.8909	51.8276	59.3072	51.8352
	b	-	-	-	-	62.6549	61.9694	54.2531	72.8155
	c	-	-	-	-	80.8788	80.1994	61.2105	78.65
	d	-	-	-	-	46.2949	78.3847	64.9029	51.6573
	médio	-	-	-	-	91.6781	69.6474	76.3267	80.3754

Ao contrário do anteriormente observado, nesta rede não é possível identificar facilmente um tipo de dados, na Tabela 4.5, que demonstre uma maior desempenho face aos outros.

Relativamente aos parâmetros de treino (Tabela 4.6), a diferença do desempenho entre eles não é evidente, no entanto, é possível verificar que os treinos iniciais possuem um desempenho ligeiramente superior aos restantes.

A evolução do desempenho nesta rede foi bastante inferior ao esperado. Foi realizado no entanto outro treino, com variação dos parâmetros relativos ao atrasado das entradas e das saídas, mantendo constante o valor dos neurónios na camada escondida. Na Tabela 4.7 estão representados os parâmetros de treino utilizados bem como o respetivo índice.

Tabela 4.7: Parâmetros de treino para a rede NARX

Índice	Parâmetros
41	Neurónios na Camada escondida= 5 Atraso entradas= 5 Atraso saídas= 5
42	Neurónios na Camada escondida= 5 Atraso entradas= 10 Atraso saídas= 10
43	Neurónios na Camada escondida= 5 Atraso entradas= 15 Atraso saídas= 15
44	Neurónios na Camada escondida= 5 Atraso entradas= 20 Atraso saídas= 20
45	Neurónios na Camada escondida= 5 Atraso entradas= 25 Atraso saídas= 25
46	Neurónios na Camada escondida= 5 Atraso entradas= 50 Atraso saídas= 50

Na Tabela 4.8 continua a não ser possível identificar o tipo de dados mais apropriado para o treino da rede. Na Tabela 4.9 podemos concluir que os parâmetros de treino 46 obtiveram o pior desempenho, no entanto nos restantes continua a não ser exequível identificar os parâmetros que resultam no melhor desempenho da rede.

Tabela 4.8: Valores RMSE NARX-Análise do tipo de dados

Dados		data original normalised with time	data original normalised without time	data original with time	data original without time	data padded normalised with time	data padded normalised without time	data padded with time	data padded without time
41	a	-	-	-	-	58.743	51.6366	58.5071	52.3239
	b	-	-	-	-	53.3041	60.5129	155.9174	66.3498
	c	-	-	-	-	38.0764	79.1718	237.7825	80.9991
	d	-	-	-	-	44.1066	62.5174	294.2421	62.7349
	médio	-	-	-	-	132.7503	66.8765	536.4151	75.4942
42	a	-	-	-	-	58.922	51.5829	58.9246	51.6719
	b	-	-	-	-	94.7962	63.0865	102.2581	57.1343
	c	-	-	-	-	81.8522	75.9234	136.1747	78.6081
	d	-	-	-	-	51.7361	70.3361	165.5772	63.7706
	médio	-	-	-	-	569.3479	65.9538	1115.3534	63.9785
43	a	-	-	-	-	58.8145	51.6758	59.1091	51.8836
	b	-	-	-	-	1407.6235	55.8121	42.3025	60.5243
	c	-	-	-	-	2796.7507	89.9813	54.4015	78.6996
	d	-	-	-	-	2724.674	57.9042	57.9422	72.4771
	médio	-	-	-	-	3458.8865	71.2328	632.3013	64.0141
44	a	-	-	-	-	59.2571	51.425	59.0645	51.9454
	b	-	-	-	-	76.1065	67.2058	58.7944	56.6405
	c	-	-	-	-	84.8378	81.5108	41.4789	75.6927
	d	-	-	-	-	90.1855	55.0155	594812	60.5021
	médio	-	-	-	-	93.551	85.5848	83.8478	68.7255
45	a	-	-	-	-	59.102	5107629	59.6576	51.7276
	b	-	-	-	-	167.1217	50.2642	104.6568	54.194
	c	-	-	-	-	612.8768	86.4774	142.2772	100.2333
	d	-	-	-	-	624.7595	66.8923	452.9942	176.729
	médio	-	-	-	-	880.3329	151.442	1876.0198	157.8531
46	a	-	-	-	-	59.2711	51.4856	59.035	51.98811
	b	-	-	-	-	283.4801	65.4442	220.2158	77.448
	c	-	-	-	-	359.8622	187.3844	422.8712	142.0013
	d	-	-	-	-	367.2594	223.9122	487.4327	380.2094
	médio	-	-	-	-	593.0616	1027.5459	802.7967	1492.3302

Tabela 4.9: Valores RMSE NARX-Análise dos parâmetros

Dados		data original normalised with time	data original normalised without time	data original with time	data original without time	data padded normalised with time	data padded normalised without time	data padded with time	data padded without time
41	a	-	-	-	-	58.743	51.6366	58.5071	52.3239
	b	-	-	-	-	53.3041	60.5129	155.9174	66.3498
	c	-	-	-	-	38.0764	79.1718	237.7825	80.9991
	d	-	-	-	-	44.1066	62.5174	294.2421	62.7349
	médio	-	-	-	-	132.7503	66.8765	536.4151	75.4942
42	a	-	-	-	-	58.922	51.5829	58.9246	51.6719
	b	-	-	-	-	94.7962	63.0865	102.2581	57.1343
	c	-	-	-	-	81.8522	75.9234	136.1747	78.6081
	d	-	-	-	-	51.7361	70.3361	165.5772	63.7706
	médio	-	-	-	-	569.3479	65.9538	1115.3534	63.9785
43	a	-	-	-	-	58.8145	51.6758	59.1091	51.8836
	b	-	-	-	-	1407.6235	55.8121	42.3025	60.5243
	c	-	-	-	-	2796.7507	89.9813	54.4015	78.6996
	d	-	-	-	-	2724.674	57.9042	57.9422	72.4771
	médio	-	-	-	-	3458.8865	71.2328	632.3013	64.0141
44	a	-	-	-	-	59.2571	51.425	59.0645	51.9454
	b	-	-	-	-	76.1065	67.2058	58.7944	56.6405
	c	-	-	-	-	84.8378	81.5108	41.4789	75.6927
	d	-	-	-	-	90.1855	55.0155	594812	60.5021
	médio	-	-	-	-	93.551	85.5848	83.8478	68.7255
45	a	-	-	-	-	59.102	5107629	59.6576	51.7276
	b	-	-	-	-	167.1217	50.2642	104.6568	54.194
	c	-	-	-	-	612.8768	86.4774	142.2772	100.2333
	d	-	-	-	-	624.7595	66.8923	452.9942	176.729
	médio	-	-	-	-	880.3329	151.442	1876.0198	157.8531
46	a	-	-	-	-	59.2711	51.4856	59.035	51.98811
	b	-	-	-	-	283.4801	65.4442	220.2158	77.448
	c	-	-	-	-	359.8622	187.3844	422.8712	142.0013
	d	-	-	-	-	367.2594	223.9122	487.4327	380.2094
	médio	-	-	-	-	593.0616	1027.5459	802.7967	1492.3302

LSTM

Para o treino da rede LSTM o procedimento manteve-se idêntico ao anteriormente realizado. Foram definidos os parâmetros de treino para avaliar o desempenho da rede, neste caso foram utilizados 2 parâmetros, o valor dos neurónios na camada

escondida que é incrementado e o do "mini Batch Size" que é mantido constante. Este último parâmetro tem como funcionalidade agrupar os dados de forma a diminuir os tempos de treino. Na Tabela 4.10 encontram-se os parâmetros para treino da LSTM.

Tabela 4.10: Parâmetros de treino para a rede LSTM

Índice	Parâmetros
141	Neurónios na Camada escondida= 10 <i>mini Batch Size</i> = 300
142	Neurónios na Camada escondida= 50 <i>mini Batch Size</i> = 300
143	Neurónios na Camada escondida= 100 <i>mini Batch Size</i> = 300
144	Neurónios na Camada escondida= 150 <i>mini Batch Size</i> = 300
145	Neurónios na Camada escondida= 200 <i>mini Batch Size</i> = 300
146	Neurónios na Camada escondida= 250 <i>mini Batch Size</i> = 300

Nas Tabelas 4.11 e 4.12 apresentadas é possível encontrar uma tendência em ambas. Na Tabela 4.11 verifica-se que existem 2 tipos de dados com melhor desempenho, nomeadamente os dados com tempo normalizados e os dados com tempo uniformizados normalizados. Na Tabela 4.12 encontra-se uma tendência de melhoria do desempenho à medida que o valor dos neurónios na camada escondida aumenta.

Tabela 4.11: Valores RMSE LSTM-Análise do tipo de dados

Dados	Parâmetros	Dados							
		Dados com tempo normalizados	Dados sem tempo normalizados	Dados com tempo	Dados sem tempo	Dados com tempo uniformizados normalizados	Dados sem tempo uniformizados normalizados	Dados com tempo uniformizados	Dados sem tempo uniformizados
141	a	8.6468	46.256	141.1697	197.7548	9.5599	37.5252	128.0407	121.6995
	b	7.2581	18.8973	154.5322	144.309	5.3378	18.4653	138.3098	131.6553
	c	6.4556	18.4021	147.1094	153.4715	5.4755	13.038	124.194	111.9133
	d	9.7263	19.3828	138.6193	143.1296	8.7922	19.9642	118.9212	138.1506
	médio	8.8361	18.6945	145.963	146.5764	8.4371	17.2998	125.801	124.6494
142	a	3.7339	49.4105	114.7925	109.7417	5.6469	23.578	104.249	96.9108
	b	6.5671	8.2062	127.0109	116.4683	5.9655	13.7731	114.0923	106.2297
	c	5.8933	23.1384	117.8426	125.0965	4.7725	14.9226	101.5601	91.2015
	d	5.5543	9.9498	111.6242	115.1444	6.6405	29.6233	96.1473	111.1053
	médio	5.6164	10.7961	118.892	118.4188	6.5168	14.2384	102.8734	100.6642
143	a	4.1209	17.3426	86.4115	77.1399	5.5995	22.4315	78.1983	69.9405
	b	4.1346	7.2847	97.0538	84.1172	8.0324	11.8085	86.933	78.6161
	c	3.0318	21.0507	90.3765	91.5448	4.672	10.7807	76.3596	68.3278
	d	6.4147	3.7368	82.7248	82.5186	3.5524	22.2035	71.0285	81.6349
	médio	4.9898	9.4303	89.8277	85.396	5.123	13.1466	77.4781	74.3815
144	a	2.6459	23.1084	61.9218	51.409	5.4753	16.2379	54.7072	45.9093
	b	5.8871	5.5445	69.7971	58.4302	6.3004	11.3151	60.7129	53.8627
	c	2.6634	11.1337	64.0815	63.4506	4.2591	10.6041	52.5371	46.7351
	d	2.8477	5.8073	57.6585	56.4326	4.3911	17.9442	48.0085	55.0304
	médio	3.7856	7.4384	64.2127	58.4604	4.9808	11.6162	53.8123	50.2082
145	a	2.7928	11.3364	42.7431	35.5141	2.3337	30.3622	38.3177	31.6723
	b	5.2133	4.7256	43.3038	41.1189	5.0262	27.0275	37.8235	38.195
	c	1.9989	10.1494	40.2416	39.6208	3.7645	19.8324	33.2572	29.9766
	d	2.699	3.4231	37.4345	38.9366	3.2276	17.5284	31.7032	38.31
	médio	3.8068	5.7519	41.7829	38.0709	3.9695	18.5497	35.3003	33.3223
146	a	1.5109	20.3971	29.5648	33.2533	3.5314	18.7345	24.1475	30.3552
	b	5.1814	4.2814	22.2764	34.3441	4.9983	6.7014	18.653	29.7351
	c	3.3173	9.443	23.2003	31.7312	2.9455	6.769	17.7082	22.6776
	d	3.8475	3.4294	25.699	38.5047	3.6311	10.7429	19.6852	37.9135
	médio	3.8436	5.2841	25.9091	32.6317	3.9149	8.3166	20.3579	27.4772

