



INSTITUTO POLITÉCNICO DE LISBOA

**ESCOLA SUPERIOR DE TECNOLOGIA DA SAÚDE DE
LISBOA**

**DESENVOLVIMENTO DE UMA REDE NEURONAL DE CONVOLUÇÃO
PARA RECONHECIMENTO DE HÉRNIAS DISCAIS EM IMAGENS DE
RESSONÂNCIA MAGNÉTICA**

SIBEL SOARES

PROFESSOR DOUTOR LUÍS FREIRE, ESTeSL - IPL

Mestrado em Radiações Aplicadas às Tecnologias da Saúde
Especialização em Imagem por Ressonância Magnética

Lisboa, 29 de abril de 2022

INSTITUTO POLITÉCNICO DE LISBOA

**ESCOLA SUPERIOR DE TECNOLOGIA DA SAÚDE DE
LISBOA**

**DESENVOLVIMENTO DE UMA REDE NEURONAL DE CONVOLUÇÃO
PARA RECONHECIMENTO DE HÉRNIAS DISCAIS EM IMAGENS DE
RESSONÂNCIA MAGNÉTICA**

SIBEL SOARES

PROFESSOR DOUTOR LUÍS FREIRE, ESTeSL - IPL

Mestrado em Radiações Aplicadas às Tecnologias da Saúde
Especialização em Imagem por Ressonância Magnética

Lisboa, 29 de abril de 2022

*“Nothing in life is to be feared, it is only to be understood. Now is the time to
understand more, so that we may fear less.”*

Marie Curie

AGRADECIMENTOS E DEDICATÓRIA

A realização deste trabalho é o culminar de um longo processo de procura pelo conhecimento, com início no ano letivo de 2011-2012.

Este foi sem dúvida um percurso tortuoso que não teria sido possível sem o apoio de inúmeras pessoas maravilhosas que me rodeiam e enriquecem a cada gesto. A todas elas, sou profundamente grata.

Aos meus queridos pais, exemplos de perseverança, amor e dedicação, serei eternamente agradecida por todos os ensinamentos, pelo vosso companheirismo e apoio incondicional.

Ao meu melhor amigo, confidente e companheiro, Paulo Alves.

Para os meus filhos, que sejam sempre exemplo de perseverança e dedicação.

Um agradecimento muito especial e sentido ao meu orientador, professor Luís Freire, pela sua orientação, dedicação, paciência e pela disponibilidade prestada no decorrer deste trabalho.

Para ti Pai, minha estrela maior!

RESUMO

INTRODUÇÃO: A hérnia discal lombar (HDL) é, atualmente, a causa mais frequente da radiculopatia lombar nos adultos jovens. A IA é considerada “a tecnologia que define o futuro”, pelo que é extremamente pertinente demonstrar a fiabilidade do uso desta tecnologia de elevado potencial no diagnóstico de HDL, fazendo uso da técnica imagiológica de maior sensibilidade e acurácia diagnóstica, a ressonância magnética.

OBJETIVOS: O objetivo principal deste trabalho é desenvolver e treinar uma rede neuronal de convolução (CNN) destinada a auxiliar o diagnóstico de HDL, tendo por base imagens de ressonância magnética da coluna lombar no plano axial.

MÉTODOS: O desenho de estudo é de carácter descritivo e estatístico, secundário, de recuperação e análise crítica da literatura. No total, foram recolhidas e analisadas 48 345 imagens totais de ressonância magnética da coluna lombar, referentes a 515 utentes, as quais se encontram disponíveis numa base de dados pública. Destas imagens, escolheram-se 3 172 ponderadas em T_2 e referentes aos planos axial e sagital. Posteriormente, recorrendo a um algoritmo de *data augmentation*, foram geradas 35 600 imagens desenvolver destinadas a treinar e validar duas CNN (VGG16 e VGG19).

RESULTADOS: Foram alcançados excelentes valores de *accuracy* durante a validação das redes, com os melhores resultados a chegarem a cerca de 0,9; estes resultados foram acompanhados de funções de *loss* decrescentes no processo de validação que atingiram valores de 0,5.

CONCLUSÕES: O contributo deste trabalho pode ser importante para o desenvolvimento de um algoritmo capaz de detetar HDL em imagens de ressonância magnética com uma precisão muito próxima da executada pelos profissionais de saúde mais experientes.

PALAVRAS-CHAVE

Ressonância magnética, hérnia discal lombar, rede neuronal de convolução

ABSTRACT

INTRODUCTION: Lumbar disc herniation is currently the most frequent cause of lumbar radiculopathy in young adults. Artificial intelligence is considered “the technology that defines the future”, so it is extremely pertinent to demonstrate the reliability of the use of this high potential tool in the diagnosis of lumbar disc herniations, through the imaging method of greater sensitivity and diagnostic accuracy, magnetic resonance imaging.

OBJECTIVES: The main objective of this work is to demonstrate the applicability and reliability of convolutional neural networks in the diagnosis of lumbar disc hernias through the application of a convolutional neural network in magnetic resonance imaging.

METHODS: The study design is descriptive and statistical, secondary, recovery and critical analysis of the literature. In total, 48 345 magnetic resonance images of the lumbar *spine* available in a public database were collected and analyzed, referring to 515 users. Of these images, 3 172 T2 – weighted were chosen and referring to the axial and sagittal planes. Subsequently, using a data augmentation algorithm, 35 600 were selected to develop, train and validate the CNN based on the VGG16 network.

RESULTS: Excellent accuracy values were achieved during network validation, reaching 0,9. The best loss function values in the validation process were 0,5.

CONCLUSIONS: After the application of a convolutional neural network, it was found that this is a tool to be taken into account in the diagnosis of HDLs.

Key words

Magnetic resonance imaging, Lumbar Disc Herniation, Convolution Neural Network

ÍNDICE GERAL	INSTITUTO POLITÉCNICO DE LISBOA	I
INSTITUTO POLITÉCNICO DE LISBOA		III
AGRADECIMENTOS E DEDICATÓRIA		VI
RESUMO		VII
ABSTRACT		VIII
ÍNDICE GERAL		IX
ÍNDICE DE TABELAS		XI
ÍNDICE DE FIGURAS		XIII
ÍNDICE DE GRÁFICOS		XVII
LISTAS DE ABREVIATURAS, SIGLAS E SÍMBOLOS		XIX
1. INTRODUÇÃO		1
1.1	Pertinência do tema	1
1.2	Objetivo Geral e Objetivos Específicos	3
1.3	Organização da dissertação	4
2. ENQUADRAMENTO TEÓRICO PARTE I – HÉRNIA DISCAL LOMBAR		5
2.1	Breve descrição anatómica da coluna lombar	5
2.2	Hérnia discal lombar	8
2.3	Epidemiologia.....	11
3. ENQUADRAMENTO TEÓRICO PARTE II – RESSONÂNCIA MAGNÉTICA		13
3.1	Princípios fundamentais da ressonância magnética.....	13
3.2	Sequências em ressonância magnética	20
3.2.1	Sequências Spin-Eco.....	20
3.2.2	Sequências Gradiente - Eco.....	21
3.3	Ressonância magnética na avaliação de hérnias discais lombares	24
3.4	Protocolo de Ressonância Magnética Lombar.....	26
4. ENQUADRAMENTO TEÓRICO PARTE III – INTELIGÊNCIA ARTIFICIAL		29
4.1	Neurónio Biológico e Neurónio Matemático	31
4.1.1	Neurónio Biológico.....	31
4.1.2	Neurónio matemático	33
4.2	Rede Neuronal Artificial	35
4.2.1	Visualização das Redes Neurais como Gráficos Direcionados.....	36
4.3	Algoritmo de aprendizagem Backpropagation	38
4.3.1	Learning rate	40
4.4	Redes Neurais Convolucionais	41
4.4.1	Extração de características	41
4.4.2	Mapeamento de características	42
4.4.3	Subamostragem	42
4.4.4	Convolução e ReLU.....	44

4.5	Dropout	47
4.6	Data Augmentation	48
4.7	Avaliação do Desempenho da Rede Neuronal.....	49
5.	METODOLOGIA.....	53
5.1	Desenho do estudo	53
5.2	Base de dados	54
5.3	Seleção de Imagens para Análise	56
5.4	Desenvolvimento de uma Rede Neuronal de Convolução	58
5.5	Treino e Validação da Rede	59
6.	RESULTADOS E DISCUSSÃO	61
6.1	Influência do Híper-parâmetro Learning rate	61
6.2	Influência do híper-parâmetro Dropout de 30% e 50%	64
6.3	Influência do treino da última camada da rede vs. o treino de toda a rede	67
6.4	Influência da Inicialização randomizada vs. pesos otimizados para a base de dados Imagenet	71
6.5	Influência do Número de épocas: 100 épocas vs. 500 épocas	79
6.6	VGG16 vs VGG19	84
6.7	Síntese dos valores obtidos.....	88
6.8	Comparação com outros estudos	93
6.9	Limitações do estudo	95
7.	CONCLUSÕES.....	97
7.1	Considerações	97
7.2	Implicações teóricas e Práticas	99
7.3	Perspectivas Futuras	99
	REFERÊNCIAS BIBLIOGRÁFICAS	103
	ANEXOS	115
	Anexo I - Déficit neurológico em cada nível de compressão radicular	116
	Anexo II – Arquitetura das diferentes redes neuronais	117
	Anexo IV – Síntese de Resultados da rede VGG19.....	131

ÍNDICE DE TABELAS

Tabela 3.1 - Classificação da degeneração do disco intervertebral segundo Pfirrmann et al. Fonte: Adaptado com modificações de Ogon et al., 2020.	24
Tabela 4.2: Descrição dos valores de AUC	51
Tabela 5.3: Parâmetros de aquisição das imagens. Fonte: Al-Kafri et al., 2019.	56
Tabela 5.4: Resumo dos dados utilizados para o treino e validação da rede.	57
Tabela 6.5: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para as situações t_0 , iw_0 , e sem dropout para 100 épocas.	63
Tabela 6.6: Análise de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com dropout de 30% para t_0 , iw_0 , ao longo de 100 épocas.	65
Tabela 6.7: Estudo de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com dropout de 50% para t_0 , iw_0 , ao longo de 100 épocas.	66
Tabela 6.8: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , sem dropout ao longo de 100 épocas.	68
Tabela 6.9: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com dropout de 30% ao longo de 100 épocas.	69
Tabela 6.10: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com dropout de 50% ao longo de 100 épocas	70
Tabela 6.11: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 , sem dropout e t_0 , ao longo de 100 épocas.	73
Tabela 6.12: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e dropout de 30% , para t_0 , ao longo de 100 épocas.	74
Tabela 6.13: Análise de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e dropout de 50% , para t_0 , ao longo de 100 épocas.	75
Tabela 6.14: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , sem dropout, ao longo de 100 épocas.	76
Tabela 6.15: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com dropout de 30% ao longo de 100 épocas.	77
Tabela 6.16: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com dropout de 50% ao longo de 100 épocas.	78
Tabela 6.17: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de 500 épocas e t_0 , w_0 e com <i>diferente dropout</i>	80
Tabela 6.18: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de 500 épocas e t_1 , w_0 e com <i>diferente dropout</i>	81
Tabela 6.19: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de 500 épocas e w_1 , t_0 e com <i>diferente dropout</i>	82

Tabela 6.20: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de 500 épocas e w_1 , t_1 e com diferente dropout	83
Tabela 6.21: Análise entre um LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_0 , iw_0 , sem dropout ao longo de 100 épocas, numa VGG19.	85
Tabela 6.22: Comparação de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com dropout de 30% para t_0 , iw_0 , ao longo de 100 épocas, numa VGG19.	86
Tabela 6.23: Estudo comparativo de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com dropout de 50% para t_0 , iw_0 , ao longo de 100 épocas, numa VGG19.	87
Tabela 6.24: Síntese dos valores obtidos com a rede VGG 16.	88
Tabela 6.25: Apresentação dos artigos que utilizaram algoritmos DL para análise de imagens de pela técnica RM da coluna lombar no plano axial.	94
Tabela 6.26: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , sem dropout ao longo de 100 épocas, em VGG19.	118
Tabela 6.27: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com dropout de 30% ao longo de 100 épocas, em VGG19.....	119
Tabela 6.28: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com dropout de 50% ao longo de 100 épocas, em VGG19	120
Tabela 6.29: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 , sem dropout e t_0 , ao longo de 100 épocas numa rede VGG19.	121
Tabela 6.30: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e dropout de 30% , para t_0 , ao longo de 100 épocas em rede VGG19.	122
Tabela 6.31: Análise do LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e dropout de 50% , para t_0 , ao longo de 100 épocas, numa rede VGG19.....	123
Tabela 6.32: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , sem dropout, ao longo de 100 épocas, em rede VGG19	124
Tabela 6.33: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com dropout de 30% ao longo de 100 épocas, em rede VGG19.....	125
Tabela 6.34: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com dropout de 50% ao longo de 100 épocas, em rede VGG19.	126
Tabela 6.35: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de 500 épocas e t_0 , w_0 e com diferente dropout , em rede VGG19.	127
Tabela 6.36: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de 500 épocas e t_1 , w_0 e com diferente dropout , em rede VGG19.....	128
Tabela 6.37: Comparação entre LR de 1×10^{-6} ao longo de 500 épocas e w_1 , t_0 e com diferente dropout	129
Tabela 6.38: Comparação entre LR de 1×10^{-6} ao longo de 500 épocas e w_1 , t_1 e com diferente dropout	130

ÍNDICE DE FIGURAS

- Figura 2.1: Localização do disco intervertebral humano entre os corpos vertebrais (A) e respetiva constituição do disco (B). Fonte: Tomaszewski et al., 2015..... 6
- Figura 2.2: Nomenclatura e classificação da patologia do disco lombar de acordo com a North American Spine Society, a American Society of Spine Radiology e a American Society of Neuroradiology. Fonte: Waldt et al., 2014. 9
- Figura 2.3: Zonas anatómicas para a localização da componente discal herniada segundo Waldt et al. no plano axial (A), sagital e coronal (B). Em a): 1 - zona central; 2 - zona subarticular; 3 - zona foraminal; 4 - zona extraforaminal. Em B) 1 - nível do disco; 2 - nível infrapedicular; 3 - nível pedicular; 4 - nível suprapedicular. Em C), D) e E): imagem do disco intervertebral normal da coluna lombar e buraco de conjugação. Imagem axial ponderada em T_2 (C) e sagital mediana ponderada em T_2 (E) de um disco intervertebral com núcleo pulposo hiperintenso (asterisco) e anel fibroso hipointenso (ponta da seta). Em D) saída das raízes nervosas (ponta da seta) no plano sagital ao nível pedicular. Fonte: Adaptado com modificações de Waldt et al., 2018 e Buller, 2018..... 10
- Figura 3.4: Representação do processo de recuperação longitudinal após um impulso de RF de 90° ser aplicado. A componente de magnetização M_z é reduzida a zero, recuperando gradualmente o seu valor de equilíbrio, quando cessam os impulsos de RF. Esta recuperação é um processo exponencial, cuja constante de tempo é T_1 , e corresponde ao momento em que a magnetização recuperou 63% do seu valor de equilíbrio. Fonte: Ridgay, 2010..... 16
- Figura 3.5: Representação da relaxação transversal após um impulso de RF de 90° aplicado à fase de equilíbrio. Inicialmente a magnetização transversal (seta vermelha) tem uma amplitude máxima à medida que os spins estão em fase. O sinal detetado FID diminui quando ocorre o desfasamento dos spins (pequenas setas pretas), sendo que o termo geral utilizado é a relaxação T_2^* (combinação do relaxação T_2 com a ausência de homogeneidade do campo). A relaxação T_2 resultante das interações spin-spin é um processo irreversível devido à natureza aleatória do movimento molecular. A relaxação T_2^* , responsável pelo decaimento mais rápido do sinal FID, pode ser revertido através da aplicação de um impulso de refasagem de 180° . Tanto T_2 como T_2^* são processos exponenciais de constante de tempo T_2 e T_2^* , respetivamente, que corresponde ao momento em que a magnetização decaiu para 37% do seu valor inicial após o impulso de RF. Fonte: Ridgay, 2010. 18
- Figura 3.6: Diagrama da magnetização e impulsos de radiofrequência: a) Quando exposta a B_0 , o vetor de magnetização M_0 , está em equilíbrio, alinhado paralelamente ao campo magnético. b) Quando um impulso de RF é aplicado, M_0 faz um ângulo com o eixo z, conhecido como ângulo de inversão, e gira em torno do eixo na direção da seta curva. A qualquer instante a magnetização pode ser dividida em dois componentes, M_z e M_{xy} . O componente M_{xy} rotativo gera o sinal da técnica de RM detetável. c) A amplitude máxima do sinal detetável após um único impulso de RF ocorre quando M_0 está inteiramente no plano dos eixos x e y, pois isso fornece o maior componente M_{xy} .

Esse impulso tem um ângulo de inclinação de 90° . d) Um impulso de RF de refasamento de 180° é normalmente aplicado enquanto há magnetização transversal já girando no plano xy e é usado para inverter instantaneamente o componente transversal de magnetização em 180° em torno de um eixo também girando no plano xy. e) Um impulso de inversão de 180° é normalmente aplicado em equilíbrio e é usado para girar a magnetização líquida em 180° do eixo z positivo para o negativo. Isso também é conhecido como impulso de preparação de magnetização e é usado como esquema de preparação para técnicas de imagem de saturação de estruturas. Fonte: Ridgay, 2010.

..... 19

Figura 3.7: Diagrama de uma sequência SE. Na 2ª linha temos a ativação e respectivo tempo de duração do gradiente de corte que ocorre em simultâneo com a aplicação dos impulsos, estando invertido entre os pontos positivos para minimizar a defasagem da magnetização transversal devido aos próprios gradientes. O tempo de ativação da codificação de fase surge representado na 3ª linha, aplicado perpendicularmente ao gradiente de corte, cuja ativação é feita com intensidades diferentes para cada repetição da sequência básica de impulso, fornecendo diferentes codificações de fase em cada repetição. Na 4ª linha temos a codificação de frequência, também conhecida como gradiente de “leitura”, que é ativado durante a medição do sinal de eco. Por último temos o sinal obtido, com um eco máximo no momento TE após o impulso de 90° . Ts corresponde ao tempo total de amostragem, durante o qual o sinal é captado pelas antenas recetoras e durante o qual o gradiente constante de codificação de frequência é aplicado. Após o início do impulso de 90° e num momento TR, a sequência é repetida da mesma forma, com a exceção dos valores do gradiente de codificação de fase. A sequência básica é repetida 128, 192, 256 ou mais vezes, para formar uma única imagem. Fonte: Hendrick, 2010. 21

Figura 3.8: Diagrama de uma sequência SE. Na 2ª linha temos a ativação e respectivo tempo de duração do gradiente de corte. Esta ativação ocorre em simultâneo com a aplicação dos impulsos, estando invertido entre os pontos positivos para minimizar a defasagem da magnetização transversal devido aos próprios gradientes. O tempo de ativação da codificação de fase surge representado na 3ª linha. Este é aplicado perpendicularmente ao gradiente de corte, cuja ativação é feita com intensidades diferentes para cada repetição da sequência básica de impulso, fornecendo diferentes codificações de fase para cada repetição. Na 4ª linha temos a codificação de frequência, também conhecida como gradiente de “leitura”, que é ativado durante a medição do sinal. Por último temos o sinal obtido, com um eco máximo no momento TE após o impulso de 90° . Ts corresponde ao tempo total de amostragem, durante o qual o sinal é captado pelas antenas recetoras e durante o qual o gradiente constante de codificação de frequência é aplicado. Após o início do impulso de 90° e num momento TR, a sequência é repetida da mesma forma, com a exceção dos valores do gradiente de codificação de fase. A sequência básica é repetida 128, 192, 256 ou mais vezes, para formar uma única imagem. Fonte: Hendrick, 2010. 22

Figura 3.9: Representação de uma sequência FSE ou TSE com 4 ETL. Devido à aplicação de um gradiente de codificação de fase antes de cada eco, é possível obter uma visualização de codificação de fase diferente por eco, o que possibilita o preenchimento

de várias linhas do espaço K por cada TR. Fonte: Hendrick, 2010.....	23
Figura 3.10: Exemplo de protrusão e extrusão do disco. A) Imagem axial ponderada em T ₂ de uma hérnia de disco focal à esquerda, provocando o deslocamento posterior da raiz nervosa no recesso lateral esquerdo (ponta de seta). B) Imagem axial ponderada em T ₂ do disco subjacente no mesmo paciente, demonstrando uma hérnia de disco focal de aparência semelhante localizada centralmente. C) Imagem sagital ponderada em T ₂ do mesmo paciente que nos permite diferenciar a extrusão de nível superior e a protusão no nível inferior. De salientar que a extrusão tem um ápice (pontas de seta) mais largo que sua base (linhas tracejadas), enquanto a protrusão não. Fonte: Buller, 2018.	25
Figura 3.11: Caracterização de fissuras anulares: A) Imagem axial ponderada em T ₂ de um disco ao nível lombar demonstrando uma linha concêntrica hiperintensa em T ₂ dentro do anel fibroso (seta), o que representa uma fissura anelar. B) Imagem sagital média ponderada em T ₂ de dois discos lombares e que apresentam uma grande fissura anular ao nível do disco superior (seta) e inferior (ponta de seta). As imagens axiais ponderadas em T ₁ (C) e sagital da linha média (D) após a administração de contraste demonstram realce das fissuras anulares. Fonte: Buller, 2018.	25
Figura 4.12: Exemplificação de um algoritmo supervisionado (a) e de um algoritmo não supervisionado (b). Fonte: Adaptado com modificações de https://towardsdatascience.com/supervised-vs-unsupervised-learning-in-2-minutes-72dad148f242 , acessado em 27//04/2022.	30
Figura 4.13: Anatomia de um neurónio. Fonte: https://askabiologist.asu.edu/neuron-anatomy (acedido em 21/02/2022).	32
Figura 4.14: Representação esquemática do neurónio matemático. Fonte: Haykin, 2018.	34
Figura 4.15: Diagrama de fluxo de sinal de uma rede neuronal de convolução. Fonte: The Neural Network Zoo - The Asimov Institute, acessado em 04/04/2022.....	38
Figura 4.16: Diagrama de fluxo de sinal de uma rede neuronal de convolução. Fonte: The Neural Network Zoo - The Asimov Institute, acessado em 04/04/2022.....	38
Figura 4.17: Ilustração das direções de dois fluxos básicos do sinal numa rede multicamada: propagação direta de sinais de função (setas pretas) e propagação reversa dos sinais de erro (setas azuis). Fonte: Haykin, 2018.....	39
Figura 4.18: Exemplificação de uma arquitetura genérica aplicada a uma imagem médica. Fonte: https://www.mdpi.com/2079-9292/11/11/1775 (acedido em 23/07/2023).....	44
Figura 4.19: A) Exemplificação das operações de convolução e de pooling: na coluna do meio temos os valores os filtros convolucionais implementados na rede (os pesos) que são multiplicados pelos valores de cada pixel e os produtos são somados, resultando nos feature maps. Em B) temos uma camada pooling em que o valor do pixel máximo é obtido uma determinada região. Fonte: Mazurowski et al., 2019.	46
Figura 4.20: Demonstração de um processo de padding e stride. Fonte: https://ayeshmanthaperera.medium.com/what-is-padding-in-CNN-71b21fb0dd7 ,	

acedido em 28.04.2022.	47
Figura 4.21: Exemplificação de à imagem original e que permitem gerar novas imagens para análise. Fonte: Nalepa et al., 2019 transformações aplicadas.....	49
Figura 4.22: Representação gráfica de uma curva ROC e respetiva área AUC. Fonte: https://doi.org/10.1016/j.buildenv.2020.107212 , acedida em 30-05-2021.	50
Figura 5.23: Arquitetura de um modelo VGG16. Fonte: Khan, 2020.	58

ÍNDICE DE GRÁFICOS

Gráfico 1.1 - Nº de publicações por tema no website PubMed em função do tempo. Results by year (série.....	3
---	---

LISTAS DE ABREVIATURAS, SIGLAS E SÍMBOLOS

B

B₀ – Campo magnético externo

C

CNN – Redes neuronais convolucionais (ou ConvNet do inglês *Convolutional Neural Network*)

CONV – Camada convolucional

CPU – *Central Processing Unit*

D

DALY – *Disability Adjusted Life Years*

DICOM – *Digital Imaging and Communications in Medicine*

DL – *Deep Learning*

d – *Dropout*

E

e – Número de épocas

ETL – *Echo Train Length*

EUA – Estados Unidos da América

F

FA – *Flip angle*

FID – *Free-induction decay*

FOV – *Field of View*

G

GBD – *Global Burden of Disease*

GE – Gradiente de Eco

GPU – Unidade de Processamento Gráfico (do inglês *Graphics Processing Unit*)

H

HD – Hérnia discal

HDL – Hérnia discal lombar

I

IA – Inteligência artificial

ILSVRC - *ImageNet Large Scale Visual Recognition Challenge*

iw_0 – Inicialização randomizada, do inglês *initialization of weight*

iw_1 – Rede com inicialização randomizada com pesos otimizados da *ImageNet*

L

LCR – Líquido cefalorraquidiano ou líquido

LR – *Learning rate*

M

MDixon – Dixon modificado

MHz – Megahertz

ML – *Machine Learning*

P

POOL – Camada *pooling*

R

ReLU – Unidade linear retificada (do inglês *Rectified Linear Unit*)

RF – Radiofrequência

RM – Ressonância magnética

RNA – Rede neuronal artificial

S

SE – Sequência *spin-eco*

STIR – do inglês *Short-TI Inversion Recovery*

T

t_0 – Treino de apenas a última camada da rede

t_1 – Treino de toda a rede

$T1$ – Tempo de recuperação da magnetização longitudinal

T_2 – Tempo de decaimento da magnetização transversal, após refasamento

T_2^* – Tempo de relaxação transversal afetada pela homogeneidade local

TE – Tempo de eco

TR – Tempo de repetição

V

VGG16 – Modelo de CNN do *Visual Geometry Group de Oxford*

VGG19 – Modelo de CNN do *Visual Geometry Group de Oxford*

Y

YOLO – *You Only Look Once*

1. INTRODUÇÃO

1.1 PERTINÊNCIA DO TEMA

A hérnia discal lombar (HDL) é, atualmente, a causa mais frequente da radiculopatia lombar nos adultos jovens, a qual se manifesta como uma lombalgia com irradiação para pelo menos um dos membros inferiores, parestesias e outros défices neurológicos, interferindo com as atividades básicas diárias e levando à perda de qualidade de vida do paciente.^(1,2) Sendo um importante problema de saúde pública nos países desenvolvidos, esta patologia traduz-se como a segunda causa de absentismo laboral, a quinta causa de admissão hospitalar e uma das mais frequentes indicações para a cirurgia lombar, quando o tratamento conservador não é eficaz.⁽³⁾ Nos últimos 10 anos a sua incidência teve um aumento superior a 200% nos Estados Unidos da América (EUA).⁽⁴⁾

Segundo o estudo “*Global Burden of Disease (GBD)*” referente ao ano de 2019, quando analisado o número total de anos de vida saudável perdidos devido à doença (*Disability Adjusted Life Years-DALY*), lesão ou fator de risco, as dores lombares figuram sempre entre as 7 principais doenças do *ranking* até à faixa etária dos 75 anos, ficando em 4º lugar no DALY da faixa etária entre os 25 aos 49 anos de idade.⁽⁵⁾

Em Portugal, num estudo realizado pelo Instituto Nacional de Saúde – Dr. Ricardo Jorge referente aos dados obtidos em 2014, a prevalência da dor lombar crónica na população portuguesa com 25 ou mais anos de idade foi de 36,6%.⁽⁶⁾ Já os dados referentes a 2019, a lombalgia foi, em Portugal, a doença prevalente entre as pessoas que requerem reabilitação, afetando cerca de 1,6 milhões de portugueses.⁽⁷⁾ Dado o peso destes dados referentes à patologia lombar, o desenvolvimento deste trabalho

debruçar-se-á apenas sobre a região lombar da coluna vertebral.

A inteligência artificial (IA) é considerada a tecnologia que define o futuro, pelo que é extremamente pertinente demonstrar a fiabilidade do uso desta tecnologia de elevado potencial no diagnóstico de HDL. Para isso, faremos uso de imagens obtidas através da técnica de ressonância magnética (RM), a qual se caracteriza pelo facto de permitir uma maior sensibilidade e acurácia diagnóstica quando comparada com outras técnicas de imagem. ^(8,9)

As redes neuronais de convolução, ou convolucionais (CNN, do inglês ConvNet ou *Convolutional Neural Network*) são algoritmos que pertencem a um subnível de aprendizagem profunda da IA, o qual é designado por *Deep Learning* (DL). Inspirados nos neurónios humanos, os algoritmos de DL têm a capacidade de mapear e aprender quais são as características representativas dos dados fornecidos que mais contribuem para a sua classificação final em diferentes grupos. Para isso, estes algoritmos necessitam de ter disponível uma grande quantidade de dados, factor relevante mas não facilitador no uso destes algoritmos na área da saúde. ⁽¹⁰⁾

O interesse nos algoritmos de DL tem vindo a aumentar exponencialmente nos últimos anos, apesar das CNN a serem aplicadas em imagens médicas desde os anos 90. ^(11,12) Os algoritmos de DL baseados em CNN são atualmente os mais bem estabelecidos devido aos resultados surpreendentes conseguidos desde 2012 na maior competição de reconhecimento de objetos, o Concurso de Reconhecimento Visual em Grande Escala *ImageNet*. ⁽¹³⁾ sendo estes algoritmos considerados a representação do estado da arte na análise de imagens. ⁽¹⁴⁾

Na área da saúde, a aplicação das CNN tem sido muito abrangente, como na triagem da retinopatia diabética, na classificação de lesões da pele e na deteção de metástases linfonodais. ⁽¹⁵⁾ Na radiologia, vários têm sido os estudos publicados nas mais diversas áreas como a deteção de tuberculose em radiologia convencional ⁽¹⁶⁾, a deteção de doenças cerebrais ⁽¹⁷⁾ a segmentação da coluna vertebral ⁽¹⁸⁾ e na reconstrução de imagem, entre muitos outros estudos sintetizados no artigo “*Automated Segmentation of Tissues using CT and MRI: A Systematic Review*” de Lenchik *et al.* e “*Deep Learning for Lesion Detection, Progression, and Prediction of Musculoskeletal Disease*” de Kijowski *et al.* ^(20,21)

Com o intuito de dar ainda mais robustez ao enorme interesse que as redes neuronais despertam na comunidade científica, recorreu-se à ferramenta “*Results by year*” disponibilizada no *website PubMed*, obtendo-se o número de publicações

científicas da base de dados online em função do tempo, com o termo “*convolutional neural network* [MeSH Terms]” (Gráfico 1.1). Analisando os dados obtidos, verificou-se que ocorreu um aumento drástico de publicações a partir de 2016, reforçando assim a pertinência do tema aqui desenvolvido. As CNN também têm vindo a ser cada vez mais aplicadas no estudo da coluna lombar pela técnica de RM, ^(10,22) sendo a maioria dos artigos científicos disponíveis referentes à segmentação da coluna lombar. Por seu turno, os artigos destinados à detecção de HDLs através da técnica RM correspondem sobretudo à aplicação de algoritmos em imagens no plano sagital.

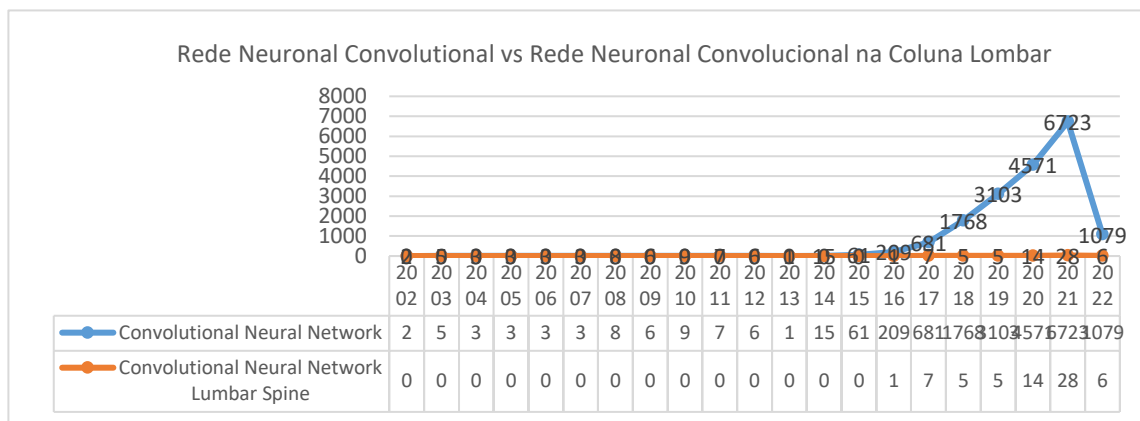


Gráfico 1.1 - Nº de publicações por tema no *website* PubMed em função do tempo. Results by year (série temporal: de 2010 a 2022, dados obtidos em 16/02/2022).

Neste sentido, o presente trabalho visa colmatar a lacuna de estudos referentes à detecção de HDLs, através do desenvolvimento de uma rede neuronal de convolução para reconhecimento de HD em imagens de pela técnica de RM no plano axial.

A metodologia a ser utilizada será a qualitativa e quantitativa através de uma pesquisa exploratória e conclusiva, respetivamente. A análise será descritiva e estatística de dados secundários disponibilizados na base de dados pública de acesso livre, disponível em https://plu.mx/plum/a/?mendeley_data_id=k57fr854j2&theme=plum-bigben-theme. No total, serão analisadas 48 345 imagens obtidas através da técnica de RM da coluna lombar, referentes a 515 utentes.

1.2 OBJETIVO GERAL E OBJETIVOS ESPECÍFICOS

O objetivo principal deste trabalho é desenvolver uma rede neuronal de convolução

destinada a auxiliar no diagnóstico de HDL, tendo por base imagens da técnica de RM da coluna lombar, e cujos objetivos específicos são:

- Desenvolver e treinar um algoritmo de CNN para a detecção de HDL em imagens da técnica de RM no plano axial;
- Proceder à aplicação da CNN a exames através da técnica de RM da coluna lombar de 515 doentes disponíveis numa base de dados de acesso público;
- Analisar a acurácia da CNN na deteção de HDL nas imagens axiais pela técnica de RM;
- Colmatar a pouca investigação e respetiva aplicabilidade destes algoritmos em imagens da técnica de RM no plano axial da coluna lombar;
- Demonstrar a aplicabilidade e compatibilidade de novas ferramentas num meio imagiológico de elevada sensibilidade no diagnóstico de HDL, a técnica de RM.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

A organização deste trabalho foi pensada de forma a proporcionar uma melhor compreensão do tema escolhido, tendo um grau de complexidade que se desenvolve de forma crescente ao longo dos capítulos e subcapítulos. A dissertação inicia-se com esta introdução numa primeira abordagem ao tema escolhido, justificando a sua escolha e pertinência, e apresentando também quer os *objetivos* gerais como os objetivos específicos do trabalho.

O enquadramento teórico está repartido por três capítulos. No capítulo 2 é feita uma breve introdução à anatomia da coluna lombar e uma caracterização das HDL. O capítulo 3 dá-nos a conhecer a da técnica de RM, juntamente com as linhas de orientação para o estudo de HDLs. Já o 4º capítulo faz uma pequena introdução à IA, seguido de uma abordagem mais aprofundada às CNN. A metodologia é apresentada no 5º capítulo, sendo aqui apresentados os passos elaborados no planeamento e execução deste trabalho. Os resultados são apresentados no Capítulo 6, juntamente com a análise e discussão dos mesmos. Por último, temos as conclusões e perspectivas futuras nos Capítulo 7.

2. ENQUADRAMENTO TEÓRICO PARTE I – HÉRNIA DISCAL LOMBAR

2.1 BREVE DESCRIÇÃO ANATÓMICA DA COLUNA LOMBAR

A coluna lombar é o segmento da coluna vertebral localizado entre a 12^a vértebra dorsal e a 1^a vértebra do sacro. Este segmento é constituído por 5 vértebras lombares, denominadas de L1, L2, L3, L4 e L5 (de superior para inferior) e separadas entre si pelos discos intervertebrais, sendo que a principal função da coluna lombar é a proteção da medula *espinhal* e das suas raízes nervosas, ao mesmo tempo que é altamente flexível e permite uma grande mobilidade corporal. ^(23–25)

A vértebra lombar é composta pelo corpo vertebral (porção anterior) e o arco vertebral (porção posterior, também denominado de anel vertebral). No arco neural temos os pedículos que saem bilateralmente da porção pósterolateral da parte superior do corpo vertebral e que se unem às lâminas, formando assim o canal medular. A junção das lâminas na sua porção posterior dá origem à apófise espinhosa da vértebra lombar, cuja projeção é alongada e posterior. Por outro lado, na junção pediculolaminar vamos ter as apófises laterais, que como o próprio nome indica, têm uma projeção lateral e uma ligeira orientação dorsal.

As vértebras estão ligadas entre si através das apófises articulares superiores (articulam com as apófises articulares inferiores da vértebra superior) e das apófises articulares inferiores (articulam com as apófises articulares superiores da vértebra inferior). As bordas laterais anguladas do canal medular são chamados de buracos de conjugação e constituem o canal ósseo para a saída das raízes nervosas. ^(23–25)

A separar as vértebras temos os discos intervertebrais que correspondem a cerca de 20 a 30% do comprimento total da coluna. ⁽²³⁾ Estes discos têm como principal função absorver os impactos e reduzir os danos que daí advenham, dispersar o peso, permitindo assim o movimento das vértebras individuais e a passagem de nutrientes e fluídos para a medula *espinhal*. ⁽²³⁾

Os discos intervertebrais são formados por um anel fibroso, o núcleo pulposos e por duas superfícies terminais cartilaginosas, as placas terminais do disco (Figura 2.1). Todavia, a distinção entre o anel fibroso e o núcleo só pode ser feita na juventude, dado que a consistência do disco torna-se mais uniforme a partir da quinta década de vida devido à perda de água. ⁽²⁴⁻²⁶⁾

O anel fibroso corresponde à porção mais externa do núcleo que é composto basicamente, por cartilagem fibrosa onde as fibras de colagénio se dispõem em diversas camadas com ângulos alternados. Esta variação dos ângulos das fibras de colagénio permitem criar uma estrutura estável que envolve o núcleo pulposos, permitindo que este suporte as diferentes forças a que está sujeito. A porção posterior do anel fibroso é mais fina em comparação à sua porção anterior, o que significa que o anel fibroso oferece melhor proteção contra deslocamentos anteriores do que dos deslocamentos posteriores do núcleo. ^(23,25)




Figura 2.1: Localização do disco intervertebral humano entre os corpos vertebrais (A) e respetiva constituição do disco (B). Fonte: Tomaszewski *et al.*, 2015.

O núcleo pulposos é composto essencialmente por uma substância gelatinosa, constituída por uma malha de fibrilas de colágeno suspensas numa base de mucoproteína, rica em mucopolissacarídeos e água. Esta substância gelatinosa diminui com o envelhecimento devido essencialmente à perda de água, pelo que este pode ser

o principal fator responsável pela degeneração discal e traduz-se na diminuição da altura do disco. ⁽²⁵⁾

As placas terminais cartilaginosas cobrem superior e inferiormente as faces do disco intervertebral, e a sua espessura varia entre os 0.6 a 1 mm. Compostas por cartilagem hialina, estas superfícies têm como principal missão funcionar como uma interface entre as superfícies dos corpos vertebrais e o anel e núcleo do disco. Possibilitam ainda a difusão, fornecendo também a principal fonte de nutrição do disco. As placas de cartilagem hialina cobrem o núcleo pulposo na sua totalidade mas não toda a periferia do anel fibroso. ⁽²⁴⁾ O espaço discal é definido superior e inferiormente pelas placas terminais do corpo vertebral e, perifericamente, pelas bordas externas das apófises do anel vertebral, excluindo os osteófitos. ^(25,26)

Os discos intervertebrais lombares são das principais estruturas anatómicas da coluna vertebral que sofrem processos degenerativos. Estes processos podem levar à diminuição da altura do disco, à alteração da amplitude dos movimentos da coluna lombar e ao comprometimento das saídas nervosas do canal medular com eventual compressão das raízes nervosas. ^(27,28) No que respeita a estabilidade da coluna lombar, esta é conseguida graças aos vários ligamentos que a constituem, incluindo os ligamentos longitudinais anterior e posterior, os ligamentos supra e inter *espinhosos* e o ligamento amarelo ou *flavum*. ⁽²⁵⁾

No interior do canal medular encontra-se a medula *espinhal* envolta por três meninges, a dura-máter (meninge mais externa), a aracnoide (camada média das meninges) e a pia-máter (meninge mais interna e transparente). A dura-máter é constituída por duas camadas (perióstea e meníngea), entre as quais está o espaço epidural. Entre a aracnoide e a pia-máter encontra-se o espaço subaracnóideo, que é preenchido com líquido cefalorraquidiano ou líquor (LCR).

A medula termina no adulto, normalmente ao nível da última vértebra dorsal e a primeira vértebra lombar (T12-L1), sendo que a sua extremidade caracteriza-se por ter uma forma de cone de onde saem várias raízes nervosas individuais, o cone medular. Este feixe de raízes nervosas é denominado de cauda equina. ^(24,25)

Os nervos *espinhais* resultam da junção das raízes motoras (anteriores) e das raízes sensoriais (dorsais). Estes ramos unem-se ao nível dos buracos de conjugação e emergem do canal medular junto à borda médio-inferior do pedículo da vértebra superior, situação que ocorre até à cauda equina. A região lombar da medula vertebral é constituída por 11 pares de nervos, 5 lombares, 5 sacrados e 1 coccígeo. ^(24,25)

2.2 HÉRNIA DISCAL LOMBAR

A HDL é um termo amplo definido pelo deslocamento localizado ou focal do material que constitui o núcleo para além dos limites do espaço do disco intervertebral, sendo que o material do disco tanto pode ser núcleo, cartilagem, fragmentos ósseos das apófises ou do tecido anular, como ainda qualquer combinação destes. ^(26,29,30)

A classificação das alterações degenerativas do disco é baseada na subdivisão do disco intervertebral em quatro partes iguais no plano axial, cada parte com uma circunferência de 90° ou 25% de toda a circunferência do disco intervertebral. A linha de corte de 25% é estabelecida por convenção para dar precisão à terminologia e não define a etiologia, a relação com os sintomas, nem as indicações de tratamento. ^(26,29)

Uma hérnia localizada é definida como envolvendo menos de 50% da circunferência do disco. As hérnias localizadas podem ainda ser divididas em hérnias de base ampla, que abrangem 25% a 50% da circunferência do disco, ou em hérnias focais, que envolvem menos de 25% da circunferência. ^(26,29)

Já a expansão generalizada do material do disco intervertebral quando superior a 180° ou 50% da circunferência do disco, é denominada como abaulamento discal (Figura 2.2). No abaulamento discal, o deslocamento é normalmente inferior a 3 mm e pode ser assimétrico se a expansão prevalecer num dos lados (ocorre em situações de escolioses devido à distribuição desigual da pressão do disco). ^(8,26,29) Relativamente à forma e ao tamanho do material deslocado, e independentemente da sua natureza, a hérnia discal pode ser classificada como protusa ou extrusa. A protrusão está presente se a base é mais larga que o seu diâmetro, quer no plano axial como no plano sagital. Na extrusão existe uma perda de continuidade do anel fibroso, e quando medido em pelo menos um plano, o diâmetro da hérnia é maior que a base da porção deslocada. A extrusão pode ainda ser subclassificada como sequestrada caso o material do disco deslocado perca completamente a sua continuidade com o disco original. O termo migração pode ser utilizado para identificar o deslocamento cranial ou caudal do fragmento no plano sagital. ^(8,26,29) Quando existe uma HD com deslocação vertical devido a uma falha na placa terminal do corpo vertebral, esta denomina-se de hérnia intravertebral, também conhecida como nódulo de Schmorl. ^(8,26,29,31)

Em relação à localização da HDL, Fardon *et al.* apresenta um método de uso comum, simples e prático. Os pontos de referência a serem utilizados para delimitar as zonas e os níveis são os mesmos para o plano axial: borda medial das facetas

articulares; bordas medial, lateral, superior e inferior dos pedículos; e planos coronal e sagital no centro do disco. No plano axial estes pontos de referência determinam os limites da zona central, a zona subarticular (recesso lateral), a zona foraminal, a zona extraforaminal e a zona anterior, respetivamente. No plano sagital (craniocaudal), estes pontos de referência determinam os limites do nível infrapedicular, pedicular e suprapedicular, respetivamente (Figura 2.3).




Figura 2.2: Nomenclatura e classificação da patologia do disco lombar de acordo com a *North American Spine Society*, a *American Society of Spine Radiology* e a *American Society of Neuroradiology*. Fonte: Waldt *et al.*, 2014.

No plano axial, e com orientação do centro para os lados direito ou esquerdo, a localização pode ser definida como central, central direita/esquerda, subarticular direita/esquerda, foraminal direita/esquerda ou extraforaminal direita/esquerda, respetivamente. No plano sagital, a localização pode ser definida como discal, infrapedicular, suprapedicular ou pedicular – ver Figura 2.3. ⁽²⁶⁾

Tanto a hérnia localizada como o abaulamento discal podem ser assintomáticos. Todavia, quando existe contacto da porção herniada com as raízes nervosas, surgem os quadros de dor lombar incapacitante. A HDL quando sintomática pode apresentar os

seguintes sintomas:

- Dor lombar contínua ou intermitente que se agrava com o movimento, com a posição ortostática parada e com a tosse do utente;
- Espasmos da musculatura lombar;
- Cialgia - dor ao longo da projeção do nervo ciático, geralmente resultante do comprometimento da raiz nervosa ao nível da coluna lombar e cuja irradiação pode atingir o pé;
- Parestesias do membro inferior;
- Alteração do controlo dos esfíncteres urinário e ou anal.⁽¹⁾

A radiculopatia é o termo utilizado quando existe dor, fraqueza, dormência ou formigamento ao longo do comprimento do nervo, devido à inflamação ou à compressão da sua raiz nervosa.⁽³²⁾

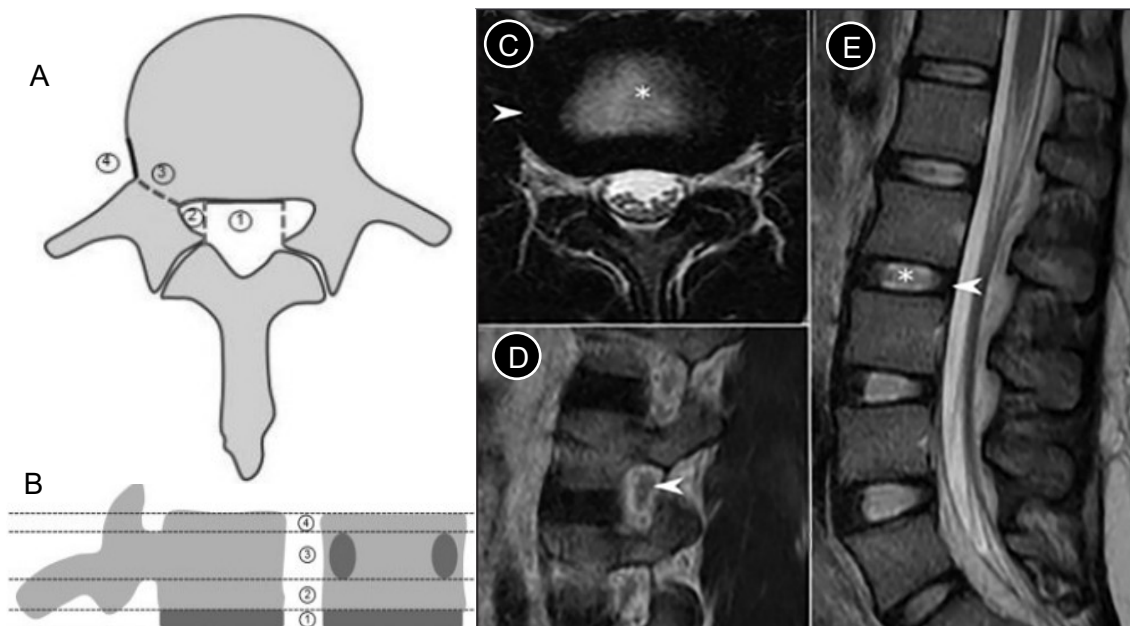


Figura 2.3: Zonas anatómicas para a localização da componente discal herniada segundo Waldt *et al.* no plano axial (A), sagital e coronal (B). Em a): 1 - zona central; 2 - zona subarticular; 3 - zona foraminal; 4 - zona extraforaminal. Em B) 1 - nível do disco; 2 - nível infrapedicular; 3 - nível pedicular; 4 - nível suprapedicular. Em C), D) e E): imagem do disco intervertebral normal da coluna lombar e buraco de conjugação. Imagem axial ponderada em T_2 (C) e sagital mediana ponderada em T_2 (E) de um disco intervertebral com núcleo pulposo hiperintenso (asterisco) e anel fibroso hipointenso (ponta da seta). Em D) saída das raízes nervosas (ponta da seta) no plano sagital ao nível pedicular. Fonte: Adaptado com modificações de Waldt *et al.*, 2018 e Buller, 2018.

Apesar de ser uma das causas mais comuns de lombalgias e ciatalgias, o desenvolvimento da HDL ainda não foi totalmente esclarecido, sendo que vários estudos indicam que esta pode ser causada por uma combinação complexa de processos mecânicos e biológicos. Os factores de risco associados à HDL podem ser os mais diversos, desde o sedentarismo, o excesso de peso, o tabagismo, género feminino (ratio de 2:1), profissões fisicamente exigentes e a prática desportiva intensa. ^(2,30,32-36)

2.3 EPIDEMIOLOGIA

Vários artigos sugerem muito claramente a associação entre lombalgia inespecífica e a degeneração dos discos intervertebrais, pelo que a abordagem neste estudo à incidência e à prevalência das HDL terá uma linha de orientação idêntica. ^(3,27,30,37,38) A lombalgia afeta cerca de 8% da população mundial ⁽³⁷⁾ e diversos estudos afirmam que cerca de 70 a 80% dos adultos já tiveram dor lombar ao longo da vida. ^(3,28,33,39,40) Por seu turno a degeneração do disco lombar é a causa mais comum de lombalgia ^(32,40), sendo que a HDL afeta entre 1 a 5% da população cada ano. ⁽⁴¹⁾

De acordo com o estudo *Global Burden of Disease* referente ao ano de 2019, cerca de 1,71 biliões de pessoas sofrem de alguma condição músculo-esquelética, sendo a dor lombar o principal contribuinte para a carga global. Em Portugal, a lombalgia foi a doença prevalente entre as que requerem reabilitação, afetando cerca de 1,6 milhões de pessoas. ⁽⁴²⁾ A nível europeu a dor lombar crónica afeta entre 5,9% e 19,9% da população. ⁽⁶⁾

As HDL acometem maioritariamente a coluna lombar inferior (níveis intervertebrais L4-L5 e L5-S1) na faixa etária dos 25 aos 55 anos, chegando a atingir valores na ordem dos 95%. Já as HDL nos níveis superiores (níveis L1-L2, L2-L3 e L3-L4) ocorrem mais frequentemente nas idades superiores aos 55 anos. ^(35,43)

A nível económico, a lombalgia está associada a custos elevados devido, não só aos custos relacionados com a assistência à saúde, como também aos custos indiretos referentes ao absentismo laboral ou à diminuição da produtividade. ^(3,30,36,40,44) Em 2006, nos Estados Unidos, os custos totais atribuíveis à lombalgia foram estimados em 100 biliões de dólares americanos, sendo que destes, dois terços foram referentes a custos indiretos de perda de salários e de produtividade. ⁽⁴⁵⁾

Todos estes dados permite-nos constatar que a dor lombar está fortemente documentada como um grande desafio de saúde pública nos países desenvolvidos,

devido não apenas aos encargos financeiros que impõe, mas também às suas
consequências psicológicas e sociais. ^(45,46)

3. ENQUADRAMENTO TEÓRICO PARTE II – RESSONÂNCIA MAGNÉTICA

Dado que a da técnica de RM é a técnica imagiológica em estudo nesta dissertação, entendeu-se no planeamento deste trabalho que seria de elevada importância fazer uma breve abordagem dos princípios fundamentais desta técnica, a par da caracterização do seu importante papel na avaliação das HDL.

3.1 PRINCÍPIOS FUNDAMENTAIS DA RESSONÂNCIA MAGNÉTICA

A da técnica de RM é uma técnica complexa que permite a obtenção de imagens médicas ricas em informação sobre as estruturas analisadas, seja esta de cariz mais marcadamente anátomo-morfológico ou funcional.

Tendo por base o fenómeno de ressonância, as imagens são adquiridas graças ao núcleo de hidrogénio que possui apenas um único protão e que, devido ao facto de estar presente em todos os tecidos biológicos, encontra-se amplamente disponível no corpo humano. Para além da abundância natural, o núcleo de hidrogénio possui duas características que fazem com que seja o núcleo de eleição da técnica de RM, a saber:

- As variáveis que caracterizam a resposta do núcleo de hidrogénio ao fenómeno de ressonância, nomeadamente os tempos de relaxação T_1 e T_2 , ou ainda outras variáveis como a difusibilidade da água, alteram-se com o meio envolvente de cada núcleo, o que permite distinguir o tipo de tecido ou meio biológico em que o hidrogénio se encontra ou ainda se o tecido biológico é normal ou patológico;
- O protão do hidrogénio apresenta o maior momento magnético

comparativamente com outros núcleos de elementos químicos que também poderiam ser utilizados pela técnica de RM; este facto leva a uma maior sensibilidade da técnica de RM quando ajustada para o núcleo de hidrogénio.

(47-49)

O núcleo de hidrogénio exhibe um momento magnético (ou momento dipolar magnético) devido à carga eléctrica que o caracteriza e à rotação espontânea sobre o seu próprio eixo (*spin* nuclear), comportando-se assim como um pequeno dipolo magnético. O momento magnético é assim definido com um vetor coincidente com o eixo de rotação natural do núcleo e tem unidades $N \cdot m \cdot T^{-1}$.

Quando vários núcleos não estão expostos a um campo magnético externo, os seus dipolos alinham-se aleatoriamente. Porém, quando expostos a um campo magnético externo (B_0), os prótons do núcleo de hidrogénio alinham-se de forma paralela ou antiparalela em relação ao eixo do campo B_0 , alinhamento este associado a um estado de baixa ou alta energia, respetivamente. Esta exposição a B_0 origina ainda o aparecimento de um movimento de precessão do vetor momento magnético em torno do vetor associado ao campo externo (movimento semelhante ao de um pião a girar sob acção do campo gravítico terrestre). Este movimento ocorre a uma frequência característica dependente da intensidade do campo B_0 , a qual é designada por *frequência de precessão* ou *frequência de Larmor*. A frequência de precessão pode ser calculada através da equação de *Larmor*, obtida pelo produto entre a magnitude do campo B_0 e a razão giromagnética (equação expressa em megahertz - MHz) (47-52):

$$\omega = \gamma \cdot B_0$$

No caso do hidrogénio $\gamma = 42,5775 \text{ MHz/T}$ (ou $267,5222 \times 10^6 \text{ rad} \cdot \text{s}^{-1} \cdot \text{T}^{-1}$). (47-49,51-53) Esta equação mostra que a frequência a que ocorrerá o fenómeno de precessão dos núcleos de hidrogénio depende da magnitude do campo magnético sentido por cada núcleo, o qual não é exactamente B_0 mas um valor próximo desse. Por esse motivo, a equação anterior dever-se-ia ser reescrita para $B_{0,ef}$, uma vez que o valor do campo magnético em cada ponto do espaço não é exactamente igual aos valores nos demais pontos, seja por inhomogeneidades do campo B_0 produzido, seja por variações locais de ambiente químico. Este facto, que poderia ser visto como problema, é na verdade, uma das mais importantes características da técnica de RM, conferindo-lhe a capacidade de discriminação dos tecidos biológicos.

Em resultado da exposição de inúmeros núcleos de hidrogénio ao campo magnético B_0 , surgirá o vetor *magnetização*, o qual corresponde à soma vetorial dos momentos

dipolares magnéticos de todos os núcleos, tanto dos que se orientam paralelamente em relação a B_0 , como dos que se orientam anti-paralelamente. Uma vez que o estado de alinhamento paralelo é mais comum – por estar associado a um estado energético mais baixo – o vetor magnetização acaba por ficar alinhado segundo o eixo positivo de Z (o eixo do campo magnético B_0 uma vez que existe aleatoriedade de fase no movimento de precessão de cada próton em torno do eixo Z. Este alinhamento da magnetização com B_0 corresponde a um estado de equilíbrio no qual é dito que a magnetização é longitudinal.

Após a emissão de um impulso de radiofrequência (RF), caracterizado por um campo magnético B_1 , ocorre o fenómeno de ressonância nuclear entre os prótons de hidrogénio e o impulso de RF. Neste caso, os prótons que precessam com a mesma frequência do impulso de RF aplicado vão absorver energia seletivamente, passando do estado alinhado paralelamente com B_0 para o estado alinhado anti-paralelamente relativamente a B_0 (ou de excitação). Dado que esta transição só ocorre se a frequência do campo magnético B_1 for igual à frequência de *Larmor*, dizemos que estamos perante um fenómeno de ressonância. ^(48–54)

Simultaneamente, a exposição da amostra ao campo magnético B_1 provoca o fenómeno de introdução de coerência de fase entre os núcleos em precessão, o que resulta no aparecimento de uma componente transversal do vetor de magnetização (perpendicular a B_0), e que pode ser visto com resultante de um movimento em espiral do vetor magnetização alinhado com o eixo Z até ao plano X-Y. Este movimento é explicado pela diminuição da componente longitudinal do vetor magnetização e consequente aumento da componente transversal. Quando o impulso de RF cessa, ocorre o fenómeno de relaxação energética (processo físico dinâmico em que o sistema de *spins* retorna ao equilíbrio), levando à recuperação da magnetização longitudinal e diminuição da magnetização transversal. ^(47–55)

Relativamente à emissão do sinal da técnica de RM, que será captado pelas antenas do equipamento ou colocadas dentro deste, ocorre durante o processo de relaxação dos *spins* e é denominado de *free-induction decay* (FID). O sinal FID tem a forma de uma onda harmónica com amplitude exponencialmente decrescente, uma vez que está associado à medição do sinal induzido pela componente transversal do vetor magnetização. ^(47–49,52)

O fenómeno de relaxação energética resulta, na prática, de dois mecanismos de relaxação, designados *spin-rede* e *spin-spin*:

- A relaxação *spin-rede* é devida à interação dos *spins* com o meio envolvente, no qual estes transferem energia para os vários núcleos das estruturas moleculares vizinhas, levando à sua perda de energia. Como consequência desta transferência de energia, os *spins* regressam ao estado de baixa energia (alinhamento paralelo com B_0). A relaxação *spin-rede* é caracterizada por uma constante, designada por T_1 , a qual corresponde ao tempo que a magnetização longitudinal demora a recuperar cerca de 63% do seu valor inicial (antes da aplicação do impulso de RF). Assim, o tempo T_1 está dependente de características específicas dos tecidos e da intensidade de B_0 .^(47-49,52). A recuperação da magnetização longitudinal, também denominada de relaxação T_1 , segue uma curva exponencial caracterizada pelo tempo T_1 , que corresponde ao tempo que os *spins* demoram a realinharem-se com o eixo Z. A constante T_1 indica o tempo necessário para a magnetização longitudinal recuperar 63% do seu valor inicial – ver Figura 3.4.^(47-52,55)




Figura 3.4: Representação do processo de recuperação longitudinal após um impulso de RF de 90° ser aplicado. A componente de magnetização M_z é reduzida a zero, recuperando gradualmente o seu valor de equilíbrio, quando cessam os impulsos de RF. Esta recuperação é um processo exponencial, cuja constante de tempo é T_1 , e corresponde ao momento em que a magnetização recuperou 63% do seu valor de equilíbrio. Fonte: Ridgay, 2010.

- A relaxação *spin-spin* deve-se às interações provocadas pelos pequenos campos magnéticos dos *spins* uns sobre os outros, o que faz com que a velocidade de precessão individual de cada um destes seja ligeiramente diferente da dos restantes, provocando uma perda gradual da coerência de fase. A relaxação *spin-spin* é caracterizada por uma constante, designada por T_2 , a qual corresponde ao tempo que a magnetização transversal demora a perder cerca de 63% do seu valor inicial (imediatamente após a aplicação do impulso de RF). De referir ainda que, para além das interações entre os *spins*, existem também inhomogeneidades do campo magnético B_0 (diferentes influências nos prótons e conseqüentes diferenças de precessão), que também contribuem para a perda de coerência de fase devido às alterações da frequência de precessão entre os vários *spins* (provocadas pela falta de homogeneidade do campo).^(47-53,55) Desta forma, o fenómeno de relaxação pode ser descrito através da variável T_2^* , a qual se relaciona com a variável T_2 através da expressão:

$$\frac{1}{T_2^*} = \frac{1}{T_2} + \frac{1}{T_2'}$$

em que T_2' é o tempo de relaxação associado à inhomogeneidade do campo magnético B_0 – por vezes, este termo é referido como δ . Os valores de T_2^* são, por isso, sempre menores do que os correspondentes valores de T_2 . Este facto é ilustrado na Figura 3.5.




Figura 3.5: Representação da relaxação transversal após um impulso de RF de 90° aplicado à fase de equilíbrio. Inicialmente a magnetização transversal (seta vermelha) tem uma amplitude máxima à medida que os spins estão em fase. O sinal detetado FID diminui quando ocorre o desfaseamento dos spins (pequenas setas pretas), sendo que o termo geral utilizado é a relaxação T_2^* (combinação do relaxação T_2 com a ausência de homogeneidade do campo). A relaxação T_2 resultante das interações spin-spin é um processo irreversível devido à natureza aleatória do movimento molecular. A relaxação T_2^* , responsável pelo decaimento mais rápido do sinal FID, pode ser revertido através da aplicação de um impulso de refasagem de 180°. Tanto T_2 como T_2^* são processos exponenciais de constante de tempo T_2 e T_2^* , respetivamente, que corresponde ao momento em que a magnetização decaiu para 37% do seu valor inicial após o impulso de RF. Fonte: Ridgay, 2010.

O mecanismo de relaxação provocado pelas inhomogeneidades do campo magnético pode ser contornado através da aplicação de impulsos adicionais de RF com um *flip angle* (FA) de 180°, o que vai permitir o aparecimento de sinais de eco (no plano transversal), os quais vão ser detetados e convertidos na imagem final. Neste caso, estamos na presença de uma imagem obtida através de um mecanismo designado por *spin-echo*, ou eco de *spin* – ver Figura 3.6. No caso do sinal de eco ter origem numa inversão dos campos magnéticos responsáveis por realizar a codificação espacial, o mecanismo é designado por *gradient-echo*, ou eco de gradiente.




Figura 3.6: Diagrama da magnetização e impulsos de radiofrequência: a) Quando exposta a B_0 , o vetor de magnetização M_0 , está em equilíbrio, alinhado paralelamente ao campo magnético. b) Quando um impulso de RF é aplicado, M_0 faz um ângulo com o eixo z, conhecido como ângulo de inversão, e gira em torno do eixo na direção da seta curva. A qualquer instante a magnetização pode ser dividida em dois componentes, M_z e M_{xy} . O componente M_{xy} rotativo gera o sinal da técnica de RM detetável. c) A amplitude máxima do sinal detetável após um único impulso de RF ocorre quando M_0 está inteiramente no plano dos eixos x e y, pois isso fornece o maior componente M_{xy} . Esse impulso tem um ângulo de inclinação de 90° . d) Um impulso de RF de refasamento de 180° é normalmente aplicado enquanto há magnetização transversal já girando no plano xy e é usado para inverter instantaneamente o componente transversal de magnetização em 180° em torno de um eixo também girando no plano xy. e) Um impulso de inversão de 180° é normalmente aplicado em equilíbrio e é usado para girar a magnetização líquida em 180° do eixo z positivo para o negativo. Isso também é conhecido como impulso de preparação de magnetização e é usado como esquema de preparação para técnicas de imagem de saturação de estruturas. Fonte: Ridgay, 2010.

Os sinais de eco resultantes de qualquer um destes dois mecanismos mencionados (eco de *spin* ou eco de gradiente) são, então, armazenados numa matriz, habitualmente denominada de espaço K , a qual, quando preenchida na íntegra, permite obter a imagem do objeto por intermédio da aplicação da Transformada de Fourier. O espaço K corresponde, então, a uma matriz cujos valores resultam da deteção dos sinais de eco obtidos em diferentes condições, as quais traduzem os princípios da codificação espacial (feita no plano de aquisição). A codificação espacial visa estabelecer uma correspondência entre a fase e a frequência de precessão dos spins e a localização destes dentro do corpo humano. Os valores de fase e de frequência são controlados através da aplicação de gradientes de campo magnético, os quais variam ao longo dos eixos x e y . A codificação em frequência é feita ao longo do eixo x e realizada durante a leitura de cada sinal de eco através da aplicação de um gradiente de campo magnético segundo a direção x , o qual é habitualmente designado por G_x ; já a codificação em fase é feita ao longo do eixo y e realizada antes da aquisição de cada sinal de eco através da aplicação de um gradiente de campo magnético segundo a direção y , o qual é

habitualmente designado por G_y . Por esse motivo, o espaço K é referido como tendo dois eixos perpendiculares entre si, o eixo de fase que corresponde às linhas horizontais e o eixo de frequência formado por colunas ou linhas verticais. ^(47,48,51,52) Os tempos e a duração de aplicação de cada gradiente, conjuntamente com os impulsos de RF, definem aquilo a que convencionalmente se resolveu chamar de *sequências*; à frente veremos algumas das sequências mais importantes. As sequências – e sobretudo o contraste das imagens produzidas – são controlados através de dois parâmetros, designados por *tempo de repetição* (TR) e *tempo de eco* (TE):

- O TR corresponde ao intervalo temporal entre a aplicação de um impulso de RF e a aplicação do impulso de RF seguinte. O TR influencia a quantidade de relaxação longitudinal que é atingida e, por isso, se a imagem final é mais ou menos ponderada em T_1 ;
- O TE corresponde ao intervalo de tempo desde a aplicação do impulso de RF e a medição do seu eco (sinal). O TE influencia a quantidade de relaxação transversal que é medida e, consecutivamente, se a imagem final é mais ou menos ponderada em T_2 . ^(47,48,51,52)

3.2 SEQUÊNCIAS EM RESSONÂNCIA MAGNÉTICA

As sequências existentes na técnica de RM são inúmeras, podendo no entanto ser distribuídas em dois grupos principais: as sequências *Spin-Eco* (SE) e as sequências de Gradiente - Eco (GE). Ambas as sequências têm por base a geração do sinal de eco após uma excitação inicial, a qual é feita através de um impulso de RF que coloca os *spins* dos prótons em coerência de fase.

3.2.1 SEQUÊNCIAS *SPIN-ECO*

A sequência SE inicia-se com o impulso excitatório de RF de 90° , seguido por um impulso de refasamento de 180° , o qual origina um novo sinal, agora denominado de eco. O eco surge no tempo $TE/2$ após o impulso de 180° , o que corresponde a TE após o impulso de 90° . O gradiente de codificação de fase é ligado após a aplicação do impulso de 90° de forma a permitir a codificação do sinal segundo uma das direções perpendiculares a B_0 - neste caso, y , ou seja, a direção de codificação em fase. O gradiente de codificação em frequência é ligado 2 vezes, uma entre os impulsos de 90°

e de 180° e a outra durante a leitura do sinal de eco. A seleção do plano é feita através da aplicação de um gradiente de campo magnético segundo a direção z, o qual é ligado durante a aplicação dos impulsos de RF – ver Figura 3.7. Esta sequência têm a capacidade de formar um sinal robusto que minimiza o efeito resultante da ausência de homogeneidade do campo magnético, através da aplicação do impulso de 180° . (47,48,51–54,56)




Figura 3.7: Diagrama de uma sequência SE. Na 2ª linha temos a ativação e respetivo tempo de duração do gradiente de corte que ocorre em simultâneo com a aplicação dos impulsos, estando invertido entre os pontos positivos para minimizar a desfasagem da magnetização transversal devido aos próprios gradientes. O tempo de ativação da codificação de fase surge representado na 3ª linha, aplicado perpendicularmente ao gradiente de corte, cuja ativação é feita com intensidades diferentes para cada repetição da sequência básica de impulso, fornecendo diferentes codificações de fase em cada repetição. Na 4ª linha temos a codificação de frequência, também conhecida como gradiente de “leitura”, que é ativado durante a medição do sinal de eco. Por último temos o sinal obtido, com um eco máximo no momento TE após o impulso de 90° . T_s corresponde ao tempo total de amostragem, durante o qual o sinal é captado pelas antenas recetoras e durante o qual o gradiente constante de codificação de frequência é aplicado. Após o início do impulso de 90° e num momento TR , a sequência é repetida da mesma forma, com a exceção dos valores do gradiente de codificação de fase. A sequência básica é repetida 128, 192, 256 ou mais vezes, para formar uma única imagem. Fonte: Hendrick, 2010.

3.2.2 SEQUÊNCIAS GRADIENTE - ECO

A sequência GE apresenta duas características principais que a diferenciam da sequência SE. O impulso de RF aplicado tem um $FA < 90^\circ$ e, após este impulso, é aplicado um gradiente de campo magnético invertido – segundo a direção de codificação em frequência - o qual se destina a realizar o refasamento dos prótons e assim obter o eco, que neste caso se designa por *eco de gradiente* – ver Figura 3.8. (47,48,56)

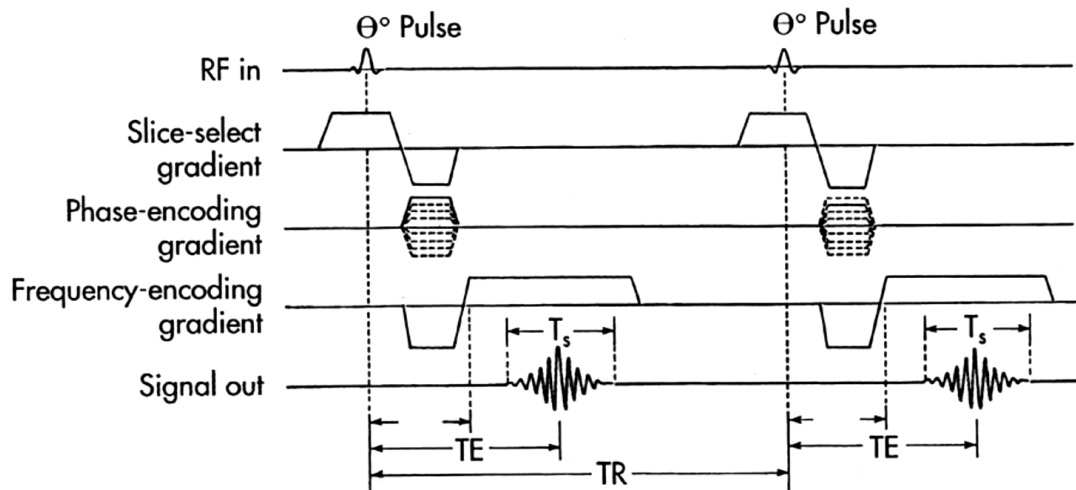


Figura 3.8: Diagrama de uma sequência SE. Na 2ª linha temos a ativação e respetivo tempo de duração do gradiente de corte. Esta ativação ocorre em simultâneo com a aplicação dos impulsos, estando invertido entre os pontos positivos para minimizar a desfase da magnetização transversal devido aos próprios gradientes. O tempo de ativação da codificação de fase surge representado na 3ª linha. Este é aplicado perpendicularmente ao gradiente de corte, cuja ativação é feita com intensidades diferentes para cada repetição da sequência básica de impulso, fornecendo diferentes codificações de fase para cada repetição. Na 4ª linha temos a codificação de frequência, também conhecida como gradiente de "leitura", que é ativado durante a medição do sinal. Por último temos o sinal obtido, com um eco máximo no momento TE após o impulso de 90° . T_s corresponde ao tempo total de amostragem, durante o qual o sinal é captado pelas antenas recetoras e durante o qual o gradiente constante de codificação de frequência é aplicado. Após o início do impulso de 90° e num momento TR, a sequência é repetida da mesma forma, com a exceção dos valores do gradiente de codificação de fase. A sequência básica é repetida 128, 192, 256 ou mais vezes, para formar uma única imagem. Fonte: Hendrick, 2010.

Nas sequências SE e GE ditas convencionais, são necessárias três etapas para a realização da codificação espacial: a seleção de corte, a codificação de fase e a codificação de frequência, sendo que cada uma destas etapas corresponde à ativação do respetivo gradiente num dos eixos x, y ou z. O preenchimento do espaço K também é igual nas duas sequências, pois em ambas apenas uma linha do espaço K é preenchida em cada TR. Neste sentido, e de forma a reduzir os tempos de aquisição de imagens pela técnica de RM, novas sequências surgiram tendo por base as ditas sequências convencionais, como é o caso das sequências *Fast Spin-Echo* (FSE) ou *Turbo Spin-Echo* (TSE). Ao contrário da sequência SE convencional, vários ecos são criados e medidos através da aplicação de vários impulsos de 180° , sendo que o sinal *spin-eco* é medido após cada impulso de 180° e cada um destes sinais apresenta uma visão de codificação de fase diferente do mesmo tecido. Ao conjunto total de ecos formados e medidos após cada impulso de 90° é atribuída a denominação *Echo Train Length* (ETL) ou *Turbo Factor*, correspondendo ao fator pelo qual o tempo total da obtenção da imagem é reduzido. Esta aceleração na deteção de dados possibilita a

aquisição de múltiplas linhas do espaço K num único TR, podendo ser otimizadas para contemplar mais ou menos linhas nesse intervalo, dependendo do número de ecos a adquirir (fator que pode ser manipulado) – ver Figura 3.9. (47,48,51,52,56)




Figura 3.9: Representação de uma sequência FSE ou TSE com 4 ETL. Devido à aplicação de um gradiente de codificação de fase antes de cada eco, é possível obter uma visualização de codificação de fase diferente por eco, o que possibilita o preenchimento de várias linhas do espaço K por cada TR. Fonte: Hendrick, 2010.

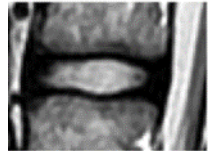
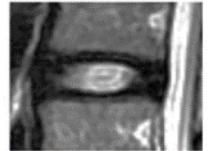
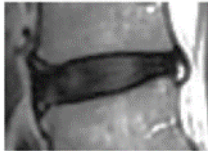
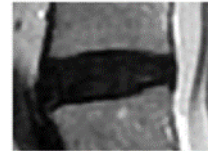
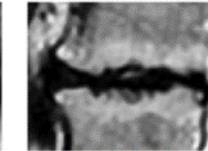
As imagens da técnica de RM caracterizam-se pela elevada diferenciação das estruturas, o que possibilita uma excelente avaliação da anatomia e da patologia das mesmas. Esta diferenciação é devida à conjugação de factores intrínsecos (tempos T_1 e T_2 característico das estruturas) e extrínsecos (parâmetros de aquisição manipuláveis, como o TE, o TR e o FA). Como resultado da manipulação destes parâmetros extrínsecos, são obtidas imagens com ponderação em T_1 (valor de TR e TE curtos), T_2 (valor de TR e TE longos), ou ainda densidade protónica (DP – valor de TR longo e TE curto). Outras técnicas podem ainda ser implementadas para modificar o contraste da imagem, como por exemplo através da anulação do sinal do tecido adiposo. Esta anulação pode ser realizada por intermédio da saturação espectral (temos como exemplo o módulo FAT-SAT do inglês *fat saturation*) ou recorrendo a impulsos de inversão-recuperação (como, por exemplo, através do o módulo STIR - do inglês *Short Time Inversion Recovery*). Sempre que necessário, é ainda possível a administração endovenosa de um produto de contraste paramagnético à base de gadolínio para uma melhor diferenciação e caracterização tecidual. (48,51–53,57)

3.3 RESSONÂNCIA MAGNÉTICA NA AVALIAÇÃO DE HÉRNIAS DISCAIS LOMBARES

A técnica de RM é considerada a técnica com maior sensibilidade diagnóstica no estudo da patologia vertebro-medular, possibilitando uma avaliação morfológica muito detalhada das estruturas vertebrais, dos discos intervertebrais e estruturas que constituem o canal medular. ^(8,9,23,32,58-61) O estudo dos discos intervertebrais por este método imagiológico permite analisar as mudanças estruturais e de composição dos mesmos, que são cada vez mais visíveis à medida que a degeneração ou a idade progridem. A classificação do estado da degeneração dos discos pela técnica de RM é efectuada tendo por base o sistema desenvolvido por Pfirrmann *et al.*, cuja classificação é feita através das imagens sagitais ponderadas em T_2 . Esta classificação é dividida em cinco níveis, do grau I ao grau V, tendo em conta a estrutura, a altura e a intensidade do sinal do disco, assim como a distinção entre o anel fibroso e o núcleo pulposo, de acordo com a Tabela 3.1. ^(9,23,58,61-63)

Tabela 3.1 - Classificação da degeneração do disco intervertebral segundo Pfirrmann *et al.* Fonte: Adaptado com modificações de Ogon *et al.*, 2020.

GRAU	ESTRUTURA	DISTINÇÃO ENTRE NÚCLEO E ANEL	INTENSIDADE DO SINAL	ALTURA DO DISCO INTERVERTEBRAL
I	Homogéneo, branco brilhante	Clara	Hiperintenso, isoíntenso ao LCR	Normal
II	Inomogéneo com ou sem bandas horizontais	Clara	Hiperintenso, isoíntenso ao LCR	Normal
III	Inomogéneo, cinzento	Pouco clara	Intermédio	Normal a ligeiramente diminuído
IV	Inomogéneo, cinzento a preto	Perdida	Intermédio a pouco intenso	Normal a moderadamente diminuído
V	Inomogéneo, preto	Perdida	Hipointenso	Espaço do disco colapsado

I
II
III
IV
V

Relativamente à avaliação da HD, a distinção desta é feita pela observação do deslocamento do material do disco para além dos limites do seu espaço normal e a sua relação com as raízes nervosa, sendo que os detalhes como as fibras do anel fibroso do disco intervertebral normal, são dificilmente visualizados – ver Figuras 3.10 e 3.11.⁽²⁶⁾




Figura 3.10: Exemplo de protrusão e extrusão do disco. A) Imagem axial ponderada em T_2 de uma hérnia de disco focal à esquerda, provocando o deslocamento posterior da raiz nervosa no recesso lateral esquerdo (ponta de seta). B) Imagem axial ponderada em T_2 do disco subjacente no mesmo paciente, demonstrando uma hérnia de disco focal de aparência semelhante localizada centralmente. C) Imagem sagital ponderada em T_2 do mesmo paciente que nos permite diferenciar a extrusão de nível superior e a protrusão no nível inferior. De salientar que a extrusão tem um ápice (pontas de seta) mais largo que sua base (linhas tracejadas), enquanto a protrusão não. Fonte: Buller, 2018.




Figura 3.11: Caracterização de fissuras anulares: A) Imagem axial ponderada em T_2 de um disco ao nível lombar demonstrando uma linha concêntrica hiperintensa em T_2 dentro do anel fibroso (seta), o que representa uma fissura anelar. B) Imagem sagital média ponderada em T_2 de dois

discos lombares e que apresentam uma grande fissura anular ao nível do disco superior (seta) e inferior (ponta de seta). As imagens axiais ponderadas em T_1 (C) e sagital da linha média (D) após a administração de contraste demonstram realce das fissuras anulares. Fonte: Buller, 2018.

3.4 PROTOCOLO DE RESSONÂNCIA MAGNÉTICA LOMBAR

O exame pela técnica de RM à coluna lombar engloba normalmente uma sequência SE sagital ponderada em T_1 , uma sequência SE sagital ponderada em T_2 e imagens axiais ou transversais ponderadas em T_2 . Adicionalmente, e dependendo do protocolo de cada instituição, da informação clínica e dos achados imagiológicos, podem ser adicionadas outras sequências, incluindo sequências ponderadas em T_1 no plano axial e sequências ponderadas em T_2 com supressão de gordura no plano sagital (obtidas com o módulo STIR). A administração de produto de contraste é efectuada quando existem informações/alterações imagiológicas que o justifiquem (como por exemplo história de cirurgia recente na área em estudo, história de cancro da mama, entre outros).⁽⁶³⁾

As imagens no plano sagital devem incluir desde a última vértebra dorsal, D12, até à segunda ou terceira vértebra sacrada (S2/S3). Já as imagens axiais são adquiridas ao nível do espaço intervertebral, de pedículo a pedículo, e incluem pelo menos os três últimos espaços intervertebrais da coluna lombar, de L3 a S1, sendo que os restantes espaços só são adquiridos quando apresentam alterações. O plano coronal não costuma constar do protocolo da técnica de RM de coluna lombar degenerativa uma vez que a sua principal aplicação reside na avaliação e caracterização de escoliose.

Relativamente aos planos de aquisição, as imagens sagitais permitem diferenciar um disco normal de um disco herniado, a localização e a forma de cada disco e as respetivas alterações que estes apresentem individualmente. Já as imagens axiais fornecem mais informação sobre a HDL, nomeadamente o tipo de hérnia e respetivo estágio de evolução.^(63,64)

As imagens ponderadas em T_1 são indicadas para a avaliação anatómica, tendo também elevada sensibilidade ao contraste paramagnético. São úteis na avaliação da medula óssea, que é normalmente gordurosa nos adultos, apresentando-se com hipersinal, tanto em T_1 como em T_2 . As imagens sagitais ponderadas em T_1 também são importantes para a avaliação do alinhamento dos corpos vertebrais e do grau de estenose dos buracos de conjugação devido ao contraste entre a gordura e as raízes nervosas.^(62,63)

As imagens ponderadas em T_2 fornecem um excelente contraste entre o líquido cefalorraquidiano no saco tecal e as estruturas circundantes e apresentam uma maior sensibilidade às variações hídricas dos tecidos. Estas características possibilitam a detecção precoce do edema de diferentes causas (tumoral, traumática, infecciosa ou inflamatória), podendo esta sensibilidade ser aumentada com o recurso a técnicas de saturação de gordura devido ao aumento do contraste.

As imagens sagitais ponderadas em T_2 permitem a avaliação do grau de degeneração dos discos e da existência de HD, assim como do grau de estenose *espinhal* em vários níveis numa única imagem. Já as imagens axiais ponderadas em T_2 possibilitam uma avaliação ao nível dos espaços intervertebrais, da integridade, da localização dos discos e da relação entre o saco tecal e as estruturas ósseas e ligamentares circundantes. São ainda utilizadas na avaliação das articulações interfacetárias e do ligamento amarelo. ^(60,62,63)

4. ENQUADRAMENTO TEÓRICO PARTE III – INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (IA) é um ramo abrangente da ciência da computação que consiste num conjunto de algoritmos matemáticos capazes de realizar tarefas complexas ou que normalmente exigem inteligência humana. ^(21,65)

Dentro deste grande universo que é a IA temos um subnível denominado de *Machine Learning* (ML) que recorre aos algoritmos para organizar dados, reconhecer padrões e possibilitar que os computadores possam aprender, sem a necessidade de uma programação prévia. Este grupo corresponde à aprendizagem automática que visa extrair automaticamente, a partir dos dados fornecidos, os padrões que servirão para o algoritmo ganhar experiência e conhecimento. Deste modo, o algoritmo de ML consegue tomar decisões informadas baseadas na aprendizagem adquirida. ⁽²¹⁾

Os algoritmos matemáticos de ML podem ainda ser agrupados em algoritmos supervisionados e não-supervisionados, embora permaneçam algumas *nuances* nesta divisão. Os algoritmos supervisionados são os mais comuns no grupo de ML e, baseiam-se na comparação entre os resultados fornecidos pelo próprio algoritmo e aqueles que se acreditam serem os correctos. Estes algoritmos classificam a entrada de dados (*input*) em classes de saída (*output*) tendo em conta informações previamente aprendidas. Para isso, são inicialmente fornecidos exemplos de treino destinados a “ensinar” o algoritmo sobre a classificação a atribuir. Posteriormente são fornecidos novos dados que deverão ser classificados tendo em conta a aprendizagem anterior. Em suma, nos algoritmos supervisionados, para cada entrada já são conhecidas as saídas (classificações) desejadas. A título de exemplo, o objetivo pode ser saber se a imagem de um determinado animal (*input*) corresponde a um cão, a um gato ou a uma

galinha (*output*), tal como esquematizado no ponto A) da Figura 4.12.

Os algoritmos de aprendizagem não-supervisionada têm como principal missão o processamento de dados não classificados, sendo estes algoritmos treinados para encontrar padrões nos dados fornecidos e agrupar os *outputs* de acordo com as suas similaridades (Figura 4.12 B). Ao contrário dos algoritmos supervisionados, não há necessidade de treinar os algoritmos não-supervisionados, dado que estes são aplicados diretamente aos dados que serão analisados. ^(11,21,66) Estes algoritmos são amplamente utilizados em diferentes aplicações como por exemplo reconhecimento de padrões e deteção de movimentos fraudulentos nas transações financeiras. ^(67,68)

Os algoritmos supervisionados englobam o grupo de algoritmos de aprendizagem profunda, o DL, grupo ao qual pertence o algoritmo utilizado no desenvolvimento deste estudo. A principal particularidade deste grupo de algoritmos é o facto de serem baseados em redes neuronais que se acredita que mimetizam da melhor forma os neurónios humanos, sendo atualmente o grupo algoritmos de ML com uma aplicabilidade mais promissora. Este grupo de algoritmos, para além de aprender um mapeamento entre características representativas e um *output* desejado, tem a capacidade de aprender as próprias características representativas de forma automática, o que representa uma enorme vantagem na execução de tarefas, uma vez que a rede aprende o que precisa ser feito e executa a função, não necessitando de guardar instruções e executá-las de forma lógica como um computador dito tradicional ⁽⁶⁴⁾.

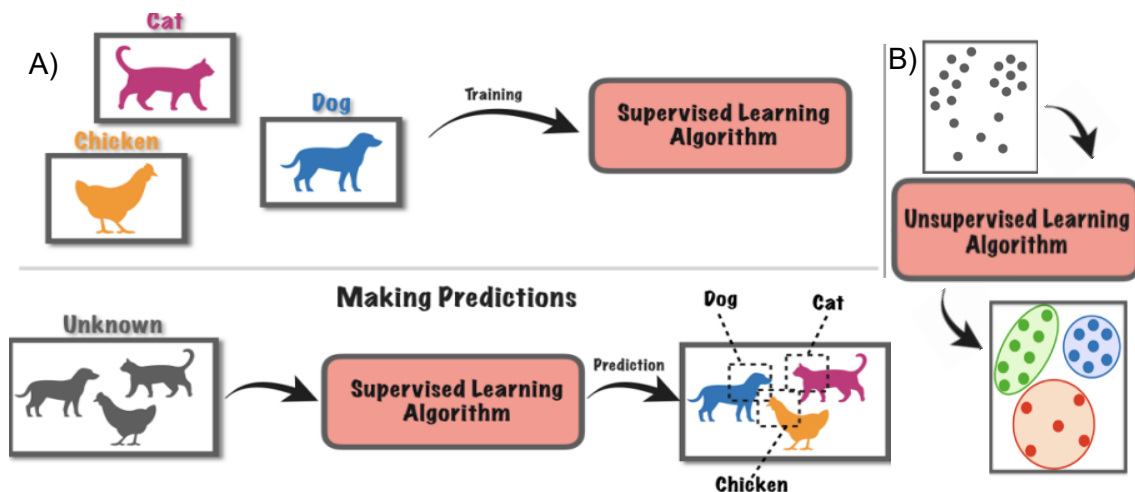


Figura 4.12: Exemplificação de um algoritmo supervisionado (a) e de um algoritmo não supervisionado (b). Fonte: Adaptado com modificações de <https://towardsdatascience.com/supervised-vs-unsupervised-learning-in-2-minutes-72dad148f242>, acessado em 27/04/2022.

Os algoritmos de DL requerem, no entanto, uma grande quantidade de dados (*big*

data) para conseguirem ser treinados e têm demonstrado uma elevada capacidade e um desempenho superior numa grande variedade de tarefas sofisticadas.⁽⁶⁹⁾ Como exemplos práticos da utilização de algoritmos de DL temos os carros com capacidade de auto condução, a deteção do uso do cartão de crédito de uma forma fraudulenta e a visão computacional para interpretar imagens (em imagens médicas, robótica e reconhecimento facial, entre outros).^(10,12,33,65)

4.1 NEURÓNIO BIOLÓGICO E NEURÓNIO MATEMÁTICO

Para uma melhor compreensão do funcionamento das redes neuronais, é fundamental conhecer o funcionamento básico de um neurónio e as suas conexões com outros neurónios, pelo que passaremos a fazer uma breve descrição do neurónio biológico e a sua analogia com o neurónio matemático.

4.1.1 NEURÓNIO BIOLÓGICO

Conhecido como a unidade funcional do sistema nervoso, o neurónio é uma célula altamente especializada responsável pela transmissão do impulso nervoso. Esta célula diferenciada pode ser dividida anatomicamente em (Figura 4.13):

- Corpo celular ou soma, o qual contém o núcleo e a grande maioria dos organelos;
- Dendrites, que são prolongamentos citoplasmáticos finos, geralmente ramificados, os quais recebem e conduzem os estímulos provenientes de outros neurónios ou de células sensoriais;
- Axónio, que é o prolongamento citoplasmático mais alongado que transmite os impulsos nervosos provenientes do corpo celular através das suas terminações. O axónio estabelece a comunicação com as dendrites ou com o corpo celular de outros neurónios, e pode estar coberto por uma camada de mielina que acelera a transmissão dos impulsos eletroquímicos.^(70,71)

Podemos então afirmar que o núcleo e as dendrites correspondem à superfície de entrada da informação no neurónio, e que o axónio corresponde à superfície de saída do fluxo de informação. As informações que os neurónios transmitem uns aos outros são impulsos eletroquímicos denominados de *potenciais de acção*, e correspondem à propagação de um estímulo captado pelos recetores nervosos. A propagação do

impulso nervoso realiza-se em sentido único, das dendrites para o axónio – ver Figura 4.13. ⁽⁷¹⁾




Figura 4.13: Anatomia de um neurónio. Fonte: <https://askabiologist.asu.edu/neuron-anatomy> (acedido em 21/02/2022).

A região de contacto entre a extremidade de um neurónio e a superfície de outra célula, quer seja um neurónio ou outra célula efetora¹, é denominada de *sinapse*. Assim, as dendrites estão cobertos por sinapses (pontos de contacto) formadas pelas extremidades dos axónios de outros neurónios. Já a região sináptica (onde ocorre a sinapse) engloba a membrana pré-sináptica, a fenda sináptica e a membrana pós-sináptica. O neurónio que conduz impulsos para um outro neurónio, ou seja, em direção à sinapse, denomina-se *neurónio pré-sináptico*. O neurónio que recebe o impulso através da sinapse é denominado *neurónio pós-sináptico*. Em suma, os neurónios pré-sinápticos são os transmissores da informação e os neurónios pós-sinápticos são recetores da informação. ⁽⁷²⁾

Os neurónios criam entre si uma rede de comunicação altamente complexa, a rede neural biológica, em que cada neurónio está ligado a milhares de outros neurónios. ⁽⁷³⁾ O sistema nervoso contém cerca de 100 biliões de neurónios, sendo que cada um pode estar ligado a 10 000 conexões sinápticas e ser estimulado por igual número de outros neurónios. ⁽⁷⁰⁾

As sinapses podem ainda ser catalogada como sinapses químicas (tipo de sinapse mais comum) ou elétricas (ocorrem apenas nas células musculares ou gliais). Nas

¹ Qualquer um dos vários tipos de células que respondem ativamente a um estímulo e afetam algumas mudanças.

sinapses químicas ocorre a libertação de neurotransmissores para a fenda sináptica, aquando da chegada do impulso nervoso à membrana pré-sináptica. Estes neurotransmissores vão-se ligar aos recetores presentes na membrana pós-sináptica, permitindo deste modo a propagação do impulso nervoso. Por seu turno, nas sinapses elétricas, o impulso nervoso propaga-se diretamente do neurónio pré-sináptico para o neurónio pós-sináptico, não havendo intervenção dos neurotransmissores.

Para que ocorra um estímulo nervoso (ou potencial de ação), o estímulo tem que ter uma determinada intensidade ou seja, um estímulo mínimo ou limiar. Quando este limiar é atingido, há um aumento de número de impulsos por segundo, levando à propagação do potencial de ação. ⁽⁷⁰⁾ Quando acontece a união entre os neurotransmissores e os respetivos recetores da membrana pós-sináptica, ocorrem alterações ao nível da permeabilidade da mesma. Por outro lado, o efeito produzido, que pode ser de excitação ou de inibição do neurónio pós-sináptico, é determinado pela natureza do neurotransmissor e da molécula do recetor. ^(70,71)

Quando o neurónio recebe os sinais, estes podem ou não ser transmitidos. Esta situação deve-se ao facto de um sinal poder ser ampliado ou atenuado, dependendo do dendrito de origem, uma vez que cada dendrito está associado a um peso pelo qual o sinal é multiplicado. Os pesos são equiparados à nossa memória e são estabelecidos devido ao treino recebido pelo cérebro durante a vida útil, ou seja, a memorização. ⁽⁷¹⁾

4.1.2 NEURÓNIO MATEMÁTICO

O neurónio matemático é uma unidade de processamento de informações fundamental para a operação de uma rede neuronal. Este neurónio artificial procura imitar o neurónio biológico, quer seja a nível estrutural como a nível funcional, numa tentativa de reproduzir computacionalmente as redes neurais humanas, ou seja, criar uma rede neuronal artificial (RNA). ⁽⁷²⁾

Em termos simples, num neurónio matemático:

- O *input* é equiparado aos impulsos provenientes dos outros neurónios – sinal de entrada;
- O *output* é equiparado ao sinal de saída no axónio.