Tabela 4.12: Valores RMSE LSTM-Análise dos parâmetros

Dados	Parâmetros	Dados							
		Dados com tempo normalizados	Dados sem tempo normalizados	Dados com tempo	Dados sem tempo	Dados com tempo uniformizados normalizados	Dados sem tempo uniformizados normalizados	Dados com tempo uniformizados	Dados sem tempo uniformizados
141	a	8.6468	46.256	141.1697	197.7548	9.5599	37.5252	128.0407	121.6995
	b	7.2581	18.8973	154.5322	144.309	5.3378	18.4653	138.3098	131.6553
	c	6.4556	18.4021	147.1094	153.4715	5.4755	13.038	124.194	111.9133
	d	9.7263	19.3828	138.6193	143.1296	8.7922	19.9642	118.9212	138.1506
	médio	8.8361	18.6945	145.963	146.5764	8.4371	17.2998	125.801	124.6494
142	a	3.7339	49.4105	114.7925	109.7417	5.6469	23.578	104.249	96.9108
	b	6.5671	8.2062	127.0109	116.4683	5.9655	13.7731	114.0923	106.2297
	c	5.8933	23.1384	117.8426	125.0965	4.7725	14.9226	101.5601	91.2015
	d	5.5543	9.9498	111.6242	115.1444	6.6405	29.6233	96.1473	111.1053
	médio	5.6164	10.7961	118.892	118.4188	6.5168	14.2384	102.8734	100.6642
143	a	4.1209	17.3426	86.4115	77.1399	5.5995	22.4315	78.1983	69.9405
	b	4.1346	7.2847	97.0538	84.1172	8.0324	11.8085	86.933	78.6161
	c	3.0318	21.0507	90.3765	91.5448	4.672	10.7807	76.3596	68.3278
	d	6.4147	3.7368	82.7248	82.5186	3.5524	22.2035	71.0285	81.6349
	médio	4.9898	9.4303	89.8277	85.396	5.123	13.1466	77.4781	74.3815
144	a	2.6459	23.1084	61.9218	51.409	5.4753	16.2379	54.7072	45.9093
	b	5.8871	5.5445	69.7971	58.4302	6.3004	11.3151	60.7129	53.8627
	c	2.6634	11.1337	64.0815	63.4506	4.2591	10.6041	52.5371	46.7351
	d	2.8477	5.8073	57.6585	56.4326	4.3911	17.9442	48.0085	55.0304
	médio	3.7856	7.4384	64.2127	58.4604	4.9808	11.6162	53.8123	50.2082
145	a	2.7928	11.3364	42.7431	35.5141	2.3337	30.3622	38.3177	31.6723
	b	5.2133	4.7256	43.3038	41.1189	5.0262	27.0275	37.8235	38.195
	c	1.9989	10.1494	40.2416	39.6208	3.7645	19.8324	33.2572	29.9766
	d	2.699	3.4231	37.4345	38.9366	3.2276	17.5284	31.7032	38.31
	médio	3.8068	5.7519	41.7829	38.0709	3.9695	18.5497	35.3003	33.3223
146	a	1.5109	20.3971	29.5648	33.2533	3.5314	18.7345	24.1475	30.3552
	b	5.1814	4.2814	22.2764	34.3441	4.9983	6.7014	18.653	29.7351
	c	3.3173	9.443	23.2003	31.7312	2.9455	6.769	17.7082	22.6776
	d	3.8475	3.4294	25.699	38.5047	3.6311	10.7429	19.6852	37.9135
	médio	3.8436	5.2841	25.9091	32.6317	3.9149	8.3166	20.3579	27.4772

4.3.2 Comparação de resultados das redes

Com base nos dados anteriormente obtidos, é necessário estabelecer uma comparação entre as redes treinadas, de forma a, definir qual a rede com a maior possibilidade de obter o melhor desempenho. Para esta comparação, foi gerado um gráfico, usando

o valor médio de RMSE de cada treino, de forma a visualizar a evolução dos treinos de cada rede. O gráfico gerado encontra-se representada na Figura 4.8.




Figura 4.8: Análise do desempenho das redes

Analisando o gráfico é possível concluir que os treinos da rede NARX possuem o pior desempenho, pelo facto dos valores de erro serem elevados e por não ser possível visualizar uma evolução da rede aos longo dos treinos. Na rede LSTM alguns valores iniciais foram bastante elevados no entanto é possível observar uma evolução ao longo dos diferentes treinos. Com este gráfico é possível concluir que as redes com melhor desempenho foram as redes LSTM e Feed-Forward. Na Figura 4.9 encontram-se apenas as curvas cujos valores de RMSE sejam inferiores a 20.




Figura 4.9: Análise do desempenho das redes (RMSE<20)

Na Figura 4.9 podemos analisar com mais detalhe as curvas dos treinos com o melhor desempenho. Neste caso é possível concluir que a rede LSTM atingiu os valores de RMSE mais baixos, bem como uma evolução mais favorável comparativamente com a rede Feed-Forward. Com base nas observações foi escolhida a rede LSTM pelos motivos acima citados.

4.4 Treino da LSTM e Resultados

Para o treino desta rede, foram criados vários conjuntos de treinos de forma a avaliar a influência dos parâmetros de treino no desempenho da rede. Cada conjunto de parâmetros tem como finalidade analisar o desempenho individual de determinados parâmetros de treino. Foram analisados os parâmetros: *hidden units*, *epochs*, *batch size*, *gradient treshold*, *initial learning rate*, *batch*, *validation frequency*, *validation patiente*. A Tabela 4.13 contém os índices de treino bem como os respectivos parâmetros utilizados.

Tabela 4.13: Parâmetros LSTM

Index	Training method	Hidden units	Epochs	Batch size	Gradient threshold	Initial learn rate	Validation frequency	Validation Patiente
101	adam	10	300	300	0.1	0.001	-	-
102	adam	50	300	300	0.1	0.001	-	-
103	adam	100	300	300	0.1	0.001	-	-
104	adam	150	300	300	0.1	0.001	-	-
105	adam	200	300	300	0.1	0.001	-	-
106	adam	250	300	300	0.1	0.001	-	-
111	adam	250	100	300	0.1	0.001	-	-
112	adam	250	200	300	0.1	0.001	-	-
113	adam	250	300	300	0.1	0.001	-	-
114	adam	250	400	300	0.1	0.001	-	-
115	adam	250	500	300	0.1	0.001	-	-
121	adam	250	300	50	0.1	0.001	-	-
122	adam	250	300	100	0.1	0.001	-	-
123	adam	250	300	200	0.1	0.001	-	-
124	adam	250	300	300	0.1	0.001	-	-
125	adam	250	300	349	0.1	0.001	-	-
131	adam	250	300	300	0.001	0.001	-	-
132	adam	250	300	300	0.01	0.001	-	-
133	adam	250	300	300	0.1	0.001	-	-
134	adam	250	300	300	0.5	0.001	-	-
135	adam	250	300	300	0.8	0.001	-	-
136	adam	250	300	300	1	0.001	-	-
141	adam	250	300	300	0.1	0.00001	-	-
142	adam	250	300	300	0.1	0.0001	-	-
143	adam	250	300	300	0.1	0.001	-	-
144	adam	250	300	300	0.1	0.01	-	-
145	adam	250	300	300	0.1	0.1	-	-
146	adam	250	300	300	0.1	1	-	-
151	adam	250	300	300	0.1	0.001	50	-
152	adam	250	300	300	0.1	0.001	40	-
153	adam	250	300	300	0.1	0.001	30	-
154	adam	250	300	300	0.1	0.001	20	-
155	adam	250	300	300	0.1	0.001	10	-
161	adam	250	300	300	0.1	0.001	10	10
162	adam	250	300	300	0.1	0.001	10	100
163	adam	250	300	300	0.1	0.001	10	1000
164	adam	250	300	300	0.1	0.001	10	10000

Para cada conjunto de parâmetros, foram criadas duas tabelas, semelhantes às apresentadas no capítulo 4.3.1 para analisar o respetivo desempenho.

4.4.1 Avaliação do tipo de dados

À semelhança das análises anteriores, para os parâmetros de treino apresentados na Tabela 4.13, é necessário avaliar o desempenho da rede relativamente aos dados utilizados para o treino das redes. De seguida serão apresentadas 7 tabelas (Tabelas 4.14 a 4.20), onde cada tabela representa um conjunto de resultados obtidos.

Tabela 4.14: Valores RMSE-Parâmetros *Hidden units*-Análise dos dados

Dados	data original normalis ed with time	data original normalis ed without time	data original with time	data original without time	data padded normalis ed with time	data padded normalis ed without time	data padded with time	data padded without time
101	9.6595	25.0563	146.1649	141.4549	16.302	27.9538	132.0544	126.8128
	4.8941	21.1734	160.396	146.8249	12.9311	23.9662	142.8404	136.1517
	7.8001	23.9243	151.8596	156.4446	17.7835	22.5858	127.6773	115.655
	9.3255	37.3942	143.7022	146.3943	13.2405	39.6196	122.9184	142.8203
	9.6038	23.0997	151.0606	149.2816	15.7577	25.9422	129.8726	128.9133
102	4.8936	15.1151	118.8863	112.3106	9.492	31.5104	109.1642	100.7166
	8.0366	14.1031	131.5925	119.0033	7.5844	20.0404	119.1201	110.1221
	5.3197	23.8743	124.3409	127.7055	7.6749	24.2725	106.2469	94.3935
	4.0364	20.3768	116.059	117.7113	9.6099	32.4081	100.8494	115.2591
	7.0123	16.0408	123.3761	120.9976	9.4881	20.2661	107.6363	104.3482
103	3.5783	23.793	27.1776	34.3112	2.699	16.2427	25.9975	30.6039
	5.1589	5.1237	19.7571	31.9251	5.3874	8.0143	18.9692	306681
	1.8993	5.2851	20.7932	31.3868	3.1792	11.2527	18.6462	23.2762
	3.0464	4.6755	23.7252	38.7197	3.6575	15.7	21.4806	37.6168
	3.8442	6.2127	23.1776	32.1357	4.0347	9.7643	21.4935	28.0944
104	1.4827	13.0306	5.1182	39.8338	1.7885	21.939	3.4879	15.6917
	3.3087	2.378	6.6615	15.542	3.4261	5.1705	6.6506	10.9488
	2.1016	3.8945	4.5342	20.8506	2.1504	8.9553	3.6854	15.1485
	3.0361	2.9102	4.1117	40.3125	1.6623	4.629	2.5229	12.5774
	3.0518	5.7333	5.8958	22.5953	2.8904	5.7676	5.1026	11.3416
105	2.7928	11.3364	42.7431	35.5141	2.3337	30.3622	38.3177	31.6723
	5.2133	4.7256	43.3038	41.1189	5.0262	27.0275	37.8235	38.195
	1.9989	10.1494	40.2416	39.6208	3.7645	19.8324	33.2572	29.9766
	2.699	3.4231	37.4345	38.9366	3.2276	17.5284	31.7032	38.31
	3.8068	5.7519	41.7829	38.0709	3.9695	18.5497	35.3003	33.3223
106	1.5109	20.3971	29.5648	33.2533	3.5314	18.7345	24.1475	30.3552
	5.1814	4.2814	22.2764	34.3441	4.9983	6.7014	18.653	29.7351
	3.3173	9.4433	23.2003	31.7312	2.9455	6.769	17.7082	22.6776
	3.8475	3.4294	25.699	38.5047	3.6311	10.7429	19.6852	37.9135
	3.8436	5.2841	25.9091	32.6317	3.9149	8.3166	20.3579	27.4772

Tabela 4.15: Valores RMSE-Parâmetros *Epochs*-Análise dos dados

Dados	data original normalis ed with time	data original normalis ed without time	data original with time	data original without time	data padded normalis ed with time	data padded normalis ed without time	data padded with time	data padded without time
111	5.8296	16.925	88.082	80.817	6.0077	31.858	80.3088	73.4325
	5.7177	8.0637	99.1447	89.721	7.9975	15.808	89.1763	82.1761
	5.661	17.9035	92.4245	97.4383	6.8555	22.8004	78.4309	71.3163
	5.2509	12.2161	84.7138	88.2264	4.9977	32.468	73.0752	85.4553
	6.7591	12.872	91.8317	91.1625	8.366	18.1872	79.5353	77.7961
112	3.7148	19.6459	48.8755	42.311	5.4508	17.6619	45.4264	38.5267
	7.5934	7.5845	52.7762	49.0245	6.0496	9.9964	48.7654	45.9855
	3.7979	17.4328	48.4311	51.9652	4.0266	13.854	42.1821	39.0871
	3.8585	4.7223	43.8597	46.8354	6.3634	28.9061	38.7199	46.5059
	5.5857	9.3265	49.3516	48.0305	5.8274	14.6619	43.7099	42.105
13	3.6114	16.645	28.826	33.6282	3.2117	16.664	24.3549	30.6433
	4.6718	7.1098	20.6711	34.9663	4.6304	10.5075	18.0124	32.2714
	3.0966	13.466	22.1972	33.198	3.6883	12.3867	17.7082	24.4814
	3.7647	6.9138	25.2861	38.8867	3.864	14.7329	20.1248	37.6596
	3.9106	8.4611	25.0324	33.5916	4.1885	11.3926	20.3444	29.0464
114	1.799	27.2591	18.4519	32.7192	3.2605	21.7816	16.7915	30.727
	6.4061	3.1423	12.2564	27.4524	4.5654	8.6113	10.8259	23.1745
	2.2316	5.0967	13.2829	29.5756	4.1273	16.0807	10.9901	20.559
	2.2889	2.39	16.8553	40.1763	3.9102	11.206	14.1959	39.8779
	3.2533	4.3697	16.1092	29.3062	4.5798	9.2104	13.7128	24.346
115	2.2476	21.321	16.8473	37.0665	3.0607	21.5368	11.4683	32.2696
	7.4351	4.5043	11.2755	23.9046	7.6767	4.2877	8.529	20.0126
	2.0307	7.2426	11.9881	27.4441	2.8077	5.5556	7.9541	19.7107
	2.2865	3.1686	15.4459	39.0849	3.3109	4.5649	9.82	40.5266
	3.3289	4.8581	14.7519	26.2646	3.9634	5.9747	10.0121	23.7448