Verifica-se ainda que:

- Cada entrada possui um determinado peso (w do inglês *weight*) associado aos pesos sinápticos e à respectiva capacidade excitatória do impulso. Quanto maior o valor do peso, mais excitatório será o impulso. Os impulsos podem ser positivos ou negativos;
- O valor do peso da entrada pode ativar ou não a sua saída e corresponde à função de transferência.

Fazendo a analogia, o corpo celular do neurónio matemático é representado por duas partes:

- A primeira é uma junção aditiva, corresponde ao somatório dos estímulos (sinais de entrada) multiplicado pelo seu factor excitatório (pesos sinápticos);
- A segunda é uma função de ativação que, com base nas entradas e pesos sinápticos, irá definir qual será a saída - y_k .

Assim temos a seguinte esquematização representativa do neurónio matemático na Figura 4.14, em que: x são as entradas, w_{kn} corresponde aos pesos sinápticos (k representa o índice do neurónio em questão e n refere-se ao terminal de entrada).⁽⁷²⁾

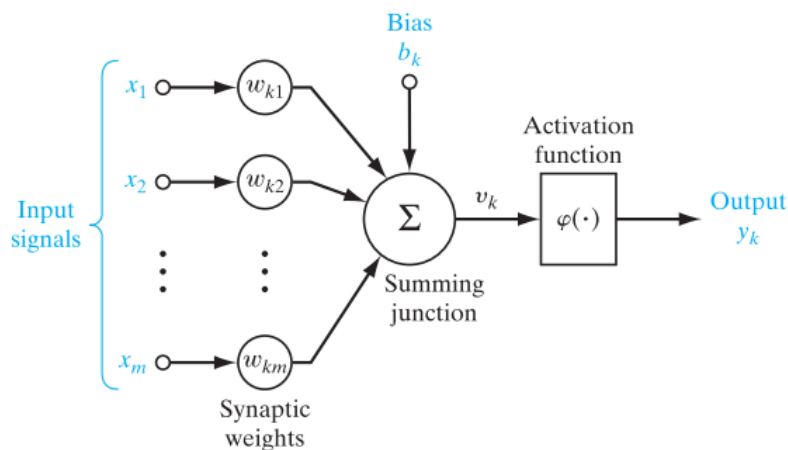


Figura 4.14: Representação esquemática do neurónio matemático. Fonte: Haykin, 2018.

O modelo neuronal inclui também um viés aplicado ao somatório da função, denominado de b_k , cujo objetivo é aumentar o grau de liberdade da função e consequentemente aumentar a capacidade de aproximação da rede. As entradas (x), quando apresentadas ao neurónio, são multiplicadas pelos pesos sinápticos correspondentes, originando as entradas ponderadas (ou seja, x_1 é multiplicado por w_1

e assim sucessivamente). Este processo descreve assim uma das bases matemáticas do funcionamento de uma RNA, a multiplicação de matrizes. ⁽⁷²⁾

4.2 REDE NEURONAL ARTIFICIAL

Segundo Simon Haykin, uma rede neuronal é um processador² distribuído massiva e paralelamente, composto por diversas unidades de processamento simples (os neurónios matemáticos) que se caracterizam por ter uma propensão natural para armazenar o conhecimento experiencial, tornando-o disponível para ser utilizado. ⁽⁷²⁾

A rede neuronal assemelha-se ao cérebro humano em dois aspetos fundamentais:

- O conhecimento é adquirido pela rede através do ambiente envolvente por meio de um processo de aprendizagem;
- As forças de ligação entre os neurónios (os pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido.

O processo de aprendizagem consiste na utilização de algoritmos cuja função é modificar, de forma ordenada, os pesos sinápticos da rede, permitindo deste modo atingir o objetivo pretendido. Fazendo novamente uma analogia com o cérebro humano, as RNA correspondem à utilização, em simultâneo, de diversos neurónios interconectados com uma capacidade única de aprender e adquirir informação através da experiência e do treino. Esta capacidade de aprendizagem resulta de um sistema conhecido como *feedback* que modifica os pesos da rede tendo em conta a comparação dos dados de saída com o valor desejado. Isto é, cada exemplo de entrada processado gera uma classificação a qual, quando comparada com o valor de classificação desejado, permite calcular um termo que vai reforçar positiva ou negativamente os diversos pesos da rede (w). Em princípio, quantos mais exemplos a rede utilizar, mais aprimorada fica, tornando-se capaz de executar as tarefas com uma elevada taxa de sucesso no final processo de aprendizagem. ⁽⁷²⁾

Devido a esta capacidade de aprendizagem, a programação recorrendo a estas redes é normalmente utilizada em problemas que exigem a análise de um grande volume de dados, de interpretação complexa e específica. Na prática, podemos dar

² É a unidade central de processamento ou CPU (Central Processing Unit). É a parte de um sistema computacional, que realiza as instruções de um programa de computador, para executar a aritmética básica, lógica, e a entrada e saída de dados. O papel da CPU pode ser comparado ao papel de um cérebro no funcionamento de um computador. Isto é, realiza operações lógicas, cálculos e processamento de dado.

como exemplo o uso diário desta tecnologia nas previsões meteorológicas em que, através da análise de várias informações como a humidade, a pressão atmosférica, a temperatura e a velocidade do vento em diversos locais e em diversos instantes, a RNA consegue determinar e obter uma previsão sobre as características do clima para um determinado local e período temporal.

A principal vantagem das redes neurais é manter sempre a mesma arquitetura principal, mudando apenas a quantidade de neurónios a serem utilizados. Porém, também é possível que uma RNA modifique sua própria topologia se achar necessário. O número de neurónios matemáticos a serem usados numa RNA dependerá sempre da quantidade e complexidade dos dados e das interpretações desejáveis. Outra característica importante das RNA é o facto do seu processo de aperfeiçoamento depender única e exclusivamente dos algoritmos de aprendizagem, como já referido anteriormente. Isto significa que quanto mais uma rede treinar, mais rapidamente irá aprender e resolver o problema inicial. ⁽⁷²⁾

As redes de aprendizagem profunda podem ter várias arquiteturas com diferentes características e graus de complexidade, como exemplificado no Anexo 1. No entanto, apenas iremos analisar a rede que utilizaremos neste trabalho, a Rede Neuronal de Convolução.

4.2.1 VISUALIZAÇÃO DAS REDES NEURONAIAS COMO GRÁFICOS DIRECIONADOS

De forma a compreendermos melhor a arquitetura das redes neuronais, importa simplificar a aparência do modelo sem sacrificar os detalhes funcionais, recorrendo como frequentemente ao diagrama de fluxo de sinal ou grafo de Mason. ⁽⁷²⁾

A *teoria dos grafos* é um ramo da matemática que estuda as relações entre os objetos de um determinado conjunto, através da utilização de estruturas denominadas de *grafos*. O grafo é uma estrutura abstrata que representa um conjunto de elementos denominados de *vértices* e as suas relações de interdependência, as chamadas *arestas*. A nível gráfico, um grafo é representado normalmente por pontos ou círculos correspondentes aos vértices e pelas linhas que os unem, as arestas. Nas redes neuronais cada ponto corresponde a um neurónio matemático e as suas ligações equivalem às sinapses.

Numa RNA, os neurónios estão organizados em forma de camadas como na Figura 4.15, existindo sempre em todas as arquiteturas uma camada de entrada e uma camada

de saída. Estas camadas são normalmente classificadas em três grupos:

- Camada de entrada - primeira camada, local onde os exemplos (imagens) são apresentados à rede;
- Camada(s) intermédia(s) ou escondida(s) - onde é feita a maior parte do processamento e a extração de características através das conexões ponderadas;
- Camada de saída - onde o resultado final (classificação) é apresentado. ⁽⁷²⁾

Uma rede neuronal pode ser constituída por apenas uma ou várias camadas intermédias. As redes denominadas de uma *camada única* são as redes que possuem apenas uma camada escondida. As redes que possuem mais do que uma camada intermédia são chamadas de *redes multicamadas*.

Quanto maior o número de camadas que constituem uma RNA, melhor será a sua capacidade de aprendizagem no caso de problemas complexos, existindo uma relação direta entre o número de camadas e o número de neurónios em cada camada e a complexidade da rede. ⁽⁷²⁾

Os neurónios que constituem uma camada escondida apresentam as seguintes particularidades:

- Só recebem informação de outros neurónios escondidos ou dos neurónios da camada de entrada;
- Só têm saídas para os outros neurónios escondidos ou para os neurónios da camada de saída;
- Não se conectam diretamente aos dados, seja de entrada ou de saída. ⁽⁷²⁾

Em relação às redes multicamadas, estas apresentam as seguintes características básicas e fundamentais:

- O modelo de cada neurónio da rede inclui uma função de ativação não-linear que o diferencia dos demais;
- A rede contém uma ou mais camadas ocultas entre as camadas de entrada e as camadas de saída;
- A rede apresenta um alto grau de conectividade, cuja extensão é determinada pelos pesos sinápticos da rede. ⁽⁷²⁾

Na figura seguinte temos um diagrama de fluxo de sinal de uma rede neuronal de convolução, onde temos a amarelo a camada de entrada, a verde as camadas completamente conectadas e a laranja as camadas de saída. Com a cor rosa temos os vértices representativos dos filtros e matrizes que serão explicados na continuidade do trabalho e que correspondem às camadas intermédias ou ocultas.




Figura 4.15: Diagrama de fluxo de sinal de uma rede neuronal de convolução. Fonte: The Neural Network Zoo - The Asimov Institute, acedido em 04/04/2022.

4.3 ALGORITMO DE APRENDIZAGEM *BACKPROPAGATION*

O processo de aprendizagem de uma rede insere-se no contexto de aprendizagem supervisionada, sendo mais difícil de visualizar e compreender devido aos neurónios nas camadas ocultas. Este processo consiste basicamente na comparação dos resultados obtidos com os resultados desejados, o que motiva o ajuste dos pesos da rede na tentativa desta ter um desempenho de classificação cada vez melhor – ver Figura 4.16. ⁽⁷²⁾

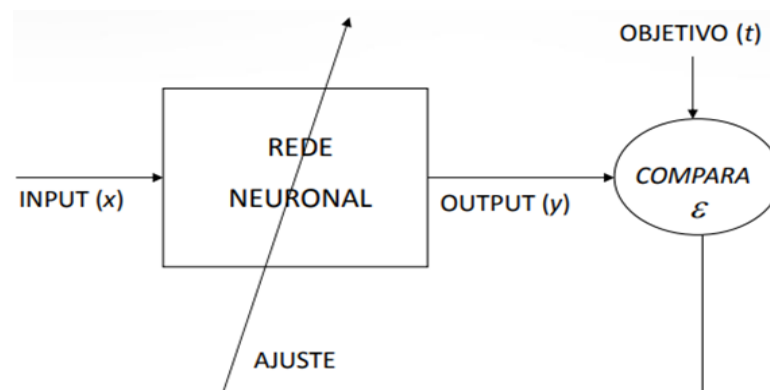


Figura 4.16: Diagrama de fluxo de sinal de uma rede neuronal de convolução. Fonte: The Neural

Network Zoo - The Asimov Institute, acessido em 04/04/2022.

O algoritmo *backpropagation* é um dos algoritmos mais utilizados no ajuste (treino) dos pesos das redes neuronais de multicamadas, e ocorre essencialmente em duas fases:

- Fase de propagação (fase direta), na qual os dados são apresentados à camada de entrada da rede. Os pesos sinápticos da rede são os resultantes dos exemplos anteriores e o sinal de entrada é propagado pela rede, camada por camada, até atingir a saída;
- Fase de retropropagação do erro (fase de retorno), na qual a saída (classificação) obtida é comparada com a saída (classificação) desejada e um valor de erro (ajuste) é produzido como resultado desta comparação. Este valor de ajuste é novamente propagado através da rede, camada por camada, mas desta vez no sentido inverso, isto é, da camada de saída para a camada de entrada. Nesta fase são realizados vários ajustes sucessivos nos pesos sinápticos da rede de forma a minimizar o erro da próxima saída – ver Figura 4.17. ⁽⁷²⁾




Figura 4.17: Ilustração das direções de dois fluxos básicos do sinal numa rede multicamada: propagação direta de sinais de função (setas pretas) e propagação reversa dos sinais de erro (setas azuis). Fonte: Haykin, 2018.

No caso de uma rede neuronal composta por 1 camada de entrada, 1 camada escondida e 1 camada de saída, as equações de um algoritmo de retropropagação que permitem ajustar os pesos das matrizes w e W que ligam as camadas de entrada, escondida e de saída são:

$$\begin{cases} W_{kj} = W_{kj} + \alpha \delta_k h_j \\ w_{ji} = w_{ji} + \alpha \delta_k W_{kj} h_j (1 - h_j) x_i \end{cases}$$

com $\delta_k = (y_k - O_k)O_k(1 - O_k)$; x_i é o valor do termo de entrada i , w_{ji} a matriz de pesos entre as unidades i da camada de entrada e as unidades j da camada escondida e W_{kj} a matriz de pesos entre as unidades j da camada escondida e as unidades k da camada de saída; por sua vez, y_k é o vector que representa a saída desejada e O_k o vector que representa a saída obtida; finalmente, α é o parâmetro *learning rate*, o qual controla a velocidade com que a rede aprende – ver secção seguinte.

Isto significa que se tivermos imagens de 128×128, as quais queremos classificar como representando cães, gatos e galinhas, teremos 128×128+1 (viés) unidades na camada de entrada e 3 unidades na camada de saída. O número de unidades da camada escondida deve ser ajustado, não havendo uma regra fixa para o determinar.

4.3.1 LEARNING RATE

O algoritmo *backpropagation* compreende um parâmetro (designado pela letra α) relativo ao rácio de aprendizagem, o *learning rate* (LR), cuja principal função é controlar o quanto deve ser alterado o modelo em resposta ao ajuste produzido de cada vez que os pesos do modelo são atualizados à medida que são fornecidos exemplos do conjunto de treino. ^(74,75)

O valor de *LR* é considerado um hiper-parâmetro configurável que controla a velocidade em que o modelo se adapta ao problema a ser solucionado. A sua escolha pode ter um efeito drástico na capacidade de generalização e na velocidade do treino, sendo que um valor demasiado pequeno pode resultar num processo de treino muito longo devido às pequenas alterações dos pesos a cada atualização. Por outro lado, um valor alto promove um treino mais rápido mas que pode levar a uma aprendizagem instável na qual a rede neuronal em vez de aprender, memoriza os últimos exemplos fornecidos provenientes do conjunto de treino. ^(74,75)

Relativamente ao valor de *LR* ideal deverá ser baixo o suficiente para que a rede seja capaz de solucionar o problema a que está destinada, mas alto o suficiente para que a rede possa ser treinada num período de tempo razoável.

4.4 REDES NEURONAIS CONVOLUCIONAIS

As CNN são redes neuronais profundas que surgiram tendo como base o córtex visual dos seres humanos. Este é composto por milhões de agrupamentos celulares complexos, onde os neurónios corticais individuais respondem a estímulos apenas em regiões restritas do campo de visão. Estas regiões, conhecidas como campos recetivos, são sensíveis a pequenas sub-regiões do campo visual. Os campos recetivos de diferentes neurónios sobrepõem-se parcialmente de forma a cobrir todo o campo de visão. ⁽⁷²⁾ Nas CNN, estas regiões são também denominadas de campos recetivos e são formadas por subconjuntos selecionados do vetor de características a ser analisado (representação numérica do objeto).

As CNN foram projetadas especificamente para reconhecer formas bidimensionais com alto grau de invariância à translação, sendo por isso muito utilizadas na classificação de imagens, no seu agrupamento por critérios de semelhança e ainda na deteção de objetos em imagens ou vídeos. A título de exemplo estes algoritmos possibilitam o reconhecimento facial, bem como a deteção de objetos como sinais de condução em imagens e vídeos. ⁽¹¹⁾

As CNN profundas, embora herdem as propriedades de uma RNA genérica, possuem também características muito próprias, a saber:

- São profundas, o que significa que normalmente são compostas entre 10 a 30 camadas e em casos extremos, podem exceder as 1.000 camadas;
- Os seus neurónios estão interligados de tal forma que vários neurónios compartilham os mesmos pesos;
- Entre algumas camadas, as CNN realizam operações de agrupamento que tornam a rede invariável a pequenas mudanças nos dados de entrada;
- Utilizam normalmente uma transformação não-linear diferente ao gerar a saída de um neurónio, contrariamente às RNA tradicionais. ⁽⁶⁵⁾

Segundo Simon Haykin, a arquitetura geral das CNN pode ser agrupada em três partes principais ⁽⁷²⁾ que serão explicados nos pontos seguintes.

4.4.1 EXTRAÇÃO DE CARACTERÍSTICAS

Ao contrário da visão humana, onde para haver a classificação de um objeto há em

primeiro lugar um reconhecimento de particularidades que o caracterizam, nas CNN o reconhecimento das características é feito através da aplicação de filtros (ou *kernels*). Os filtros são matrizes de menores dimensões que percorrem o espaço da imagem de entrada, produzindo novas imagens, denominadas de mapas de características ou *feature maps*, através da aplicação da operação matemática de convolução, a qual será detalhada posteriormente. O número de *feature maps* aumenta ao longo da arquitetura de forma a representar melhor as características das imagens de entrada, garantido assim a precisão na classificação.

Cada neurónio recebe os sinais de saída da sua camada anterior como sinais de entrada, forçando a extração de características locais. Estas características são referentes aos parâmetros específicos do filtro aplicado, sendo que a escolha dos parâmetros convolucionais do filtro depende da tarefa a ser resolvida. Os sinais de saída da camada passam como sinal de entrada para a camada seguinte.

4.4.2 MAPEAMENTO DE CARACTERÍSTICAS

Cada camada computacional da rede é composta por diversos mapas de características ou *filtros* que refletem as regiões onde os neurónios compartilham as mesmas características, os denominados pesos sinápticos. Estes pesos correspondem às características evidenciadas pelos *filtros* utilizados e dão robustez ao modelo, fazendo com que este seja capaz de lidar com variações de distorção, rotação e translação na imagem. Esta partilha dos pesos promove uma grande redução no número de parâmetros a serem otimizados, sendo que cada plano de uma camada é geralmente derivado da combinação de um ou mais planos da camada anterior.

4.4.3 SUBAMOSTRAGEM

Após cada camada de convolução é aplicada uma camada computacional que elabora a média local e subamostragem (*subsampling ou pooling*), onde a resolução do mapa de características é reduzida. Ou seja, um conjunto de entradas gera um conjunto de saída com menor dimensão. ^(72,76)

A arquitetura de uma rede neuronal convolucional é formada por uma sucessão de blocos de construção que extraem as características que, no final, ajudarão a especificar a classe a que o objeto representado pertence. Assim, um bloco de construção consiste

em uma ou mais:

- Camada convolucional (CONV) que processa os dados de um campo recetor;
- Camada de correção (ReLU - unidade linear retificada do inglês *Rectified Linear Unit*), nome referente à função de ativação utilizada;
- Camada de *pooling* (POOL) que compacta as informações reduzindo as dimensões do *features maps* obtido, também conhecida como camada de agrupamento. ^(10,15,72)

Para uma melhor compreensão do que é uma CNN, é importante compreendermos em primeiro lugar a representação computacional de uma imagem. Uma imagem numa escala de tons cinzentos, é representada como uma matriz de duas dimensões (2D), em que cada elemento da matriz representa um *pixel* da imagem. Os valores para cada elemento da matriz variam, geralmente, entre 0 (preto) até 255 (branco), embora possam tomar outros valores, o que é referido como “*profundidade da imagem*”.

Aplicamos então uma CNN a uma imagem médica como exemplificado na Figura 4.18 em que estão representadas as camadas supra referidas que passaremos a descrever:

- Camada de entrada – composta por tantas unidades quantas os *pixels* de cada imagem utilizada para treino e avaliação da rede;
- Camada de Convolução e ReLU – camada oculta que consiste na aplicação de filtros espaciais. Os filtros são representados de forma empilhada e são utilizados recorrendo à operação matemática de convolução. A operação de convolução produz tantos mapas de *features* quanto o número de filtros usados;
- Camada de *pooling* – recebe o *output* do *features maps* da CONV, disponibilizando um mapa de características condensado;
- Camada de classificação – à última camada totalmente conectada é aplicada uma função de ativação consoante o objetivo pretendido, que irá normalizar os valores de saída e criar as probabilidades de classificação, sendo que os valores variam entre 0 e 1 e a soma total dos mesmos é 1.

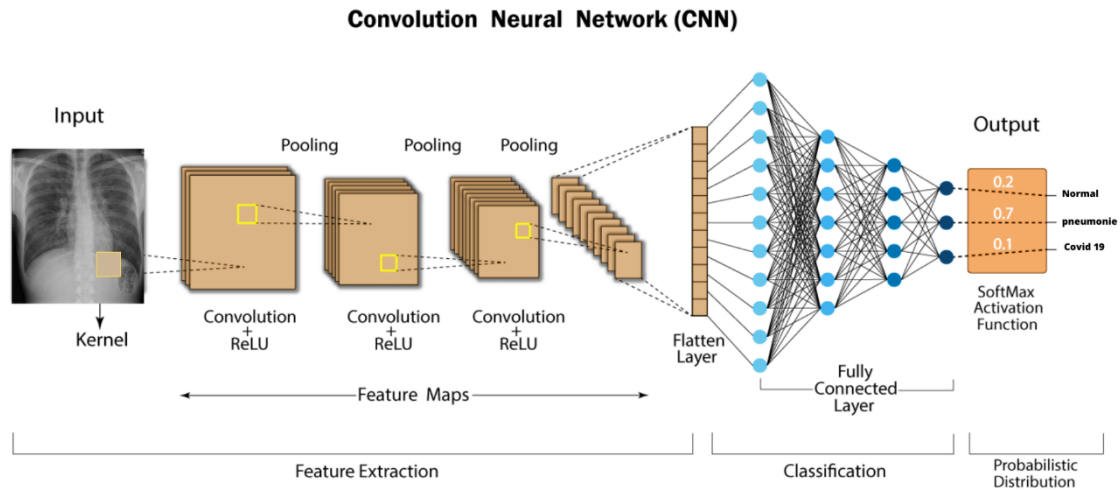


Figura 4.18: Exemplificação de uma arquitetura genérica aplicada a uma imagem médica.
Fonte: Rguibi *et al.*, 2022.

4.4.4 CONVOLUÇÃO E RELU

A operação matemática de convolução é uma das mais importantes para a compreensão das CNN. Matematicamente, uma convolução é uma operação linear que, a partir de duas funções, origina uma terceira através da multiplicação localizada de uma pela outra. Aplicando este termo à análise de imagens, podemos entender este processo como a aplicação de um filtro que transforma uma imagem de entrada, originando uma imagem de saída. ^(10,15,72)

Neste caso, o filtro é definido através de uma matriz significativamente mais pequena do que a imagem, a qual é multiplicada localmente pela imagem original numa base *pixel-a-pixel*. Após a realização da operação de multiplicação, a seguinte é realizada sobrepondo o filtro com a região seguinte da imagem, a qual está afastada da primeira, ao longo das colunas, por um valor (parâmetro) conhecido como *stride*. O parâmetro *stride* decide assim o intervalo entre cada cálculo de produto escalar. Normalmente o *stride* possui o valor 1, o que significa que a transformação será aplicada em todos os *pixels* da imagem (Figura 4.19 A). ^(10,15) O tamanho e os valores do filtro determinam o efeito que este tem na imagem.

Os filtros compartilham exatamente os mesmos pesos em todo o domínio da entrada, o que leva a uma enorme redução do número de pesos que precisam ser aprendidos (ajustados) pela rede. ^(10,15) O principal motivo para esta partilha de pesos é

o facto de que as características que surgem numa determinada parte da imagem provavelmente também aparecem em outras partes da imagem. Exemplificando com um filtro aplicado para detetar linhas horizontais, este poderá ser utilizado para detetar estas linhas em qualquer sítio que estas se encontrem numa imagem. A aplicação de todos os filtros convolucionais em todos os *pixels* da entrada numa CONV resulta num novo mapa de características, designado por *feature map*.

Após cada camada de convolução, é aplicada uma função de ativação não-linear que permite alcançar uma certa invariância dos dados e uma representação computacionalmente eficiente. Os mapas de características de uma CONV são impulsionados através de funções de ativação, que podem ser interpretadas como um conjunto de regras que determinam se um neurónio é ativado ou não. ^(10,12,15)

As funções de ativação mais frequentemente utilizadas em CNN são as funções ReLU, as quais se definem pela seguinte equação:

$$f(x) = \begin{cases} 0 & \text{se } x < 0 \\ x & \text{se } x \geq 0 \end{cases}$$

Um neurónio associado a uma função ReLU assume qualquer valor real como uma entrada mas só é ativado quando essa mesma entrada é superior a zero, valorizando assim as características relevantes em detrimento das menos relevantes.

As operações de não-linearidade não são tecnicamente “camadas” (devido ao facto de que nenhum parâmetro/peso é aprendido dentro de uma camada de ativação). Esta situação leva a que por vezes as funções de ativação sejam omitidas dos diagramas da arquitetura da rede, sendo assumido que uma operação de ativação se segue imediatamente a uma operação de convolução. ^(10,12,15)

Por outro lado, a camada de *Pooling* ou de subamostragem serve para reduzir o tamanho dos *feature maps*, ou seja o número de parâmetros da rede, acelerando o tempo de cálculo. Para tal, é aplicado na saída da camada anterior uma matriz de tamanho 2x2 mas com *stride* de 2, ou seja, avança duas casas entre cada aplicação, não se sobrepondo (Figura 4.19 B). Assim, na saída da camada de *pooling*, é obtido um mapa de características compactadas por um valor de 4, onde é maximizado o peso de ativações fortes ao ser selecionado o valor mais alto da matriz resultante no caso do *maxpooling* (a operação mais comum). No caso do *averagepooling* é obtida a média dos valores dos *pixels*. ^(10,15)

O objetivo de uma função de *pooling* é extrair um resumo estatístico das

características de áreas não sobrepostas, de forma a reduzir o número de parâmetros para as camadas seguintes, controlar o sobreajuste e possibilitar alguma invariância translacional, dado que um pequeno deslocamento da imagem de entrada resulta em pequenas mudanças nos mapas de ativação. ^(10,12)

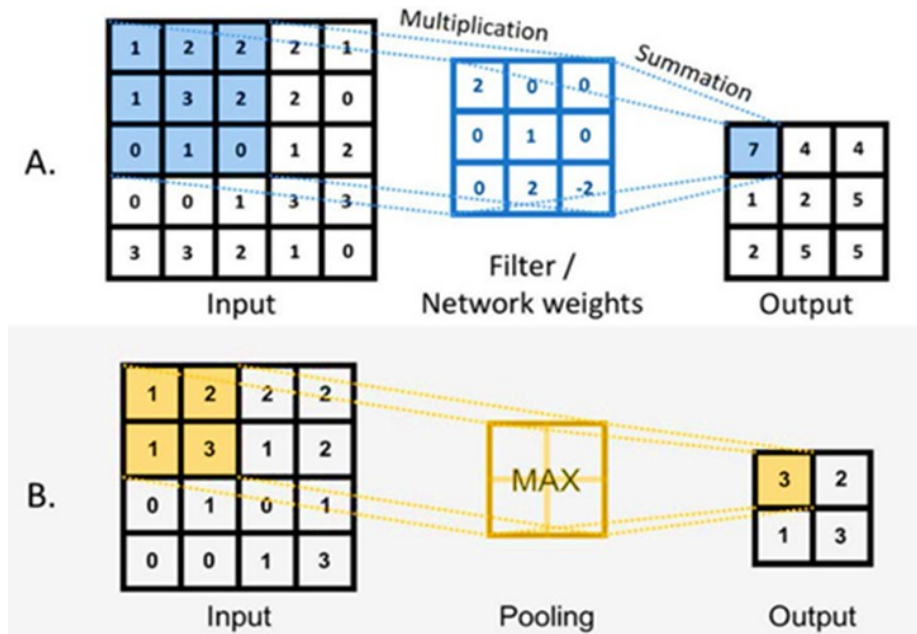


Figura 4.19: A) Exemplificação das operações de convolução e de *pooling*: na coluna do meio temos os valores dos filtros convolucionais implementados na rede (os pesos) que são multiplicados pelos valores de cada *pixel* e os produtos são somados, resultando nos *feature maps*. Em B) temos uma camada *pooling* em que o valor do *pixel* máximo é obtido em uma determinada região. Fonte: Mazurowski *et al.*, 2019.

Como o mapa de características resultante desta camada de subamostragem possui uma dimensionalidade menor que a imagem de origem, o tamanho da imagem poderá ser muito reduzido e levar a problemas de assertividade da CNN. Para contornar este cenário é utilizado o processo de *padding* que ocorre antes da operação de convolução em que alguns *pixels* são adicionados em torno da imagem de forma a manter as dimensões de todas as imagens geradas ao longo da rede – ver Figura 4.20.




Figura 4.20: Demonstração de um processo de *padding* e *stride*. Fonte: <https://ayeshmanthaperera.medium.com/what-is-padding-in-CNN-71b21fb0dd7>, acessado em 28.04.2022.

Na extremidade da CNN existem geralmente uma ou duas camadas totalmente conectadas, vulgarmente designadas por *fully connected*, destinadas a realizar a classificação das imagens como se de uma rede neuronal convencional se tratasse. Cada camada *fully connected* apresenta uma ligação a todas as unidades da camada anterior. Nesta camada, as características que apresentam uma estrutura 2D são transformadas num vetor de características unidimensionais. ^(10,12,15)

Finalmente, a *camada de saída* executa um último processo de convolução, permitindo a classificação da imagem com base nas características extraídas pela sucessão de blocos de processamento.

4.5 DROPOUT

Vários são os métodos que têm surgido numa tentativa de regularizar as redes neurais profundas, minimizando a possibilidade de adaptação excessiva da rede aos dados de treino, sendo o método *dropout* o mais utilizado na prática.

O método *dropout* consiste na inativação aleatória de alguns neurónios ocultos de forma a minimizar o *overfitting* da rede, fazendo com que as unidades desativadas não influenciem as outras unidades. A inativação dos neurónios por este método leva a que os restantes neurónios tenham que intervir e esforçar-se para executar as previsões necessárias para os neurónios inativados. Como resultado de um menor número de neurónios ativos, a rede adquire uma maior capacidade de generalização. O parâmetro de *dropout* é definido através de um número positivo entre 0 e 1, o qual define a percentagem de neurónios escondidos inativados (0 a 100%).^(77,78)

4.6 DATA AUGMENTATION

A aprendizagem das CNN depende fortemente de um grande volume de dados de forma a evitar situações de *overfitting* (sobre-ajuste). O *overfitting* ocorre quando uma rede ajusta-se muito bem ao conjunto de dados de aprendizagem, mas mostra-se ineficaz perante novos dados, ou seja, a rede aprende uma função de elevada variância, de forma a modelar perfeitamente os dados de aprendizagem. Quando ocorre *overfitting*, a rede apresenta elevada precisão quando testada com o seu conjunto de dados, não sendo no entanto uma boa representação da realidade. Assim, quanto mais exemplos a rede analisar durante o seu treino, mais facilmente esta aprenderá a sua principal função, que no caso deste estudo é reconhecer as diversas representações da patologia em estudo, as HDLs. ^(79,80)

Atualmente, as redes neuronais de última geração apresentam inúmeros parâmetros (podendo atingir milhões), pelo que é necessário apresentar uma quantidade igualmente elevada de dados para treinar uma rede e para obter um bom desempenho da mesma. O acesso a um limitado número de dados para a aplicação de CNN corresponde assim a uma das maiores dificuldades no uso destas redes artificiais. Esta situação problemática é ainda mais relevante na análise de imagens médicas devido ao reduzido número de base de dados, quer seja pela falta de precisão na catalogação das imagens médicas, quer seja pelas leis do direito de privacidade dos utentes. Neste sentido, soluções para esta problemática de dados limitados têm sido amplamente pesquisadas, surgindo assim diversas técnicas de *Data Augmentation* que possibilitam aumentar artificialmente o número de imagens disponíveis na aprendizagem da rede. ^(79,80)

A *Data Augmentation* engloba um conjunto de técnicas que visam o aumento do número dos dados de aprendizagem através da aplicação de alterações aleatórias aos dados existentes, ampliando assim a quantidade e variabilidade dos mesmos – ver Figura 4.21. Esta técnica parte do princípio que é possível extrair mais informações do conjunto original de dados através da sua multiplicação.

O aumento do número de dados disponíveis resulta de ligeiras transformações geométricas e de cores, supressão aleatória de pontos na imagem ou da mistura de *pixels* das imagens. Estas modificações são realizadas sem que a classificação das imagens seja alterada. As imagens sintéticas obtidas com esta técnica são posteriormente adicionadas aos conjuntos de aprendizagem, teste e validação. ^(79,80)

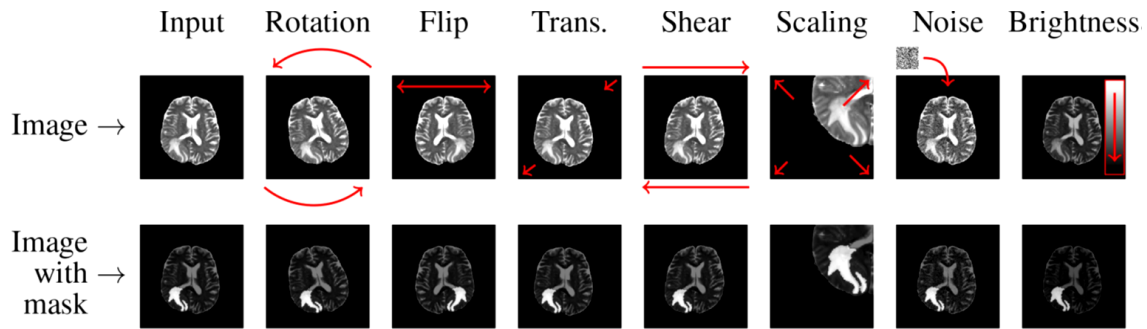


Figura 4.21: Exemplificação de à imagem original e que permitem gerar novas imagens para análise. Fonte: Nalepa *et al.*, 2019 transformações aplicadas.

4.7 AVALIAÇÃO DO DESEMPENHO DA REDE NEURONAL

As funções disponíveis para avaliar o desempenho de uma rede neuronal são cruciais no desenvolvimento aprimorado da mesma, sendo estas funções utilizadas nas duas etapas principais do processo, o treino da rede e a sua validação.⁽⁸¹⁾ No entanto, importa salientar que os valores que verdadeiramente interessam são os resultantes da aplicação da rede aos conjuntos de validação e de teste. No contexto desta dissertação passamos a explicar as métricas mais utilizadas nas CNN:

- *Accuracy*;
- Sensibilidade ou *Recall*;
- Especificidade;
- Curva ROC (do inglês *Receiver Operating Characteristic*);
- Área AUC (do inglês *Area Under the Curve*);
- Função *Loss* (*Loss Functions*).

A *accuracy* de um algoritmo de DL mede a frequência com que este classifica corretamente um grupo de dados, sendo expresso normalmente em percentagem. Este método de avaliação binário (verdadeiro/falso) corresponde ao número de dados corretamente previstos para o número total de amostras avaliadas.⁽⁸¹⁾

No nosso caso, a sensibilidade corresponde à capacidade do algoritmo em identificar corretamente as imagens com HDL, ou seja, dá-nos a probabilidade da rede identificar corretamente as HDL, e a especificidade corresponde à capacidade do algoritmo em identificar corretamente as imagens sem HDL.

A curva ROC é uma função de avaliação extremamente importante e muito utilizada na análise do desempenho de sistemas de classificação e corresponde a uma representação gráfica bidimensional da performance de um modelo de dados quantitativos segundo a sua taxa de sensibilidade (fração dos verdadeiros positivos) e a fração dos falsos positivos (calculada por $(1 - \text{especificidade})$). Aplicando ao nosso estudo, a fração de verdadeiros positivos corresponde às imagens definidas pela rede como tendo HD e que na realidade têm HD e a fração dos falsos positivos corresponde às imagens definidas pela rede como tendo HDL quando na realidade não têm esta patologia. Por convenção, a sensibilidade é representada no eixo das ordenadas e os falsos positivos estão representados no eixo das abcissas, sendo que ambas as coordenadas variam entre 0 e 1 (0 - 100%). Deste modo, cada ponto da curva ROC é um par de dados verdadeiros positivo/falso positivo, sendo que o resultado perfeito seria o ponto (0,1) indicativo de 100% de verdadeiros positivos e 0% de falsos positivos. Esta análise dos pontos de corte pode ser realizada ao longo dos diferentes valores obtidos e que por sua vez irão delimitar a curva ROC – ver Figura 4.22. ⁽⁸²⁻⁸⁷⁾




Figura 4.22: Representação gráfica de uma curva ROC e respetiva área AUC. Fonte: <https://doi.org/10.1016/j.buildenv.2020.107212>, acedida em 30-05-2021.

Em termos simplificados a curva ROC é então uma técnica gráfica que neste caso em concreto irá avaliar a capacidade da rede em distinguir imagens pela técnica de RM lombar com ou sem HD.

Para além da análise dos pontos que originam a curva propriamente dita, a área situada por baixo da curva ROC, a AUC (*area under curve*) é um dos índices de precisão mais utilizado para avaliar a qualidade da curva e o desempenho de uma CNN. A AUC

representa a integração de todos os pontos durante o trajeto da curva e avalia em simultâneo a sensibilidade e a especificidade da rede, refletindo assim a acurácia global da rede. Regra geral, os valores da AUC são descritos tal como indicado na Tabela 4.2:

Tabela 4.2: Descrição dos valores de AUC

AUC = 0.5	Sem discriminação
$0.6 \geq \text{AUC} > 0.5$	Pouco discriminativo
$0.7 \geq \text{AUC} > 0.6$	Discriminação aceitável
$0.8 \geq \text{AUC} > 0.7$	Excelente discriminação
AUC > 0.9	Discriminação excepcional

A AUC pode ainda ser usada para encontrar o valor de corte ideal para um teste específico, bem como para comparar o desenvolvimento entre dois ou mais testes nativos. Tanto os pontos de sensibilidade e especificidade como a estimativa da AUC possuem propriedades de inferência cujos erros-padrão dependem das dimensões, do efeito e do tamanho da amostra. ⁽⁸³⁾

A função *loss* é um dos parâmetros mais importantes de uma CNN (juntamente com os optimizadores) uma vez que está diretamente responsável por ajustar a rede aos dados de treino fornecidos. Esta função é utilizada na última camada de uma rede neuronal e tem como principal função calcular o valor de erro previsto gerado ao longo do treino. Este erro representa o quanto os resultados da rede diferem da saída esperada, sendo logo de seguida otimizado através do processo de treino da rede. ⁽⁸¹⁾

No modelo de classificação binária, a função *loss* utilizada é a função *binary_crossentropy* (também conhecida como função *log*) cujo objetivo principal é calcular a desordem do sistema, ou seja, a entropia cruzada entre a classificação verdadeira e a classificação prevista. Na classificação binária, o modelo recebe uma entrada que deverá ser classificada em uma de duas categorias pré-definidas, existindo apenas dois valores reais possíveis, 0 ou 1. Com a minimização da entropia cruzada entre a distribuição estipulada pelo modelo e a verdadeira distribuição das classes, ocorre uma melhoria da capacidade de generalização da rede neuronal, pelo que o uso da função *loss* é amplamente utilizado para avaliar o desempenho da CNN. Neste

sentido, o desempenho da rede neuronal será melhor, quanto mais próximo de zero for o valor da função *loss* para as imagens do conjunto de validação. ⁽⁸¹⁾

5. METODOLOGIA

Segundo Judith Bell, “uma investigação é conduzida para resolver problemas e para alargar conhecimentos”. Neste sentido, a metodologia utilizada baseou-se nos objetivos definidos para o presente estudo.

Deste modo, pretende-se neste capítulo caracterizar a metodologia aplicada no decorrer do presente estudo, descrever a seleção dos dados a serem utilizados assim como a caracterização dos mesmos e quais os procedimentos utilizados na sua aplicação. Por último, pretende-se indicar os procedimentos de análise e tratamento dos dados, bem como efetuar uma análise dos dados obtidos.

5.1 DESENHO DO ESTUDO

O trabalho de investigação aqui apresentado seguiu um desenho de estudo de carácter descritivo e estatístico de dados secundários, cuja sustentação teórica passou por uma criteriosa e exaustiva recolha de informações de carácter científico, de modo a valorizar o tema escolhido. Recorreu-se aos métodos qualitativo e quantitativo, através de uma pesquisa exploratória e conclusiva, respetivamente. Para um melhor entendimento do tema, realizou-se um enquadramento teórico da patologia em estudo, da técnica de RM e da sua importância imagiológica e das RNA, mais detalhadamente das CNN.

Tendo como ponto de partida um dos temas mais pesquisados atualmente - a IA - levantou-se a questão: “pode a IA melhorar o diagnóstico de alguma patologia frequentemente diagnosticada com recurso a imagens pela técnica de RM?” A pesquisa para responder a esta pergunta demonstrou que muitos são os estudos em que a IA

está a ser aplicada a imagens pela técnica de RM, nomeadamente no estudo cerebral, prostático e da patologia mamária ^(17,20,21,79,88,89). Porém, uma lacuna na investigação de uma das patologias mais frequentes nos países desenvolvidos, a HDL, foi evidenciada: a pouca pesquisa e aplicabilidade das CNN no diagnóstico das HDL no plano que melhor evidencia a compressão radicular, o plano axial.

E assim surge a questão de partida para o desenvolvimento deste trabalho:

“A deteção de HDL pode ser realizada de forma automática e fiável através de algoritmos de aprendizagem profunda aplicados a imagens da técnica de RM lombar, especialmente no plano axial?”

Procedeu-se então a uma pesquisa exploratória e conclusiva com o intuito de dar a esta questão uma resposta assente na elevada exigência científica e tecnológica, e que culminou no desenvolvimento de uma rede neuronal de convolução para reconhecimento de HDL em imagens da técnica de RM no plano axial.

5.2 BASE DE DADOS

Para a realização deste trabalho recorreu-se a uma base de dados de acesso público, com um elevado número de imagens de exames pela técnica RM lombar e que se encontra disponível através da seguinte hiperligação:

https://plu.mx/plum/a/?mendeley_data_id=k57fr854j2&theme=plum-bigben-theme

Esta base de dados contém estudos clínicos através da técnica de RM dirigida à coluna lombar de 515 pacientes, cuja principal sintomatologia correspondia a lombalgias. Os exames disponibilizados são anónimos, tendo-lhes sido atribuído um número, de 1 a 515, para a identificação de cada paciente. Alguns pacientes tinham mais que um exame pela técnica de RM associado, apesar de o segundo exame não ser referente à coluna lombar.

Cada um destes exames à coluna lombar contém imagens adquiridas nos planos axiais e sagitais, sendo que no plano axial, as imagens correspondem principalmente aos três últimos níveis vertebrais e respetivos discos (incluindo o espaço entre a última vértebra lombar e a última vértebra do sacro, L5-S1). O plano de corte da aquisição das imagens axiais foi orientado paralelamente ao DIV, excetuando o nível L5-S1 cuja orientação respeitou a curvatura fisiológica da coluna lombar.

No plano axial, e entre cada espaço intervertebral analisado, foram obtidos entre

quatro a cinco imagens com direção craniocaudal, desde os pedículos da vértebra superior aos pedículos da vértebra imediatamente inferior. Esta área de planeamento de cortes engloba desta forma, todo o espaço intervertebral, sendo que o número total de imagens obtidas varia entre 12 a 15 imagens. Todavia, em alguns casos teremos até 20 imagens como resultado de um número acrescido de espaços intervertebrais analisados.

Relativamente ao plano sagital, o número de imagens também variou entre alguns pacientes devido à necessidade de abranger os buracos de conjugação na sua totalidade. Neste plano, e em todos os pacientes, foram ainda incluídas as duas primeiras vértebras do sacro, bem como a última vértebra da coluna dorsal (D12).

Todas as imagens adquiridas nesta base de dados perfazem um total de 48 345 imagens disponibilizadas pela técnica de RM da coluna lombar em formato *Digital Imaging and Communications in Medicine* (DICOM), no plano sagital e axial e nas ponderações T_1 e T_2 . Em relação ao tamanho das imagens, apenas três estudos apresentam uma dimensões de 320×310 *pixels*, tendo os restantes estudos dimensões de 320×320 *pixels*.⁽⁹⁰⁾

No que concerne a profundidade de imagem, todas as imagens apresentam 12 *bits* por *pixel*, muito superior às imagens padrão numa escala de cinzento de 8 *bits*, no qual é possível ter apenas 256 níveis de intensidade diferentes. Esta profundidade de imagem permite o registo de 4 096 níveis de cinzento diferentes que, apesar de não serem diferenciáveis ao olho humano, possibilita um pós processamento de imagem com menor perda de qualidade.^(90,91)

Os exames foram realizados num aparelho de RM de 1,5 T Siemens Magnetom Essenza, recorrendo à sequência SE e cujos valores dos parâmetros de aquisição das imagens encontram-se descritos na Tabela 5.3. A grande maioria dos exames foi realizada com os pacientes posicionados em supinação e a entrar no aparelho de cabeça (*head first supine*), tendo um pequeno grupo sido posicionado em supinação mas a entrar no aparelho de pés (*feet first supine*). A aquisição dos exames variou entre 15 a 45 minutos e os pacientes com mais do que um exame associado realizaram os mesmos em horários distintos ou com alguns dias de intervalo.

Esta base de dados fornece ainda uma classificação das patologias diagnosticadas em cada exame por médicos radiologistas experientes, em que são descritas diversas características como o estado da coluna lombar, presença de doenças da medula óssea, alterações dos discos intervertebrais, compressão do saco tecal, estenose central ou

foraminal, hipertrofia das articulações interfacetárias e/ou do ligamento amarelo, espondilolisteses, fraturas vertebrais, presença de nódulos de Schmorl, entre outras. Desta classificação diagnóstica temos que 78 utentes não apresentam HDL e dos restantes 515 utentes, 339 apresentam HDL compressivas e 98 apresentam HDL não compressivas.

Tabela 5.3: Parâmetros de aquisição das imagens. Fonte: Al-Kafri *et al.*, 2019.

CARACTERÍSTICAS DA SEQUÊNCIA	SAGITAL		AXIAL	
	T_1	T_2	T_1	T_2
Nº de Ecos	3	15 a 18	3	9 a 16
TR (ms)	330 a 926	3190 a 4000	385 a 953	1900 a 5000
TE (ms)	9.2 a 12.0	67.0 a 96.0	11.0	84.0 a 96.0
Espessura de corte	3.0 a 4.0 mm	3.0 a 5.0 mm	4.0 mm	3.0 a 5.0 mm
Espaçamento entre cortes	3.3 a 4.8 mm	3.3 a 6.5 mm	4.4 mm	3.3 a 6.5 mm
FOV (mm)	280	280	220	220
Matriz (Frequência × Fase)	100%	100%	100%	100%
Nº. de Codificação de Fase	288 a 540	408 a 544	295 a 336	272 a 360

5.3 SELEÇÃO DE IMAGENS PARA ANÁLISE

A seleção das imagens para treinar e validar a rede foi criteriosa e apoiou-se no diagnóstico executado por um médico radiologista, tendo o relatório médico de cada exame sido disponibilizado juntamente com a base de dados. Após a análise exaustiva das 48 345 imagens disponíveis, a escolha das imagens teve por base os seguintes pontos:

- Seleção de uma imagem representativa de cada disco intervertebral analisado de todos os doentes nas imagens axiais ponderadas em T_2 ;
- Caracterização das imagens como representativas da patologia em estudo ou como consideradas normais para a HDL;
- Diferenciação e agrupamento das imagens de HDL em hérnias compressivas ou

hérnias não compressivas;

- Exclusão de todas as imagens de HDL não-compressivas, uma vez que, não sendo compressivas, não são sintomáticas.

Esta seleção e catalogação imagiológica resultou em 477 imagens de discos intervertebrais sem HDL e 521 imagens de discos intervertebrais com HDL compressivas. Com estes dados e de modo a equilibrar a base de dados, foram selecionadas 400 imagens de cada grupo para o treino da rede e 45 imagens de cada grupo para a validação da mesma.

Devido ao reduzido número de imagens recorreu-se à técnica de *data augmentation* para aumentar artificialmente o número de imagens na nossa base de dados. Para isso, foram criadas imagens modificadas geometricamente, aplicando transformações aleatórias de *shear* (deformação) para a direita, com distribuição uniforme e valor máximo de 0,2, ou 20%. Conseguiu-se o mesmo efeito de shearing para a esquerda após *flip* em torno do eixo vertical. Desta forma, originaram-se artificialmente um total de 35 600 imagens, em que destas 17 800 correspondem a imagens de HDL e as restantes 17 800 correspondem a imagens de discos vertebrais lombares sem HDL.

A Tabela 5.4 resume os dados dos dados apresentados à rede para o treino e para a validação.

Tabela 5.4: Resumo dos dados utilizados para o treino e validação da rede.

	DIV sem HDL	DIV com HDL
IMAGENS PARA TREINO	400	400
<i>Data augmentation</i>	40×	40×
Total de imagens para treino	16 000	16 000
IMAGENS PARA VALIDAÇÃO	45	45
<i>Data augmentation</i>	40×	40×
Total de imagens para validação	1800	1800
NÚMERO TOTAL DE IMAGENS PARA ANÁLISE	35 600 IMAGENS	

5.4 DESENVOLVIMENTO DE UMA REDE NEURONAL DE CONVOLUÇÃO

O desenvolvimento da rede neuronal de convolução teve como principal objetivo o reconhecimento da HDL pela técnica de RM no plano transversal, tendo por base a CNN com arquitetura pré-treinada do modelo VGG16.

O modelo VGG16 é um modelo de uma CNN apresentado por investigadores do Oxford *Visual Geometry Group* em 2014 na maior competição anual de algoritmos para classificação de imagens e detecção de objetos, o *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC). Este modelo caracteriza-se por ter 16 camadas profundas das quais 13 são camadas convolucionais e as restantes três são camadas completamente conectadas – ver Figura 5.23. A VGG16 caracteriza-se por ter uma arquitetura uniforme, sendo um bom modelo para extrair características de imagens. Todavia, este não é o modelo ideal para ser treinado do zero devido aos seus cerca de 138 milhões de parâmetros.




Figura 5.23: Arquitetura de um modelo VGG16. Fonte: Khan, 2020.

A arquitetura do modelo VGG16 é composto por 13 camadas convolucionais (com filtros 3x3) e 3 camadas totalmente conectadas, resultando em 16 camadas com parâmetros ajustáveis (camadas convolucionais e camadas totalmente conectadas). Estas camadas são divididas em blocos de 1 a 5, em que cada bloco contém múltiplas camadas convolucionais as quais são seguidas de uma de uma camada de *pooling* (filtro

de 2×2 e *stride* 2).

No primeiro bloco existem duas camadas convolucionais cada uma com 16 filtros para a extração de características que são duplicados nos blocos seguintes até um total de 512 filtros. Os blocos 3, 4 e 5 apresentam três camadas de convolução e diferente número de filtros de forma a aprofundar a rede e melhorar a sua precisão. Para finalizar este modelo surgem duas de três camadas ocultas totalmente conectadas, cada uma com 4096 neurónios, seguidas de uma terceira camada de saída com até 1000 neurónios. ⁽⁸⁹⁾

5.5 TREINO E VALIDAÇÃO DA REDE

O processo de treino da rede foi realizado numa Unidade de Processamento Gráfico (GPU - do inglês *Graphics Processing Unit*) recorrendo a um conjunto de códigos genéricos que podem ser usados no desenvolvimento de aplicações e sistemas, os *frameworks*. Os *frameworks* utilizados foram o *Tensorflow* (biblioteca de código aberto) e o *Keras* (biblioteca de rede neuronal de código aberto escrita em *Python* de interface simples e otimizada que facilita a criação e o entendimento de um modelo de rede neuronal profunda).

Numa primeira fase, as imagens previamente selecionadas para o treino da rede foram dadas a uma rede de arquitetura VGG16 de onde se otimizou os parâmetros e os pesos, desenvolvendo-se assim uma arquitetura VGG16 específica e ajustada aos objetivos propostos. Após a aprendizagem da rede, os vetores característicos de cada aprendizagem foram extraídos e concatenados entre si. Seguidamente, estes vetores foram transferidos para um classificador de forma a realizarem o reconhecimento de HDs.

No decorrer deste projeto, vários foram os parâmetros testados e avaliados de forma a compreendermos a sua influência na otimização da rede, nomeadamente:

- O valor de LR;
- O treino de apenas a última camada da rede (t_0) vs. o treino de toda a rede (t_1); estas duas situações serão sinteticamente referidas como t_0 e t_1 ;
- Uso ou não de camadas *de dropout* com 30% e 50%; estas 3 situações serão sinteticamente referidas como $d0$, $d0.3$ e $d0.5$;
- Número de épocas (e): 100 épocas vs. 500 épocas;

- Inicialização randomizada do modelo vs. inicialização do modelo com pesos otimizados a partir da base de dados *ImageNet*; estas duas situações serão sinteticamente referidas como iw_0 e iw_1 ;
- O desempenho de uma rede VGG16 vs. o desempenho de uma rede VGG19, utilizando exatamente os mesmos parâmetros e os mesmos dados.

No capítulo seguinte, passaremos a apresentar os resultados obtidos para os parâmetros testados, seguido de uma breve discussão sobre os mesmos.

6. RESULTADOS E DISCUSSÃO

Na rotina clínica, os profissionais de saúde necessitam de ter um longo e intensivo treino na análise e interpretação de imagens pela técnica de RM da coluna lombar. Neste sentido, o objetivo principal deste estudo foi desenvolver uma rede neuronal de convolução para o reconhecimento de HDL em imagens pela técnica de RM e validar o seu desempenho, pelo que passaremos a apresentar e a discutir os resultados obtidos com o desenvolvimento da rede a que nos propusemos.

6.1 INFLUÊNCIA DO HÍPER-PARÂMETRO *LEARNING RATE*

O ponto de partida para o desenvolvimento e otimização da rede deu-se com a experimentação de diversos valores para o hiper-parâmetro LR, de modo a compreendermos o seu efeito no desempenho da rede. Partindo de uma rede VGG16 com inicialização randomizada dos seus pesos, começámos por treinar apenas a última camada da mesma, até 100 épocas, modificando em cada *run* valor do LR.

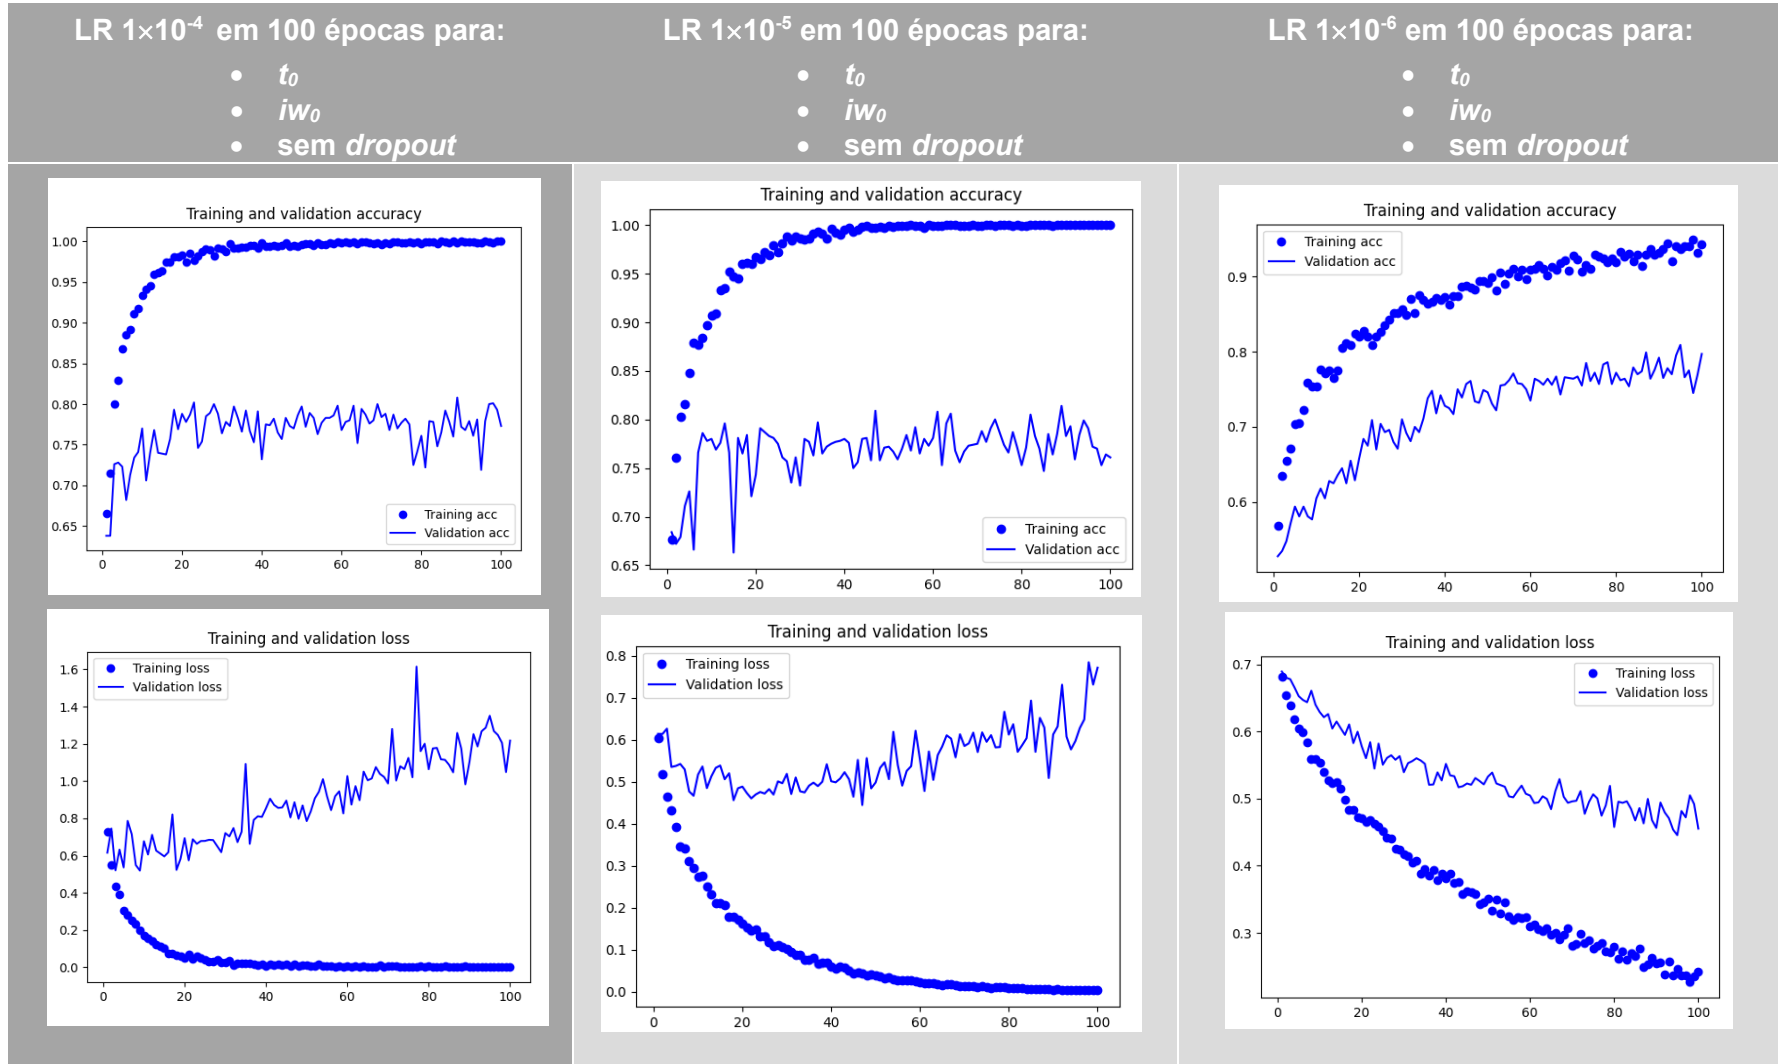
Os valores de LR utilizados foram 1×10^{-4} , 1×10^{-5} e 1×10^{-6} , e o objetivo principal foi obter um valor de LR ideal que nos permitisse diminuir gradualmente o erro ao longo das várias épocas, até que o menor valor possível fosse alcançado. Os resultados obtidos durante o processo de treino e de validação encontram-se disponíveis na Tabela 6.5.

Ao utilizarmos um valor de LR de 1×10^{-4} e de 1×10^{-5} no processo de treino, a rede comportou-se como esperado aprendendo mais rapidamente como detetar as HDL comparativamente ao valor de LR e 1×10^{-6} , atingindo logo nas primeiras vinte épocas o

valor desejado. Já durante o processo de validação, os valores de *accuracy* variaram entre os 0,75 e os 0,8 para um valor de LR de 1×10^{-4} e 1×10^{-5} , e entre 0,7 e 0,8 para o valor de LR de 1×10^{-6} .

Relativamente à evolução da função *loss*, a rede teve, para o conjunto de validação, um comportamento crescente para valores de valor de LR de 1×10^{-4} e 1×10^{-5} , evoluindo assim no sentido contrário ao desejado atingindo valores de 1,2 e 0,8, respetivamente. Para um valor de valor de LR de 1×10^{-6} os valores de *loss* seguem um comportamento decrescente, atingindo o valor mínimo de 0,5, o que revela uma melhor capacidade de generalização da rede para este valor de valor de LR.

Tabela 6.5: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para as situações t_0 , iw_0 , e sem *dropout* para 100 épocas.



6.2 INFLUÊNCIA DO HÍPER-PARÂMETRO *DROPOUT* DE 30% E 50%

Com o objetivo de evitar o *overfitting* da rede em estudo, recorreu-se à técnica de *dropout* com valores de 30 e 50%, aplicados em situações com valores de LR diferentes, e para *runs* de 100 épocas, no modelo em que só foi treinada a última camada da rede com inicialização randomizada dos pesos (Tabelas 6.6 e 6.7)

Para um *dropout* de 30% e valores de LR = 1×10^{-4} e 1×10^{-5} verificamos os valores de *accuracy* alcançados rondaram os 0,8 para o conjunto de validação. Já com um valor de LR de 1×10^{-6} , para o conjunto de validação o valor máximo de *accuracy* ficou ligeiramente abaixo dos 0,8. Todavia, e à semelhança do verificado anteriormente na análise da Tabela 6.5, o comportamento e o valor da função *loss* foram melhores para um valor de LR de 1×10^{-6} , atingindo um mínimo de 0,5 no final das 100 épocas para o conjunto de validação. Para valores de LR de 1×10^{-4} e de 1×10^{-5} , a função *loss* terminou com valores para o conjunto de 1 e 0,6, respetivamente.

Recorrendo a 50% de *dropout*, houve uma maior lentidão no treino da rede, como seria de esperar. Para o conjunto de validação, a rede conseguiu alcançar os 0,8 de *accuracy* para valores de LR de 1×10^{-4} e de 1×10^{-5} , e de 0,75 para um para um valor de LR de 1×10^{-6} . Com o *dropout* de 50%, a função *loss* obtida com valor de LR de 1×10^{-4} cresceu ao invés de diminuir, terminando as 100 épocas com valor de 1. Já nas grupos com um valor de LR de 1×10^{-5} e de 1×10^{-6} , os valores da função de *loss* decresceram no decorrer das 100 épocas, terminando com valores de *loss* de 1 e de 0,6 respetivamente.

Estes dados permitem-nos aferir que a técnica de *dropout* teve mais efeito na *accuracy* da rede com valor de LR de 1×10^{-6} , sobretudo com *dropout* de 50%, apesar de ao nível da função *loss* a alteração ser mínima, o que demonstra uma grande estabilidade da rede quando ocorreu inativação dos neurónios das camadas escondidas. No geral, os valores de *accuracy* e da função *loss* mantiveram-se satisfatórios, demonstrando que esta técnica deve ser tida em conta durante o desenvolvimento e otimização de uma rede neuronal, visto que permite um ganho de tempo quer ao nível do treino como ao nível de validação da rede, sem grande comprometimento dos resultados obtidos.

Tabela 6.6: Análise de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com **dropout de 30%** para t_0 , iw_0 , ao longo de 100 épocas.

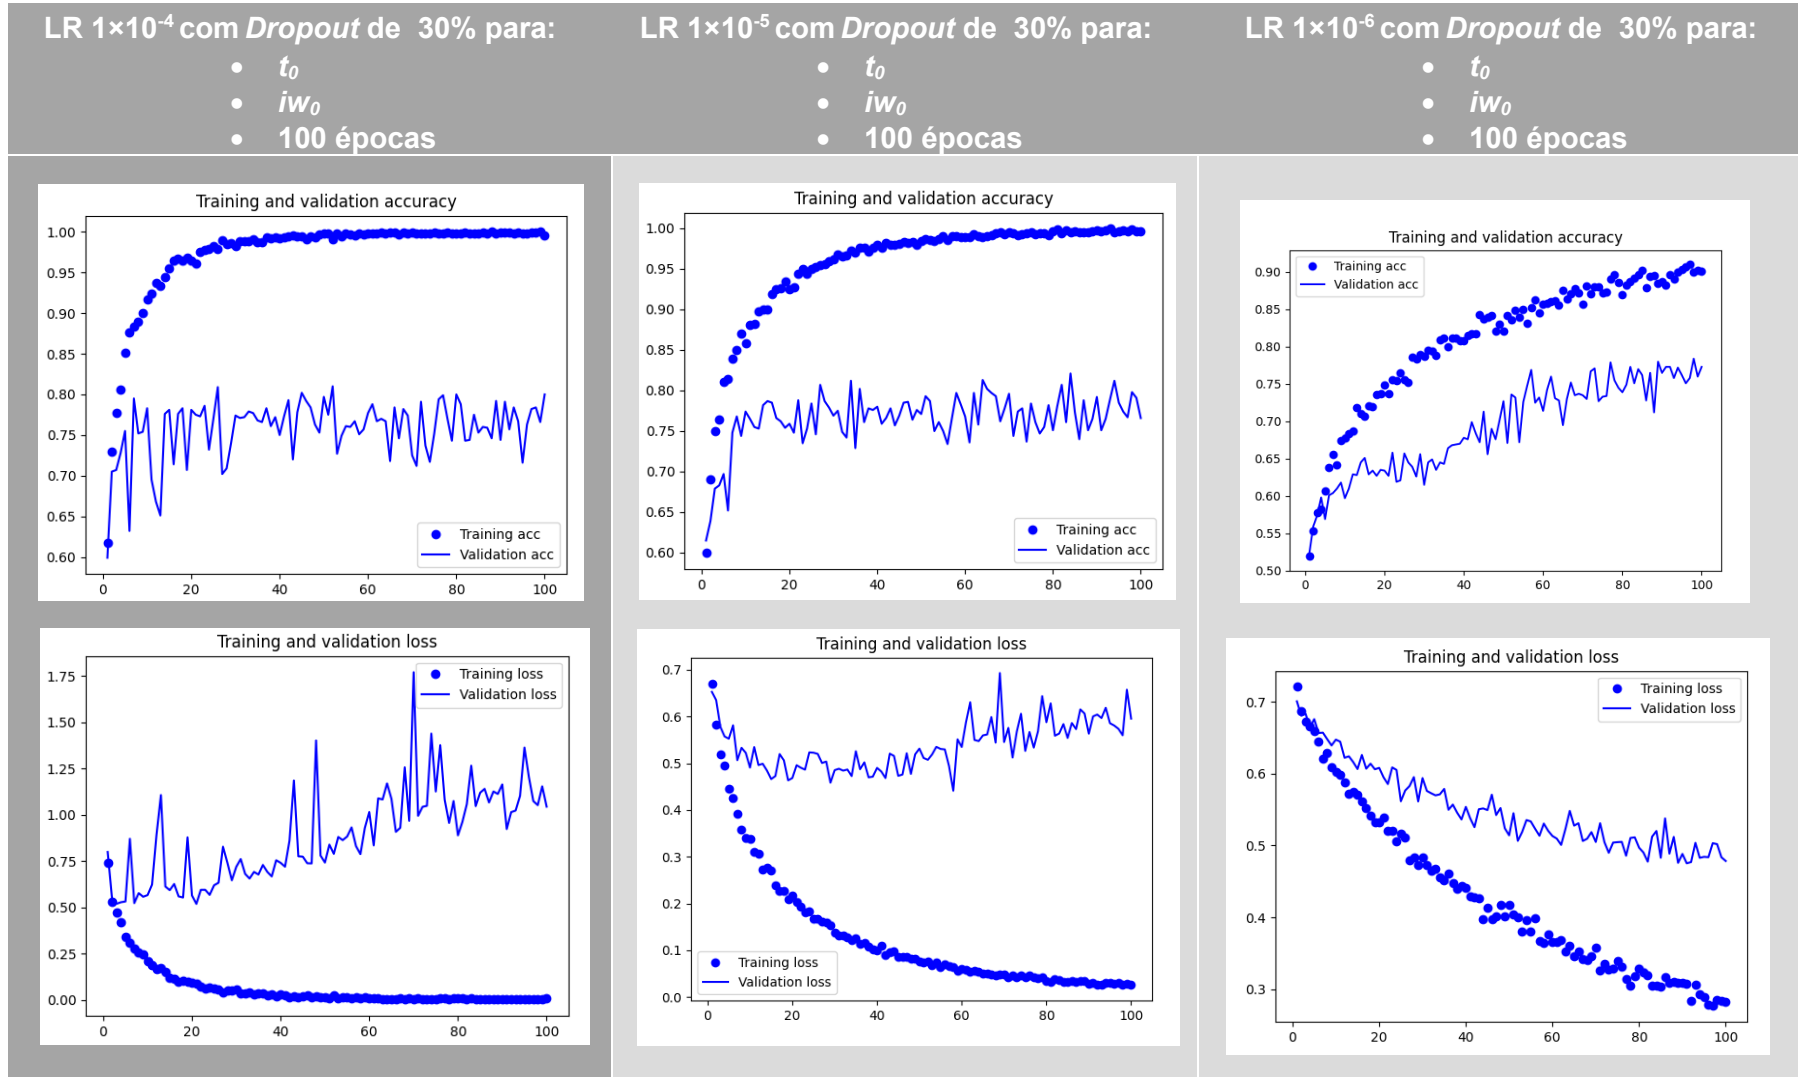
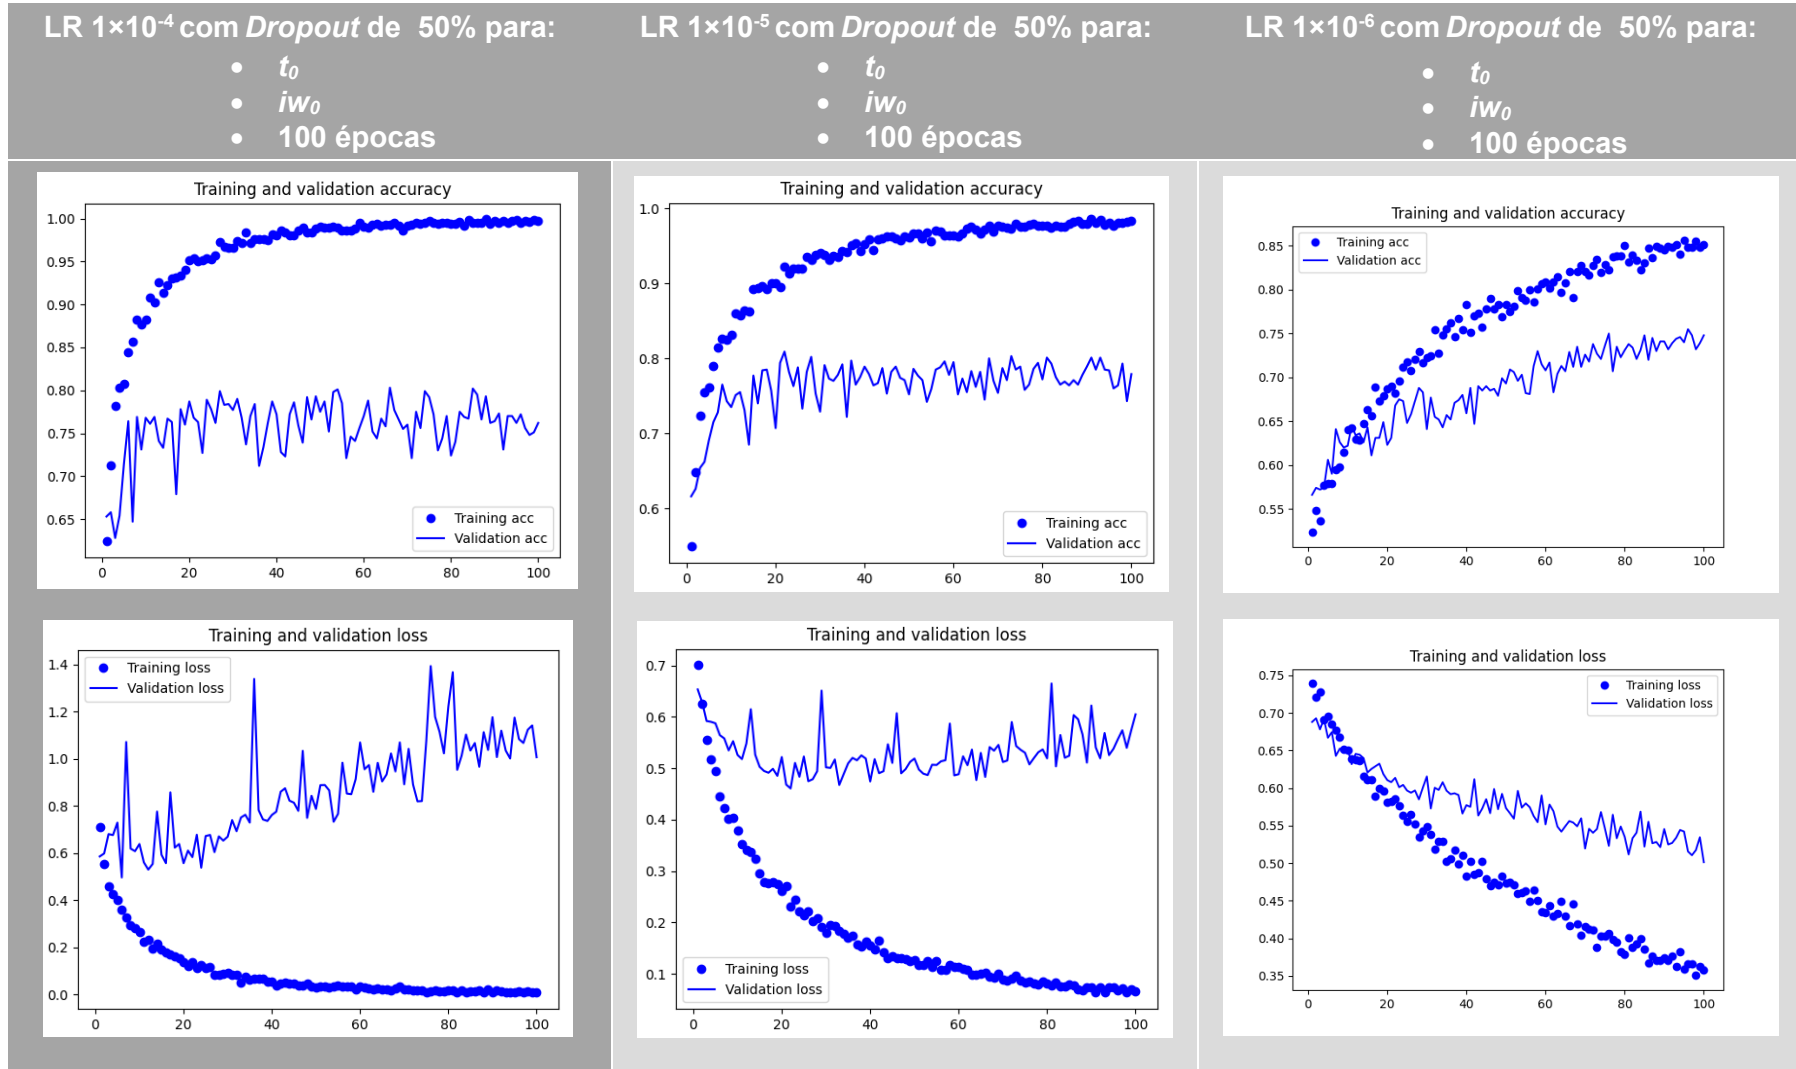


Tabela 6.7: Estudo de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com **dropout de 50%** para t_0 , iw_0 , ao longo de 100 épocas.



6.3 INFLUÊNCIA DO TREINO DA ÚLTIMA CAMADA DA REDE VS. O TREINO DE TODA A REDE

O treino de todos os parâmetros da rede é muito moroso mas poderá ser a melhor opção no desenvolvimento de uma CNN mais eficaz e com maior capacidade de generalização. Neste sentido, a influência de todos os parâmetros até aqui analisados foram reavaliados mas numa rede treinada em todas as camadas, ao contrário dos pontos anteriores em que só a última camada da rede foi treinada.

Assim, na situação t_1 , todos os pesos de todas as camadas foram treinados e reajustados na procura de uma melhor performance da rede, ao longo de 100 épocas, tendo sido atribuído aos pesos iniciais valores randomizados. Neste processo, os valores de *accuracy* obtidos para o conjunto de validação, para os três valores de LR foram muito animadores, atingindo os 0,90 para um valor de LR de 1×10^{-4} e 0,85 para um valor de LR de 1×10^{-6} . Para um valor de LR de 1×10^{-5} o valor alcançado foi superior a 0,85 – ver Tabela 6.8).

As funções de *loss* para os três valores de LR apresentaram comportamentos idênticos para o conjunto de validação, chegando aproximadamente os 2 para um valor de LR de 1×10^{-4} e 1×10^{-5} , e aproximadamente 1,5 para o valor de LR de 1×10^{-6} . De salientar que durante as 20 primeiras épocas, a rede com um valor de LR de 1×10^{-6} apresentou um comportamento descendente da função *loss*, chegando perto do valor 0,4, o que traduz um excelente resultado da rede com os parâmetros até aqui aprendidos.

Recorrendo à técnica de *dropout* de 30% (Tabela 6.9) e de 50% (Tabela 6.10), os valores de *accuracy* alcançados foram semelhantes aos anteriores durante o treino e durante a validação da rede para os três valores de LR em estudo. Contudo, destacamos o comportamento da função *loss* para o valor de LR de 1×10^{-6} em que, durante as 20 primeiras épocas foi decrescente atingindo o valor de 0,4 nas duas frações de *dropout*, terminando as 100 épocas com um valor de 0,7 com um *dropout* de 30% e superior a 1 com *dropout* de 50%.

Em suma, com o treino de todas as camadas da rede, a *accuracy* foi melhorada para o conjunto de validação da rede. Porém as funções *loss* apresentaram um comportamento oscilante e crescente nos dois processos, terminando as 100 épocas com valores mais elevados que a rede em que só a última camada foi treinada.

Tabela 6.8: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iW_0 , **sem dropout** ao longo de 100 épocas.

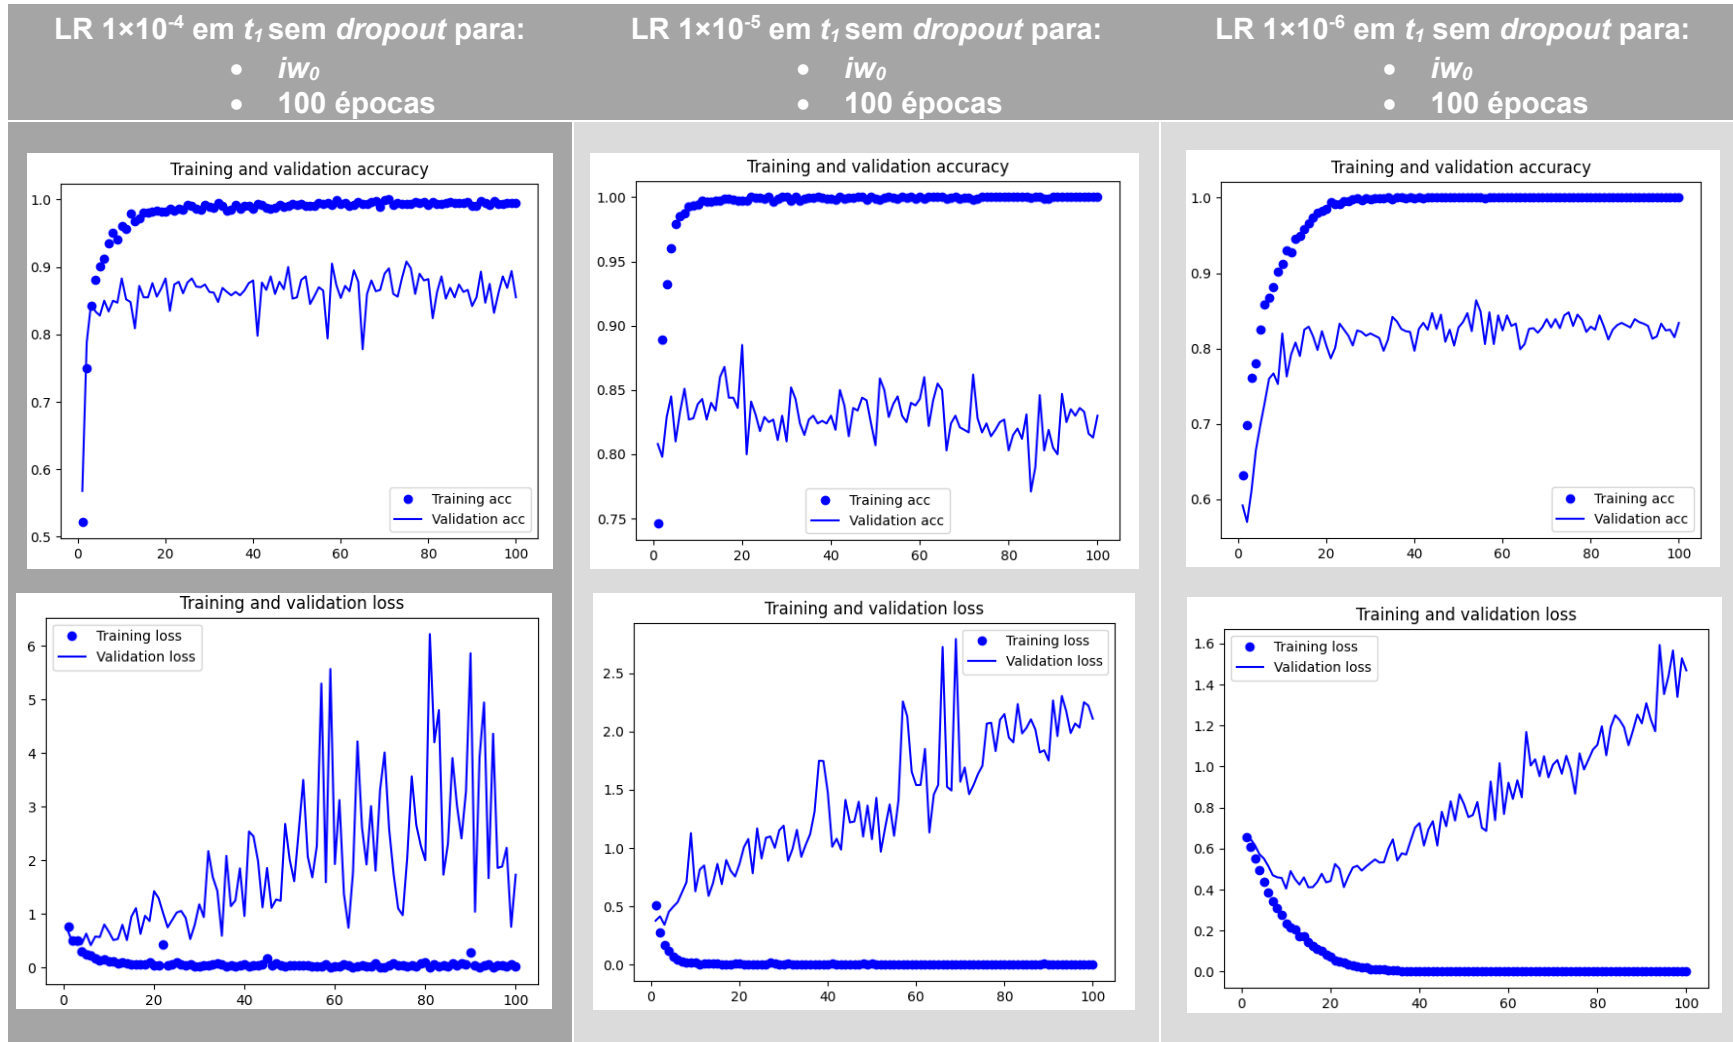


Tabela 6.9: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com **dropout de 30%** ao longo de 100 épocas.

LR 1×10^{-4} em t_1 com **dropout** de 30% para:

- iw_0
- 100 épocas

LR 1×10^{-5} em t_1 com **dropout** de 30% para:

- iw_0
- 100 épocas

LR 1×10^{-6} em t_1 com **dropout** de 30% para:

- iw_0
- 100 épocas







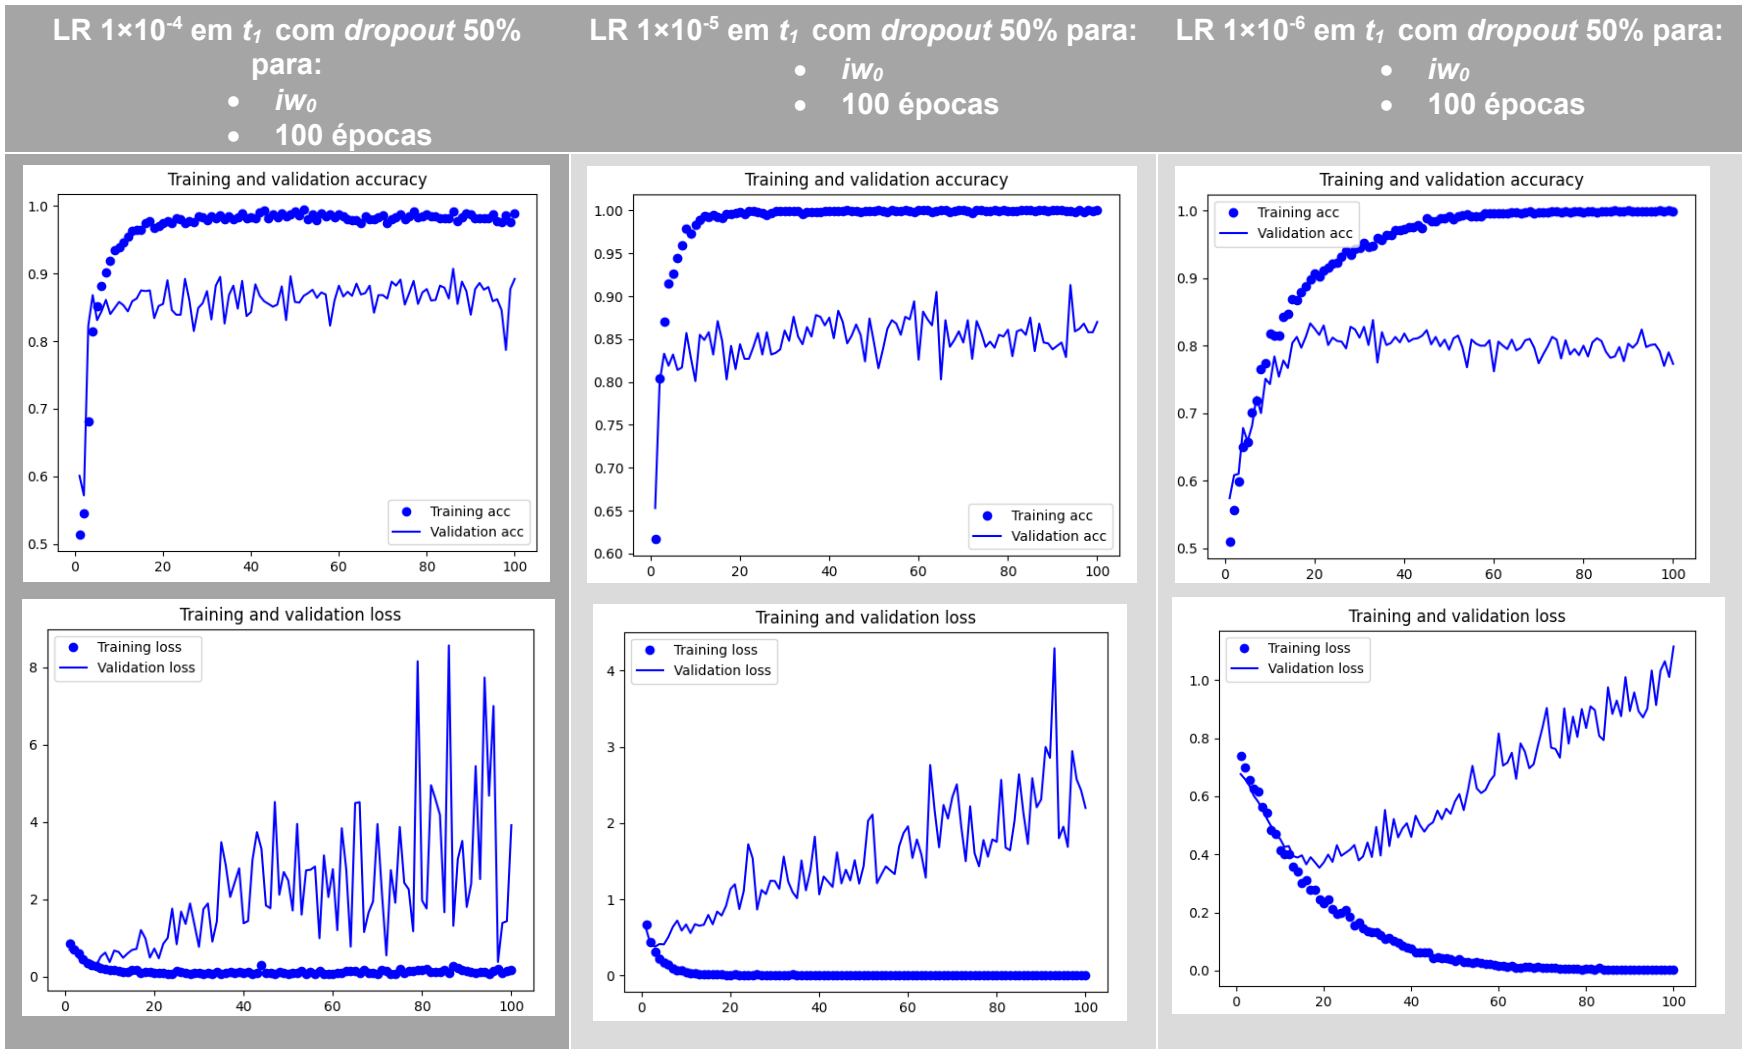


Tabela 6.10: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com **dropout de 50%** ao longo de 100 épocas



6.4 INFLUÊNCIA DA INICIALIZAÇÃO RANDOMIZADA VS. PESOS OTIMIZADOS PARA A BASE DE DADOS *IMAGNET*

Uma das técnicas utilizadas para diminuir o tempo necessário para o desenvolvimento de uma rede é recorrer a uma rede pré-treinada para iniciar o processo. Neste caso recorreu-se à rede VGG16 pré-treinada com a base de dados *ImageNet*, uma grande base de dados visuais projetada para ser utilizada na pesquisa e desenvolvimento de *softwares* de reconhecimento e classificação de imagens, de onde aproveitamos a rede com os pesos otimizados para iniciarmos o estudo. Esta técnica justifica-se uma vez que as primeiras camadas de uma CNN aprendem o reconhecimento de elementos básicos das imagens (como por exemplo os contornos, as formas arredondadas ou outras formas básicas). Deste modo, quando as redes pré-treinadas são utilizadas para aprenderem novas categorias, as camadas iniciais serão pouco modificadas por representarem os elementos básicos presentes em qualquer tipo de imagens. A Tabela 6.11 demonstra os diferentes resultados obtidos para diferentes valores de LR, em que iw_1 é o parâmetro que indica que se utilizou a rede pré-treinada com os dados da base de dados *ImageNet*.

Os valores de *accuracy* foram muito satisfatórios na rede em que só a última camada foi treinada e sem *dropout*, dado que para os valores de LR de 1×10^{-4} de 1×10^{-5} , atingiu cerca de 0,80 para o conjunto de validação. Com valor de LR de 1×10^{-6} conseguiu-se alcançar muito próximo de 0,8 para o conjunto de validação. Os respetivos valores *loss* para o conjunto de validação, a única curva descendente foi conseguida para o valor de LR de 1×10^{-6} que terminou aproximadamente no valor 0,5. A rede com valor de LR de 1×10^{-4} de 1×10^{-5} apresentaram uma função *loss* crescente, atingindo no fim das 100 épocas valores superiores a 1 e 0,7, respetivamente.