Tabela 4.16: Valores RMSE-Parâmetros *Batch size*-Análise dos dados

Dados	data original normalis ed with time	data original normalis ed without time	data original with time	data original without time	data padded normalis ed with time	data padded normalis ed without time	data padded with time	data padded without time
121	2.4873	36.7564	6.7164	51.7463	1.3161	18.8669	8.6602	23.8525
	1.9072	1.6994	8.4691	6.0076	1.7509	3.6845	4.5048	10.2622
	1.4882	2.152	7.5714	84326	0.99052	4.1976	4.7293	8.2333
	1.7927	1.2812	5.2627	9.9162	1.0236	2.6144	9.5483	13.8096
	2.902	2.8432	7.5475	9.5878	2.047	3.4081	7.6195	10.4809
122	1.891	3.7878	10.7646	32.9498	1.2715	32.2776	6.9844	41.2919
	3.2284	24.4464	8.0018	15.9734	3.1026	2.9801	8.0686	13.9605
	1.9533	3.4325	8.4079	12.3915	1.6161	4.5732	9.1564	15.7909
	2.0575	4.0894	11.3837	23.0694	1.4385	3.0366	5.4708	20.5882
	3.1892	2.4549	10.6047	17.6381	2.4714	4.262	7.4807	15.842
123	1.2975	25.5909	14.0926	35.2979	2.1101	20.0954	11.3843	31.5358
	3.7385	2.8046	9.3475	23.0907	4.1231	4.2684	7.5514	22.1515
	2.3148	3.9496	10.2585	25.4896	2.1735	6.0908	8.4719	19.2112
	1.4643	2.8827	13.6675	40.0911	1.8462	5.2044	10.3447	39.2491
	2.8216	3.6791	12.6232	26.1685	2.8905	5.5022	10.0812	23.4994
124	3.332	15.5262	22.7083	32.8277	2.7029	18.153	24.0629	30.3956
	6.9175	6.2375	19.097	33.8638	7.1495	7.0622	18.1857	30.686
	3.0937	8.7349	19.5527	32.1222	3.5414	12.0981	17.6566	23.7442
	3.5816	2.3316	21.7153	38.2918	3.2142	12.3029	19.9639	37.9948
	4.1102	6.1956	22.0477	32.923	4.0832	9.6444	20.2934	28.2844
125	1.9852	15.91	27.6979	34.8262	3.2378	33.2582	26.0661	30.873
	5.7967	4.1573	20.3055	35.0151	5.3287	7.8517	19.8604	31.7047
	3.2187	5.6512	21.2007	32.6491	3.7151	10.7708	19.0954	23.8436
	2.6007	3.4228	24.1047	38.2801	2.5142	14.2995	21.2016	37.5451
	3.6179	5.5883	24.0824	33.4586	4.5262	8.9893	21.8676	28.4582

Tabela 4.17: Valores RMSE-Parâmetros *Gradient threshol*-Análise dos dados

Dados	data original normalis ed with time	data original normalis ed without time	data original with time	data original without time	data padded normalis ed with time	data padded normalis ed without time	data padded with time	data padded without time
131	5.4352	17.4954	31.2707	34.0452	6.4265	28.6206	27.3883	30.3958
	3.6093	5.6838	26.7504	35.8043	5.2723	24.6556	24.7001	30.0502
	2.8281	10.3293	26.3967	33.076	5.2091	11.5213	21.7982	23.3043
	5.2291	4.1605	27.0824	38.5827	4.9741	12.8064	22.2362	37.3542
	4.6839	7.0864	28.5402	33.2637	5.1215	12.0507	24.1236	27.9174
132	4.4819	14.6124	26.8897	33.1835	4.2689	13.2247	25.3483	29.7961
	3.9913	5.9986	21.1274	33.0804	5.0723	8.5066	20.7502	31.0387
	3.2852	14.8782	21.4086	30.9421	2.3228	12.1017	19.3278	23.8214
	5.1012	5.2883	23.4134	38.2494	3.5138	10.7921	20.6653	37.2469
	4.9096	7.6217	23.9519	31.9923	6.8977	9.6077	21.8416	28.3622
133	3.9336	22.1945	27.0782	33.8762	5.7387	18.3543	25.2462	29.331
	5.6128	5.7649	21.0858	32.9487	8.3661	15.1344	19.2551	29.6498
	3.9589	10.8037	21.1462	31.9956	3.7057	8.8475	18.4977	22.8512
	3.6531	4.3486	23.3943	38.6829	4.9877	19.7545	20.8555	37.7709
	5.6085	6.6452	23.9742	32.5762	5.3611	13.0896	21.2156	27.2704
134	1.9409	64.9561	26.6984	34.0015	5.6375	20.0416	24.4748	30.3775
	6.1473	3.7272	19.8391	33.9793	5.068	10.6486	17.4927	29.3296
	3.5735	7.3965	20.6944	31.5	3.8835	13.3962	17.2515	22.386
	4.539	2.9951	23.3821	38.2257	3.9564	16.4489	20.3016	38.0331
	4.227	5.8289	23.3268	32.4051	4.4222	12.7921	20.1656	27.5115
135	3.133	15.8661	26.5707	33.3521	3.0943	20.1536	27.0291	30.0003
	5.3317	4.6706	19.3847	32.2427	4.7139	13.3189	18.9278	31.5183
	2.6339	7.141	20.2182	32.2831	3.5874	12.7792	19.1141	24.5639
	3.039	4.385	23.1941	38.9307	4.2151	14.4382	22.3573	37.51
	3.8351	5.4479	23.184	32.5401	4.4433	11.1815	22.1904	28.7944
136	3.5823	16.286	30.2887	34.2065	4.8927	16.5762	25.7232	30.393
	6.8047	4.4864	21.4943	34.097	4.0292	9.9953	18.0261	30.5058
	2.4906	7.1939	23.3659	32.2513	3.0294	8.5121	17.978	23.286
	3.2543	4.3693	26.687	38.601	4.8603	7.856	21.2468	38.0869
	3.9155	5.9129	26.1931	32.939	4.6153	9.3628	21.0548	27.9389

Tabela 4.18: Valores RMSE-Parâmetros *Initial learning rate*-Análise dos dados

Dados	data original normalis ed with time	data original normalis ed without time	data original with time	data original without time	data padded normalis ed with time	data padded normalis ed without time	data padded with time	data padded without time
141	9.6595	25.0563	146.1649	141.4549	16.302	27.9538	132.0544	126.8128
	4.8941	21.1734	160.396	146.8249	12.9311	23.9662	142.8404	136.1517
	7.8001	23.9243	151.8596	156.4446	17.7835	22.5858	127.6773	115.655
	9.3255	37.3942	143.7022	146.3943	13.2405	39.6196	122.9184	142.8203
	9.6038	23.0997	151.0606	149.2816	15.7577	25.9422	129.8726	128.9133
142	4.8936	15.1151	118.8863	112.3106	9.4929	31.5104	109.1642	100.7166
	8.0366	14.1031	131.5925	119.0033	7.5844	20.0404	119.1201	110.1221
	5.3197	23.8743	124.3409	127.7055	7.6749	24.2725	106.2469	94.3935
	4.0364	20.3768	116.059	117.7113	9.6099	32.4081	100.8494	115.2591
	7.0123	16.0408	123.3761	120.9976	9.4881	20.2661	107.6363	104.3482
143	4.1209	17.3426	86.1415	77.1399	5.5995	22.4315	78.1983	69.9405
	4.1346	7.2847	97.0538	84.1172	8.0324	11.8085	86.933	78.6161
	3.0918	21.0507	90.3765	91.5448	4.672	10.7807	76.3596	68.3278
	6.4147	3.7368	82.7248	82.5186	3.5524	22.2035	71.0285	81.6349
	4.9898	9.4303	89.8277	85.396	5.123	13.1466	77.4781	74.3815
144	1.4827	13.0306	5.1182	39.8338	1.7885	21.939	3.4879	15.6917
	3.3087	2.378	6.6615	15.542	3.4261	5.1705	6.6506	10.9488
	2.1016	3.8945	4.5342	20.8506	2.1504	8.9553	3.6854	15.1485
	3.0361	2.9102	4.1117	40.3125	1.6623	4.629	2.5229	12.5774
	3.0518	5.7333	5.8958	22.5953	2.8904	5.7676	5.1026	11.3416
145	NaN	NaN	NaN	31.9712	NaN	NaN	6.0301	28.5809
	NaN	NaN	NaN	34.1521	NaN	NaN	11.4708	15.2812
	NaN	NaN	NaN	26.3204	NaN	NaN	5.9783	17.071
	NaN	NaN	NaN	41.512	NaN	NaN	6.3621	36.2592
	NaN	NaN	NaN	31.2316	NaN	NaN	7.0294	20.6136
146	NaN	NaN	13.0863	NaN	NaN	NaN	10.3453	26.1347
	NaN	NaN	21.2882	NaN	NaN	NaN	16.6643	32.0324
	NaN	NaN	23.5998	NaN	NaN	NaN	12.1615	36.7825
	NaN	NaN	17.0427	NaN	NaN	NaN	10.0858	43.0565
	NaN	NaN	21.8667	NaN	NaN	NaN	12.0199	33.0326

Tabela 4.19: Valores RMSE-Parâmetros *Validation frequency*-Análise dos dados

Dados	data original normalis ed with time	data original normalis ed without time	data original with time	data original without time	data padded normalis ed with time	data padded normalis ed without time	data padded with time	data padded without time
151	4.0483	19.8718	25.0204	34.3499	8.0335	22.0284	22.4439	30.7987
	3.9765	4.1417	20.5913	34.2957	4.3766	7.5475	16.3008	30.2117
	2.0649	7.1282	20.0316	32.7961	4.8457	10.7185	15.8858	23.6721
	4.806	4.4254	21.5703	38.5038	7.7948	11.214	18.758	37.2821
	4.5775	5.3523	22.5522	33.1554	7.4704	11.3105	18.6431	28.0632
152	3.1489	13.4497	27.8734	33.929	4.2998	27.2115	25.0376	28.5978
	9.9447	3.2255	22.4582	32.3864	4.9215	7.4242	17.8083	28.1309
	3.1057	6.9869	22.3045	31.1398	2.5941	10.3354	17.6598	23.0583
	3.3135	2.8055	23.9102	39.3174	3.9662	11.4704	20.6749	38.7475
	4.334	5.4918	24.9093	32.2088	4.2362	9.411	20.6627	27.6247
153	3.3168	9.0691	30.1294	30.3673	3.3848	17.8084	25.7766	29.4325
	5.6636	4.8487	21.9613	32.4595	6.8998	12.62	17.8613	30.4109
	2.7018	9.4327	23.0693	32.0397	3.6364	12.6043	18.118	22.7846
	4.8117	4.0663	26.0726	38.6995	3.0469	9.667	21.327	37.8549
	4.6737	5.6085	26.0871	32.4254	4.4216	11.5437	21.012	27.6663
154	1.939	15.6831	29.5811	32.6621	3.2167	43.4887	23.8065	28.2375
	5.5798	4.2419	21.0227	31.2116	6.1956	11.8727	17.9875	31.1236
	3.5196	7.6805	22.3086	31.3186	4.4657	8.1061	17.4102	24.5384
	3.3574	3.5855	25.8424	35.6032	4.4155	12.641	19.7514	37.9937
	3.8296	5.37	25.411	31.348	4.599	10.8445	19.9874	28.755
155	1.955	16.9569	26.2561	34.4153	4.4683	17.5621	22.8594	30.4247
	5.0531	5.2885	19.0207	34.1637	6.9944	10.2719	16.7669	28.7941
	2.2542	9.7826	19.8388	32.3987	2.7341	7.2528	16.2978	22.5895
	3.9152	4.5686	22.9769	38.5455	3.2993	11.6408	18.9546	38.2176
	4.2473	6.4182	22.8672	33.1967	4.692	10.4494	19.0502	27.2422

Tabela 4.20: Valores RMSE-Parâmetros *Validation* *Paciente*-Análise dos dados

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
161	2.5453	11.9414	30.3374	34.1221	1.9119	23.3615	34.8022	35.6785
	5.7039	6.1522	21.5133	33.019	6.0589	8.1343	17.2666	30.2239
	3.1468	13.2601	23.0051	31.7192	3.4997	14.3672	17.4609	22.996
	4.6134	4.7385	26.5943	39.1201	3.3029	8.3657	20.6452	37.5068
	4.2118	7.1773	26.1343	32.551	4.0802	9.9786	20.3516	27.8234
162	2.2615	17.5505	28.7017	35.0443	3.956	27.8528	25.3184	30.489
	5.3358	5.8983	20.593	32.224	5.8255	8.5794	18.1186	29.7813
	3.4679	8.6305	21.8988	31.3051	3.4739	9.2381	17.8543	23.3465
	3.7713	5.338	25.0409	38.6584	3.2135	19.8234	20.8417	37.9213
	4.1699	6.2235	24.752	31.99	4.214	11.428	20.9242	27.8631
163	3.5282	27.6853	29.1669	33.877	3.2775	39.8803	25.7385	30.1168
	7.1385	4.7949	20.7482	31.8339	3.29	7.228	18.7893	30.721
	3.4049	7.1825	22.2246	32.1391	2.6371	16.5604	18.5695	23.5674
	5.25	4.0654	25.522	39.8296	3.3149	25.8845	21.1899	37.4692
	4.4727	6.3618	25.185	32.4789	4.0974	12.9679	21.376	28.1766
164	3.7651	23.2125	28.295	32.3785	3.9958	29.0481	25.8677	25.9322
	4.8935	6.1065	20.0609	32.0285	5.6013	11.8308	18.1927	29.4886
	2.1426	6.2256	21.4137	31.5625	3.9466	12.632	18.2913	22.5168
	4.0308	5.6052	24.7529	38.3747	4.2423	11.6811	21.2057	37.7788
	4.3121	7.4652	24.3936	32.1121	4.9322	11.0095	21.164	27.3814

Analisando as tabelas apresentadas, é possível concluir que, existem 2 conjuntos de dados com um desempenho superior constante ao longo dos diferentes treinos. Os conjuntos de dados: dados com tempo normalizados e dados com tempo uniformizados normalizados, demonstraram ser aqueles que resultaram em desempenho superior.

4.4.2 Avaliação dos parâmetros

De forma a ser possível definir que valores para os parâmetros resultam no melhor desempenho possível, foi efetuada uma análise para cada parâmetro de treino.

Relativamente ao parâmetro *hidden units*, foram realizados 6 treinos com os seguintes valores: 10, 50, 100, 150, 200, 250. Na Tabela 4.21 encontram-se os valores de RMSE dos treinos.

Tabela 4.21: Valores RMSE-Parâmetro *Hidden units*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
101	9.6595	25.0563	146.1649	141.4549	16.302	27.9538	132.0544	126.8128
	4.8941	21.1734	160.396	146.8249	12.9311	23.9662	142.8404	136.1517
	7.8001	23.9243	151.8596	156.4446	17.7835	22.5858	127.6773	115.655
	9.3255	37.3942	143.7022	146.3943	13.2405	39.6196	122.9184	142.8203
	9.6038	23.0997	151.0606	149.2816	15.7577	25.9422	129.8726	128.9133
102	4.8936	15.1151	118.8863	112.3106	9.492	31.5104	109.1642	100.7166
	8.0366	14.1031	131.5925	119.0033	7.5844	20.0404	119.1201	110.1221
	5.3197	23.8743	124.3409	127.7055	7.6749	24.2725	106.2469	94.3935
	4.0364	20.3768	116.059	117.7113	9.6099	32.4081	100.8494	115.2591
	7.0123	16.0408	123.3761	120.9976	9.4881	20.2661	107.6363	104.3482
103	3.5783	23.793	27.1776	34.3112	2.699	16.2427	25.9975	30.6039
	5.1589	5.1237	19.7571	31.9251	5.3874	8.0143	18.9692	306681
	1.8993	5.2851	20.7932	31.3868	3.1792	11.2527	18.6462	23.2762
	3.0464	4.6755	23.7252	38.7197	3.6575	15.7	21.4806	37.6168
	3.8442	6.2127	23.1776	32.1357	4.0347	9.7643	21.4935	28.0944
104	1.4827	13.0306	5.1182	39.8338	1.7885	21.939	3.4879	15.6917
	3.3087	2.378	6.6615	15.542	3.4261	5.1705	6.6506	10.9488
	2.1016	3.8945	4.5342	20.8506	2.1504	8.9553	3.6854	15.1485
	3.0361	2.9102	4.1117	40.3125	1.6623	4.629	2.5229	12.5774
	3.0518	5.7333	5.8958	22.5953	2.8904	5.7676	5.1026	11.3416
105	2.7928	11.3364	42.7431	35.5141	2.3337	30.3622	38.3177	31.6723
	5.2133	4.7256	43.3038	41.1189	5.0262	27.0275	37.8235	38.195
	1.9989	10.1494	40.2416	39.6208	3.7645	19.8324	33.2572	29.9766
	2.699	3.4231	37.4345	38.9366	3.2276	17.5284	31.7032	38.31
	3.8068	5.7519	41.7829	38.0709	3.9695	18.5497	35.3003	33.3223
106	1.5109	20.3971	29.5648	33.2533	3.5314	18.7345	24.1475	30.3552
	5.1814	4.2814	22.2764	34.3441	4.9983	6.7014	18.653	29.7351
	3.3173	9.4433	23.2003	31.7312	2.9455	6.769	17.7082	22.6776
	3.8475	3.4294	25.699	38.5047	3.6311	10.7429	19.6852	37.9135
	3.8436	5.2841	25.9091	32.6317	3.9149	8.3166	20.3579	27.4772

Para o parâmetro *epochs*, foram realizados 5 treinos com os seguintes valores: 100, 200, 300, 400, 500. Na Tabela 4.22 encontram-se os valores de RMSE dos treinos.

Tabela 4.22: Valores RMSE-Parâmetro *Epochs*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
111	5.8296	16.925	88.082	80.817	6.0077	31.858	80.3088	73.4325
	5.7177	8.0637	99.1447	89.721	7.9975	15.808	89.1763	82.1761
	5.661	17.9035	92.4245	97.4383	6.8555	22.8004	78.4309	71.3163
	5.2509	12.2161	84.7138	88.2264	4.9977	32.468	73.0752	85.4553
	6.7591	12.872	91.8317	91.1625	8.366	18.1872	79.5353	77.7961
112	3.7148	19.6459	48.8755	42.311	5.4508	17.6619	45.4264	38.5267
	7.5934	7.5845	52.7762	49.0245	6.0496	9.9964	48.7654	45.9855
	3.7979	17.4328	48.4311	51.9652	4.0266	13.854	42.1821	39.0871
	3.8585	4.7223	43.8597	46.8354	6.3634	28.9061	38.7199	46.5059
	5.5857	9.3265	49.3516	48.0305	5.8274	14.6619	43.7099	42.105
113	3.6114	16.645	28.826	33.6282	3.2117	16.664	24.3549	30.6433
	4.6718	7.1098	20.6711	34.9663	4.6304	10.5075	18.0124	32.2714
	3.0966	13.466	22.1972	33.198	3.6883	12.3867	17.7082	24.4814
	3.7647	6.9138	25.2861	38.8867	3.864	14.7329	20.1248	37.6596
	3.9106	8.4611	25.0324	33.5916	4.1885	11.3926	20.3444	29.0464
114	1.799	27.2591	18.4519	32.7192	3.2605	21.7816	16.7915	30.727
	6.4061	3.1423	12.2564	27.4524	4.5654	8.6113	10.8259	23.1745
	2.2316	5.0967	13.2829	29.5756	4.1273	16.0807	10.9901	20.559
	2.2889	2.39	16.8553	40.1763	3.9102	11.206	14.1959	39.8779
	3.2533	4.3697	16.1092	29.3062	4.5798	9.2104	13.7128	24.346
115	2.2476	21.321	16.8473	37.0665	3.0607	21.5368	11.4683	32.2696
	7.4351	4.5043	11.2755	23.9046	7.6767	4.2877	8.529	20.0126
	2.0307	7.2426	11.9881	27.4441	2.8077	5.5556	7.9541	19.7107
	2.2865	3.1686	15.4459	39.0849	3.3109	4.5649	9.82	40.5266
	3.3289	4.8581	14.7519	26.2646	3.9634	5.9747	10.0121	23.7448

Analisando a Tabela 4.22, observa-se uma tendência de melhoria de desempenho ao longo dos treinos, sendo o treino 115 aquele que demonstrou melhor desempenho global (análise visual baseada nas cores de cada célula). Com auxílio dos gráficos presentes no Anexo B.2 é possível confirmar que o treino 114 é aquele com melhor desempenho num conjunto de dados e o treino 115 noutro. No entanto o valor de RMSE médio mais baixo de todos os treinos é relativo ao treino 114 com o conjunto de dados com tempo normalizados. O valor do parâmetro *epochs* do treino com índice 114 é de 400 e do 115 é de 500 tal como representado na Tabela 4.13.

Para o parâmetro *Batch Size*, foram realizados 5 treinos com os seguintes valores: 50, 100, 200, 300, 349. Na Tabela 4.23 encontram-se os valores de RMSE dos treinos.

Tabela 4.23: Valores RMSE-Parâmetro *Batch size*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
121	2.4873	36.7564	6.7164	51.7463	1.3161	18.8669	8.6602	23.8525
	1.9072	1.6994	8.4691	6.0076	1.7509	3.6845	4.5048	10.2622
	1.4882	2.152	7.5714	84326	0.99052	4.1976	4.7293	8.2333
	1.7927	1.2812	5.2627	9.9162	1.0236	2.6144	9.5483	13.8096
	2.902	2.8432	7.5475	9.5878	2.047	3.4081	7.6195	10.4809
122	1.891	3.7878	10.7646	32.9498	1.2715	32.2776	6.9844	41.2919
	3.2284	24.4464	8.0018	15.9734	3.1026	2.9801	8.0686	13.9605
	1.9533	3.4325	8.4079	12.3915	1.6161	4.5732	9.1564	15.7909
	2.0575	4.0894	11.3837	23.0694	1.4385	3.0366	5.4708	20.5882
	3.1892	2.4549	10.6047	17.6381	2.4714	4.262	7.4807	15.842
123	1.2975	25.5909	14.0926	35.2979	2.1101	20.0954	11.3843	31.5358
	3.7385	2.8046	9.3475	23.0907	4.1231	4.2684	7.5514	22.1515
	2.3148	3.9496	10.2585	25.4896	2.1735	6.0908	8.4719	19.2112
	1.4643	2.8827	13.6675	40.0911	1.8462	5.2044	10.3447	39.2491
	2.8216	3.6791	12.6232	26.1685	2.8905	5.5022	10.0812	23.4994
124	3.332	15.5262	22.7083	32.8277	2.7029	18.153	24.0629	30.3956
	6.9175	6.2375	19.097	33.8638	7.1495	7.0622	18.1857	30.686
	3.0937	8.7349	19.5527	32.1222	3.5414	12.0981	17.6566	23.7442
	3.5816	2.3316	21.7153	38.2918	3.2142	12.3029	19.9639	37.9948
	4.1102	6.1956	22.0477	32.923	4.0832	9.6444	20.2934	28.2844
125	1.9852	15.91	27.6979	34.8262	3.2378	33.2582	26.0661	30.873
	5.7967	4.1573	20.3055	35.0151	5.3287	7.8517	19.8604	31.7047
	3.2187	5.6512	21.2007	32.6491	3.7151	10.7708	19.0954	23.8436
	2.6007	3.4228	24.1047	38.2801	2.5142	14.2995	21.2016	37.5451
	3.6179	5.5883	24.0824	33.4586	4.5262	8.9893	21.8676	28.4582

Analisando a Tabela 4.23, observa-se uma tendência de agravamento de desempenho ao longo dos treinos, sendo o treino 121 aquele que demonstrou melhor desempenho global (análise visual baseada nas cores de cada célula). Com auxílio dos gráficos presentes no Anexo B.3 é possível afirmar que o treino que gerou melhor resultado foi o treino 121 para o conjunto de dados com tempo uniformizados normalizados. O valor do parâmetro *batch* do treino com índice 121 é de 50, tal como representado na Tabela 4.13.