Recorrendo ao método *dropout* de 30% e 50% (Tabela 6.12 e 6.13), para um valor de LR de 1×10^{-4} e de 1×10^{-5} , os valores de *accuracy* conseguidos foram de aproximadamente 0,8 para o conjunto de validação. Já a rede com um valor de LR de 1×10^{-6} atingiu valores de *accuracy* de 0,75 para o conjunto de validação para um *dropout* de 30%. Aumentando o *dropout* para 50%, a *accuracy* foi de 0,75 para o conjunto de validação para o valor de LR de 1×10^{-6} . Em relação à função *loss*, o comportamento das redes com diferentes valores de LR foi idêntico ao observado sem recorrer à técnica de *dropout*, havendo apenas ligeiras variações nos valores finais.

Ao treinarmos a rede neural de convolução partindo de uma versão em que esta foi inicializada com os pesos decorrentes do seu treino prévio com a base de dados *ImageNet*, os valores de *accuracy* atingiram valores surpreendentes sem recorrer à técnica de *dropout*, alcançando valores superiores a 0,9 para o conjunto de validação para os valores de LR de 1×10^{-4} de 1×10^{-5} e de 0,85 para o valor de LR de 1×10^{-6} . Apesar destes excelentes resultados, as funções *loss* correspondentes apresentaram uma trajetória muito oscilante e crescente, indicadora de memorização por parte da rede e de menor capacidade de generalização por parte da rede quando confrontada com novos dados. Contudo, e durante as primeiras 20 épocas, a rede com um valor de LR de 1×10^{-6} apresentou um comportamento descendente da função *loss*, que atingindo o seu valor mais baixo para o valor de 0,4 antes de começar a crescer novamente até terminar com o valor de cerca de 1,2 ao fim de 100 épocas – ver Tabela 6.14.

Esta combinação de variáveis associada à técnica de *dropout*, quer seja de 30% ou 50%, permitiu obter valores de *accuracy* que para o conjunto de validação, de 0,90 para os valores de LR de 1×10^{-4} e de 1×10^{-5} , e cerca de 0,8 para o valor de LR de 1×10^{-6} para a valor de 30% de *dropout* (Tabela 6.15). Com dropout de 50% (Tabela 6.16) houve uma melhoria da *accuracy* para o valor de LR de 1×10^{-6} , passando para os 85%. Os restantes valores de foram idênticos aos conseguidos sem recorrer à técnica de *dropout*.

O comportamento das funções *loss* foi igualmente semelhante aos obtidos sem a técnica de *dropout*, sendo que para o valor de LR de 1×10^{-4} a oscilação desta função foi aumentando à medida que a percentagem de *dropout* também aumentou, traduzindo uma reduzida capacidade de generalização da rede com estes parâmetros perante os novos dados. Para o valor de LR de 1×10^{-6} o valor de *loss* mínimo conseguido foi de 0,4 nas três situações de *dropout* apresentadas neste ponto, valor este alcançado nas primeiras 20 épocas.

Em suma, a rede com inicialização a partir dos dados obtidos com a base de dados *ImageNet*, quando treinada na sua totalidade, possibilitou a obtenção de valores de *accuracy* muito satisfatórios. No entanto, devido ao comportamento das respetivas funções de *loss* para cada valor de LR, podemos aferir que após as primeiras 20 épocas a rede começa a memorizar sem aprender corretamente a classificação de HDL. Neste sentido, deverá ser considerado o uso dos parâmetros aprendidos apenas até às primeiras 20 épocas, possibilitando assim uma melhor performance da rede e respetiva capacidade de generalização quando confrontada com dados nunca antes analisados.

Tabela 6.11: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 , sem dropout e t_0 , ao longo de 100 épocas.

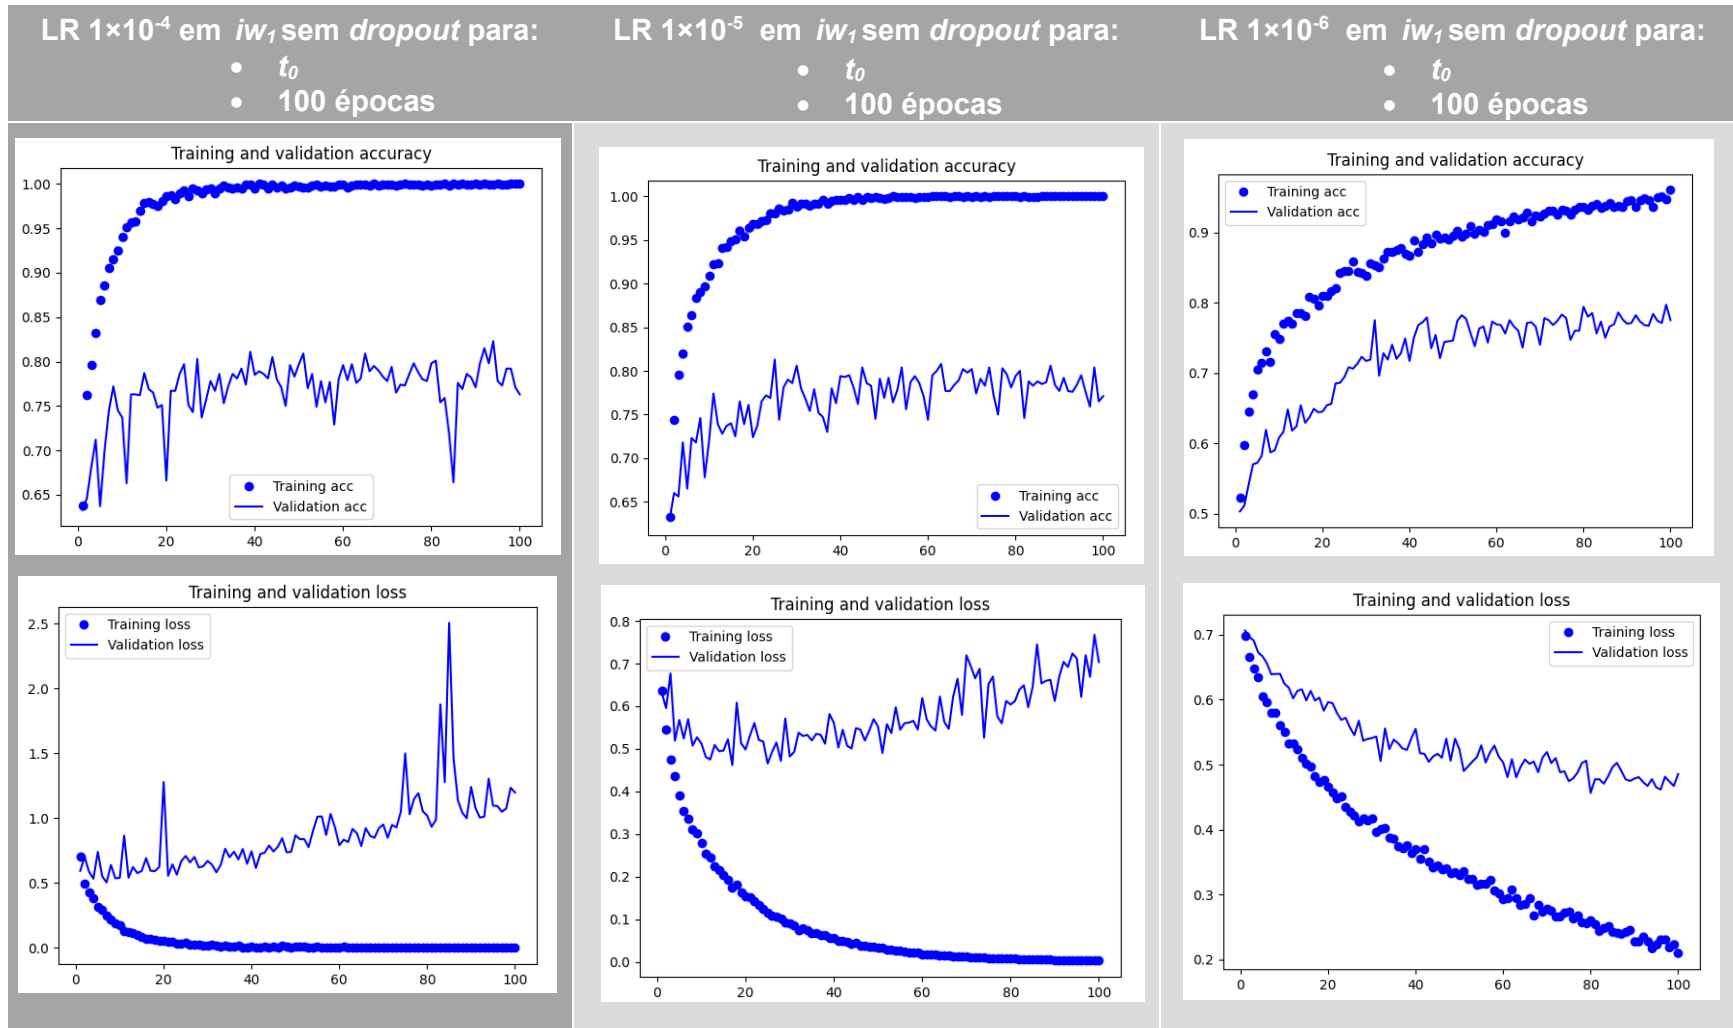


Tabela 6.12: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e **dropout de 30%**, para t_0 , ao longo de 100 épocas.

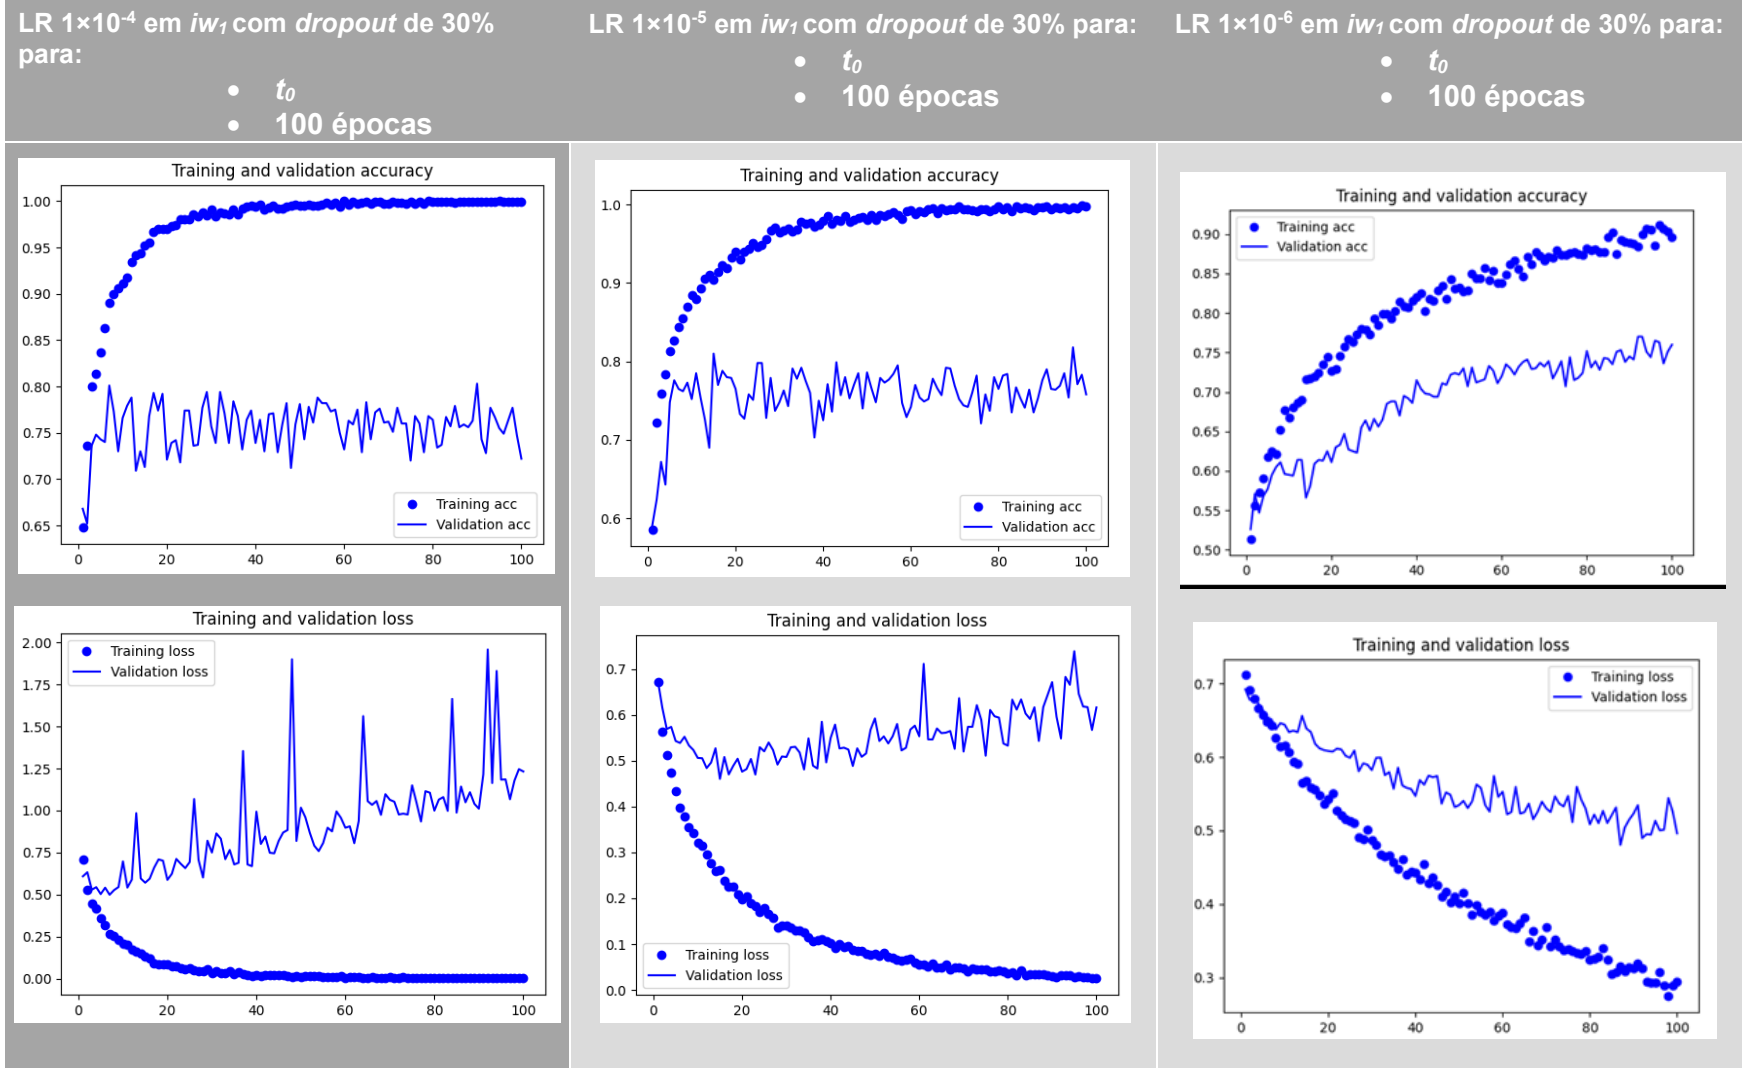


Tabela 6.13: Análise de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e dropout de 50%, para t_0 , ao longo de 100 épocas.

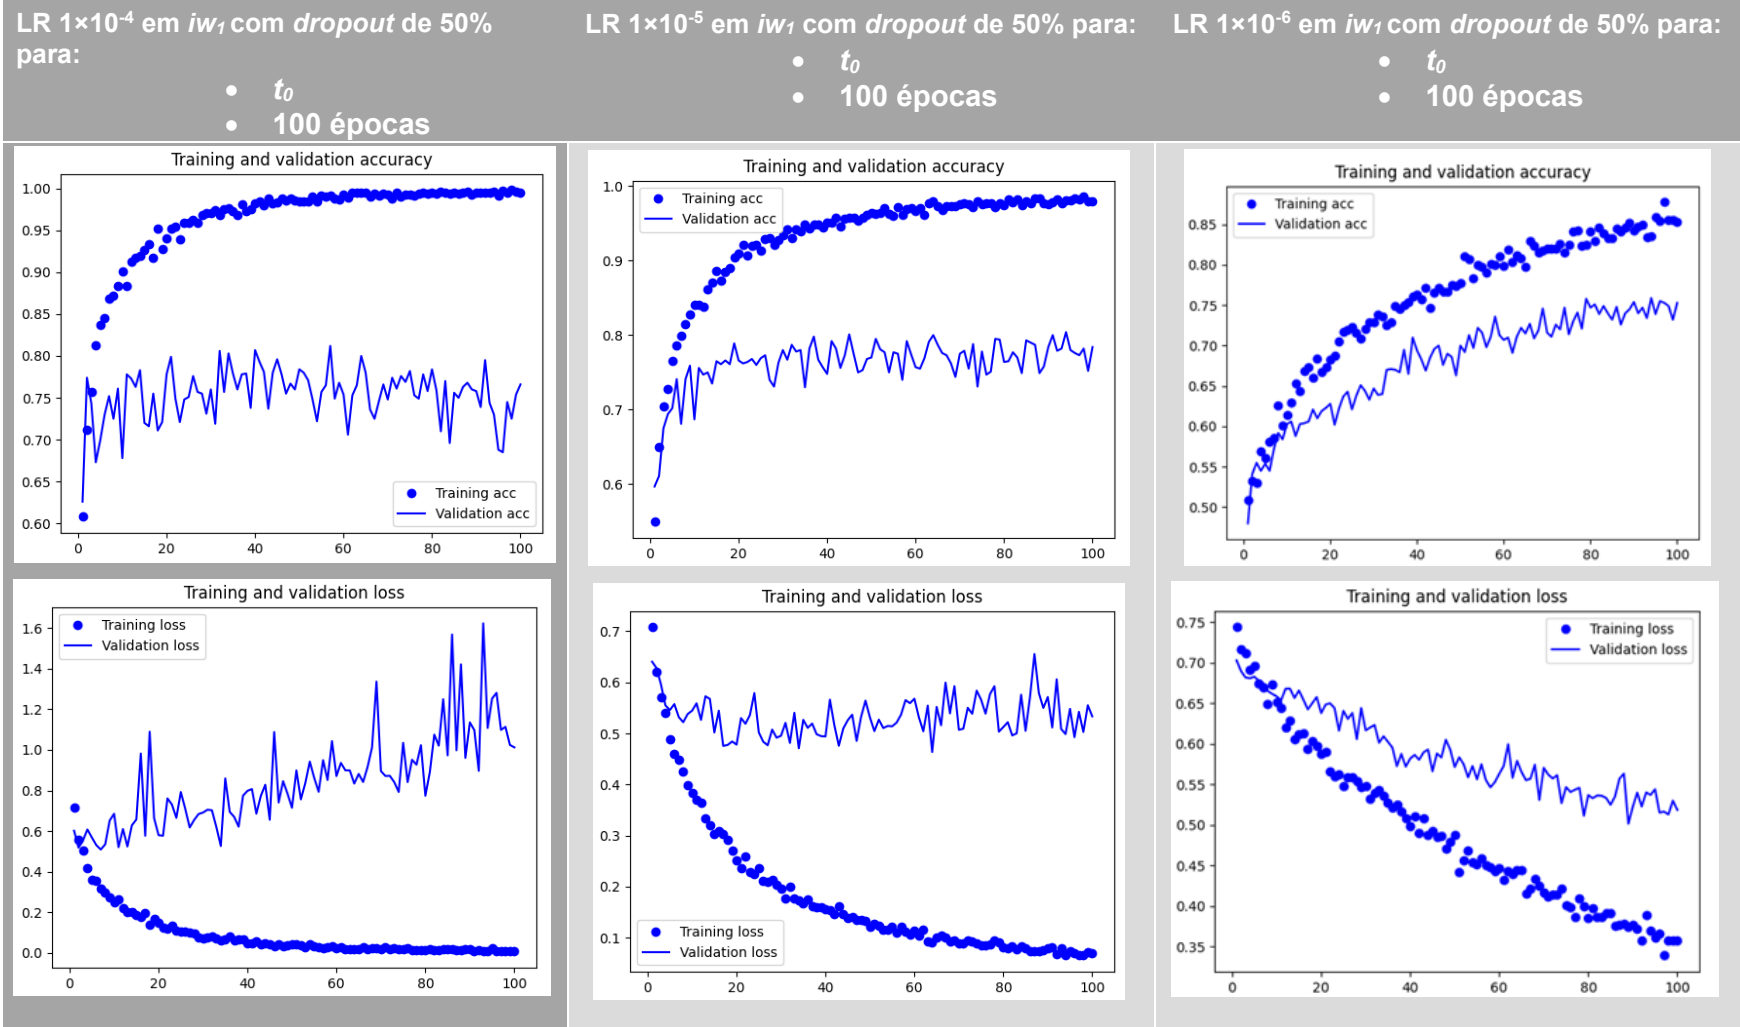


Tabela 6.14: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , sem dropout, ao longo de 100 épocas.

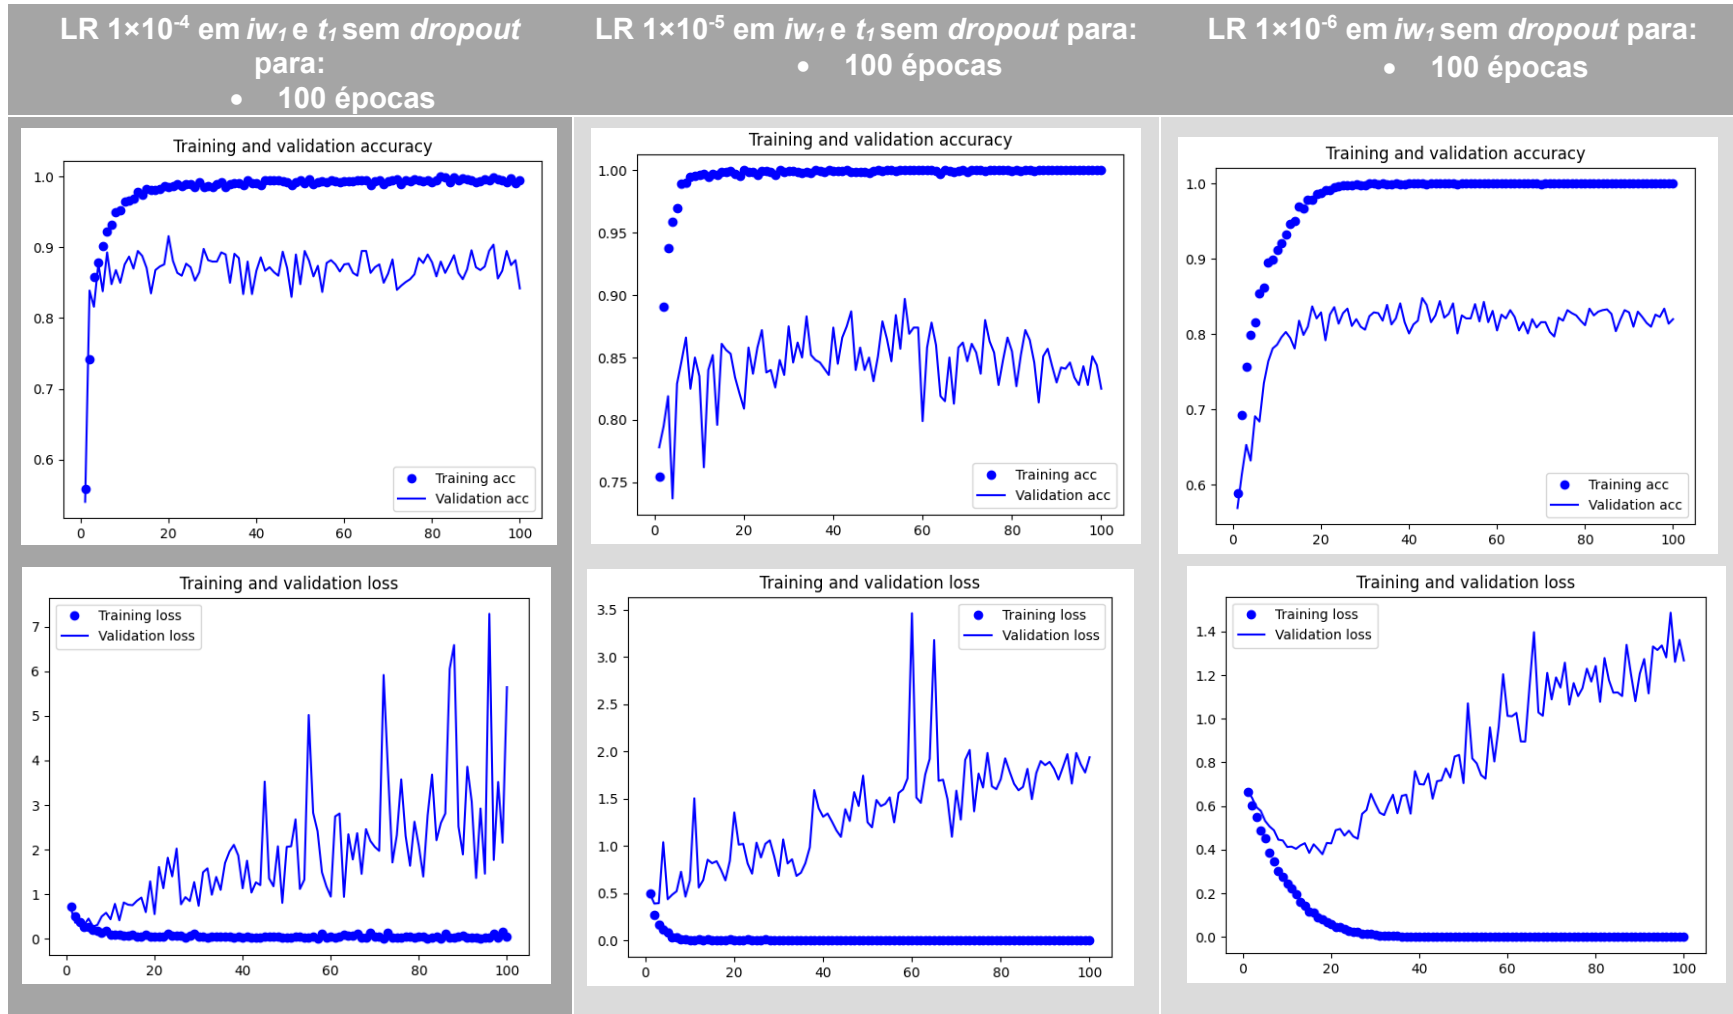


Tabela 6.15: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com **dropout de 30%** ao longo de 100 épocas.

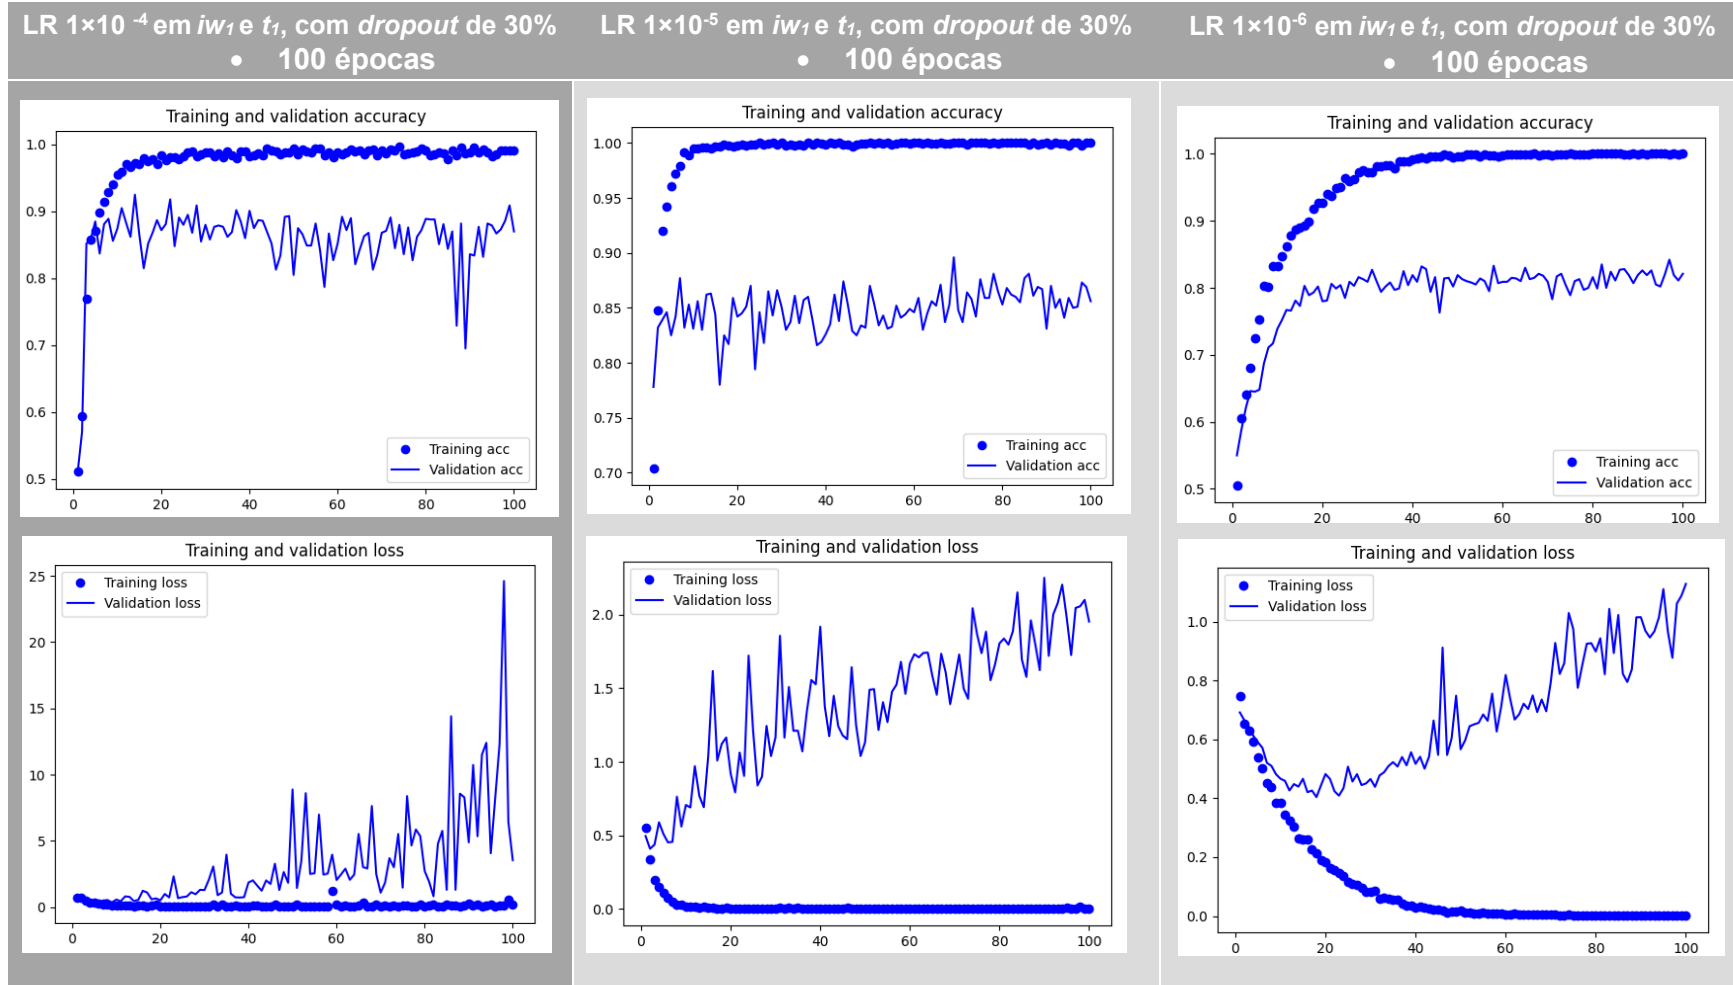
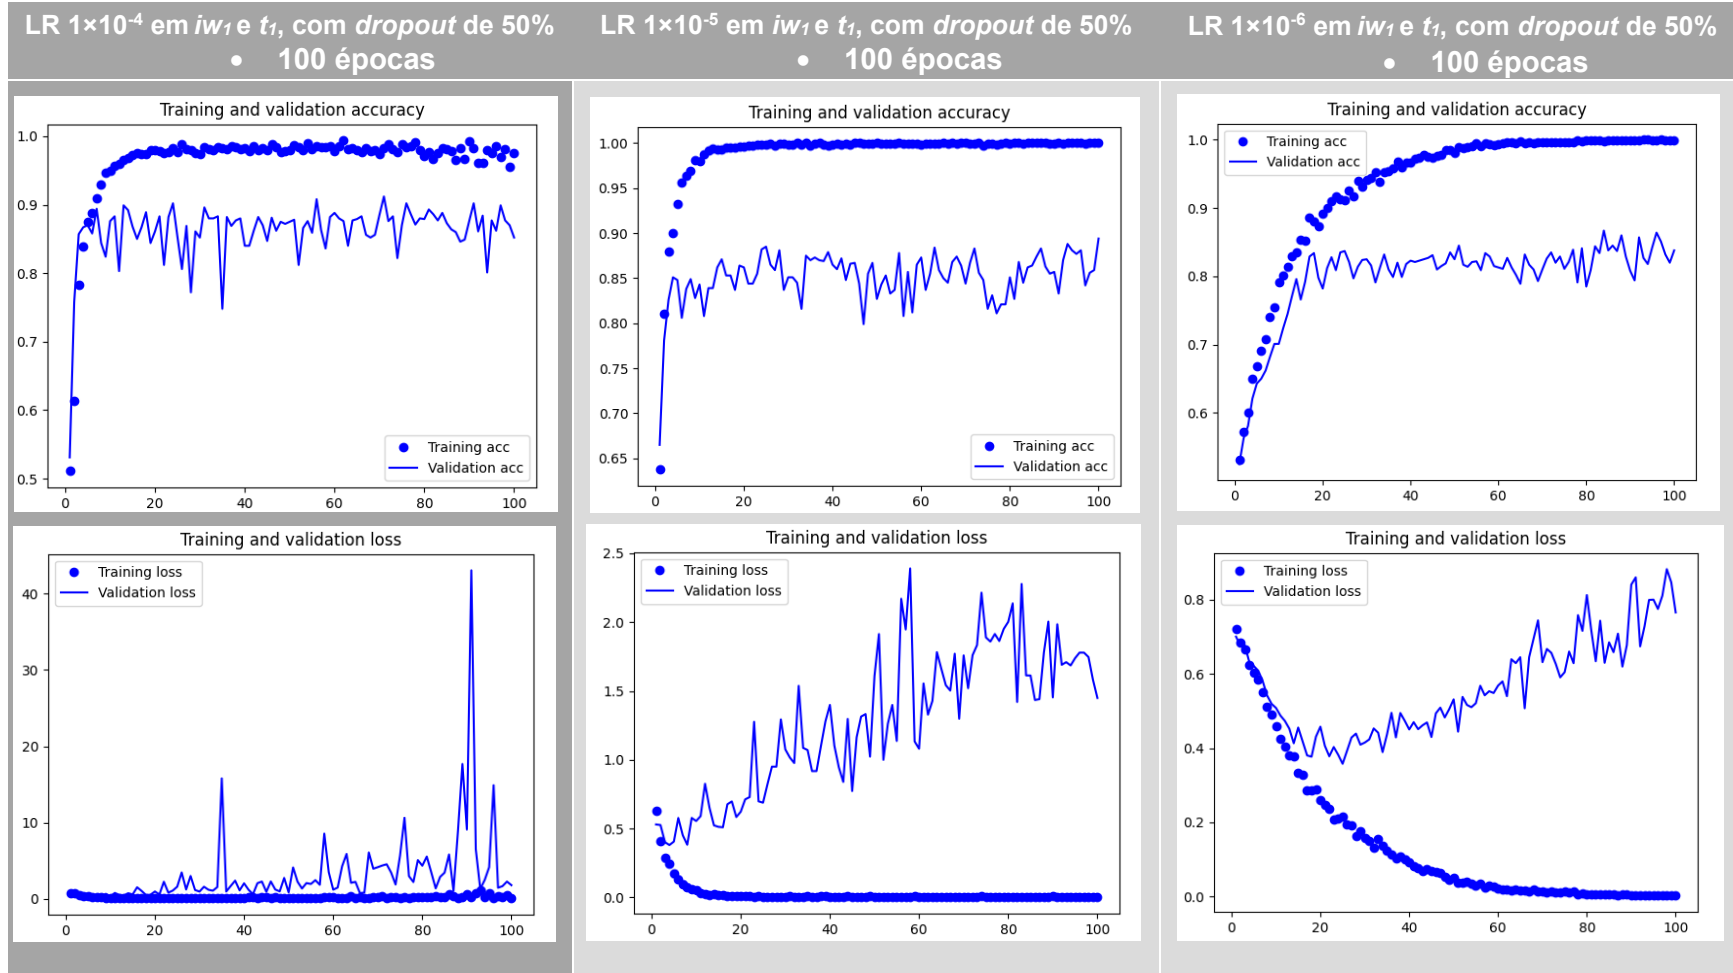


Tabela 6.16: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com **dropout de 50%** ao longo de 100 épocas.



6.5 INFLUÊNCIA DO NÚMERO DE ÉPOCAS: 100 ÉPOCAS VS. 500 ÉPOCAS

O número de épocas corresponde ao número de vezes em que os dados são apresentados à rede neuronal, completando todo um ciclo de passagem por todas as camadas da rede. A escolha do número de épocas é de elevada importância dado que um número reduzido de épocas pode levar a problemas de *underfitting* e por outro lado, um número elevado pode levar à situação oposta, de *overfitting*.

Uma vez que nas análises anteriores o modelo com um valor de LR de 1×10^{-6} apresentou constantemente os melhores resultados e a melhor capacidade de generalização da rede, o estudo da influência das 500 épocas só foi realizado para este valor de LR.

Os resultados obtidos alterando as diversas variáveis aqui estudadas estão disponíveis nas tabelas seguintes (Tabela 6.17, 6.18, 6.19 e 6.20) de onde podemos destacar que, para todas as variáveis, o comportamento da rede manteve-se constante após as 100 primeiras épocas durante o treino e a validação, tanto ao nível da *accuracy* como da função *loss*. De salientar ainda que para todas as variáveis, em relação ao conjunto de validação, foram sempre alcançados valores de cerca de 0,8.

À semelhança do constatado na análise de todas as variáveis em 100 épocas, a rede conseguiu alcançar sempre valores de pelo menos 0,8 de *accuracy* para o conjunto de validação. Já os dados obtidos através da função *loss* são indicadores de que a partir de um determinado número de épocas, a rede começa a memorizar em vez de continuar a aprender, diminuindo assim a sua capacidade de generalização. Desta forma, o número elevado de épocas traz poucos benefícios no desenvolvimento e otimização da rede neuronal a que nos propusemos.

De todas as variáveis analisadas para 500 épocas destacamos os melhores resultados obtidos, nomeadamente treinando toda a rede com pesos randomizados, em que a *accuracy* obtida foi de 0,85 (para o conjunto de validação), para uma função *loss* decrescente até às 20 épocas. A inicialização com os pesos decorrentes do treino com a base de dados *ImageNet* permitiu obter valores de *accuracy* em torno dos 0,75, com bons resultados da função *loss* para os três valores de LR, cuja curva foi decrescente, estabilizando por volta do valor 0,5.

Tabela 6.17: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de **500 épocas** e t_0 , w_0 e com *diferente dropout*.

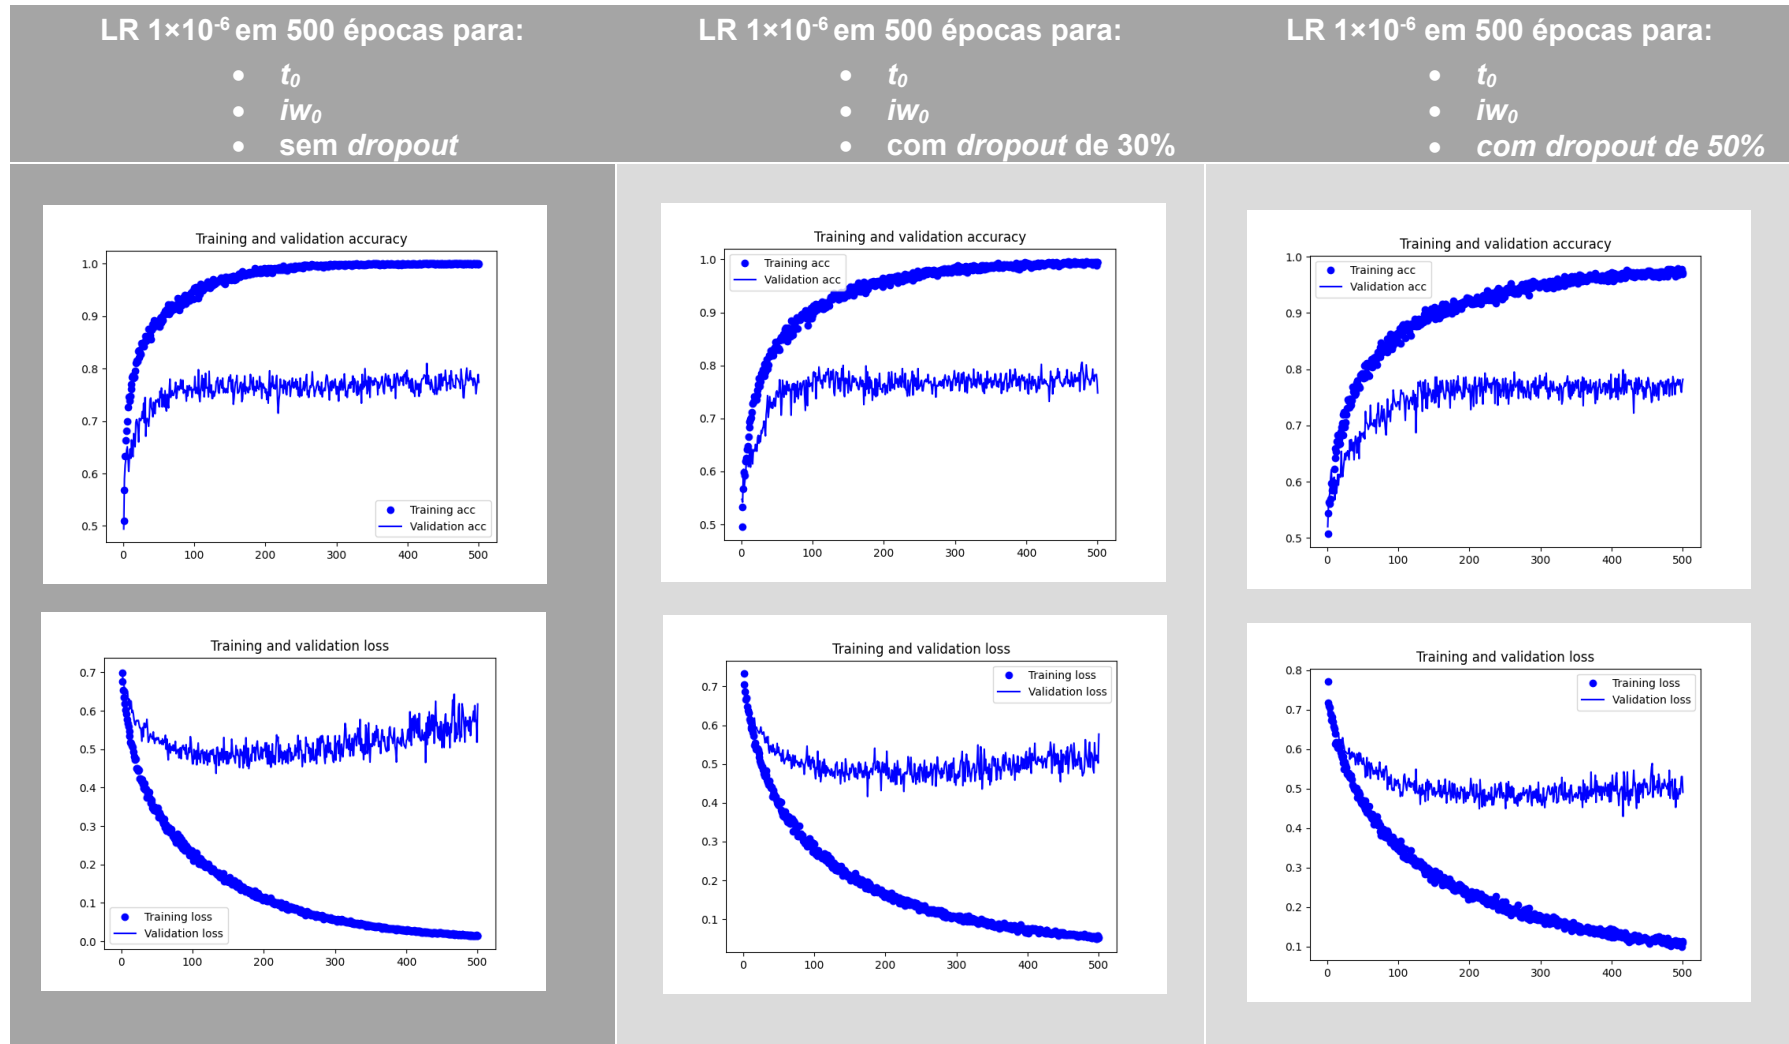


Tabela 6.18: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de **500 épocas** e t_1 , w_0 e com diferente **dropout**.