Para o parâmetro *Gradient threshold*, foram realizados 6 treinos com os seguintes valores: 0.001, 0.01, 0.1, 0.5, 0.8, 1. Na Tabela 4.24 encontram-se os valores de RMSE dos treinos.

Tabela 4.24: Valores RMSE-Parâmetro *Gradient threshol*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
131	5.4352	17.4954	31.2707	34.0452	6.4265	28.6206	27.3883	30.3958
	3.6093	5.6838	26.7504	35.8043	5.2723	24.6556	24.7001	30.0502
	2.8281	10.3293	26.3967	33.076	5.2091	11.5213	21.7982	23.3043
	5.2291	4.1605	27.0824	38.5827	4.9741	12.8064	22.2362	37.3542
	4.6839	7.0864	28.5402	33.2637	5.1215	12.0507	24.1236	27.9174
132	4.4819	14.6124	26.8897	33.1835	4.2689	13.2247	25.3483	29.7961
	3.9913	5.9986	21.1274	33.0804	5.0723	8.5066	20.7502	31.0387
	3.2852	14.8782	21.4086	30.9421	2.3228	12.1017	19.3278	23.8214
	5.1012	5.2883	23.4134	38.2494	3.5138	10.7921	20.6653	37.2469
	4.9096	7.6217	23.9519	31.9923	6.8977	9.6077	21.8416	28.3622
133	3.9336	22.1945	27.0782	33.8762	5.7387	18.3543	25.2462	29.331
	5.6128	5.7649	21.0858	32.9487	8.3661	15.1344	19.2551	29.6498
	3.9589	10.8037	21.1462	31.9956	3.7057	8.8475	18.4977	22.8512
	3.6531	4.3486	23.3943	38.6829	4.9877	19.7545	20.8555	37.7709
	5.6085	6.6452	23.9742	32.5762	5.3611	13.0896	21.2156	27.2704
134	1.9409	64.9561	26.6984	34.0015	5.6375	20.0416	24.4748	30.3775
	6.1473	3.7272	19.8391	33.9793	5.068	10.6486	17.4927	29.3296
	3.5735	7.3965	20.6944	31.5	3.8835	13.3962	17.2515	22.386
	4.539	2.9951	23.3821	38.2257	3.9564	16.4489	20.3016	38.0331
	4.227	5.8289	23.3268	32.4051	4.4222	12.7921	20.1656	27.5115
135	3.133	15.8661	26.5707	33.3521	3.0943	20.1536	27.0291	30.0003
	5.3317	4.6706	19.3847	32.2427	4.7139	13.3189	18.9278	31.5183
	2.6339	7.141	20.2182	32.2831	3.5874	12.7792	19.1141	24.5639
	3.039	4.385	23.1941	38.9307	4.2151	14.4382	22.3573	37.51
	3.8351	5.4479	23.184	32.5401	4.4433	11.1815	22.1904	28.7944
136	3.5823	16.286	30.2887	34.2065	4.8927	16.5762	25.7232	30.393
	6.8047	4.4864	21.4943	34.097	4.0292	9.9953	18.0261	30.5058
	2.4906	7.1939	23.3659	32.2513	3.0294	8.5121	17.978	23.286
	3.2543	4.3693	26.687	38.601	4.8603	7.856	21.2468	38.0869
	3.9155	5.9129	26.1931	32.939	4.6153	9.3628	21.0548	27.9389

Analisando a Tabela 4.24 e nos gráficos presentes no Anexo B.4, ao contrário do anteriormente observado nos diferentes treinos, neste não é possível observar uma tendência de melhoria ou de agravamento. No entanto vão ser considerados os valores que produziram os melhores resultados para os conjuntos de dados com tempo normalizados e com tempo uniformizados normalizados.

Para o parâmetro *Initial learning rate*, foram realizados 6 treinos com os seguintes valores: 0.00001, 0.0001, 0.001, 0.01, 0.1, 1. Na Tabela 4.25 encontram-se os valores de RMSE dos treinos.

Tabela 4.25: Valores RMSE-Parâmetro *Initial learning rate*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
141	9.6595	25.0563	146.1649	141.4549	16.302	27.9538	132.0544	126.8128
	4.8941	21.1734	160.396	146.8249	12.9311	23.9662	142.8404	136.1517
	7.8001	23.9243	151.8596	156.4446	17.7835	22.5858	127.6773	115.655
	9.3255	37.3942	143.7022	146.3943	13.2405	39.6196	122.9184	142.8203
	9.6038	23.0997	151.0606	149.2816	15.7577	25.9422	129.8726	128.9133
142	4.8936	15.1151	118.8863	112.3106	9.4929	31.5104	109.1642	100.7166
	8.0366	14.1031	131.5925	119.0033	7.5844	20.0404	119.1201	110.1221
	5.3197	23.8743	124.3409	127.7055	7.6749	24.2725	106.2469	94.3935
	4.0364	20.3768	116.059	117.7113	9.6099	32.4081	100.8494	115.2591
	7.0123	16.0408	123.3761	120.9976	9.4881	20.2661	107.6363	104.3482
143	4.1209	17.3426	86.1415	77.1399	5.5995	22.4315	78.1983	69.9405
	4.1346	7.2847	97.0538	84.1172	8.0324	11.8085	86.933	78.6161
	3.0918	21.0507	90.3765	91.5448	4.672	10.7807	76.3596	68.3278
	6.4147	3.7368	82.7248	82.5186	3.5524	22.2035	71.0285	81.6349
	4.9898	9.4303	89.8277	85.396	5.123	13.1466	77.4781	74.3815
144	1.4827	13.0306	5.1182	39.8338	1.7885	21.939	3.4879	15.6917
	3.3087	2.378	6.6615	15.542	3.4261	5.1705	6.6506	10.9488
	2.1016	3.8945	4.5342	20.8506	2.1504	8.9553	3.6854	15.1485
	3.0361	2.9102	4.1117	40.3125	1.6623	4.629	2.5229	12.5774
	3.0518	5.7333	5.8958	22.5953	2.8904	5.7676	5.1026	11.3416
145	NaN	NaN	NaN	31.9712	NaN	NaN	6.0301	28.5809
	NaN	NaN	NaN	34.1521	NaN	NaN	11.4708	15.2812
	NaN	NaN	NaN	26.3204	NaN	NaN	5.9783	17.071
	NaN	NaN	NaN	41.512	NaN	NaN	6.3621	36.2592
	NaN	NaN	NaN	31.2316	NaN	NaN	7.0294	20.6136
146	NaN	NaN	13.0863	NaN	NaN	NaN	10.3453	26.1347
	NaN	NaN	21.2882	NaN	NaN	NaN	16.6643	32.0324
	NaN	NaN	23.5998	NaN	NaN	NaN	12.1615	36.7825
	NaN	NaN	17.0427	NaN	NaN	NaN	10.0858	43.0565
	NaN	NaN	21.8667	NaN	NaN	NaN	12.0199	33.0326

Analisando a Tabela 4.25 bem como os gráficos presentes no Anexo B.5, observa-se uma tendência de melhoria ao longo dos treinos, no entanto, nos dois últimos treinos a rede não foi capaz de gerar resultados para todos os conjuntos de dados. Nesta situação conclui-se que o melhor valor para o parâmetro *initial learning rate* é de 0.01 que corresponde ao treino 144 (Tabela 4.13).

Para o parâmetro *Validation frequency*, foram realizados 5 treinos com os seguintes valores: 50, 40, 30, 20, 10. Na Tabela 4.26 encontram-se os valores de RMSE dos treinos.

Tabela 4.26: Valores RMSE-Parâmetro *Validation frequency*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
151	4.0483	19.8718	25.0204	34.3499	8.0335	22.0284	22.4439	30.7987
	3.9765	4.1417	20.5913	34.2957	4.3766	7.5475	16.3008	30.2117
	2.0649	7.1282	20.0316	32.7961	4.8457	10.7185	15.8858	23.6721
	4.806	4.4254	21.5703	38.5038	7.7948	11.214	18.758	37.2821
	4.5775	5.3523	22.5522	33.1554	7.4704	11.3105	18.6431	28.0632
152	3.1489	13.4497	27.8734	33.929	4.2998	27.2115	25.0376	28.5978
	9.9447	3.2255	22.4582	32.3864	4.9215	7.4242	17.8083	28.1309
	3.1057	6.9869	22.3045	31.1398	2.5941	10.3354	17.6598	23.0583
	3.3135	2.8055	23.9102	39.3174	3.9662	11.4704	20.6749	38.7475
	4.334	5.4918	24.9093	32.2088	4.2362	9.411	20.6627	27.6247
153	3.3168	9.0691	30.1294	30.3673	3.3848	17.8084	25.7766	29.4325
	5.6636	4.8487	21.9613	32.4595	6.8998	12.62	17.8613	30.4109
	2.7018	9.4327	23.0693	32.0397	3.6364	12.6043	18.118	22.7846
	4.8117	4.0663	26.0726	38.6995	3.0469	9.667	21.327	37.8549
	4.6737	5.6085	26.0871	32.4254	4.4216	11.5437	21.012	27.6663
154	1.939	15.6831	29.5811	32.6621	3.2167	43.4887	23.8065	28.2375
	5.5798	4.2419	21.0227	31.2116	6.1956	11.8727	17.9875	31.1236
	3.5196	7.6805	22.3086	31.3186	4.4657	8.1061	17.4102	24.5384
	3.3574	3.5855	25.8424	35.6032	4.4155	12.641	19.7514	37.9937
	3.8296	5.37	25.411	31.348	4.599	10.8445	19.9874	28.755
155	1.955	16.9569	26.2561	34.4153	4.4683	17.5621	22.8594	30.4247
	5.0531	5.2885	19.0207	34.1637	6.9944	10.2719	16.7669	28.7941
	2.2542	9.7826	19.8388	32.3987	2.7341	7.2528	16.2978	22.5895
	3.9152	4.5686	22.9769	38.5455	3.2993	11.6408	18.9546	38.2176
	4.2473	6.4182	22.8672	33.1967	4.692	10.4494	19.0502	27.2422

Na Tabela 4.26 e nos gráficos do Anexo B.6, é possível observar que não existe nenhum treino com um desempenho superior face aos restantes. Neste caso a validação não revelou qualquer melhoria no desempenho da rede, portanto, este parâmetro poderá ser desprezado caso o próximo (*Validation patiente*) também não demonstre qualquer tipo de melhoria.

Para o parâmetro *Validation patiente*, foram realizados 4 treinos com os seguintes valores: 10, 100, 1000, 10000. Na Tabela 4.27 encontram-se os valores de RMSE dos treinos.

Tabela 4.27: Valores RMSE-Parâmetro *Validation patiente*-Análise dos parâmetros

Dados	dados com tempo normalizados	dados sem tempo normalizados	dados com tempo	dados sem tempo	dados com tempo uniformizados normalizados	dados sem tempo uniformizados normalizados	dados com tempo uniformizados	dados sem tempo uniformizados
161	2.5453	11.9414	30.3374	34.1321	1.9119	23.8515	24.8022	30.6785
	5.7039	6.1522	21.3133	33.019	6.0589	8.1343	17.2666	30.2239
	3.1468	13.2601	23.0051	31.7192	3.4997	14.3672	17.4609	22.996
	4.6134	4.7385	26.5943	39.1201	3.3029	8.3657	20.6452	37.5068
	4.2118	7.1773	26.1343	32.551	4.0402	9.9786	20.3516	27.8234
162	2.2615	17.5505	28.7817	35.0443	3.956	27.8528	25.3184	30.489
	5.3358	5.8083	20.593	32.224	5.8255	8.5754	18.1186	29.7813
	3.4679	8.6305	21.8988	31.3051	3.4739	9.2381	17.8543	23.3465
	3.7711	5.338	25.0409	38.6584	3.2135	19.8234	20.8417	37.9213
	4.1699	6.2235	24.752	31.99	4.214	11.428	20.9242	27.8611
163	2.5202	27.6853	29.1669	33.877	3.2775	39.0601	25.7365	30.1168
	7.1385	4.7949	20.7482	31.8339	3.29	7.228	18.7893	30.721
	3.4049	7.1825	22.2246	32.1391	2.6371	16.5604	18.5695	23.5674
	5.25	4.0654	25.522	39.8296	3.3149	25.8845	21.1899	37.4692
	4.4727	6.3618	25.185	32.4789	4.0974	12.9679	21.376	28.1766
164	3.7651	23.23125	28.259	32.9735	3.5958	29.0481	25.6077	29.9522
	4.8935	6.1065	20.0609	32.0285	5.6013	11.8308	18.1927	29.4886
	2.1426	6.2256	21.4137	31.5625	3.9466	12.632	18.2913	22.5168
	4.0308	5.6052	24.7529	38.3747	4.2423	11.6811	21.2057	37.7798
	4.3121	7.4652	24.3936	32.1121	4.9322	11.0095	21.164	27.3614

À semelhança do observado no caso anterior, na Tabela 4.27 e no Anexo B.7, nenhum treino demonstrou uma melhoria de desempenho, pelo que se pode concluir

que neste caso os parâmetros relativos à validação podem ser omitidos dos treinos. Escolhida a rede foram realizados variados treinos de forma a definir os melhores parâmetros. Por fim foi realizada uma conclusão de forma a resumir o comportamento das redes e dos parâmetros treinados.