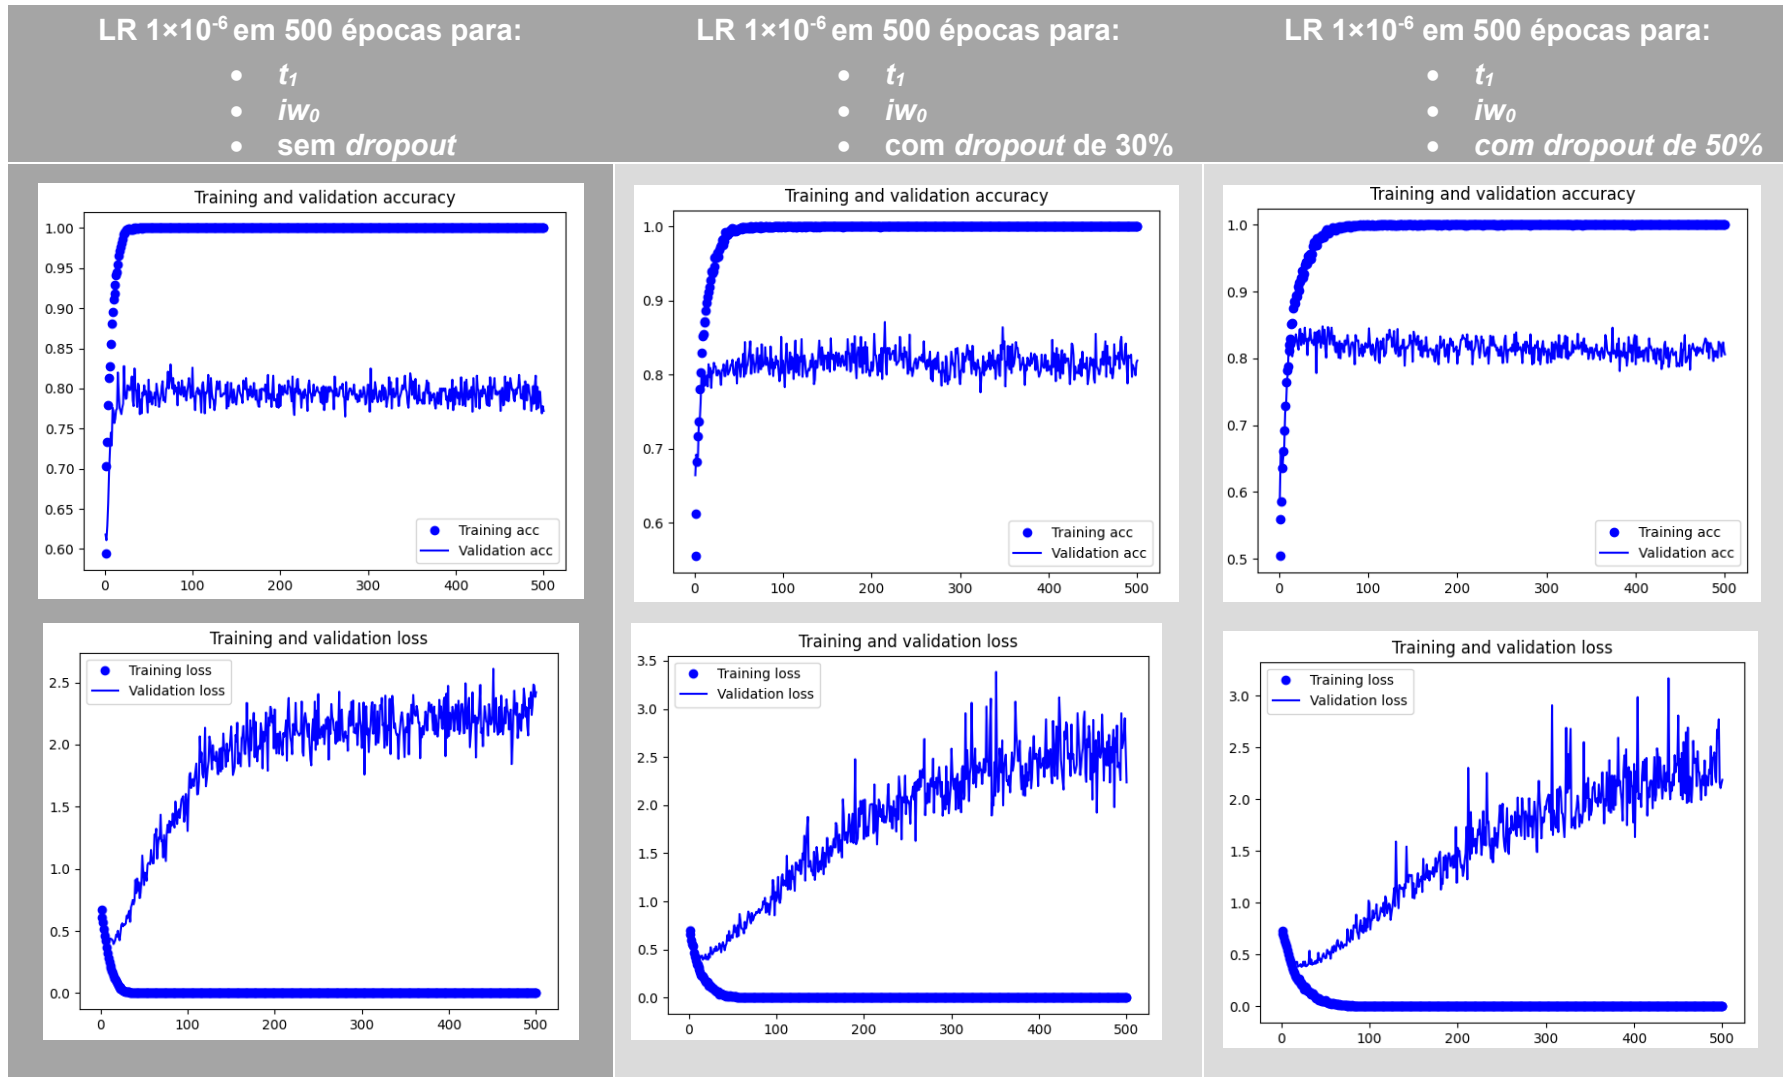


Tabela 6.19: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de **500 épocas** e w_1 , t_0 e com diferente **dropout**.

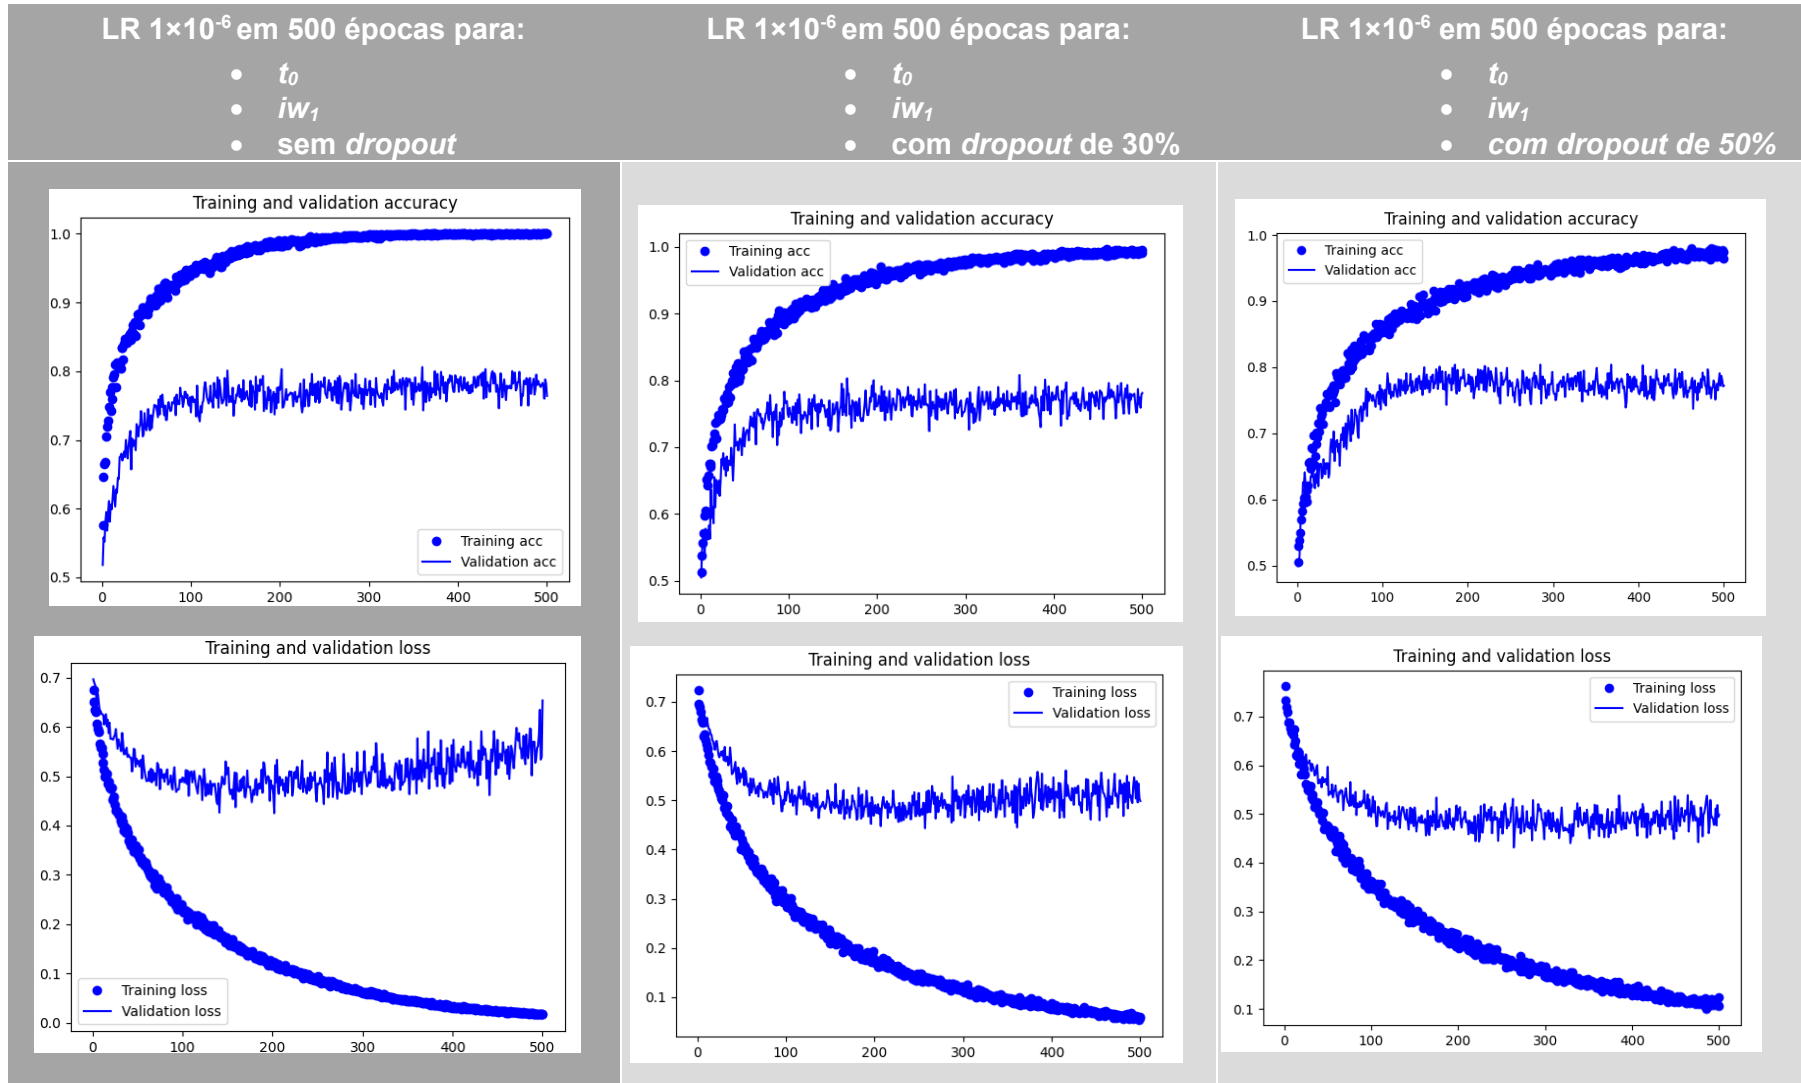
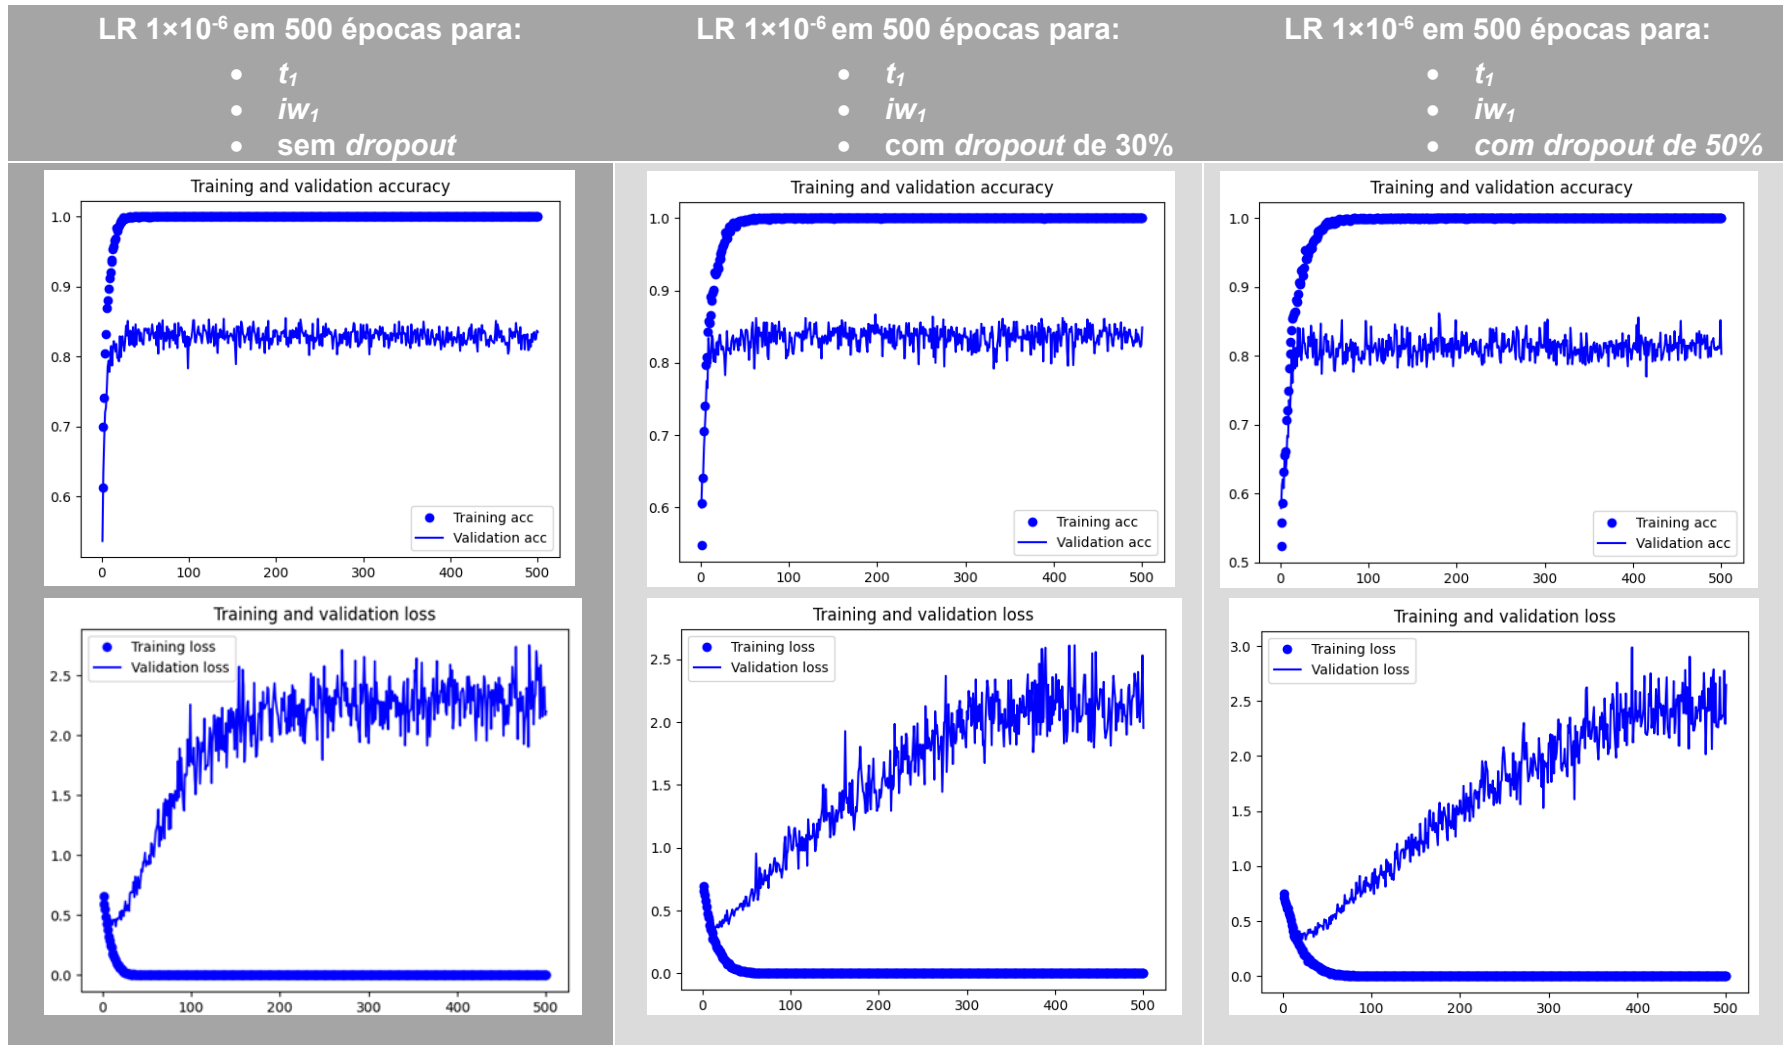


Tabela 6.20: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de **500 épocas** e w_1 , t_1 e com diferente **dropout**.



6.6 VGG16 vs VGG19

O modelo VGG19 tem por base o modelo VGG16, sendo a sua principal diferença o número de camadas convolucionais que neste novo modelo são 6 camadas, resultando numa rede com cerca de 148 milhões de parâmetros.⁽⁹²⁾ De forma a analisarmos a potencialidade de uma rede mais profunda no diagnóstico de HDL em imagens pela técnica de RM lombar, todos os testes realizados com o modelo VGG16 foram realizados no modelo VGG19, tendo sido programado de igual modo todos os parâmetros analisados no modelo com menor número de camadas.

Tendo em conta a extensão dos resultados obtidos, e uma vez que a análise da VGG19 não constava dos objetivos deste trabalho, apenas iremos apresentar e comparar os gráficos obtidos para uma VGG19 com inicialização randomizada, treinando apenas a última camada da rede e com os diferentes valores de LR ao longo de 100 épocas. Os restantes resultados estarão disponíveis para consulta nos anexos.

Relativamente aos diferentes valores de LR, em que a rede iniciou os seus pesos de forma randomizada e a última camada foi a única treinada, verificamos que o valor de *accuracy* atingido para o conjunto de validação foi ligeiramente inferior ao obtido com a rede VGG16, situando-se em torno dos 0,75 valores. A função *loss* para o valor de LR de 1×10^{-6} teve um comportamento descendente, terminando as 100 épocas com um valor superior a 0,5, contrariamente às funções *loss* obtidas para valores de LR de 1×10^{-4} e 1×10^{-5} que foram crescendo ao longo das épocas e atingiram os valores de 1,4 e cerca de 0,7 valores respetivamente – ver Tabela 6.21.

Quando recorremos à técnica de *dropout* de 30% conseguimos uma melhoria dos resultados, sendo superiores aos 0,8 para o conjunto de validação da rede, com ligeira melhoria também dos valores da função *loss* para os três valores de LR, desempenho superior que o obtido através da técnica de *dropout* de 50% – ver Tabela 6.22 e 6.23.

Numa avaliação geral de todas as variáveis analisadas, o desempenho da VGG19 possibilitou atingir alguns valores de *accuracy* mais elevados comparativamente ao modelo VGG16. Contudo, o comportamento e valores das funções de *loss* levam-nos a acreditar que a rede memorizou mais facilmente os dados em vez de os aprender como seria desejável, levando-nos a concluir que o aumento da profundidade da rede não será necessário para obter uma melhor performance da CNN a que nos propusemos.

Tabela 6.21: Análise entre um LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_0 , iw_0 , sem *dropout* ao longo de 100 épocas, numa VGG19.

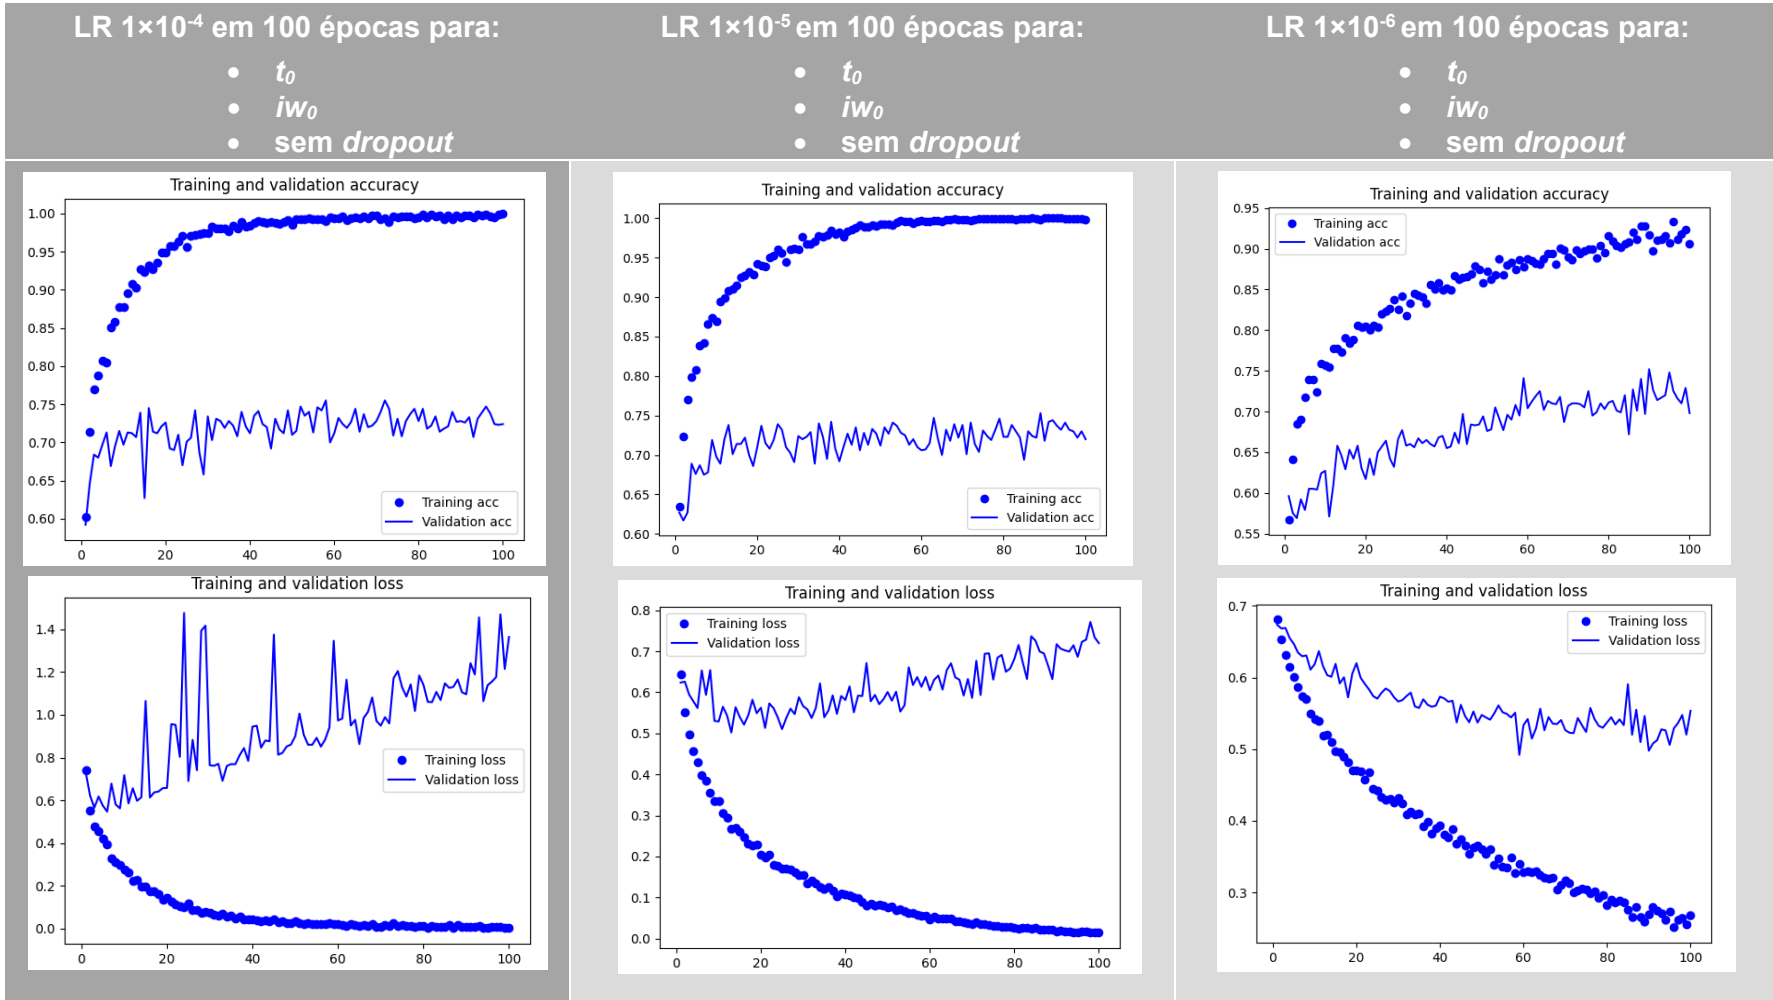


Tabela 6.22: Comparação de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com **dropout de 30%** para t_0 , iw_0 , ao longo de 100 épocas, numa VGG19.

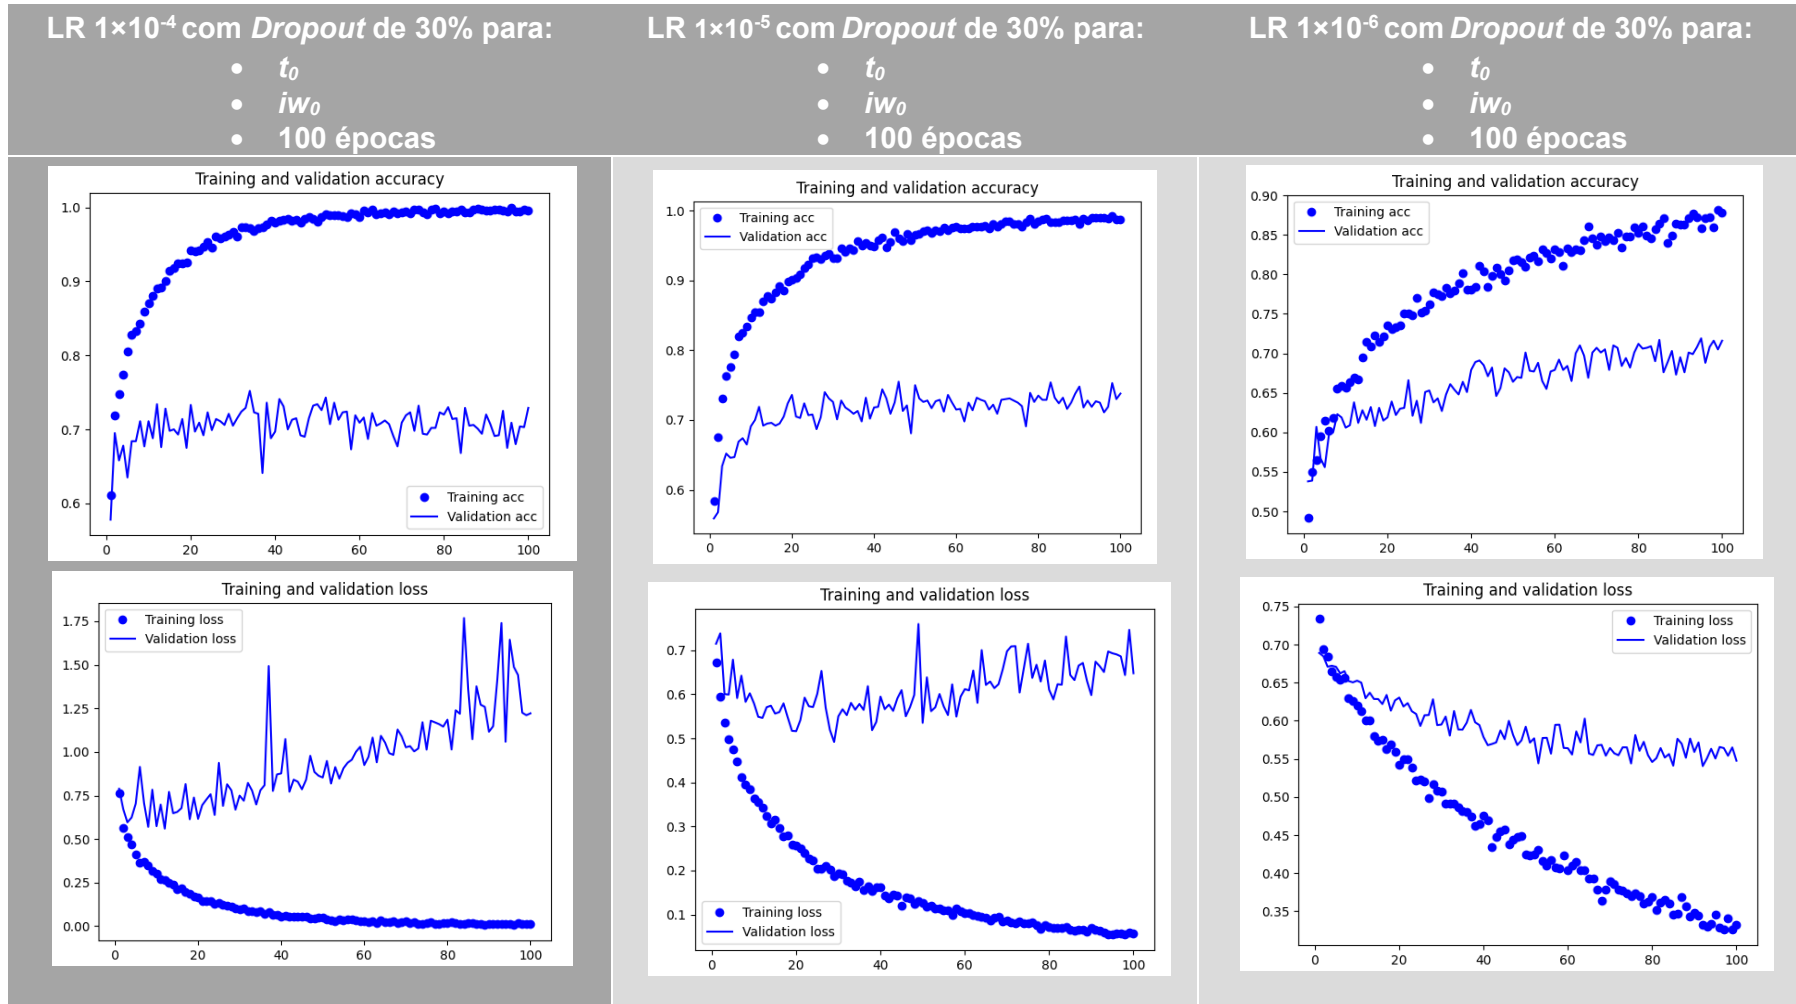



Tabela 6.23: Estudo comparativo de LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} com **dropout de 50%** para t_0 , iw_0 , ao longo de 100 épocas, numa VGG19.



6.7 SÍNTESE DOS VALORES OBTIDOS

A investigação e a análise das diversas variáveis ao longo deste trabalho resultou num considerável número de gráficos, pelo que a leitura e interpretação dos mesmos pode ser exaustiva. Neste sentido, e de forma a facilitar a interpretação dos resultados apresentados, evidenciaremos na Tabela 6.24, o resumo dos valores de *accuracy* e da função *loss* obtidos para cada variável analisada na rede VGG16. As tabelas com o resumo dos valores obtidos com a rede VGG19 estão disponíveis para consulta nos anexos.

Tabela 6.24: Síntese dos valores obtidos com a rede VGG 16.

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_0 • sem <i>dropout</i> • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,8	0	1,2
LR de 1×10^{-5}	1	> 0,8	0	0,8
LR de 1×10^{-6}	~ 0,95	> 0,8	0,2	0,5
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_0 • <i>dropout</i> de 30% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,8	0	1
LR de 1×10^{-5}	1	0,8	0	0,6
LR de 1×10^{-6}	9	~ 0,8	0,3	0,5

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_0 • <i>dropout</i> de 50% • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,8	0	1
LR de 1×10^{-5}	1	0,8	0,1	1
LR de 1×10^{-6}	0,85	0,75	0,35	0,6
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_0 • sem <i>dropout</i> • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,9	0	~2
LR de 1×10^{-5}	1	> 0,85	0	> 2
LR de 1×10^{-6}	1	~ 0,85	0	~1,5
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_0 • <i>dropout</i> de 30% • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,9	0	4
LR de 1×10^{-5}	1	> 0,85	0	> 1,5
LR de 1×10^{-6}	1	0,85	0	> 0,7

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_0 • <i>dropout</i> de 50% • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,9	0	4
LR de 1×10^{-5}	1	> 0,9	0	> 2
LR de 1×10^{-6}	1	> 0,8	0	> 1
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_1 • sem <i>dropout</i> • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,8	0	> 1
LR de 1×10^{-5}	1	> 0,8	0	> 0,7
LR de 1×10^{-6}	> 0,9	~ 0,8	0,2	~ 0,5
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_1 • <i>dropout</i> de 30% • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,8	0	1,25
LR de 1×10^{-5}	1	> 0,8	0	> 0,6
LR de 1×10^{-6}	> 0,9	> 0,75	< 0,3	0,5

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_1 • <i>dropout</i> de 50% • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,8	0	> 1
LR de 1×10^{-5}	1	0,8	< 0,1	> 0,5
LR de 1×10^{-6}	> 0,85	0,75	< 0,35	> 0,5
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_1 • sem <i>dropout</i> • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,9	0	> 5
LR de 1×10^{-5}	1	~ 0,9	0	~2
LR de 1×10^{-6}	1	> 0,85	0	> 1,2
Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_1 • <i>dropout</i> de 30% • 100 épocas 	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,9	0	> 5
LR de 1×10^{-5}	1	~ 0,9	0	~2
LR de 1×10^{-6}	1	> 0,8	0	> 1

Caraterísticas da Rede:	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
<ul style="list-style-type: none"> • t_1 • iw_1 • <i>dropout</i> de 50% • 100 épocas 	1	> 0,9	0	~ 0
LR de 1×10^{-4}	1	> 0,9	0	~ 0
LR de 1×10^{-5}	1	~ 0,9	0	1,5
LR de 1×10^{-6}	1	> 0,85	0	< 0,8
LR de 1×10^{-6}				
Caraterísticas da rede:	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
<ul style="list-style-type: none"> • t_0 • iw_0 • 500 épocas 				
<i>sem dropout</i>	1	> 0,8	0	> 0,5
<i>dropout</i> de 30%	1	> 0,8	~ 0	~ 0,6
<i>dropout</i> de 50%	1	0,8	< 0,1	0,5
LR de 1×10^{-6}				
Caraterísticas da rede:	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
<ul style="list-style-type: none"> • t_1 • iw_0 • 500 épocas 				
<i>sem dropout</i>	1	> 0,8	0	< 2,5
<i>dropout</i> de 30%	1	> 0,8	0	> 2,5
<i>dropout</i> de 50%	1	0,8	0	~2

Caraterísticas da rede: • t_0 • iW_1 • 500 épocas	LR de 1×10^{-6}			
	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
<i>sem dropout</i>	1	> 0,8	0	> 0,6
<i>dropout de 30%</i>	1	> 0,8	~ 0	> 0,5
<i>dropout de 50%</i>	1	> 0,8	< 0,1	> 0,5

Caraterísticas da rede: • t_1 • iW_1 • 500 épocas	LR de 1×10^{-6}			
	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
<i>sem dropout</i>	1	> 0,85	0	> 2
<i>dropout de 30%</i>	1	> 0,85	0	> 2
<i>dropout de 50%</i>	1	> 0,85	0	> 2,5

6.8 COMPARAÇÃO COM OUTROS ESTUDOS

Nos últimos anos, a investigação sobre a utilização das CNN no estudo da coluna lombar pela técnica de RM tem vindo a aumentar. Todavia, a maioria dos estudos encontrados recorrem a imagens da técnica de RM no plano sagital, cujo objetivo principal centra-se na deteção e segmentação vertebral, e análise da degeneração discal ou estenose foraminal. ^(18,33,93-98)

Relativamente à classificação de HDL em imagens pela técnica de RM recorrendo aos algoritmos DL, o número de estudos realizados e disponíveis até à data são muito inferiores e estão resumidos na Tabela 6.25. De todos os artigos analisados, e que serviram de apoio para o desenvolvimento do presente trabalho, temos a destacar o

estudo apresentado em 2020 por Mbarki *et al.*, “*Lumbar spine discs classification based on deep convolutional neural networks using axial view MRI*”.

Tabela 6.25: Apresentação dos artigos que utilizaram algoritmos DL para análise de imagens de pela técnica RM da coluna lombar no plano axial.

SÍNTESE DO ARTIGO	AUTORES/ANO DE PUBLICAÇÃO	PUBLICAÇÃO
OBJETIVO: desenvolver um sistema para reconhecer automaticamente HDL com base numa rede VGG16 e base de dados própria do <i>Sahloul University Hospital de Sousse</i> , Tunísia. MÉTODOS: aplicar o sistema de deteção desenvolvido à técnica de RM lombar de 200 pacientes. RESULTADOS: 94% de <i>accuracy</i> conseguida com a rede desenvolvida.	Mbarki <i>et al.</i> , 2020 (99)	Interdisciplinary Neurosurgery: Advanced Techniques and Case Management
OBJETIVO: analisar o nível de concordância entre os relatórios da técnica de RM lombar criados por uma CNN e a leitura realizada pelos radiologistas. MÉTODOS: 65 pacientes com um total de 383 níveis analisados pela técnica de RM lombar de um centro imagiológico. Comparação do relatório médico vs predição do algoritmo utilizado. RESULTADOS: análise realizada pelo algoritmo foi de 0.627 contra o valor de 0.808 dos médicos radiologistas.	Lewandrowski <i>et al.</i> , 2020 (100)	International Journal of Spine Surgery

Para o desenvolvimento do referido artigo, os autores utilizaram o seu próprio conjunto de dados recolhidos no Hospital Universitário Sahloul de Sousse na Tunísia, referentes a 200 utentes. As idades compreendidas dos pacientes situaram-se entre os 14 e 81 anos, e todos os analisados tinham em comum pelo menos uma HDL diagnosticada, de entre outras alterações ao nível da coluna lombar. Destes 200 utentes, 50 casos foram utilizados no treino das redes e os restantes 150 para a validação das mesmas.

O modelo VGG16 foi o utilizado neste estudo, cujo principal objetivo era a localização das HDL através de duas etapas: 1ª etapa - marcação manual da segmentação do disco e apófises através de um *software*, de forma a retirar a área de interesse a ser analisada; 2ª etapa - segmentação e classificação do disco intervertebral através de imagens axiais pela técnica de RM lombar ponderadas em T_2 .

Neste artigo, os autores apresentaram uma precisão do modelo treinado de 94%, não fazendo referência a outras métricas de avaliação que possibilitem aferir a capacidade de generalização da rede. Desta forma, e comparando o valor mais elevado de *accuracy* atingido ao longo de todo o processo, 0,9 para valores de LR de 1×10^{-4} e

de 1×10^{-5} ao treinarmos toda rede da *ImageNet*, podemos afirmar que os resultados estão em sintonia com o estudo de Mbarki *et al.*, revelando que as redes neuronais podem ser uma tecnologia a ser aproveitada pela técnica de RM.

6.9 LIMITAÇÕES DO ESTUDO

A utilização das CNN nas imagens médicas tem demonstrado ser altamente promissora, apesar da pouca disponibilidade de dados à data de hoje. Este primeiro e grande desafio, juntamente com o elevado número de parâmetros que constituem uma rede neuronal profunda, pode diminuir e limitar a sua aplicação e o seu desempenho.⁽⁶⁵⁾

De igual modo, o primeiro grande desafio enfrentado no desenvolvimento deste trabalho foi conseguir uma base de dados de imagens pela técnica de RM da coluna lombar de acesso público que, para além de ter um número de imagens consideráveis e necessárias, disponibilizasse imagens de elevada qualidade. Já o desenvolvimento de uma CNN otimizada requer uma pesquisa profunda na temática e uma abrangência vasta de conhecimentos, pelo que o tempo necessário para a finalização deste projeto tornou-se ainda mais desafiante e até uma limitação para o projeto idealizado ao longo da pesquisa.

Por outro lado, o reconhecimento HDL no plano axial através de uma CNN apresenta uma dificuldade elevada devido aos diversos desafios a ultrapassar relativamente às características das imagens, onde se destaca o ruído, a qualidade e o fundo complexo de cada imagem a ser analisada. O grau de complexidade e de dificuldade no diagnóstico de HDL aumenta ainda devido a uma das tarefas mais importantes das CNN no diagnóstico de HD, a segmentação e localização dos diferentes discos intervertebrais, como referido por Mbarki *et al.*⁽¹⁰¹⁾

De um ponto de vista mais abrangente, a utilização das CNN na área da saúde, assim como de outros algoritmos de IA enfrentam desde logo diversas limitações gerais, também sentidas na elaboração desta dissertação, como o custo e disponibilidade de unidades computacionais de elevada capacidade para o desenvolvimento e otimização de uma rede neuronal de convolução.

Segundo Han *et al.*, “a evidência da qualidade promove o desenvolvimento e o progresso da tecnologia diagnóstica e do tratamento médico baseado na inteligência artificial”.⁽⁹⁶⁾ Deste modo, e sendo a técnica de RM e a IA duas áreas complexas e exigentes mas de elevado interesse em vários domínios, a estreita colaboração com

outras áreas do conhecimento como a matemática e a tecnologia computacional avançada poderá permitir ultrapassar os mais diversos desafios que surjam e de difícil resolução, engrandecendo ainda mais a capacidade diagnóstica pela técnica de RM.

7. CONCLUSÕES

7.1 CONSIDERAÇÕES

As RNA são atualmente um campo promissor da IA com inúmeras aplicações nos mais variados ramos da Medicina. Sendo cada vez mais utilizadas como uma tecnologia de apoio, estas redes permitem soluções económicas na gestão de tempo e de recursos. Recentemente, a IA e seus respetivos algoritmos impulsionaram rápidos avanços na avaliação de várias doenças, incluindo da coluna vertebral, onde são utilizadas no diagnóstico e prognóstico clínico, na previsão de resultados pós-cirúrgicos, bem como na pesquisa e avaliação biomecânica da patologia vertebral. ⁽²²⁾

No que concerne a área da Radiologia, os algoritmos de DL apresentam um enorme potencial uma vez que quase todos os dados primários utilizados na imagem, assim como os relatórios médicos são digitais. ⁽⁶⁵⁾ Assim, e tendo em conta a lacuna encontrada sobre os estudos das CNN aplicados a imagens pela técnica de RM da coluna lombar, surgiu a questão que levou ao desenvolvimento desta dissertação:

“A deteção de HDL pode ser realizada de forma automática e fiável através de algoritmos inteligentes aplicados aos exames pela técnica de RM lombar, especialmente no plano axial?”

- De forma a encontrar uma resposta a esta pergunta inicial, este trabalho teve como objetivo principal desenvolver uma rede neuronal de convolução destinada a auxiliar no diagnóstico de HDL, tendo por base imagens da técnica de RM da coluna lombar no plano axial. Como objetivos específicos, e aos quais conseguimos dar resposta com esta dissertação, propusemo-nos a: Desenvolver

e treinar um algoritmo de CNN para a detecção de HDL em imagens da técnica de RM adquiridas no plano axial;

- Proceder à aplicação da CNN a exames da técnica de RM da coluna lombar de 515 doentes disponíveis numa base de dados de acesso público;
- Analisar a *accuracy* da CNN na deteção de HDL nas imagens axiais da técnica de RM;
- Colmatar a pouca investigação e respetiva aplicabilidade destes algoritmos em imagens da técnica de RM no plano axial da coluna lombar;
- Demonstrar a aplicabilidade e compatibilidade de novas ferramentas num meio imagiológico de elevada sensibilidade no diagnóstico de HL, a técnica de RM.

Com o desenvolvimento e otimização da rede a que nos propusemos, conseguimos não só obter excelentes valores de *accuracy*, mas também valores de função *loss* que nos permitem afirmar que é possível treinar de forma robusta uma CNN destinada a auxiliar no diagnóstico de HDL, tendo por base imagens da técnica de RM da coluna lombar adquiridas no plano axial.

A melhor performance da rede VGG16 foi conseguida com um valor de LR de 1×10^{-6} que alcançou excelentes valores de *accuracy* e da função *loss*, de entre os quais se destacam os seguintes resultados:

- Um valor de *accuracy* superior a 0,8 para o conjunto de validação, quando a rede é treinada apenas para a última camada da rede (t_0), rede com inicialização randomizada (iw_0), sem *dropout* ao longo de 100 épocas, com valores da função *loss* de 0,5 para o conjunto de validação;
- Quando a rede é treinada apenas na última camada da rede (t_0) e com inicialização randomizada (iw_0), um *dropout* de 30%, durante 100 épocas obteve um valor de *accuracy* de aproximadamente 0,8 e um valor da função *loss* de 0,5;
- Um valor de *accuracy* de 0,85 na validação com o treino de toda a rede (t_1), rede com inicialização randomizada (iw_0) e *dropout* de 30%, ao longo de 100 épocas. O valor da função *loss* foi ligeiramente superior a 0.7.

Dado os resultados obtidos e apresentados, podemos concluir que o objetivo principal foi alcançado, assim como todos os objetivos específicos.

7.2 IMPLICAÇÕES TEÓRICAS E PRÁTICAS

A familiaridade com as novas ferramentas, neste caso em concreto com as CNN, permite ajudar não só os profissionais que as aplicam no seu trabalho diário, mas também os médicos radiologistas nas suas tarefas de análise e interpretação de milhares de imagens. Este conhecimento pode influenciar num futuro próximo a prática diária dos profissionais de saúde, tanto de um ponto de vista do técnico de Radiologia como do médico radiologista, possibilitando um diagnóstico mais célere e que poderá resultar num benefício para os utentes.

São inúmeras as evidências que sugerem que as RNA podem ser utilizadas com sucesso no estudo da patologia vertebral, de forma a melhor coordenar o diagnóstico, o prognóstico, o tratamento e a previsão de resultados. ⁽²²⁾ Segundo Miskin *et al.*, a variabilidade de interpretação na análise de alterações degenerativas da coluna lombar em imagens da técnica de RM é um problema clínico reconhecido, o que contribui para imprecisões na correlação das características imagiológicas com a sintomatologia do paciente. Esta situação leva a que relatar este tipo de exame levante questões únicas que normalmente não ocorrem em outros exames. ⁽¹⁰²⁾ Neste sentido, o desenvolvimento e otimização de uma CNN capaz de detetar HDL poderá minimizar esta problemática. Em suma, o contributo deste trabalho poderá ser importante para o desenvolvimento de um algoritmo capaz de detetar HDL em imagens pela técnica de RM, com uma precisão muito próxima da executada pelos profissionais de saúde mais experientes na prática clínica diária.