4.5 Rede final

Com base na análise realizada na secção anterior, foram definidos alguns conjuntos de parâmetros que seriam capazes de gerar os melhores resultados possíveis. Na Tabela 4.28 encontram-se representados os conjuntos de parâmetros usados para os treinos finais.

Tabela 4.28: Parâmetros de treino finais para LSTM

Index	Training method	Hidden units	Epochs	Batch size	Gradient treshold	Initial learn rate
301	adam	150	400	50	0.5	0.01
302	adam	150	400	50	0.8	0.01
303	adam	150	400	1	0.5	0.01
304	adam	150	450	1	0.5	0.01
305	adam	150	500	1	0.5	0.01
306	adam	150	400	1	0.8	0.01

Para o treino dos parâmetros referidos foram apenas utilizados os dados com tempo normalizados e os dados com tempo uniformizados normalizados, tal como concluído na secção 4.4.1. Os resultados obtidos dos treinos dos parâmetros referidos estão expostos nas Tabelas 4.29 e 4.30.

Tabela 4.29: Valores RMSE-Treinos Finais-Análise dos parâmetros

Dados		dados com tempo normalizados	dados com tempo uniformizados normalizados
301	a	0.82786	1.1274
	b	1.7879	1.4451
	c	0.84537	1.2006
	d	0.66114	0.9941
	médio	1.5337	1.7268
302	a	0.7932	1.3572
	b	1.3104	2.1671
	c	0.5843	1.0398
	d	1.5321	1.3376
	médio	1.5321	1.9664
303	a	1.2122	3.7512
	b	3.077	2.4043
	c	1.215	2.5431
	d	2.1946	2.5599
	médio	2.66858	3.5506
304	a	3.6778	5.9076
	b	6.7109	5.4455
	c	3.649	2.4639
	d	4.1755	4.5805
	médio	4.5347	4.0685
305	a	2.2145	NaN
	b	7.0356	NaN
	c	1.6421	NaN
	d	1.2423	NaN
	médio	2.967	NaN
306	a	1.7953	1.6863
	b	2.2511	3.1191
	c	0.8333	1.2814
	d	1.5818	2.1201
	médio	2.7367	2.7235

Tabela 4.30: Valores RMSE-Treinos finais-Análise dos parâmetros

Dados		dados com tempo normalizados	dados com tempo uniformizados normalizados
301	a	0.82786	1.1274
	b	1.7879	1.4451
	c	0.84537	1.2006
	d	0.66114	0.9941
	médio	1.5337	1.7268
302	a	0.7932	1.3572
	b	1.3104	2.1671
	c	0.5843	1.0398
	d	1.5321	1.3376
	médio	1.5321	1.9664
303	a	1.2122	3.7512
	b	3.077	2.4043
	c	1.215	2.5431
	d	2.1946	2.5599
	médio	2.66858	3.5506
304	a	3.6778	5.9076
	b	6.7109	5.4455
	c	3.649	2.4639
	d	4.1755	4.5805
	médio	4.5347	4.0685
305	a	2.2145	NaN
	b	7.0356	NaN
	c	1.6421	NaN
	d	1.2423	NaN
	médio	2.967	NaN
306	a	1.7953	1.6863
	b	2.2511	3.1191
	c	0.8333	1.2814
	d	1.5818	2.1201
	médio	2.7367	2.7235

De forma a facilitar a análise dos resultados foi gerado um gráfico de barras com os valores de RMSE médio de cada treino (Figura 4.10).




Figura 4.10: Gráfico de barras parcial dos resultados dos treinos relativos aos treinos 301 a 306

Realizando uma análise às tabelas e ao gráfico, é possível constatar que, os melhores resultados foram obtidos com os dados com tempo normalizados e com os parâmetros de treino 301 e 302. Comparando os resultados obtidos nos treinos 303, 304 e 305, é possível concluir que, o melhor valor para o parâmetro *epochs* será de 400, valor usado nos treinos 301 e 302. Entre os treinos 303 e 306, a diferença entre os parâmetros, observa-se apenas no *gradient threshold*, sendo o treino 303 aquele com um desempenho superior, em que o melhor valor para o parâmetro será de 0.5. Estando os treinos 301 e 302 bastantes semelhantes, a escolha dos parâmetros, relativos ao treino 301, como parâmetros ideais, deve-se à análise dos restantes treinos desta secção. A Figura 4.11 demonstra 4 resultados do treino 301, onde se pode observar que, as duas curvas (curva de temperatura real e curva de temperatura gerada) são praticamente coincidentes à exceção de um gráfico que é possível observar uma pequena discrepância.




Figura 4.11: Gráficos dos 4 primeiros resultados do treino 301

Em suma, os melhores parâmetros encontrados, para realizar o treino da rede neuronal LSTM, que simula, a curva de temperatura gerada por um torrador, durante o processo de torrefação são os seguintes:

- *Hidden units* : 150;
- *Epochs* : 400;
- *Batch size* : 50;
- *Gradient treshold* : 0.5;
- *Initial learning rate* : 0.01.

4.6 Conclusões

É possível depreender que das três redes analisadas a LSTM foi aquela que demonstrou melhores resultados com possibilidade de melhoria. Com os treinos realizados, conclui-se que, os parâmetros *hidden units*, *epochs*, *batch size* e *initial learning rate* foram aqueles que demonstraram possuir um impacto superior no desempenho da rede. Enquanto que os parâmetros *gradient treshold*, *Validation frequency* e *Validation patiente* não revelaram grande importância na influência do desempenho da rede. O parâmetro *batch size*, com o aumento do seu valor demonstrou piores resultados, no entanto, o tempo de treino de rede reduz significativamente. Mediante

os resultados pretendidos pode ser preferível aumentar o erro da rede em prol da diminuição do tempo de treino. De notar que as exigências computacionais deste parâmetro aumentam significativamente com o aumento do seu valor.

Capítulo 5

Conclusões

No início desta dissertação, foram estudados alguns temas necessários ao desenvolvimento da mesma. O estudo do café, das suas propriedades bem como a constituição dos torradores, o respetivo modo de funcionamento e como é que o café se comporta durante o processo de torrefação, são essenciais, para a compreensão do problema, bem como, entender as diferentes abordagens e o impacto que produziriam no sistema.

No processo de torrefação existem várias variáveis que têm impacto no modo de funcionamento do torrador bem como no café produzido. Os torradores com que a empresa trabalha possuem apenas sonda de temperatura dentro do tambor para obtenção do valor de temperatura do café e do ar e exaustão. De forma a ser possível criar um simulador mais preciso seriam necessárias mais sensores para obter informações dos restantes elementos que influenciam a torra. Os elementos que podem influenciar a torra são a temperatura e humidade exterior (consequentes do clima da localização em que se encontra), o tipo do grão de café, bem como o seu tamanho e humidade. Outra questão é a relação que, existe entre a potência do queimador e a sua capacidade de aquecer o ar de entrada. Esta relação é variável entre os torradores, pois depende do tipo de gás usado bem como do tipo e modelo de queimador usado.

O estudo da Inteligência Artificial e dos seus campos é fulcral ao desenvolvimento desta dissertação pois todo o desenvolvimento se baseia na mesma. A compreensão da AI e dos seus sub-campos não foi uma tarefa fácil tendo em conta a elevada complexidade do tema. A descoberta de que algoritmos de DL existem e quais fariam

sentido testar no trabalho mostrou-se uma tarefa bastante árdua pela inexperiência e falta de conhecimento total da área. Apesar das barreiras encontradas foi possível identificar alguns tipos de redes neurais que poderiam se adequar ao sistema.

O desenvolvimento e teste dos algoritmos mostrou ser um processo bastante moroso, o qual requer um elevado poder computacional. A falta de tecnologia de ponta fez com que os processos de teste e obtenção de resultados se prolongassem por várias horas até à obtenção de um único resultado. Qualquer erro no desenvolvimento do algoritmo resultava numa perda total de todos os resultados obtidos até ao momento.

Não obstante de todas as complicações foi possível obter resultados favoráveis. No final obteve-se uma rede neuronal LSTM capaz de gerar a curva de temperatura do torrador com um erro aceitável. Este estudo de utilização de inteligência artificial para simulação do funcionamento de um torrador, revelou-se bastante proveitoso. Novas abordagens para a implementação da inteligência artificial no processo de torrefação encontram-se em avaliação.

No futuro, pretende-se implementar o algoritmo no programa Brigus desenvolvido pela M de Máquina. Este algoritmo, terá a capacidade de auxiliar o mestre de torra no processo de criação de receitas e de ajustes nas mesmas, gerando a curva de temperatura o mais aproximada possível à real.

Referências

- [1] “The discovery of coffee: the legend of Kaldi.” Disponível em <https://www.compatible-capsules.com/coffee-culture/discovery-of-coffee-legend-of-kaldi/>, Abr 2005. (Acedido em 2021-09-28). [Citado nas páginas ix e 8]
- [2] “Planta do café.” Disponível em <https://www.coffeelover.com.br/cafe-arabica-e-cafe-robusta-qual-diferenca/>. (Acedido em 2019-07-25). [Citado nas páginas ix e 8]
- [3] “As primeiras cafeterias europeias.” Disponível em <https://100anos100fatos.com.br/fatos/first-european-coffee-shops-established-armenians/>. (Acedido em 2021-09-28). [Citado nas páginas ix e 9]
- [4] “Festa do chá de boston.” Disponível em https://pt.wikipedia.org/w/index.php?title=Festa_do_Ch%C3%A1_de_Boston&oldid=62108542, Set 2021. (Acedido em 2021-09-28). [Citado nas páginas ix e 10]
- [5] “Coffee family tree.” Disponível em https://www.esseloncoffee.com/coffee-terminology/coffee-family-tree/?doing_wp_cron=1633622004.5844841003417968750000. (Acedido em 2021-10-07). [Citado nas páginas ix e 11]
- [6] “Robusta coffee and arabica coffee: What’s the difference? news.” Disponível em <https://asiacom.vn/robusta-coffee-and-arabica-coffee-whats-difference/>. (Acedido em 2021-10-07). [Citado nas páginas ix e 11]
- [7] “Plantação de café aéreo no estado de São Paulo - Brasil - gráficos de vetor.” Disponível em <https://br.depositphotos.com/147102021/stock-video-aerial-coffee-plantation-in-sao.html>. (Acedido em 2019-07-25). [Citado nas páginas ix e 13]
- [8] “Delta cafés.” Disponível em Available:<http://www.deltacafes.pt/pt/o-cafe-da-planta-a-chavena/planta>. (Acedido em 2019-07-25). [Citado nas páginas ix, 12, 13, 14 e 15]
- [9] “¿son los cursos universitarios el futuro de la educación en café?.” Disponível em <https://perfectdailygrind.com/es/2016/12/14/>