Como defendido por Han *et al.*, “a evidência da qualidade promove o desenvolvimento e o progresso da tecnologia diagnóstica e do tratamento médico baseado na inteligência artificial”. ⁽⁹⁶⁾ Deste modo, e sendo a técnica de RM e a IA duas áreas complexas e exigentes mas de elevado interesse em vários domínios, a estreita colaboração com outras áreas do conhecimento como a matemática e a tecnologia computacional avançada poderá permitir ultrapassar os mais diversos desafios que surjam e de difícil resolução, engrandecendo ainda mais a capacidade diagnóstica da técnica de RM.

7.3 PERSPECTIVAS FUTURAS

A importância da técnica de RM no diagnóstico de HDL, bem como a pertinência desta

patologia, foram bem evidenciadas ao longo deste estudo, pelo que importa salientar a relevância da utilização de ferramentas de ponta como as CNN no reconhecimento de HD em imagens pela técnica de RM. Segundo Azimi *et al.*, as RNA que englobam as CNN são ferramentas de grande valor e com elevada capacidade para melhorar a compreensão do diagnóstico e prognóstico, dos valores preditivos e da avaliação biomecânica da coluna vertebral. Assim, e dado o contínuo desenvolvimento de métodos de *hardware*, *software*, da ciência e da tecnologia computacional avançada, é espectável que num futuro próximo haja uma maior consideração e uma aplicação mais vasta da IA nas doenças da coluna vertebral. ⁽²²⁾

Tendo em conta o trabalho desenvolvido ao longo desta dissertação, e numa perspetiva futura da aplicabilidade de redes neuronais às imagens pela técnica de RM da coluna lombar, seria estimulante desenvolver um algoritmo capaz de detetar as HDL no plano axial e sagital em simultâneo.

Dado que a coluna lombar apresenta uma anatomia dinâmica e sujeita a várias alterações morfológicas consoante o posicionamento em supinação ou em decúbito do utente, seria igualmente interessante realizar o estudo dos discos intervertebrais e possíveis HDL recorrendo à técnica de RM cinemática com suporte de peso, tal como realizado no estudo de 2021 de Roberts *et al.* ⁽⁴⁶⁾ Ou ainda, desenvolver uma CNN capaz de simular o posicionamento do disco quando sujeito a uma carga, possibilitando uma análise ainda mais real da sua relação com as raízes nervosas.

A criação de diversas CNN a serem aplicadas no estudo da coluna lombar pela técnica de RM poderiam potenciar e alargar a possibilidade diagnóstica de outras patologias num único exame, aumentando a precisão e a abrangência diagnóstica no estudo de outras patologias e diminuindo a necessidade de realização de diversos exames de diagnóstico. A título de exemplo, e tendo a técnica de RM da coluna lombar sido o segundo exame imagiológico mais frequente e adequado para a avaliação da aorta segundo Zucker *et al.*, a criação de um CNN para a deteção e avaliação do aneurisma da aorta abdominal através de um estudo da coluna lombar pela técnica de RM seria muito interessante.

“If you wish to succeed, you must brave the risk of failure.”

Garry Kasparov

REFERÊNCIAS BIBLIOGRÁFICAS

1. Verheijen EJA, Munts AG, van Haagen OBHAM, de Vries D, Vleggeert-Lankamp CLA. The Outcome of Epidural Injections in Lumbar Radiculopathy Is Not Dependent on the Presence of Disc Herniation on Magnetic Resonance Imaging: Assessment of Short-Term and Long-Term Efficacy. *World Neurosurg* [Internet]. 2021;148:e643–9. Available from: <https://doi.org/10.1016/j.wneu.2021.01.051>
2. Yu H, Zhu B, Liu X. Comparison of Percutaneous Endoscopic Lumbar Discectomy and Open Lumbar Discectomy in the Treatment of Adolescent Lumbar Disc Herniation: A Retrospective Analysis. *World Neurosurg* [Internet]. 2021;151:e911–7. Available from: <https://doi.org/10.1016/j.wneu.2021.05.007>
3. Sinmaz T, Akansel N. Experience of Pain and Satisfaction with Pain Management in Patients After a Lumbar Disc Herniation Surgery. *J Perianesthesia Nurs*. 2021;36(6):647–55.
4. Chu WT, Lin E, Tung HH, Clinciu DL. Simulated Health Education Measures after Lumbar Disk Herniation Surgery: A Quasi-Experimental Study in Taiwan. *Clin Simul Nurs* [Internet]. 2020;44:50–8. Available from: <https://doi.org/10.1016/j.ecns.2020.01.005>
5. Abbafati C, Abbas KM, Abbasi-Kangevari M, Abd-Allah F, Abdelalim A, Abdollahi M, et al. Global burden of 369 diseases and injuries in 204 countries and territories, 1990–2019: a systematic analysis for the Global Burden of Disease Study 2019. *Lancet*. 2020;396(10258):1204–22.
6. Kislaya I, Neto M. Sociodemographic characterization of self-reported chronic low back pain prevalence in Portugal: results from the National Health Survey 2014. *Bol Epidemiológico Obs*. 2017;9:39–42.
7. Institute for Health Metrics and Evaluation (IHME). GBD Compare visualizations [Internet]. Seattle, WA: IHME, University of Washington. 2019. Available from: <http://vizhub.healthdata.org/gbd-compare>.
8. Vialle LR, Vialle EN, Henao JE, Giraldo G. Lumbar disc herniation. *Adv Environ Biol* [Internet]. 2015;9(2):44–9. Available from: [http://dx.doi.org/10.1016/S2255-4971\(15\)30211-1](http://dx.doi.org/10.1016/S2255-4971(15)30211-1)
9. Urrutia J, Besa P, Campos M, Cikutovic P, Cabezon M, Molina M, et al. The

- Pfirrmann classification of lumbar intervertebral disc degeneration: an independent inter- and intra-observer agreement assessment. *Eur Spine J.* 2016;25(9):2728–33.
10. Lundervold AS, Lundervold A. An overview of deep learning in medical imaging focusing on MRI. *Z Med Phys.* 2019;29(2):102–27.
 11. Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015;521(7553):436–44.
 12. Bernal J, Kushibar K, Asfaw DS, Valverde S, Oliver A, Martí R, et al. Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: a review. *Artif Intell Med [Internet].* 2019;95:64–81. Available from: <https://doi.org/10.1016/j.artmed.2018.08.008>
 13. Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, et al. *ImageNet* Large Scale Visual Recognition Challenge. *Int J Comput Vis [Internet].* 2015;115(3):211–52. Available from: <http://dx.doi.org/10.1007/s11263-015-0816-y>
 14. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide. *Radiology.* 2019;290(3):590–606.
 15. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition. *Insights Imaging.* 2018;9:611–29.
 16. Lakhani P, Sundaram B. Deep learning at chest radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks. *Radiology [Internet].* 2017;284(2):574–82. Available from: <http://pubs.rsna.org.ezp-prod1.hul.harvard.edu/doi/pdf/10.1148/radiol.2017162326>
 17. Talo M, Yildirim O, Baloglu UB, Aydin G, Acharya UR. Convolutional neural networks for multi-class brain disease detection using MRI images. *Comput Med Imaging Graph [Internet].* 2019;78:101673. Available from: <https://doi.org/10.1016/j.compmedimag.2019.101673>
 18. Jamaludin A, Kadir T, Zisserman A. *SpineNet*: Automated classification and evidence visualization in *spinal* MRIs. *Med Image Anal [Internet].* 2017;41:63–73. Available from: <http://dx.doi.org/10.1016/j.media.2017.07.002>

19. Kim KH, Choi SH, Park SH. Improving arterial *spin* labeling by using deep learning. *Radiology*. 2018;287(2):658–66.
20. Leon Lenchik, Laura Heacock, Ashley A. Weaver, Robert D. Boutin, Tessa S. Cook, Jason Itri, Christopher G. Filippi, Rao P. Gullapalli, James Lee, Marianna Zagurovskaya, Tara Retson, Kendra Godwin, Joey Nicholson PAN. Automated Segmentation of Tissues using CT and MRI: A Systematic Review. *Acad Radiol*. 2019;26(12):1695–706.
21. Kijowski R, Liu F, Caliva F, Pedoia V. Deep Learning for Lesion Detection, Progression, and Prediction of Musculoskeletal Disease. *J Magn Reson Imaging*. 2020;52(6):1607–19.
22. Azimi P, Yazdanian T, Benzel EC, Aghaei HN, Azhari S, Sadeghi S, et al. A Review on the use of artificial intelligence in *spinal* diseases. *Asian Spine J*. 2020;14(4):543–71.
23. Frost BA, Camarero-Espinosa S, Johan Foster E. Materials for the *spine*: Anatomy, problems, and solutions. *Materials (Basel)*. 2019;12(2):1–41.
24. Ombregt L. Applied anatomy of the lumbar *spine*. In: *A System of Orthopaedic Medicine*. 2013. p. 415-436.e4.
25. Ebraheim NA, Hassan A, Lee M, Xu R. Functional anatomy of the lumbar *spine*. *Semin Pain Med*. 2004;2(3):131–7.
26. Fardon DF, Williams AL, Dohring EJ, Murtagh FR, Rothman SLG, Sze GK. Lumbar disc nomenclature : version 2 . 0 Recommendations of the combined task forces of the North American *Spine Society* , the American Society of *Spine Radiology* and the American Society of Neuroradiology. *Spine J* [Internet]. 2014;14(11):2525–45. Available from: <http://dx.doi.org/10.1016/j.spinee.2014.04.022>
27. Dugailly PM, Dethier C, Salem W. Immediate alteration of the lumbar intervertebral foramen during the so-called osteopathic locking technique: A preliminary analysis on healthy subjects. *Int J Osteopath Med* [Internet]. 2021;42(March):69–75. Available from: <https://doi.org/10.1016/j.ijosm.2021.12.006>
28. Andreula C, Muto M, Leonardi M. Interventional *spinal* procedures. *Eur J Radiol*. 2004;50(2):112–9.

29. Waldt S, Gersing A, Brügel M, Angle F, Angle C. Measurements and Classifications in *Spine* Imaging. *Semin Musculoskelet Radiol*. 2014;18(3):219–27.
30. Kelekis A, Bonaldi G, Cianfoni A, Filippiadis D, Scarone P, Bernucci C, et al. Intradiscal oxygen-ozone chemonucleolysis versus microdiscectomy for lumbar disc herniation radiculopathy: a non-inferiority randomized control trial. *Spine J* [Internet]. 2021;000:1–15. Available from: <https://doi.org/10.1016/j.spinee.2021.11.017>
31. Kim S, Jang S. Radicular pain caused by Schmorl's node: a case report. *Brazilian J Anesthesiol* [Internet]. 2018;68(3):322–4. Available from: <http://dx.doi.org/10.1016/j.bjan.2017.07.007>
32. Foti G, Lombardo F, Fighera A, Giaretta A, Catania M, Serra G, et al. Role of diffusion tensor imaging of sciatic nerve in symptomatic patients with inconclusive lumbar MRI. *Eur J Radiol* [Internet]. 2020;131:109249. Available from: <https://doi.org/10.1016/j.ejrad.2020.109249>
33. Tsai J-Y, Hung IY-J, Guo YL, Jan Y-K, Lin C-Y, Shih TT-F, et al. Lumbar Disc Herniation Automatic Detection in Magnetic Resonance Imaging Based on Deep Learning. *Front Bioeng Biotechnol*. 2021;9(August):1–11.
34. Jordan J, Konstantinou K, O'Dowd J. Herniated lumbar disc. *Clin Evid (Online)*. 2009;03:1118.
35. Goncalves LC, Gotfryd AO, Silber Caffaro MF, Astur N, de Mendonca RGM, Toma MK, et al. Analysis of the reliability of the lee classification for lumbar disc herniations. *Coluna/ Columna*. 2020;19(4):258–61.
36. Shepard N, Cho W. Recurrent Lumbar Disc Herniation: A Review. *Glob Spine J*. 2019;9(2):202–9.
37. Bailey JF, Nyayapati P, Johnson GTA, Dziesinski L, Scheffler AW, Crawford R, et al. Biomechanical changes in the lumbar *spine* following spaceflight and factors associated with postspaceflight disc herniation. *Spine J* [Internet]. 2021;000:1–10. Available from: <https://doi.org/10.1016/j.spinee.2021.07.021>
38. Cai X yi, Sun M si, Huang Y peng, Liu Z xuan, Liu C jie, Du C fei, et al. Biomechanical Effect of L4–L5 Intervertebral Disc Degeneration on the Lower Lumbar *Spine*: A Finite Element Study. *Orthop Surg*. 2020;12(3):917–30.
39. Jiang Y, Yu L, Luo X, Lin Y, He B, Wu B, et al. Quantitative synthetic MRI for

- evaluation of the lumbar intervertebral disk degeneration in patients with chronic low back pain. *Eur J Radiol*. 2020;124(January):108858 (1-5).
40. Berg AJ, Ahmadje U, Jayanna HH, Trégouët P, Sanville P, Kapoor V. The prevalence of lumbar disc degeneration in symptomatic younger patients: A study of MRI scans. *J Clin Orthop Trauma*. 2020;11(5):932–6.
 41. Rickers KW, Pedersen PH, Tvedebrink T, Eiskjær SP. Comparison of interventions for lumbar disc herniation: a systematic review with network meta-analysis. *Spine J* [Internet]. 2021;21(10):1750–62. Available from: <https://doi.org/10.1016/j.spinee.2021.02.022>
 42. Cieza A, Causey K, Kamenov K, Hanson SW, Chatterji S, Vos T. Global estimates of the need for rehabilitation based on the Global Burden of Disease study 2019: a systematic analysis for the Global Burden of Disease Study 2019. *Lancet* [Internet]. 2020;396(10267):2006–17. Available from: [http://dx.doi.org/10.1016/S0140-6736\(20\)32340-0](http://dx.doi.org/10.1016/S0140-6736(20)32340-0)
 43. Yüce, Kahyaoğlu O, Mertan P, Çavuşoğlu H, Aydın Y. Analysis of clinical characteristics and surgical results of upper lumbar disc herniations. *Neurochirurgie*. 2019;65(4):158–63.
 44. Ogon I, Takebayashi T, Takashima H, Morita T, Terashima Y, Yoshimoto M, et al. Imaging diagnosis for intervertebral disc. *JOR SPINE* [Internet]. 2020 Mar;3(1):1–6. Available from: <https://onlinelibrary.wiley.com/doi/10.1002/jsp2.1066>
 45. Qaseem A, Wilt TJ, McLean RM, Forciea MA. Noninvasive treatments for acute, subacute, and chronic low back pain: A clinical practice guideline from the American College of Physicians. *Ann Intern Med*. 2017;166(7):514–30.
 46. Roberts S, Gardner C, Jiang Z, Abedi A, Buser Z, Wang JC. Analysis of trends in lumbar disc degeneration using kinematic MRI. *Clin Imaging* [Internet]. 2021;79:136–41. Available from: <https://doi.org/10.1016/j.clinimag.2021.04.028>
 47. Ansorge R, Graves M. The Physics and Mathematics of MRI. In: *The Jerusalem Talmud, First order: Zeraim, Tractate Berakhot*. 2013. p. 39–155.
 48. Sprawls P. *Magnetic Resonance Imaging Principles and Techniques*. Medical Physics Publishing Corporation. 2000. 26–102 p.
 49. Warach S, Kidwell CS, Baird AE. *Magnetic Resonance Imaging*. In: *Stroke: Pathophysiology, Diagnosis, and Management*. 2004. p. 461–79.

50. Mastrogiacomo S, Dou W, Jansen JA, Walboomers XF. Magnetic Resonance Imaging of Hard Tissues and Hard Tissue Engineered Bio-substitutes. *Mol Imaging Biol.* 2019;21(6):1003–19.
51. Mazzola AA. Ressonancia magnética: princípios de formação da imagem e aplicações em imagem funcional. *Rev Bras Física Médica.* 2009;3(1):117–29.
52. Ridgway JP. Cardiovascular magnetic resonance physics for clinicians: Part I. *J Cardiovasc Magn Reson* [Internet]. 2010;12(71):1–28. Available from: <http://www.jcmr-online.com/content/12/1/71>
53. Bitar R, Leung G, Perng R, Tadros S, Moody AR, Sarrazin J, et al. MR pulse sequences: What every radiologist wants to know but is afraid to ask. *Radiographics.* 2006;26(2):513–37.
54. Tseng WYI, Su MYM, Tseng YHE. Introduction to cardiovascular magnetic resonance: Technical principles and clinical applications. *Acta Cardiol Sin.* 2016;32(2):129–44.
55. Caspani S, Magalhães R, Araújo JP, Sousa CT. Magnetic nanomaterials as contrast agents for MRI. *Materials (Basel).* 2020;13(11):1–29.
56. Hendrick R. Breast MRI: Using physics to maximize its sensitivity and specificity to breast cancer. *Med Phys* [Internet]. 2004;31(6):1737–1737. Available from: <http://www.aapm.org/meetings/04AM/pdf/14-2345-77728.pdf>
57. Biglands JD, Radjenovic A, Ridgway JP. Cardiovascular magnetic resonance physics for clinicians: Part II. *J Cardiovasc Magn Reson* [Internet]. 2012;14(66):1–40. Available from: *Journal of Cardiovascular Magnetic Resonance*
58. Pfirrmann CWA, Metzdorf A, Zanetti M, Hodler J, Boos N. Magnetic resonance classification of lumbar intervertebral disc degeneration. *Spine (Phila Pa 1976).* 2001;26(17):1873–8.
59. Li Y, Fredrickson V, Resnick DK. How Should We Grade Lumbar Disc Herniation and Nerve Root Compression? A Systematic Review. *Clin Orthop Relat Res* [Internet]. 2015;473(6):1896–902. Available from: <http://dx.doi.org/10.1007/s11999-014-3674-y>
60. Natalia F, Meidia H, Afriliana N, Al-Kafri AS, Sudirman S, Simpson A, et al. Development of Ground Truth Data for Automatic Lumbar *Spine* MRI Image Segmentation. *Proc - 20th Int Conf High Perform Comput Commun 16th Int Conf*

- Smart City 4th Int Conf Data Sci Syst HPCC/SmartCity/DSS 2018. 2019;1449–54.
61. Jiang Y, Yu L, Luo X, Lin Y, He B, Wu B, et al. Quantitative synthetic MRI for evaluation of the lumbar intervertebral disk degeneration in patients with chronic low back pain. *Eur J Radiol* [Internet]. 2020;124:108858. Available from: <https://doi.org/10.1016/j.ejrad.2020.108858>
 62. Kushchayev S V., Glushko T, Jarraya M, Schuleri KH, Preul MC, Brooks ML, et al. ABCs of the degenerative *spine*. *Insights Imaging* [Internet]. 2018 Apr 22;9(2):253–74. Available from: <https://insightsimaging.springeropen.com/articles/10.1007/s13244-017-0584-z>
 63. Buller M. MRI Degenerative Disease of the Lumbar *Spine*: A Review. *J Am Osteopat Coll Radiol*. 2018;7(4):11–9.
 64. Mbarki W, Bouchouicha M, Frizzi S, Tshibas F, Ben Farhat L, Sayadi M. A novel method based on deep learning for herniated lumbar disc segmentation. *Proc Int Conf Adv Syst Emergent Technol IC_ASET 2020*. 2020;(December):394–9.
 65. Mazurowski MA, Buda M, Saha A, Bashir MR. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI [Internet]. Vol. 49, *Journal of Magnetic Resonance Imaging*. 2019. p. 939–54. Available from: <https://www.sciencedirect.com/science/article/pii/S0925443916302150?via%3Dihub>
 66. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60–88.
 67. Dridi S. UNSUPERVISED LEARNING - A SYSTEMATIC LITERATURE REVIEW. *A Prepr Res*. 2021;1–8.
 68. Dike HU, Zhou Y, Deveerasetty KK, Wu Q. Unsupervised Learning Based On Artificial Neural Network: A Review. *2018 IEEE Int Conf Cyborg Bionic Syst CBS 2018*. 2019;322–7.
 69. Petersen SE, Sporns O. Brain Networks and Cognitive Architectures. *Neuron* [Internet]. 2015;88(1):207–19. Available from: <http://dx.doi.org/10.1016/j.neuron.2015.09.027>
 70. Wang L, Lu SR, Wen J. Recent Advances on Neuromorphic Systems Using

- Phase-Change Materials. *Nanoscale Res Lett.* 2017;12(1):1–22.
71. Moreira C. Neurónio. *Rev Ciência Elem.* 2013;1(1):1–3.
 72. Haykin S. *Neural Networks and Learning Machines*. Vols. 1–3, *Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics*. 2018. 1–46; 790–842 p.
 73. Stahl S. Structure and Function of Neurons and Neuroglia. In: *Stahl's Essential Psychopharmacology: Neuroscientific Basis and Practical Applications*. Third Edit. Cambridge University Press; 2015. p. 1–10.
 74. Wilson DR, Martinez TR. The need for small *learning rates* on large problems. *Proc Int Jt Conf Neural Networks*. 2001;1(January):115–9.
 75. Jepkoech J, Mugo DM, Kenduiywo BK, Too EC. The Effect of Adaptive *Learning rate* on the Accuracy of Neural Networks. *Int J Adv Comput Sci Appl*. 2021;12(8):736–51.
 76. Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidike P, Nasrin MS, et al. A state-of-the-art survey on deep learning theory and architectures. *Electron*. 2019;8(3):1–67.
 77. Jabir B, Falih N. Dropout, a basic and effective regularization method for a deep learning model: A case study. *Indones J Electr Eng Comput Sci*. 2021;24(2):1009–16.
 78. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. *J Mach Learn Res*. 2014;15:1929–58.
 79. Nalepa J, Marcinkiewicz M, Kawulok M. Data Augmentation for Brain-Tumor Segmentation: A Review. *Front Comput Neurosci*. 2019;13:1–18.
 80. Shorten C, Khoshgoftaar TM. A survey on Image Data Augmentation for Deep Learning. *J Big Data [Internet]*. 2019;6(1):1–48. Available from: <https://doi.org/10.1186/s40537-019-0197-0>
 81. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data [Internet]*. 2021;8(53):1–74. Available from: <https://doi.org/10.1186/s40537-021-00444-8>







82. Jeklin A. revista de programação. 2016;(July):1–23.
83. Namdar K, Haider MA, Khalvati F. A Modified AUC for Training Convolutional Neural Networks: Taking Confidence Into Account. *Front Artif Intell.* 2021;4:1–19.
84. Gajowniczek K, Ząbkowski T, Szupiluk R. Estimating the ROC curve and its significance for classification models' assessment. *Quant Methods Econ.* 2014;XV(2):382–91.
85. Yang S, Berdine G. The receiver operating characteristic (ROC) curve. *Southwest Respir Crit Care Chronicles.* 2017;5(19):34–6.
86. Fawcett T. An introduction to ROC analysis. *Pattern Recognit Lett.* 2006;27(8):861–74.
87. Polo TCF, Miot HA. Aplicações da curva ROC em estudos clínicos e experimentais. *J Vasc Bras.* 2020;19:13–6.
88. Sairamy NJ, Susmitha L, Thomas George S, Subathra MSP. Hybrid approach for classification of electroencephalographic signals using time-frequency images with wavelets and texture features. *Intell Data Anal Biomed Appl Challenges Solut.* 2019;253–73.
89. Khan HA, Jue W, Mushtaq M, Mushtaq MU. Brain tumor classification in MRI image using convolutional neural network. *Math Biosci Eng.* 2020;17(5):6203–16.
90. Al-Kafri AS, Sudirman S, Hussain A, Al-Jumeily D, Natalia F, Meidia H, et al. Boundary Delineation of MRI Images for Lumbar *Spinal* Stenosis Detection Through Semantic Segmentation Using Deep Neural Networks. *IEEE Access.* 2019;7(April):43487–501.
91. Indrajit I, Verma B. Digital imaging in radiology practice: An introduction to few fundamental concepts. *Indian J Radiol Imaging.* 2007;17(4):230–6.
92. Sudha V, Ganeshbabu TR. A convolutional neural network classifier VGG-19 architecture for lesion detection and grading in diabetic retinopathy based on deep learning. *Comput Mater Contin.* 2021;66(1):827–42.
93. Zhou Y, Liu Y, Chen Q, Gu G, Sui X. Automatic Lumbar MRI Detection and Identification Based on Deep Learning. *J Digit Imaging.* 2019;32(3):513–20.
94. Zhou J, Damasceno PF, Chachad R, Cheung JR, Ballatori A, Lotz JC, et al. Automatic Vertebral Body Segmentation Based on Deep Learning of Dixon

- Images for Bone Marrow Fat Fraction Quantification. *Front Endocrinol (Lausanne)*. 2020;11(September):1–10.
95. Huang J, Shen H, Wu J, Hu X, Zhu Z, Lv X, et al. *Spine Explorer: a deep learning based fully automated program for efficient and reliable quantifications of the vertebrae and discs on sagittal lumbar spine MR images*. *Spine J [Internet]*. 2020;20(4):590–9. Available from: <https://doi.org/10.1016/j.spinee.2019.11.010>
 96. Han M, Liu L, Hu M, Liu G, Li P. Medical expert and machine learning analysis of lumbar disc herniation based on magnetic resonance imaging. *Comput Methods Programs Biomed [Internet]*. 2022;213:106498. Available from: <https://doi.org/10.1016/j.cmpb.2021.106498>
 97. Natalia F, Young JC, Afriliana N, Meidia H, Yunus RE, Sudirman S. Automated selection of mid-height intervertebral disc slice in traverse lumbar *spine* MRI using a combination of deep learning feature and machine learning classifier. *PLoS One*. 2022;17(1 January):1–30.
 98. Masood RF, Taj IA, Khan MB, Qureshi MA, Hassan T. Deep Learning based Vertebral Body Segmentation with Extraction of *Spinal* Measurements and Disorder Disease Classification. *Biomed Signal Process Control [Internet]*. 2022;71(PB):103230. Available from: <https://doi.org/10.1016/j.bspc.2021.103230>
 99. Mbarki W, Bouchouicha M, Frizzi S, Tshibas F, Farhat L Ben, Sayadi M. Lumbar *spine* discs classification based on deep convolutional neural networks using axial view MRI. *Interdiscip Neurosurg Adv Tech Case Manag [Internet]*. 2020;22:100837. Available from: <https://doi.org/10.1016/j.inat.2020.100837>
 100. Lewandrowski KU, Muraleedharan N, Eddy SA, Sobti V, Reece BD, León JFR, et al. Reliability analysis of deep learning algorithms for reporting of routine lumbar MRI scans. *Int J Spine Surg*. 2020;14(3):S98–107.
 101. Mbarki W, Bouchouicha M, Frizzi S, Tshibas F, Ben Farhat L, Sayadi M. A novel method based on deep learning for herniated lumbar disc segmentation. *Proc Int Conf Adv Syst Emergent Technol IC_ASET 2020*. 2020;(January 2021):394–9.
 102. Miskin N, Gaviola GC, Huang RY, Kim CJ, Lee TC, Small KM, et al. Intra- and Intersubspecialty Variability in Lumbar *Spine* MRI Interpretation: A Multireader Study Comparing Musculoskeletal Radiologists and Neuroradiologists. *Curr Probl Diagn Radiol*. 2020;49(3):182–7.

103. Zucker EJ, Prabhakar AM. Lumbar *Spine* MRI: Missed Opportunities for Abdominal Aortic Aneurysm Detection. *Curr Probl Diagn Radiol* [Internet]. 2020;49(4):254–9. Available from: <https://doi.org/10.1067/j.cpradiol.2019.05.002>
104. Rguibi Z, Hajami A, Zitouni D, Elqaraoui A, Bedraoui A. CXAI: Explaining Convolutional Neural Networks for Medical Imaging Diagnostic. *Electronics* [Internet]. 2022; 11(11): 1775. Available from: <https://doi.org/10.3390/electronics11111775>

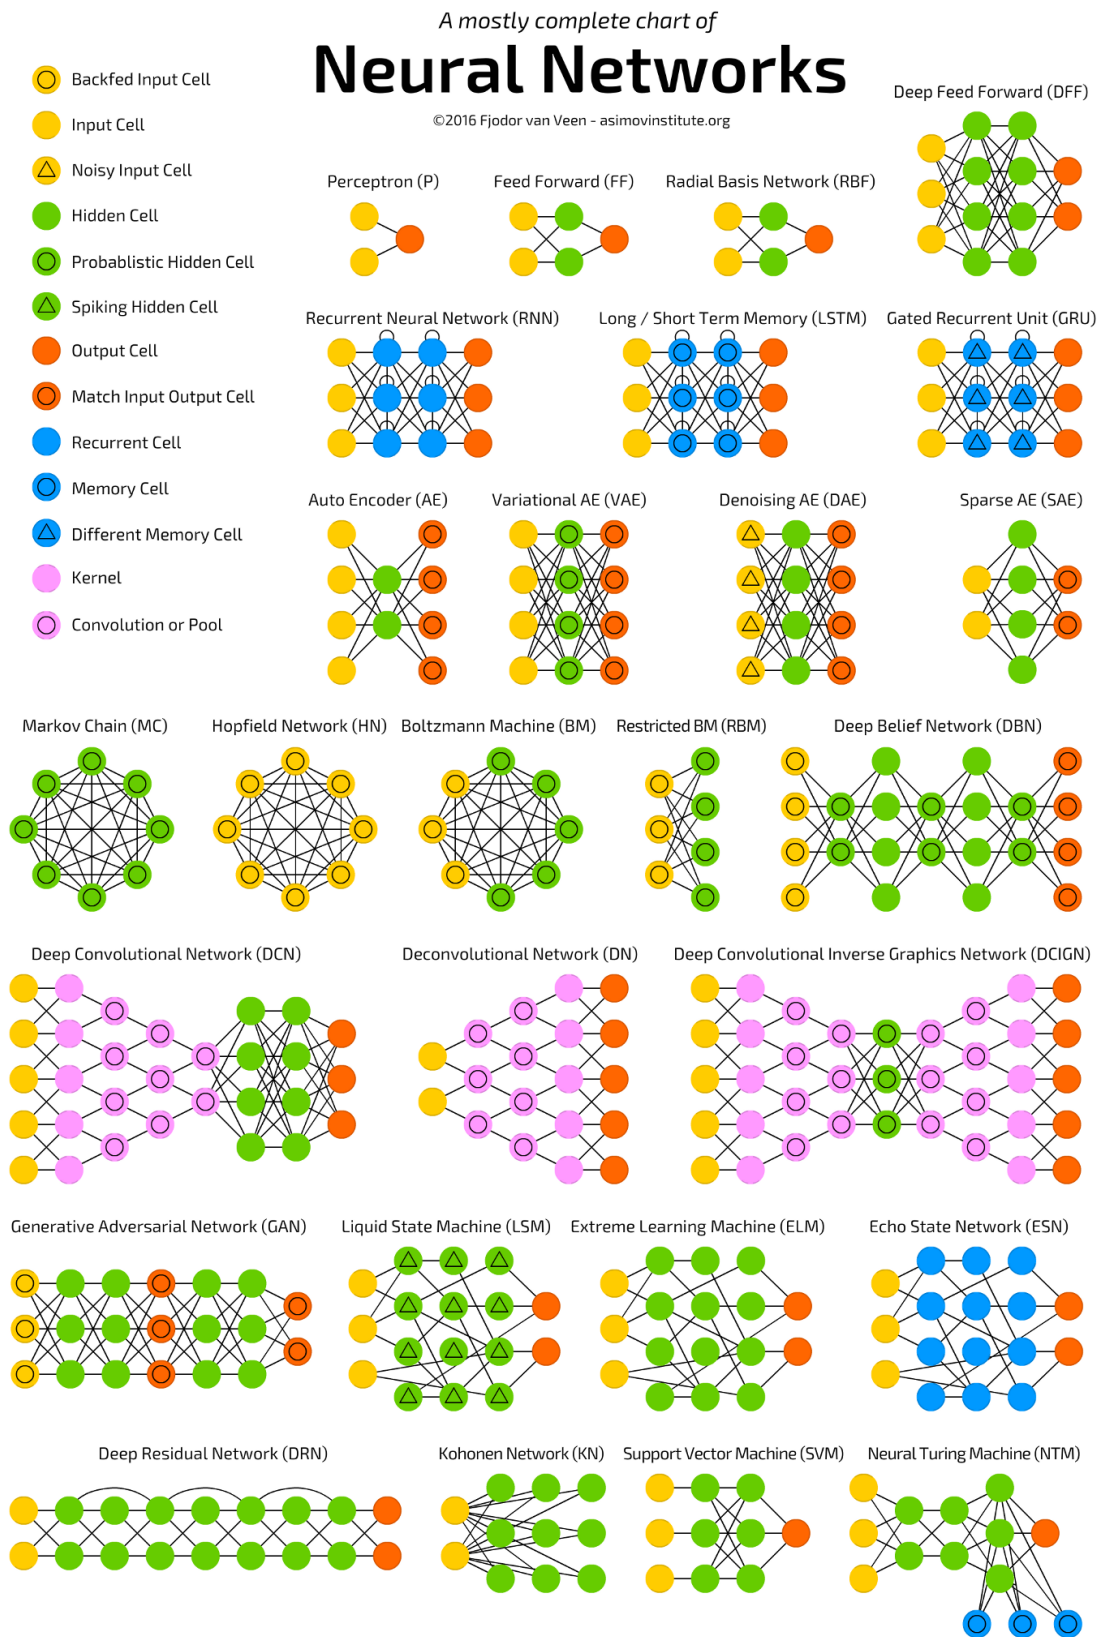
ANEXOS

ANEXO I - DÉFICE NEUROLÓGICO EM CADA NÍVEL DE COMPRESSÃO RADICULAR

NÍVEL	DÉFICE NEUROLÓGICO EM CADA NÍVEL	
L1		<p>A compressão da raiz de L1 não produz parestesia nem fraqueza muscular. A analgesia cutânea é encontrada apenas abaixo da metade interna do ligamento inguinal.</p>
L2		<p>O envolvimento da raiz de L2 causa parestesia e analgesia localizada na face anterior da coxa, da virilha até à rótula. A fraqueza muscular é encontrada no músculo psoas.</p>
L3		<p>A compressão na raiz de L3 causa parestesia na face anterior da perna desde o terço distal da coxa, passando sobre o joelho e a parte inferior da perna até o tornozelo. A analgesia cutânea estende-se da rótula ao longo da parte frontal e interna da perna e termina logo acima do tornozelo. Os músculos fracos são o psoas e o quadríceps. O movimento do joelho é lento ou ausente.</p>
L4		<p>A compressão de L4 tem os seguintes sinais clínicos: parestesia na parte externa da perna e no 1º dedo do pé; déficit sensorial na face lateral da perna, sobre o pé até ao 1º dedo do pé; e fraqueza do extensor do hálux e do músculo tibial anterior.</p>
L5		<p>O envolvimento da raiz de L5 resulta em parestesia na perna externa, na frente do pé e nos primeiros três dedos do pé. Analgesia cutânea na perna externa, no dorso do pé e nos três dedos internos. A fraqueza é encontrada no extensor longo do hálux, nos músculos tibial e glúteo médio.</p>
S1		<p>A compressão da raiz nervosa de S1 mostra os seguintes sinais: parestesia nos dois dedos externos do pé, dormência nos músculos posteriores da perna, no calcanhar e na face lateral do pé. Os músculos fracos são os gêmeos, os isquiotibiais, o glúteo maior e o tibial.</p>

Adaptado de ⁽²⁴⁾ - Ombregt L. Applied anatomy of the lumbar *spine*. In: A System of Orthopaedic Medicine. 2013. p. 415-436.e4.

ANEXO II – ARQUITETURA DAS DIFERENTES REDES NEURONAIS



ANEXO III – RESULTADOS OBTIDOS COM A REDE VGG19

Tabela 6.26: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , sem *dropout* ao longo de 100 épocas, em VGG19.

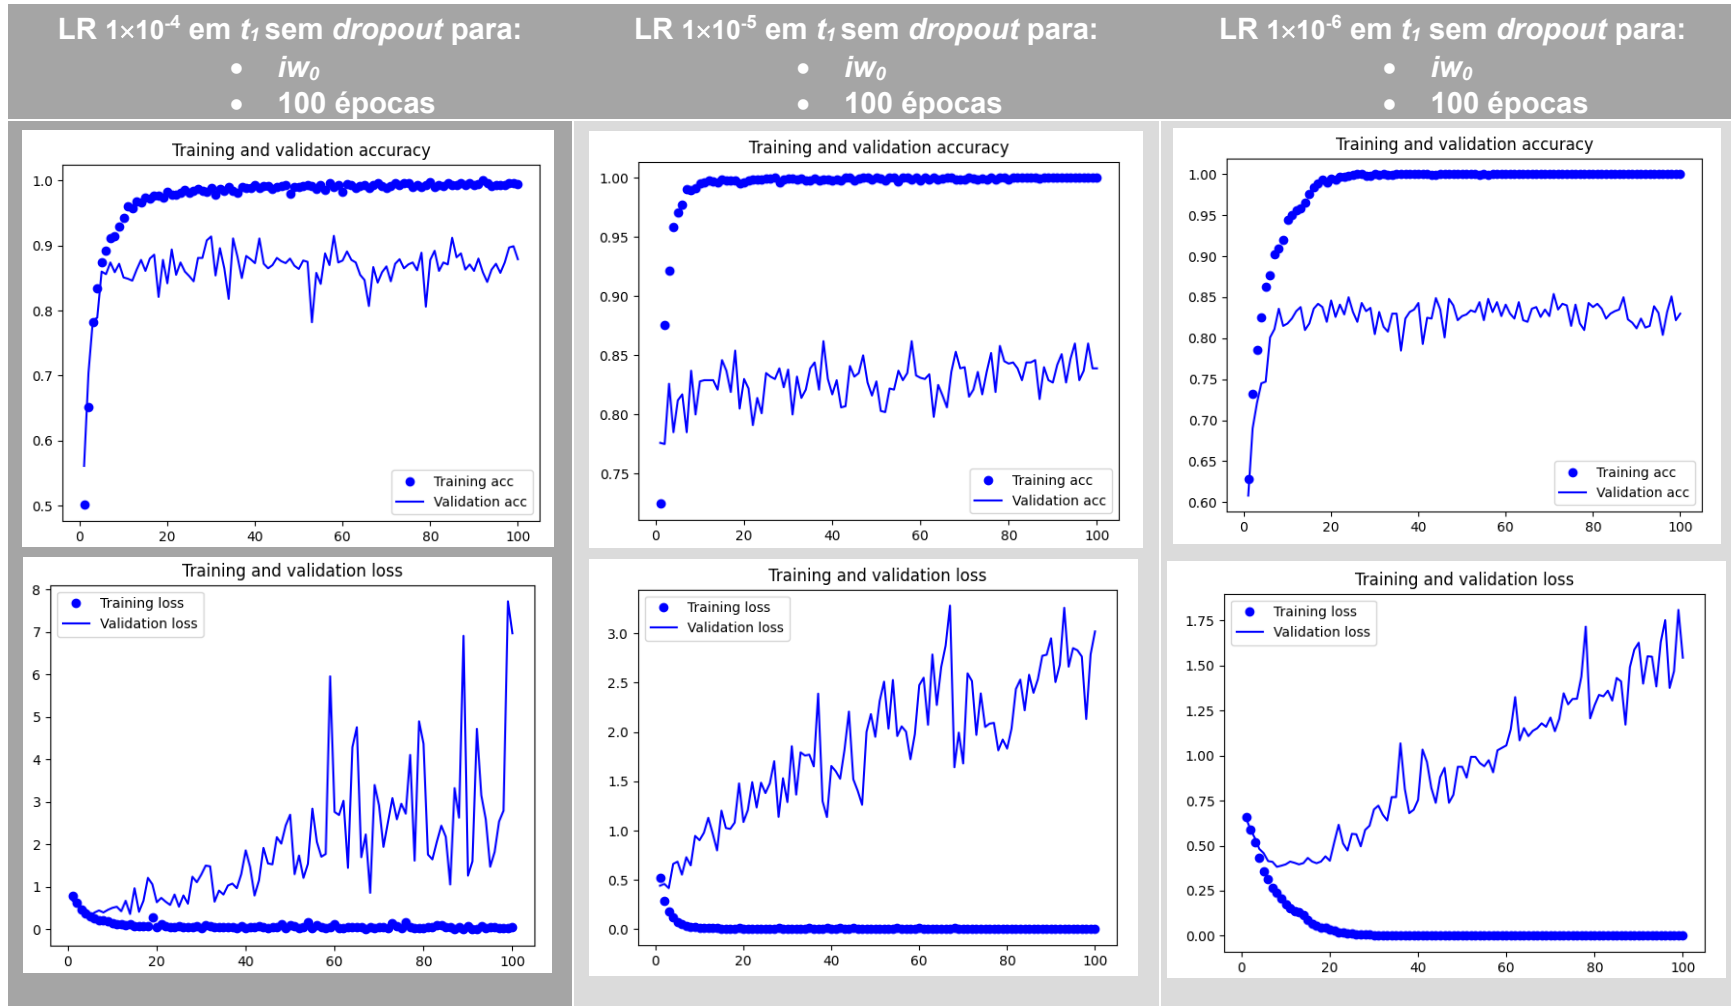


Tabela 6.27: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com **dropout de 30%** ao longo de 100 épocas, em VGG19.