- son-los-cursos-universitarios-el-futuro-de-la-educacion-en-cafe/. (Acedido em 2021-10-07). [Citado nas páginas ix, 14 e 15]
- [10] “Moisture of green coffee beans.” Disponível em <https://www.giesencoffeeroasters.eu/moisture-of-green-coffee-beans/>. (Acedido em 2021-09-28). [Citado nas páginas ix e 16]
- [11] “4 types of coffee roasts explained with images.” Disponível em <https://coffeeaffection.com/types-of-coffee-roasts/>. (Acedido em 2021-09-28). [Citado nas páginas ix, 18, 19, 20 e 21]
- [12] R. Muinhos, “A ciência da torra.” Disponível em <http://buenavistacafe.com.br/blog/2017/01/18/a-ciencia-da-torra/>. (Acedido em 2019-07-25). [Citado nas páginas ix, 22 e 26]
- [13] “Crm-30 - joper roasters the best technology for coffee industry.” Disponível em <https://joper-roasters.com/product/crm-30/>. (Acedido em 2021-09-28). [Citado nas páginas ix e 23]
- [14] “(31) pinterest.” Disponível em <https://www.pinterest.pt/chihtsunglee/roasters-coffee/>. (Acedido em 2021-09-28). [Citado nas páginas ix e 24]
- [15] “3kg coffee roaster for sale | midium coffee roaster machine.” Disponível em <https://shopcoffeeroasters.com/product/zd-3kg-coffee-roaster-for-sale/>. (Acedido em 2021-08-30). [Citado nas páginas ix e 25]
- [16] “Alan turing.” Disponível em https://pt.wikipedia.org/wiki/Alan_Turing. (Acedido em 2022-02-22). [Citado nas páginas ix e 30]
- [17] “Runaround by isaac asimov.” Disponível em <https://www.goodreads.com/book/show/48928553-runaround>. (Acedido em 2022-02-22). [Citado nas páginas ix e 31]
- [18] “Eliza.” Disponível em <https://stringfixer.com/pt/ELIZA>. (Acedido em 2022-02-22). [Citado nas páginas ix e 32]
- [19] “Darpa.” Disponível em <https://stringfixer.com/pt/DARPA>. (Acedido em 2022-02-22). [Citado nas páginas ix e 33]
- [20] A. Arbuckle, “20 years ago, a computer first beat a chess world champion.” Disponível em <https://mashable.com/archive/kasparov-deep-blue#dxBEd4gvHEqH>, 02 2016. (Acedido em 2022-02-22). [Citado nas páginas ix e 34]
- [21] J. Hurwitz and D. Kirsch, eds., *Machine Learning For Dummies®*, IBM Limited Edition. John Wiley Sons, Inc., 2018. [Citado nas páginas ix, 36, 37 e 38]

-
- [22] M. H. B. O. D. J. Martin T. Hagan, Howard B. Demuth, *Neural Network Design, 2nd Edition, eBook*. [Citado nas páginas x, 39, 40 e 41]
- [23] I. C. Education, “Recurrent neural networks.” Disponível em <https://www.ibm.com/cloud/learn/recurrent-neural-networks>, 09 2020. (Acedido em 2022-03-12). [Citado nas páginas x, 41, 42 e 43]
- [24] M. Z. e Ruhui Zhang e Cheng Lin e Hui Zhou e Junhui Shi, “Stochastic model predictive control for dual-motor battery electric bus based on signed markov chain monte carlo method.” Disponível em https://www.researchgate.net/figure/The-architecture-of-NARX-neural-networks_fig3_342616647. (Acedido em 2022-04-06). [Citado nas páginas x e 55]
- [25] “The history of coffee.” Disponível em <https://www.ncausa.org/About-Coffee/History-of-Coffee>. (Acedido em 2021-06-22). [Citado na página 10]
- [26] “10 steps from seed to cup.” Disponível em <https://www.ncausa.org/About-Coffee/10-Steps-from-Seed-to-Cup>. (Acedido em 2021-10-07). [Citado nas páginas 13, 14 e 15]
- [27] “Desde a planta ate à chávena.” Disponível em <https://www.delonghi.com/pt-pt/produtos/cafe/cultura-do-cafe/processo-da-producao-de-cafe>. (Acedido em 2019-07-25). [Citado na página 14]
- [28] “8 best home coffee roasters..” Disponível em <https://www.roastycoffee.com/home-coffee-roasters/>. (Acedido em 2019-07-25). [Citado na página 22]
- [29] “Toper 60kg industrial coffee roaster.” Disponível em <https://topercoffeeroasters.co.uk/products/toper-60kg-industrial-coffee-roaster>. (Acedido em 2021-10-08). [Citado na página 22]
- [30] “Roasting equipment - giesen coffee roasters - introducing our roasting equipment.” Disponível em <https://www.giesencoffeeroasters.eu/roasting-equipment/>. (Acedido em 2021-09-28). [Citado na página 24]
- [31] “Cyclone separator - construction and working.” Disponível em <https://solutionpharmacy.in/cyclone-separator/>. (Acedido em 2021-09-28). [Citado na página 24]
- [32] “Coffee roaster machine control panel.” Disponível em <https://www.shutterstock.com/image-photo/coffee-roaster-machine-control-panel-various-1043724790>. (Acedido em 2021-09-28). [Citado na página 26]

-
- [33] “Genio 15 precision - genio roasters.” Disponível em <https://genioroasters.co.za/products/genio-15-precision/>. (Acedido em 2021-08-31). [Citado na página 26]
- [34] J. McCarthy, “What is artificial intelligence?,” *Stanford University*, 2007. [Citado nas páginas 29 e 30]
- [35] I. C. Education, “Artificial intelligence (ai).” Disponível em <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>, 07 2020. (Acedido em 2021-11-24). [Citado nas páginas 30, 32 e 35]
- [36] R. Anyoha, “The history of artificial intelligence.” Disponível em <https://sitn.hms.harvard.edu/flash/2017/history-artificial-intelligence/>, 8 2017. (Acedido em 2022-01-13). [Citado na página 34]
- [37] P. Ongsulee, “Artificial intelligence, machine learning and deep learning,” 2017. [Citado na página 36]
- [38] P. P. Shinde and D. S. Shah, “A review of machine learning and deep learning applications,” 2018. [Citado na página 38]
- [39] I. C. Education, “Neural networks.” Disponível em <https://www.ibm.com/cloud/learn/neural-networks#toc-history-of-rIfu5uF2>, 08 2020. (Acedido em 2022-03-10). [Citado nas páginas 38 e 43]

Anexo A

Códigos de programação

A.1 Código Python para filtragem de ficheiros

```
1 import pandas as pd
2 import numpy as np
3 import os
4 #ISO-8859-1
5 k=int(0)
6 values_to_add = {'time':0,'temp':0,'ror':0,'burner':0,'fan':0,'air':0}
7 for i in range(1237):
8     filename= "C:\\Users\\MdeMaquina\\Documents\\dados_torras_edit\\Data_roasts_processing_data\\Data_separation_original_1\\Torr faction "+str(i)+".csv"
9     newpath="C:\\Users\\MdeMaquina\\Documents\\dados_torras_edit\\Data_roasts_processing_data\\Data_separation_original_1\\bad_files\\Torr faction "+str(i)+".csv"
10    treated = "C:\\Users\\MdeMaquina\\Documents\\dados_torras_edit\\Data_roasts_processing_data\\Data_separation_original_1\\treated\\Torr faction " + str(i) + ".csv"
11    try:
12        teste=pd.read_csv(filename,delimiter=';',encoding='ISO-8859-1',header=0, names=['time','temp','ror','burner','fan','air'])
13        ya=teste['burner']
14
```

```

15         for j in range(70,(len(ya)-120)):
16             a = ya[j]
17             a1 = ya[(j+5)]
18             a2 = ya[(j+10)]
19             a3 = ya[(j+15)]
20             a4 = ya[(j+20)]
21             a5 = ya[(j+25)]
22             a6 = ya[(j+30)]
23             a7 = ya[(j+35)]
24             a8 = ya[(j+40)]
25             a9 = ya[(j+45)]
26             a10 = ya[(j+50)]
27             b=a.strip()
28             if (a==a1==a2==a3==a4==a5==a6==a7==a8==a9==a10) and b!=
                '100':
29                 print("File not usable-",i,"--",j,"--",a,a1,a2,a3,
                    a4,a5,a6,a7,a8,a9,a10,"-",b,"-")
30                 os.replace(filename, newpath)
31                 k=k+1
32             break
33
34
35         for r in range(1230-(len(ya))):
36             teste = teste.append(values_to_add, ignore_index=True)
37             teste.to_csv(path_or_buf=treated, sep=';', header=False,
                index=False, encoding='utf-8')
38             print(i)
39
40     except:
41         print("failed to load file",i)
42
43     print("not usable",k)

```

A.2 Código MATLAB de importação dos dados com tempo

```

1 % Importa o dos ficheiros de dados
2 function import_com_tempo(actual)
3 % Directorio com ficheiros de dados
4 %actual=cd;
5 add_1='\dados_originais';
6 add_2='\ficheiros_mat';
7 dados=strcat(actual,add_1);
8 export=strcat(actual,add_2);
9 cd (dados);

```

```

10 % Dados de teste 15%
11 index=linspace(0,1000,150);
12 index=round(index);
13 index_treino=0;
14 index_teste=0;
15 %%
16 % Dados de Treino e Teste com escala de tempo
17 files = dir('*.csv');
18 for k = 1:numel(files);
19     filename=files(k).name;
20     T1 = readtable(filename);
21     %altera o dos cabe alhos da tabela
22     T1.Properties.VariableNames = {'time' 'bean' 'ror' 'burner' '
        fan' 'air'};
23     %remo o de variav is desnecess rias
24     T2 = removevars(T1,{'ror' 'air'});
25     %convers o do tipo da coluna do tempo
26     T2.time=datetime(T2.time);
27     %convers o do tempo de HH:MM:SS para segundos
28     Tb=1:height(T1);
29     Tc=Tb';
30     Td=array2table(Tc);
31     %modifica o dos valores na tabela 2
32     T2(:,1)=Td;
33
34     ta=T2(:,1);
35     tb=T2(:,2);
36     tc=T2(:,3);
37     td=T2(:,4);
38
39     ta=rows2vars(ta);
40     tb=rows2vars(tb);
41     tc=rows2vars(tc);
42     td=rows2vars(td);
43
44     ta = removevars(ta,{'OriginalVariableNames'}); %1
45     tb = removevars(tb,{'OriginalVariableNames'}); %2
46     tc = removevars(tc,{'OriginalVariableNames'}); %3
47     td = removevars(td,{'OriginalVariableNames'}); %4
48
49     % reconstru o das tabelas de dados
50     %input: tempo, temperatura gr o, ventoinha || output:%
        queimador
51     X_t=[ta;td;tb];
52     Y_t=[tc];
53     X_t= table2array(X_t);
54     Y_t= table2array(Y_t);
55     %input: tempo, % queimador, ventoinha || output: temperatura
        gr o

```

```

56     X1_t=[ta;td;tc];
57     Y1_t=[tb];
58     X1_t= table2array(X1_t);
59     Y1_t= table2array(Y1_t);
60     %dados de teste
61     if any(k==index)
62         index_teste=index_teste+1;
63         %vetor de dados
64         X_data_test{k-index_treino}= X_t;
65         Y_data_test{k-index_treino}= Y_t;
66         %vetor de dados
67         X1_data_test{k-index_treino}= X1_t;
68         Y1_data_test{k-index_treino}= Y1_t;
69     %Dados de treino
70     else
71         index_treino=index_treino+1;
72         %vetor de dados
73         X_data_train{k-index_teste}= X_t;
74         Y_data_train{k-index_teste}= Y_t;
75         %vetor de dados
76         X1_data_train{k-index_teste}= X1_t;
77         Y1_data_train{k-index_teste}= Y1_t;
78     end
79
80 end
81 %exporta o
82 if k==numel(files)
83     cd (export);
84     save('data_original_with_time','X_data_train','
        Y_data_train','X1_data_train','Y1_data_train','
        X_data_test','Y_data_test','X1_data_test','Y1_data_test
        ');
85 end
86 cd (actual);
87 end

```

A.3 Código MATLAB de importação dos dados sem tempo

```

1 % Importa o dos ficheiros de dados
2 function import_com_tempo(actual)
3 % Directorio com ficheiros de dados
4 add_1='\dados_originais';
5 add_2='\ficheiros_mat';
6 dados=strcat(actual,add_1);

```

```

7  export=strcat(actual,add_2);
8  cd (dados);
9  % Dados de teste 15%
10 index=linspace(1,1000,150);
11 index=round(index);
12 index_treino=0;
13 index_teste=0;
14 % Dados de Treino e Teste com escala de tempo
15 files = dir('*.csv')
16 for k = 1:numel(files);
17     filename=files(k).name;
18     T1 = readtable(filename);
19     %altera o dos cabe alhos da tabela
20     T1.Properties.VariableNames = {'time' 'bean' 'ror' 'burner' '
        fan' 'air'};
21     %remo o de variav is desnecess rias
22     T2 = removevars(T1,{'ror' 'air'});
23     %convers o do tipo da coluna do tempo
24     T2.time=datetime(T2.time);
25     %convers o do tempo de HH:MM:SS para segundos
26     Tb=1:height(T1);
27     Tc=Tb';
28     Td=array2table(Tc);
29     %modifica o dos valores na tabela 2
30     T2(:,1)=Td;
31
32     ta=T2(:,1);
33     tb=T2(:,2);
34     tc=T2(:,3);
35     td=T2(:,4);
36
37     ta=rows2vars(ta);
38     tb=rows2vars(tb);
39     tc=rows2vars(tc);
40     td=rows2vars(td);
41
42     ta = removevars(ta,{'OriginalVariableNames'}); %1
43     tb = removevars(tb,{'OriginalVariableNames'}); %2
44     tc = removevars(tc,{'OriginalVariableNames'}); %3
45     td = removevars(td,{'OriginalVariableNames'}); %4
46
47     % reconstru o das tabelas de dados
48     %input: tempo, temperatura gr o, ventoinha || output:%
        queimador
49     X_t=[td;tb];
50     Y_t=[tc];
51     X_t= table2array(X_t);
52     Y_t= table2array(Y_t);

```

```

53      %input: tempo, % queimador, ventoinha || output: temperatura
        gr o
54      X1_t=[td;tc];
55      Y1_t=[tb];
56      X1_t= table2array(X1_t);
57      Y1_t= table2array(Y1_t);
58      %dados de teste
59      if any(k==index)
60          index_teste=index_teste+1;
61          %vetor de dados
62          X_data_test{k-index_treino}= X_t;
63          Y_data_test{k-index_treino}= Y_t;
64          %vetor de dados
65          X1_data_test{k-index_treino}= X1_t;
66          Y1_data_test{k-index_treino}= Y1_t;
67      %Dados de treino
68      else
69          index_treino=index_treino+1;
70          %vetor de dados
71          X_data_train{k-index_teste}= X_t;
72          Y_data_train{k-index_teste}= Y_t;
73          %vetor de dados
74          X1_data_train{k-index_teste}= X1_t;
75          Y1_data_train{k-index_teste}= Y1_t;
76      end
77
78  end
79  %exporta o
80  if k==numel(files)
81      cd (export);
82      save('data_original_without_time','X_data_train','
          Y_data_train','X1_data_train','Y1_data_train','
          X_data_test','Y_data_test','X1_data_test','Y1_data_test
          ');
83  end
84  cd (actual);
85  end

```

A.4 Código MATLAB para uniformização dos dados

```

1  function manual_padding(actual)
2  % Diretorio com ficheiros de dados
3  actual=cd;
4  path=strcat(cd,'\dados_originais');
5  export=strcat(cd,'\ficheiros_mat');
6  cd (path);

```

```

 7 % data max size
 8 files = dir('*.csv');
 9 max=0;
10 for k = 1:numel(files);
11     filename=files(k).name;
12     T1 = readtable(filename);
13     %altera o
14     tb=T1(:,2);
15     if height(tb)>max;
16         max=height(tb)
17         k2=filename
18     end
19
20 end
21 % Padding
22 full_size=max+10;
23 for xy=1:2
24     if xy==1
25         try
26             cd (export);
27             load data_original_with_time
28         catch
29             warning('MANUAL PADDING:carregamento de
30                     data_original_with_time falhou!')
31             xy=2;
32         end
33     if xy==2
34         try
35             cd (export);
36             load data_original_without_time
37         catch
38             warning('MANUAL PADDING:carregamento de
39                     data_original_without_time falhou!')
40             return;
41         end
42     end
43     for k=1:length(X_data_train)
44         array_size= size(X_data_train{k});
45         C=X_data_train{k}
46         pad_size= full_size - array_size(2)
47         X_data_train{k}=padarray(C,[0 pad_size],0,'post')
48     end
49     for k=1:length(Y_data_train)
50         array_size= size(Y_data_train{k});
51         C=Y_data_train{k}
52         pad_size= full_size - array_size(2)
53         Y_data_train{k}=padarray(C,[0 pad_size],0,'post')

```

```

54     end
55     for k=1:length(X_data_test)
56         array_size= size(X_data_test{k});
57         C=X_data_test{k}
58         pad_size= full_size - array_size(2)
59         X_data_test{k}=padarray(C,[0 pad_size],0,'post')
60     end
61     for k=1:length(Y_data_test)
62         array_size= size(Y_data_test{k});
63         C=Y_data_test{k}
64         pad_size= full_size - array_size(2)
65         Y_data_test{k}=padarray(C,[0 pad_size],0,'post')
66     end
67     for k=1:length(X1_data_train)
68         array_size= size(X1_data_train{k});
69         C=X1_data_train{k}
70         pad_size= full_size - array_size(2)
71         X1_data_train{k}=padarray(C,[0 pad_size],0,'post')
72     end
73     for k=1:length(Y1_data_train)
74         array_size= size(Y1_data_train{k});
75         C=Y1_data_train{k}
76         pad_size= full_size - array_size(2)
77         Y1_data_train{k}=padarray(C,[0 pad_size],0,'post')
78     end
79     for k=1:length(X1_data_test)
80         array_size= size(X1_data_test{k});
81         C=X1_data_test{k}
82         pad_size= full_size - array_size(2)
83         X1_data_test{k}=padarray(C,[0 pad_size],0,'post')
84     end
85     for k=1:length(Y1_data_test)
86         array_size= size(Y1_data_test{k});
87         C=Y1_data_test{k}
88         pad_size= full_size - array_size(2)
89         Y1_data_test{k}=padarray(C,[0 pad_size],0,'post')
90     end
91
92     if xy==1
93         cd (export);
94         save('data_padded_with_time','X_data_train','Y_data_train',
95             'X1_data_train','Y1_data_train','X_data_test','
96             Y_data_test','X1_data_test','Y1_data_test')
97     end
98
99     if xy==2
100         cd (export);

```

```

99         save('data_padded_without_time','X_data_train','
              Y_data_train','X1_data_train','Y1_data_train','
              X_data_test','Y_data_test','X1_data_test','Y1_data_test
              ')
100     end
101 end
102 cd (actual);
103 end

```

A.5 Código MATLAB para normalização dos dados

```

1 function normalisation(actual)
2 % Diretorio com ficheiros de dados
3 add_1='\dados_originais';
4 add_2='\ficheiros_mat';
5 dados=strcat(actual,add_1);
6 export=strcat(actual,add_2);
7 cd (dados);
8 % data max s
9 % Normalization
10 for xy=1:4
11     cd (export)
12     if xy==1
13         try
14             load data_original_with_time
15         catch
16             warning('NORMALISATION:carregamento de
                    data_original_with_time falhou!')
17             xy=2;
18         end
19     end
20     if xy==2
21         try
22             load data_original_without_time
23         catch
24             warning('NORMALISATION:carregamento de
                    data_original_without_time falhou!')
25             xy=3;
26         end
27     end
28     if xy==3
29         try
30             load data_padded_with_time
31         catch
32             warning('NORMALISATION:carregamento de
                    data_padded_with_time falhou!')

```



```

33         xy=4;
34     end
35 end
36 if xy==4
37     try
38         load data_padded_without_time
39     catch
40         warning('NORMALISATION: carregamento de
41                 data_padded_without_time falhou!')
42         return;
43     end
44 end
45 %test
46 %Dados para simular queimador
47 X_data_train_mu = mean([X_data_train{:}],2);
48 X_data_train_sig = std([X_data_train{:}],0,2);
49 for i = 1:numel(X_data_train)
50     X_data_train{i} = (X_data_train{i} - X_data_train_mu) ./
51         X_data_train_sig;
52 end
53 Y_data_train_mu = mean([Y_data_train{:}],2);
54 Y_data_train_sig = std([Y_data_train{:}],0,2);
55 for i = 1:numel(Y_data_train)
56     Y_data_train{i} = (Y_data_train{i} - Y_data_train_mu) ./
57         Y_data_train_sig;
58 end
59 %Dados para simular temperatura
60 X1_data_train_mu = mean([X1_data_train{:}],2);
61 X1_data_train_sig = std([X1_data_train{:}],0,2);
62 for i = 1:numel(X1_data_train)
63     X1_data_train{i} = (X1_data_train{i} - X1_data_train_mu)
64         ./ X1_data_train_sig;
65 end
66 Y1_data_train_mu = mean([Y1_data_train{:}],2);
67 Y1_data_train_sig = std([Y1_data_train{:}],0,2);
68 for i = 1:numel(Y1_data_train)
69     Y1_data_train{i} = (Y1_data_train{i} - Y1_data_train_mu)
70         ./ Y1_data_train_sig;
71 end
72 %Teste
73 %Dados para simular queimador
74 for i = 1:numel(X_data_test)
75     X_data_test{i} = (X_data_test{i} - X_data_train_mu) ./
76         X_data_train_sig;
77 end
78 %Dados para simular temperatura

```

```

76     for i = 1:numel(X1_data_test)
77         X1_data_test{i} = (X1_data_test{i} - X1_data_train_mu) ./
            X1_data_train_sig;
78     end
79
80     % export ficheiros mat
81     if xy==1
82         cd (export)
83         save('data_original_normalized_with_time','X_data_train','
            Y_data_train','X1_data_train','Y1_data_train','
            X_data_test','Y_data_test','X1_data_test','Y1_data_test
            ','X_data_train_mu','Y_data_train_mu','X1_data_train_mu
            ','Y1_data_train_mu','X_data_train_sig','
            Y_data_train_sig','X1_data_train_sig','
            Y1_data_train_sig')
84     end
85
86     if xy==2
87         cd (export)
88         save('data_original_normalized_without_time','X_data_train
            ','Y_data_train','X1_data_train','Y1_data_train','
            X_data_test','Y_data_test','X1_data_test','Y1_data_test
            ','X_data_train_mu','Y_data_train_mu','X1_data_train_mu
            ','Y1_data_train_mu','X_data_train_sig','
            Y_data_train_sig','X1_data_train_sig','
            Y1_data_train_sig')
89     end
90     if xy==3
91         cd (export)
92         save('data_padded_normalized_with_time','X_data_train','
            Y_data_train','X1_data_train','Y1_data_train','
            X_data_test','Y_data_test','X1_data_test','Y1_data_test
            ','X_data_train_mu','Y_data_train_mu','X1_data_train_mu
            ','Y1_data_train_mu','X_data_train_sig','
            Y_data_train_sig','X1_data_train_sig','
            Y1_data_train_sig')
93     end
94
95     if xy==4
96         cd (export)
97         save('data_padded_normalized_without_time','X_data_train',
            'Y_data_train','X1_data_train','Y1_data_train','
            X_data_test','Y_data_test','X1_data_test','Y1_data_test
            ','X_data_train_mu','Y_data_train_mu','X1_data_train_mu
            ','Y1_data_train_mu','X_data_train_sig','
            Y_data_train_sig','X1_data_train_sig','
            Y1_data_train_sig')
98     end
99 end

```

```
100  cd (actual);  
101  end
```

Anexo B

Gráficos do RMSE médio dos treinos da rede LSTM

B.1 Análise do parâmetro *hidden units*




Figura B.1: Gráfico de linhas dos resultados dos treinos relativos ao treinos 101 a 106




Figura B.2: Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 101 a 106




Figura B.3: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 101 a 106

B.2 Análise do parâmetro *Epochs*




Figura B.4: Gráfico de linhas dos resultados dos treinos relativos ao treinos 111 a 115




Figura B.5: Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 111 a 115




Figura B.6: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 111 a 115

B.3 Análise do parâmetro *Batch*




Figura B.7: Gráfico de linhas dos resultados dos treinos relativos aos treinos 121 a 125




Figura B.8: Gráfico de linhas parcial dos resultados dos treinos relativos aos treinos 121 a 125




Figura B.9: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 121 a 125

B.4 Análise do parâmetro *Gradient threshold*




Figura B.10: Gráfico de linhas dos resultados dos treinos relativos aos treinos 131 a 135




Figura B.11: Gráfico de linhas parcial dos resultados dos treinos relativos aos treinos 131 a 135




Figura B.12: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 131 a 135

B.5 Análise do parâmetro *Initial learning rate*




Figura B.13: Gráfico de linhas dos resultados dos treinos relativos aos treinos 141 a 146




Figura B.14: Gráfico de linhas parcial dos resultados dos treinos relativos aos treinos 141 a 146




Figura B.15: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 141 a 146

B.6 Análise do parâmetro *Validation frequency*




Figura B.16: Gráfico de linhas dos resultados dos treinos relativos ao treinos 151 a 155




Figura B.17: Gráfico de linhas parcial dos resultados dos treinos relativos ao treinos 151 a 155




Figura B.18: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 151 a 155

B.7 Análise do parâmetro *Validation patient*




Figura B.19: Gráfico de linhas dos resultados dos treinos relativos aos treinos 161 a 166




Figura B.20: Gráfico de linhas parcial dos resultados dos treinos relativos aos treinos 161 a 166




Figura B.21: Gráfico de barras parcial dos resultados dos treinos relativos ao treinos 161 a 166