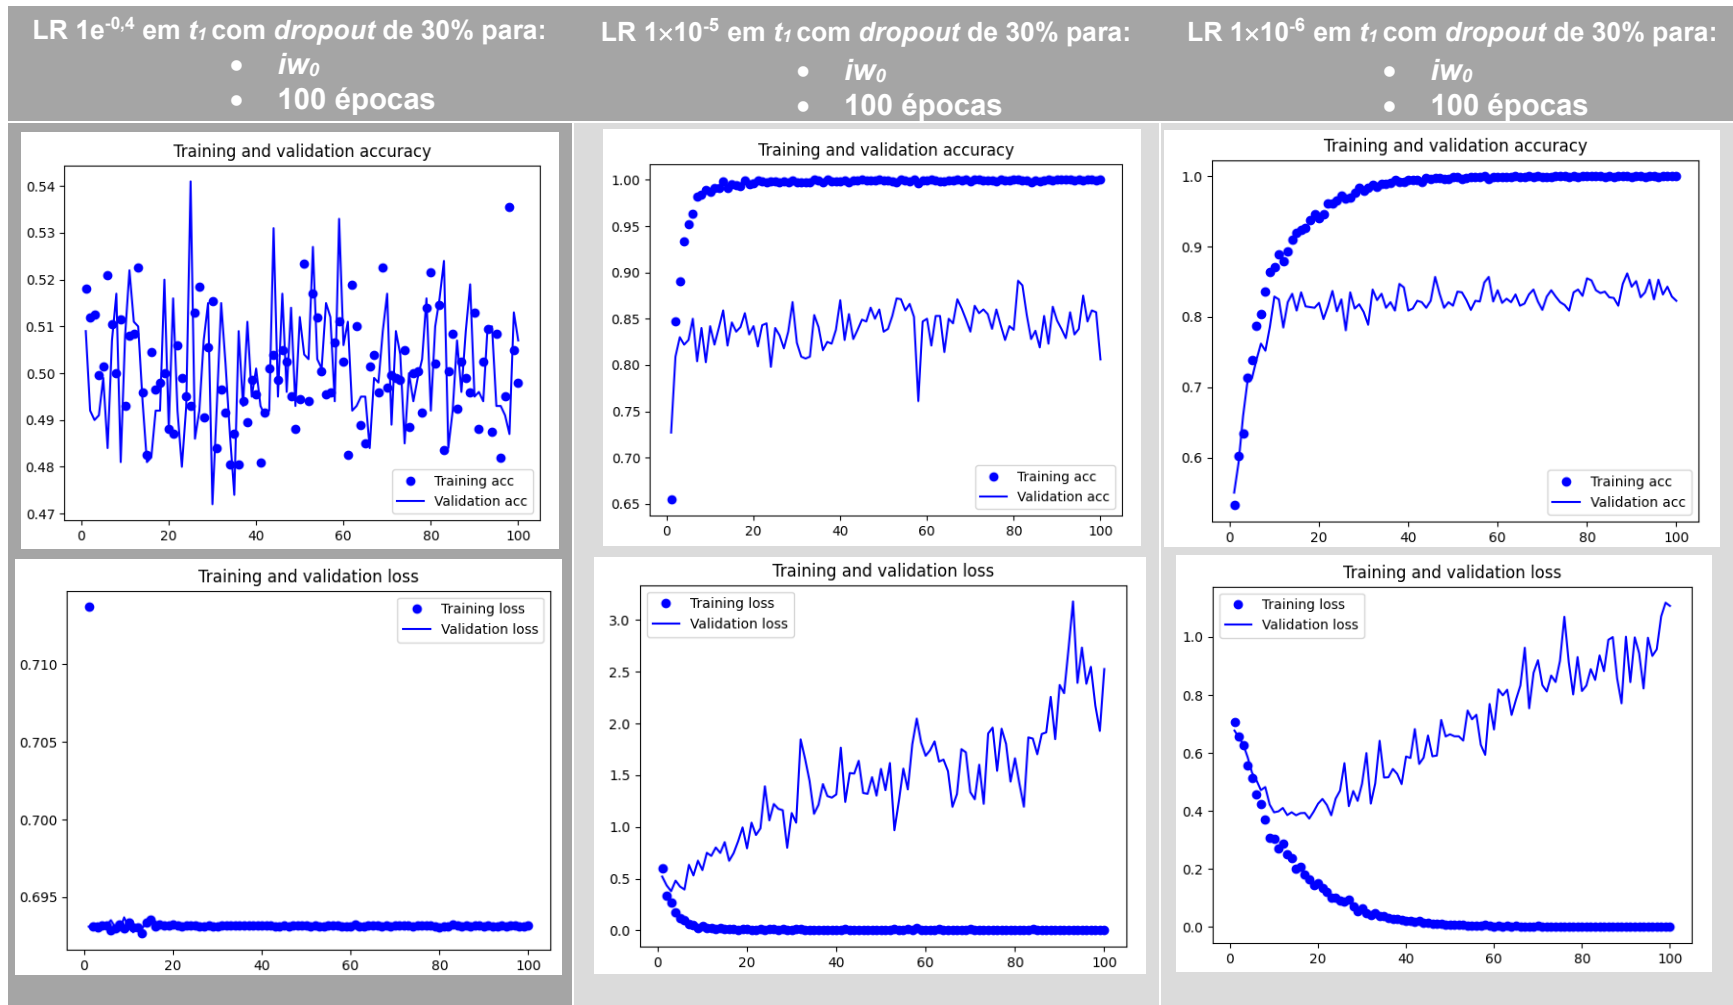


Tabela 6.28: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para t_1 , iw_0 , com **dropout de 50%** ao longo de 100 épocas, em VGG19

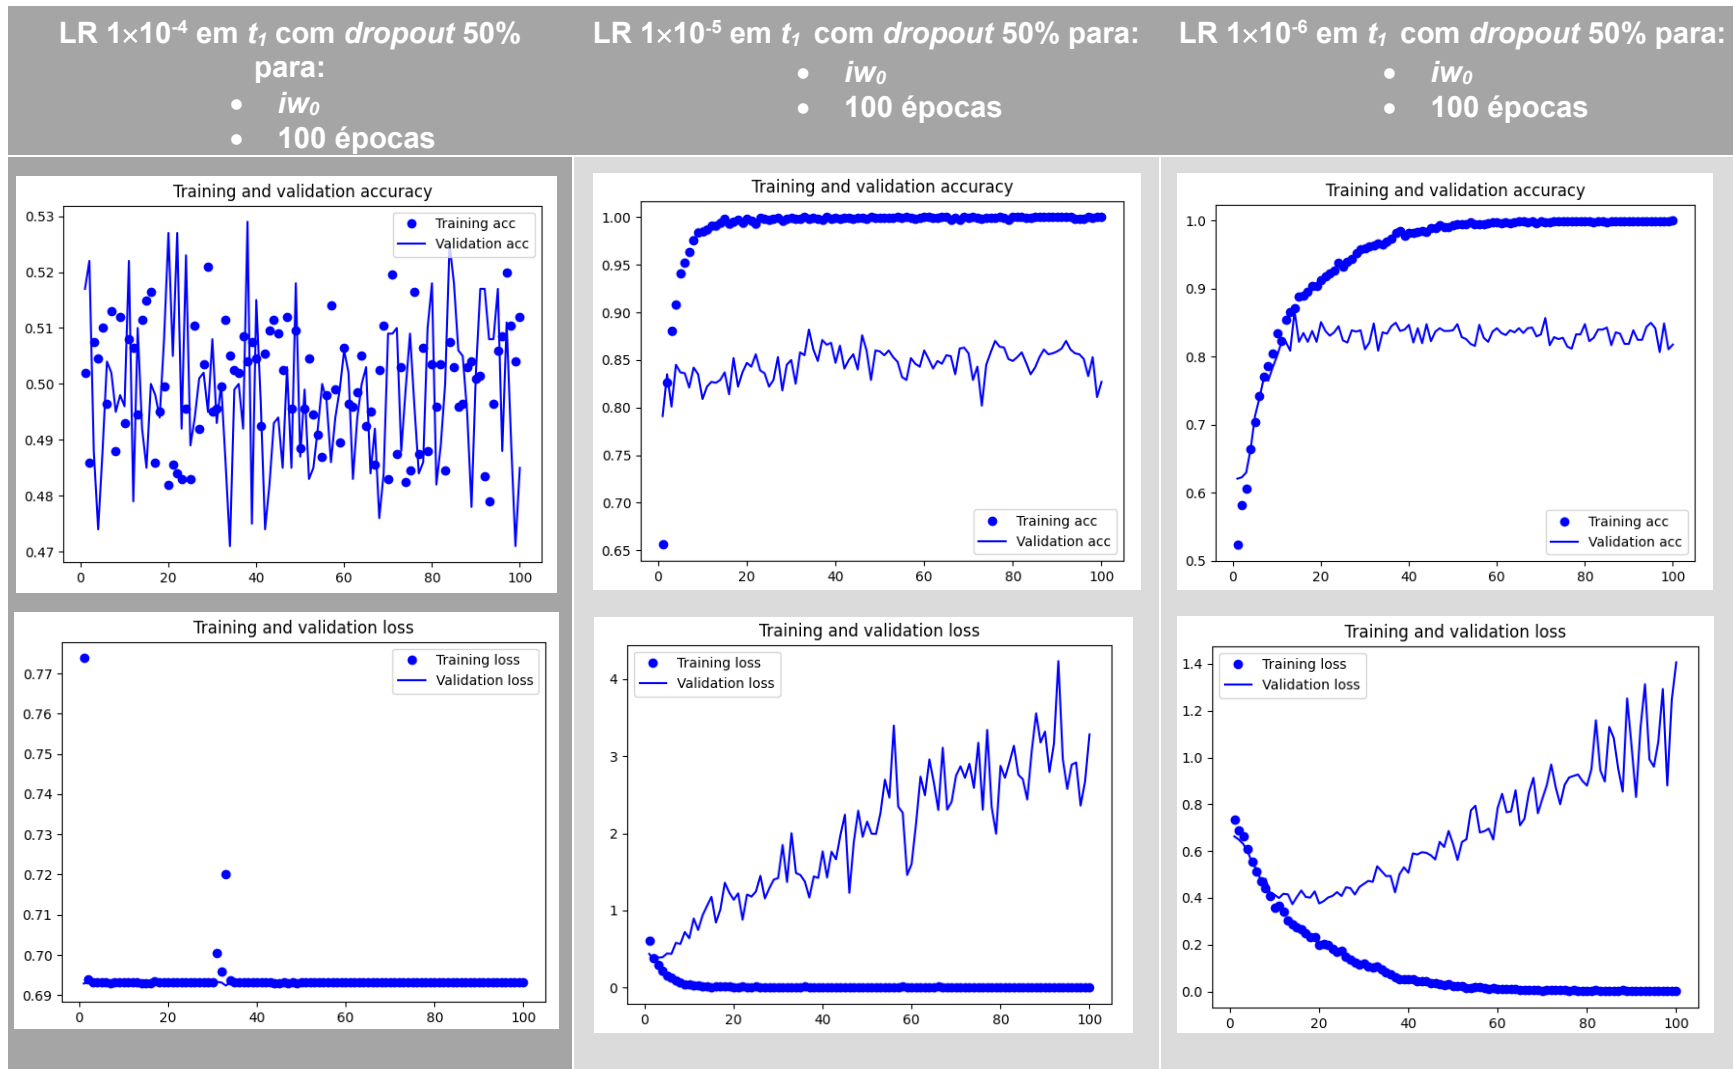


Tabela 6.29: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 , sem *dropout* e t_0 , ao longo de 100 épocas numa rede VGG19.

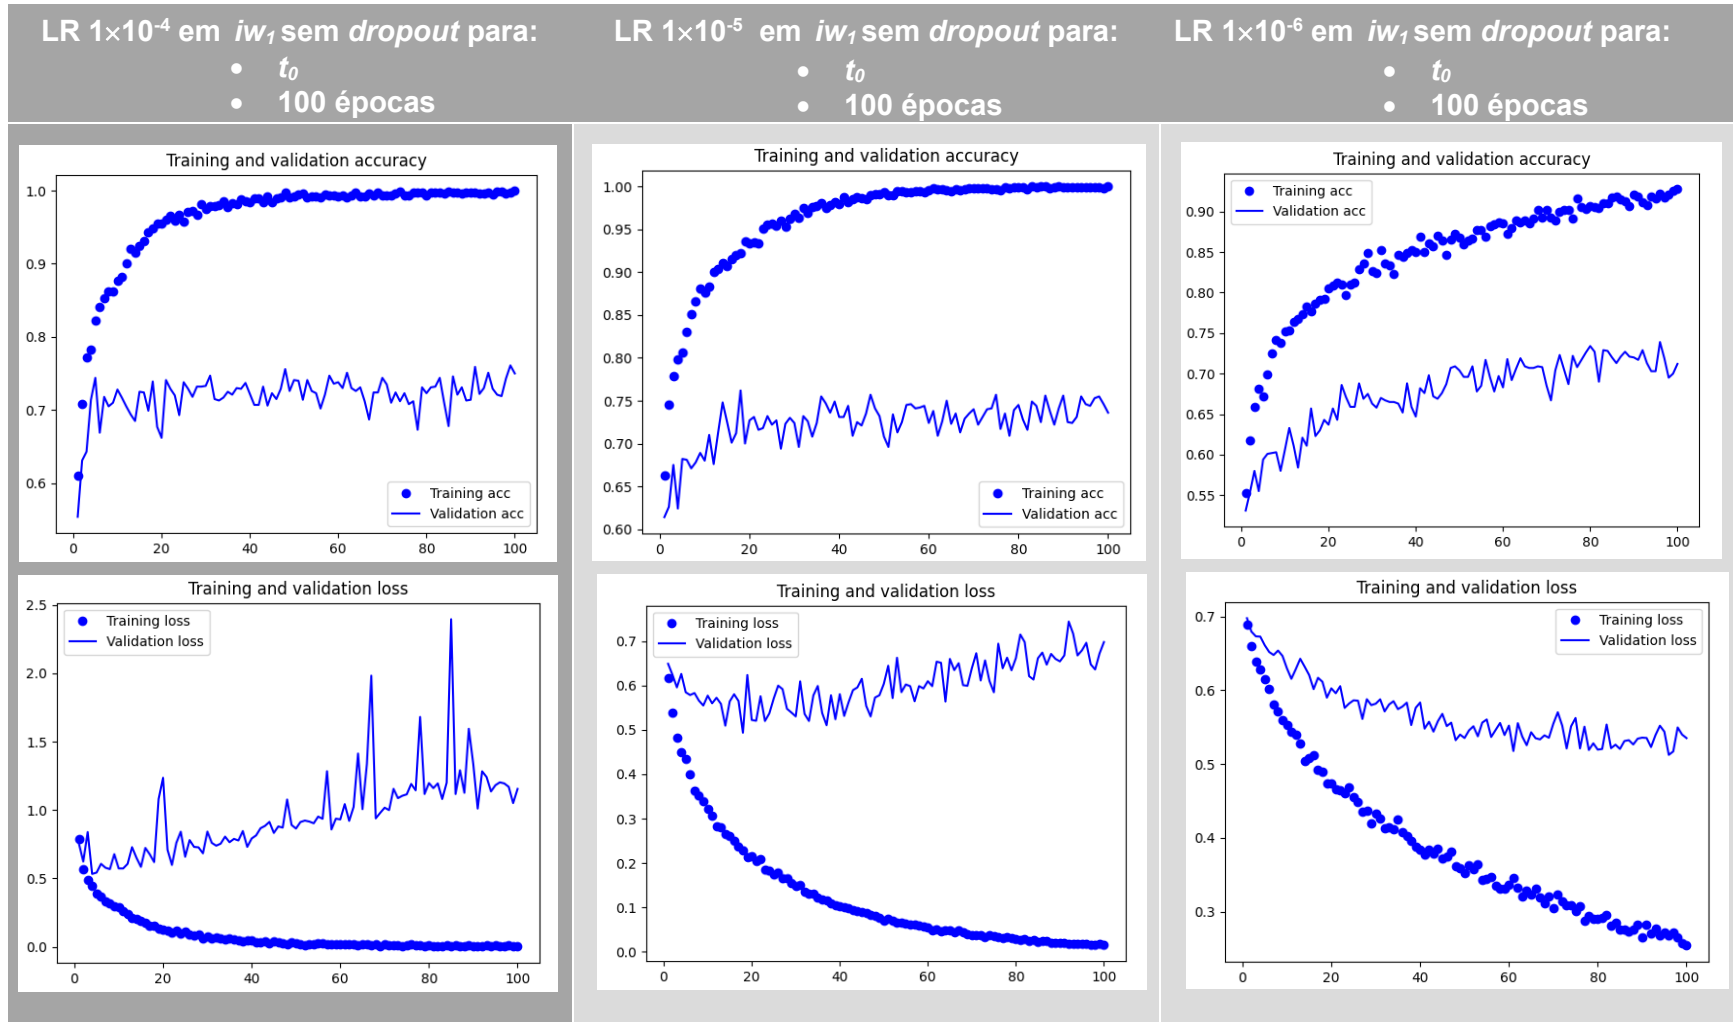


Tabela 6.30: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e **dropout de 30%**, para t_0 , ao longo de 100 épocas em rede VGG19.

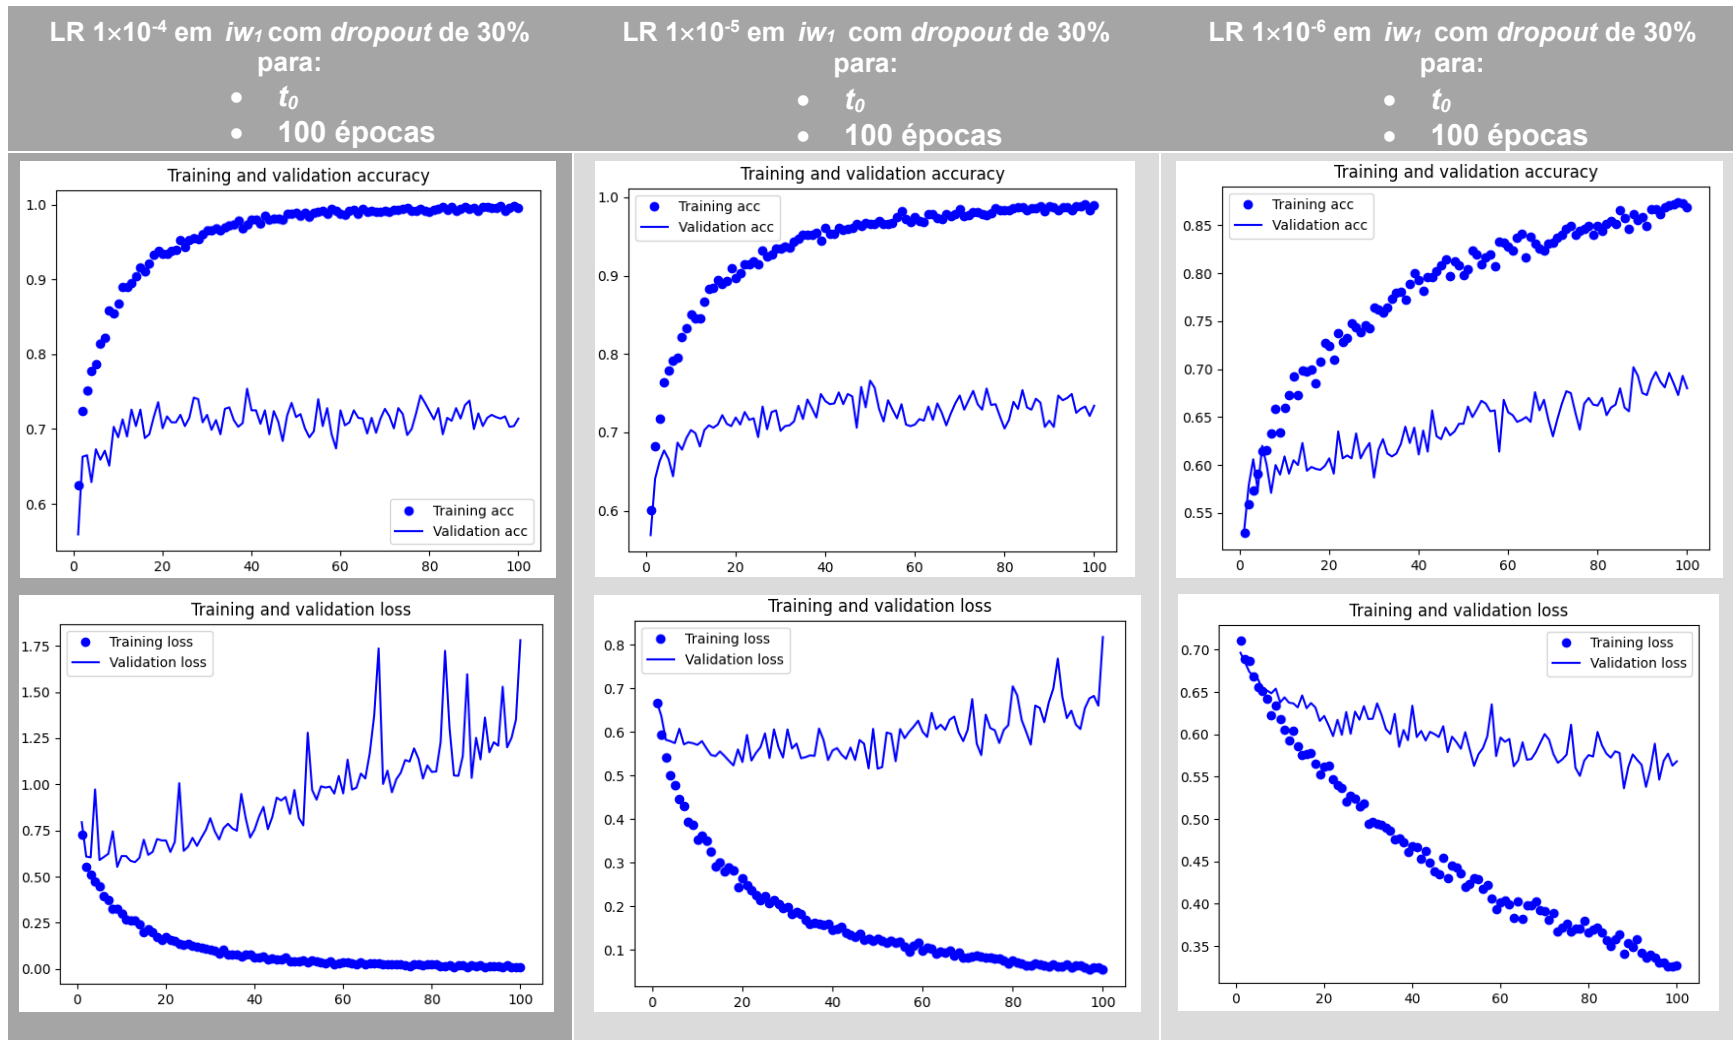


Tabela 6.31: Análise do LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e **dropout de 50%**, para t_0 , ao longo de 100 épocas, numa rede VGG19.

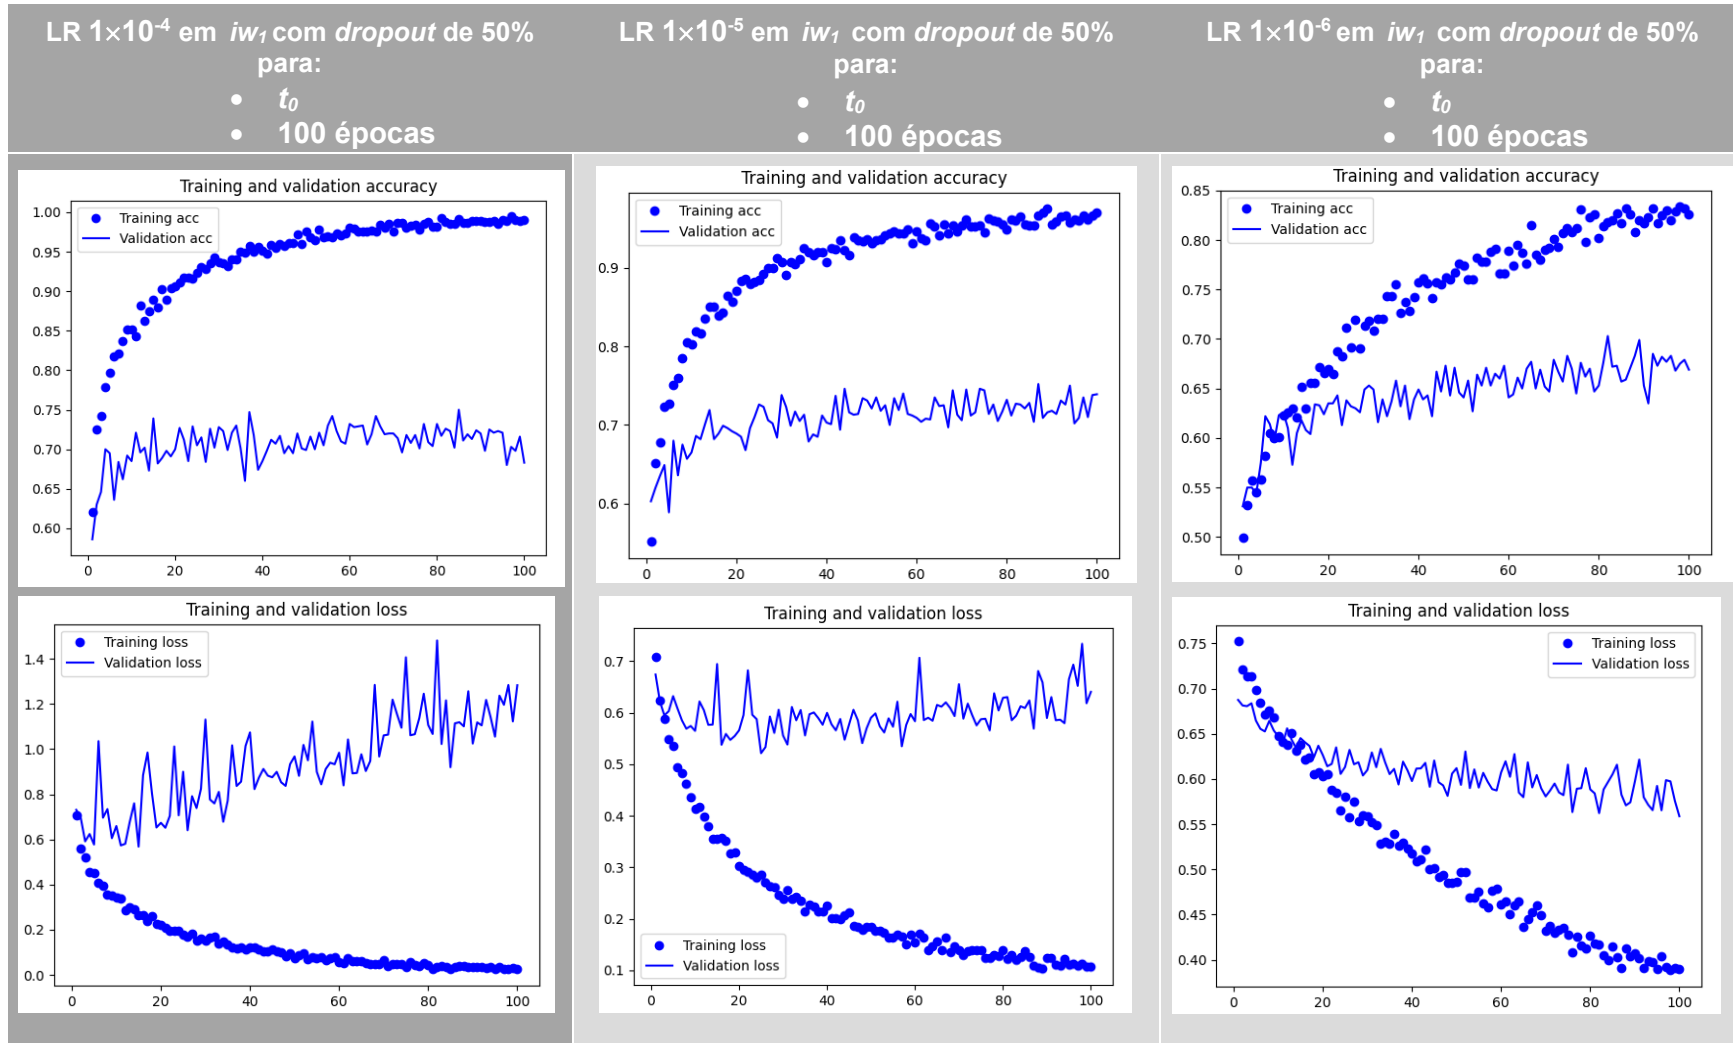


Tabela 6.32: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , sem dropout, ao longo de 100 épocas, em rede VGG19

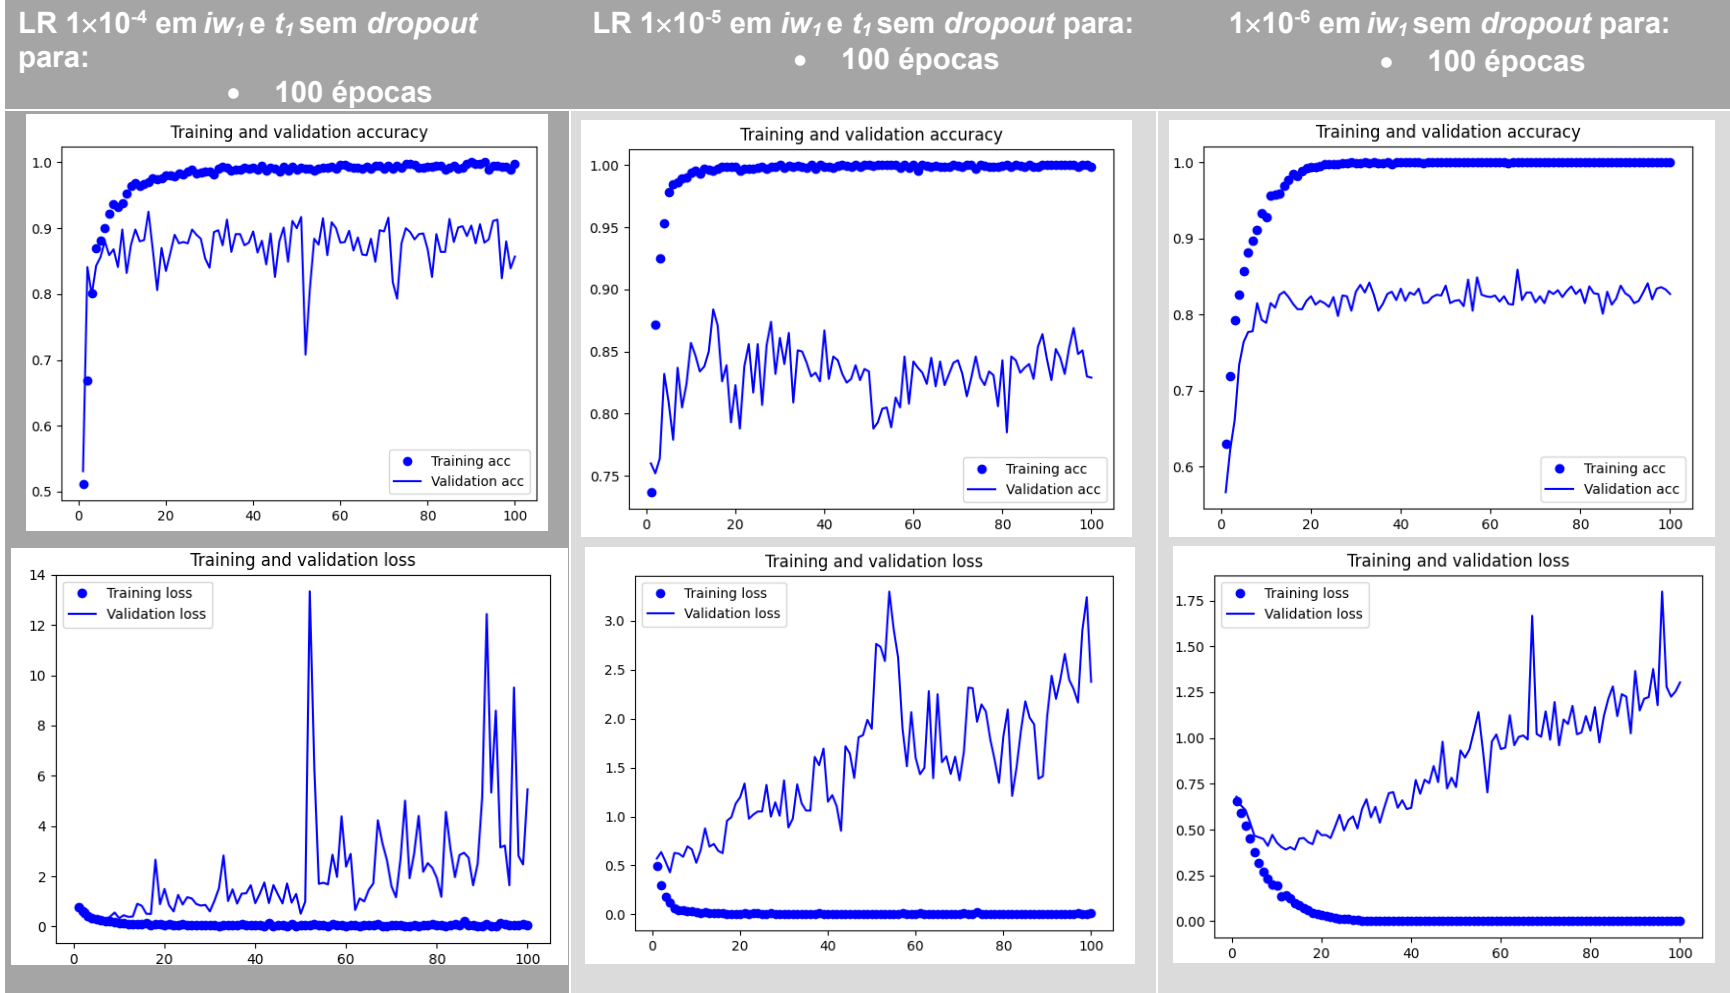


Tabela 6.33: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com **dropout de 30%** ao longo de 100 épocas, em rede VGG19.




Tabela 6.34: Estudo entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} para iw_1 e t_1 , com **dropout de 50%** ao longo de 100 épocas, em rede VGG19.

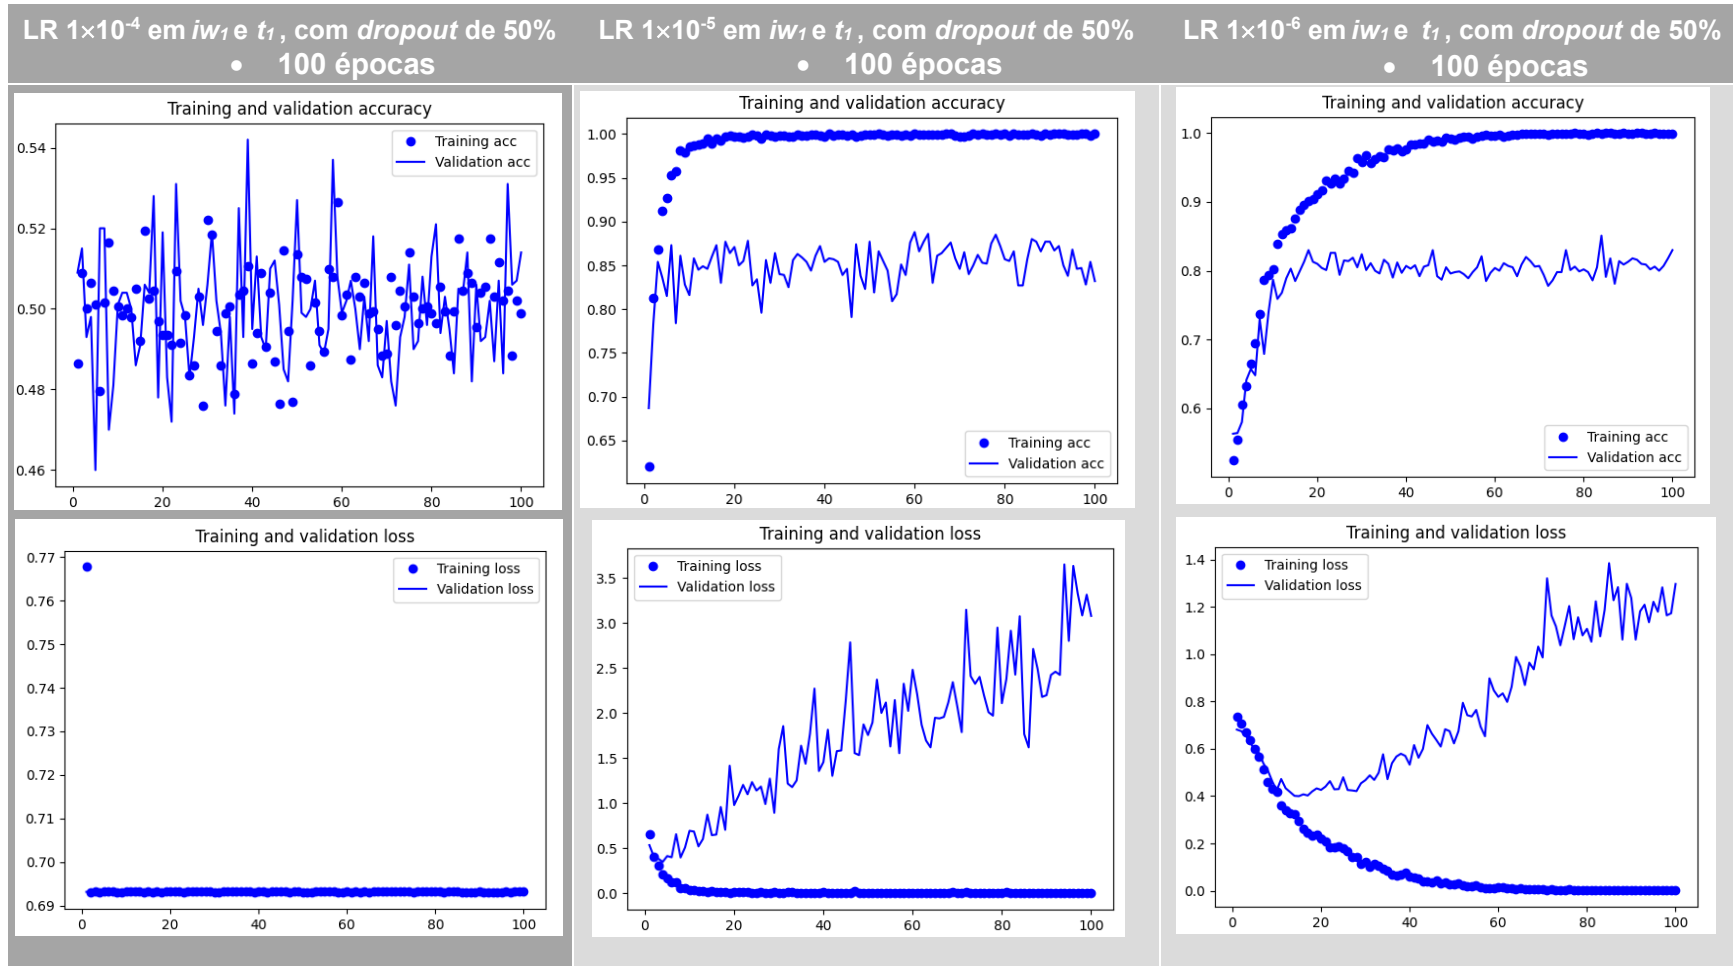


Tabela 6.35: Comparação entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de **500 épocas** e t_0 , w_0 e com diferente **dropout**, em rede VGG19.

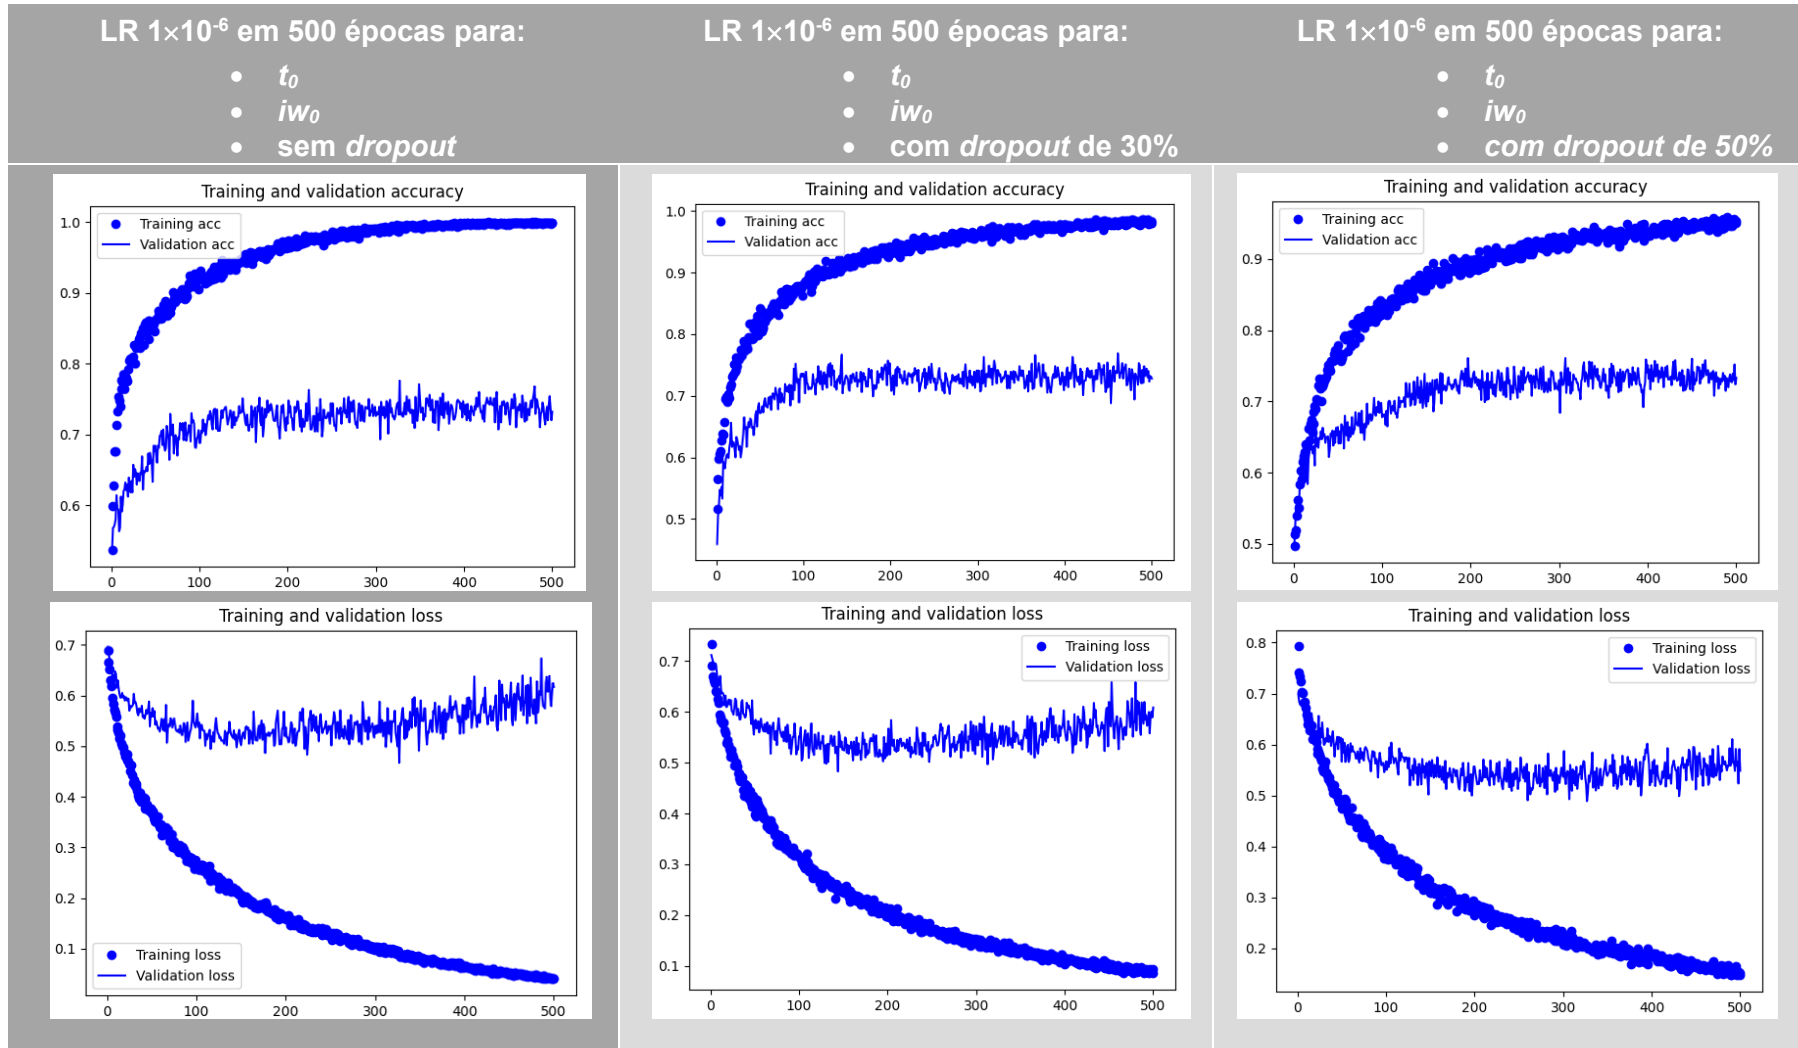


Tabela 6.36: Análise entre LR de 1×10^{-4} , de 1×10^{-5} e de 1×10^{-6} ao longo de **500 épocas** e t_1 , w_0 e com diferente **dropout**, em rede VGG19.




Tabela 6.37: Comparação entre LR de 1×10^{-6} ao longo de **500 épocas** e w_1 , t_0 e com diferente **dropout**.

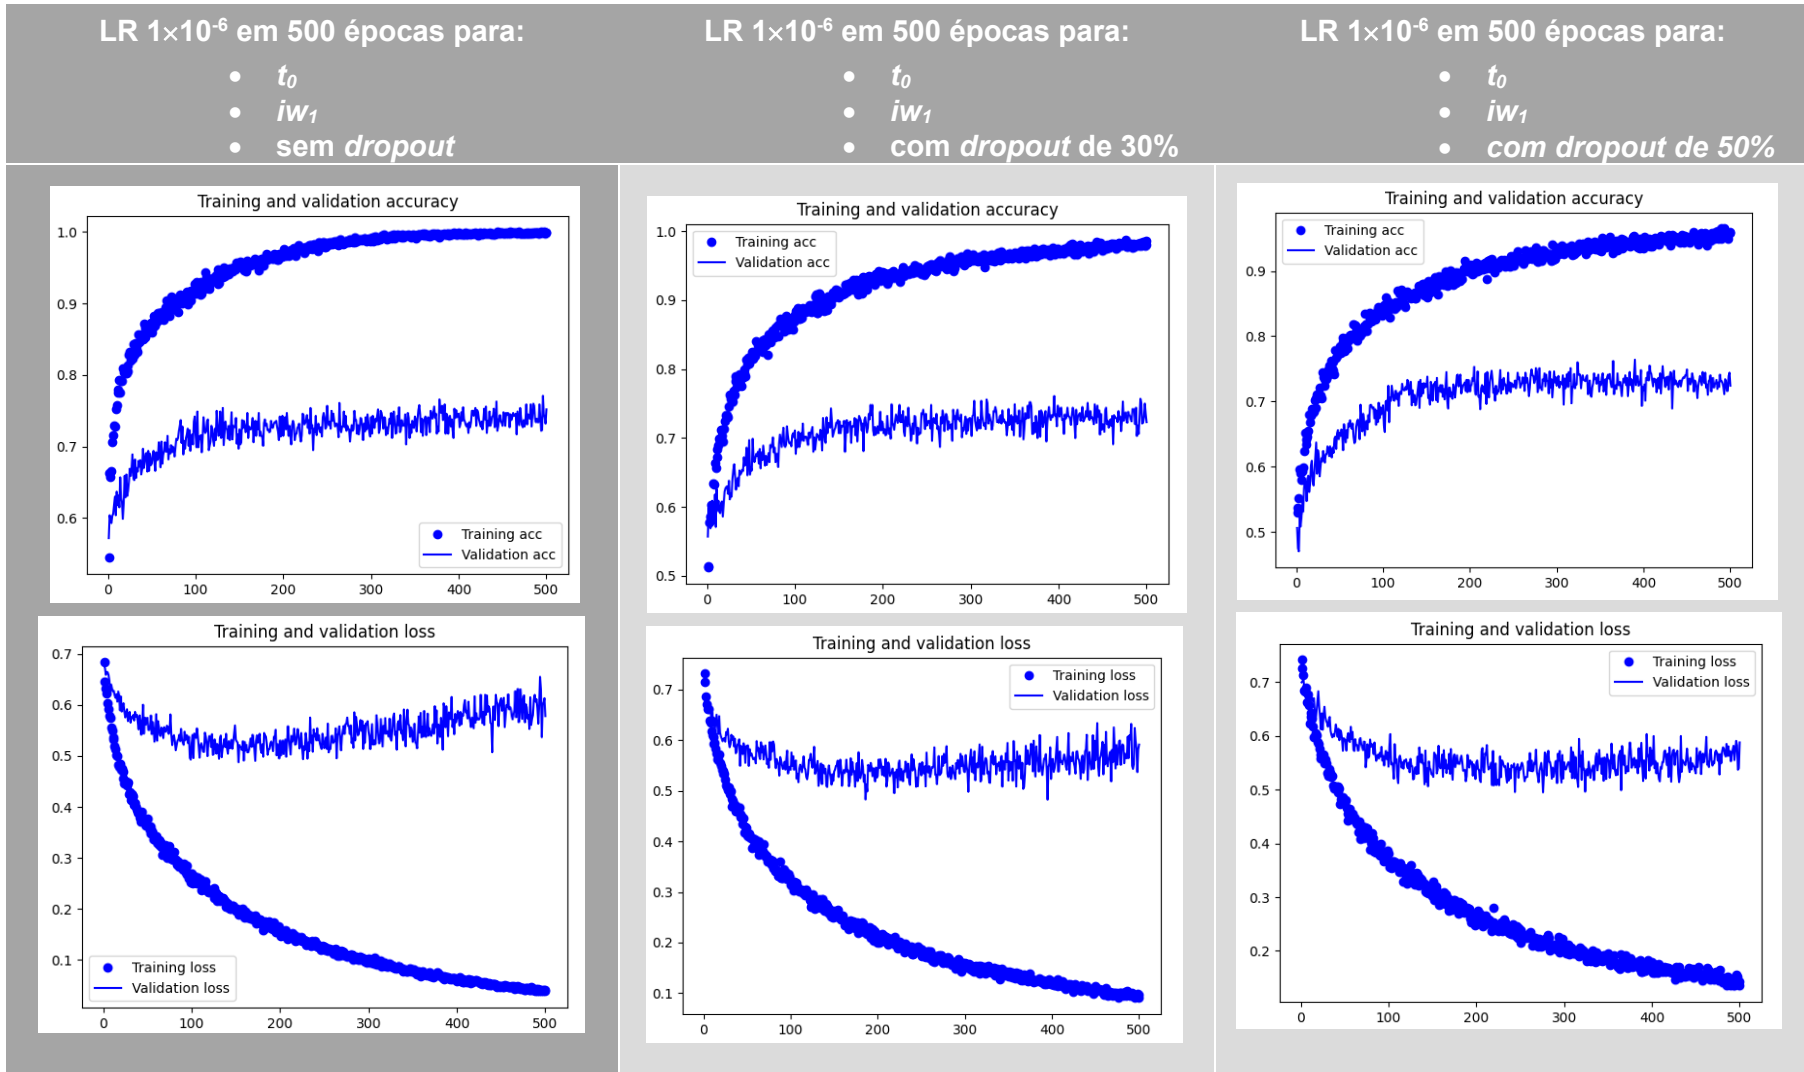
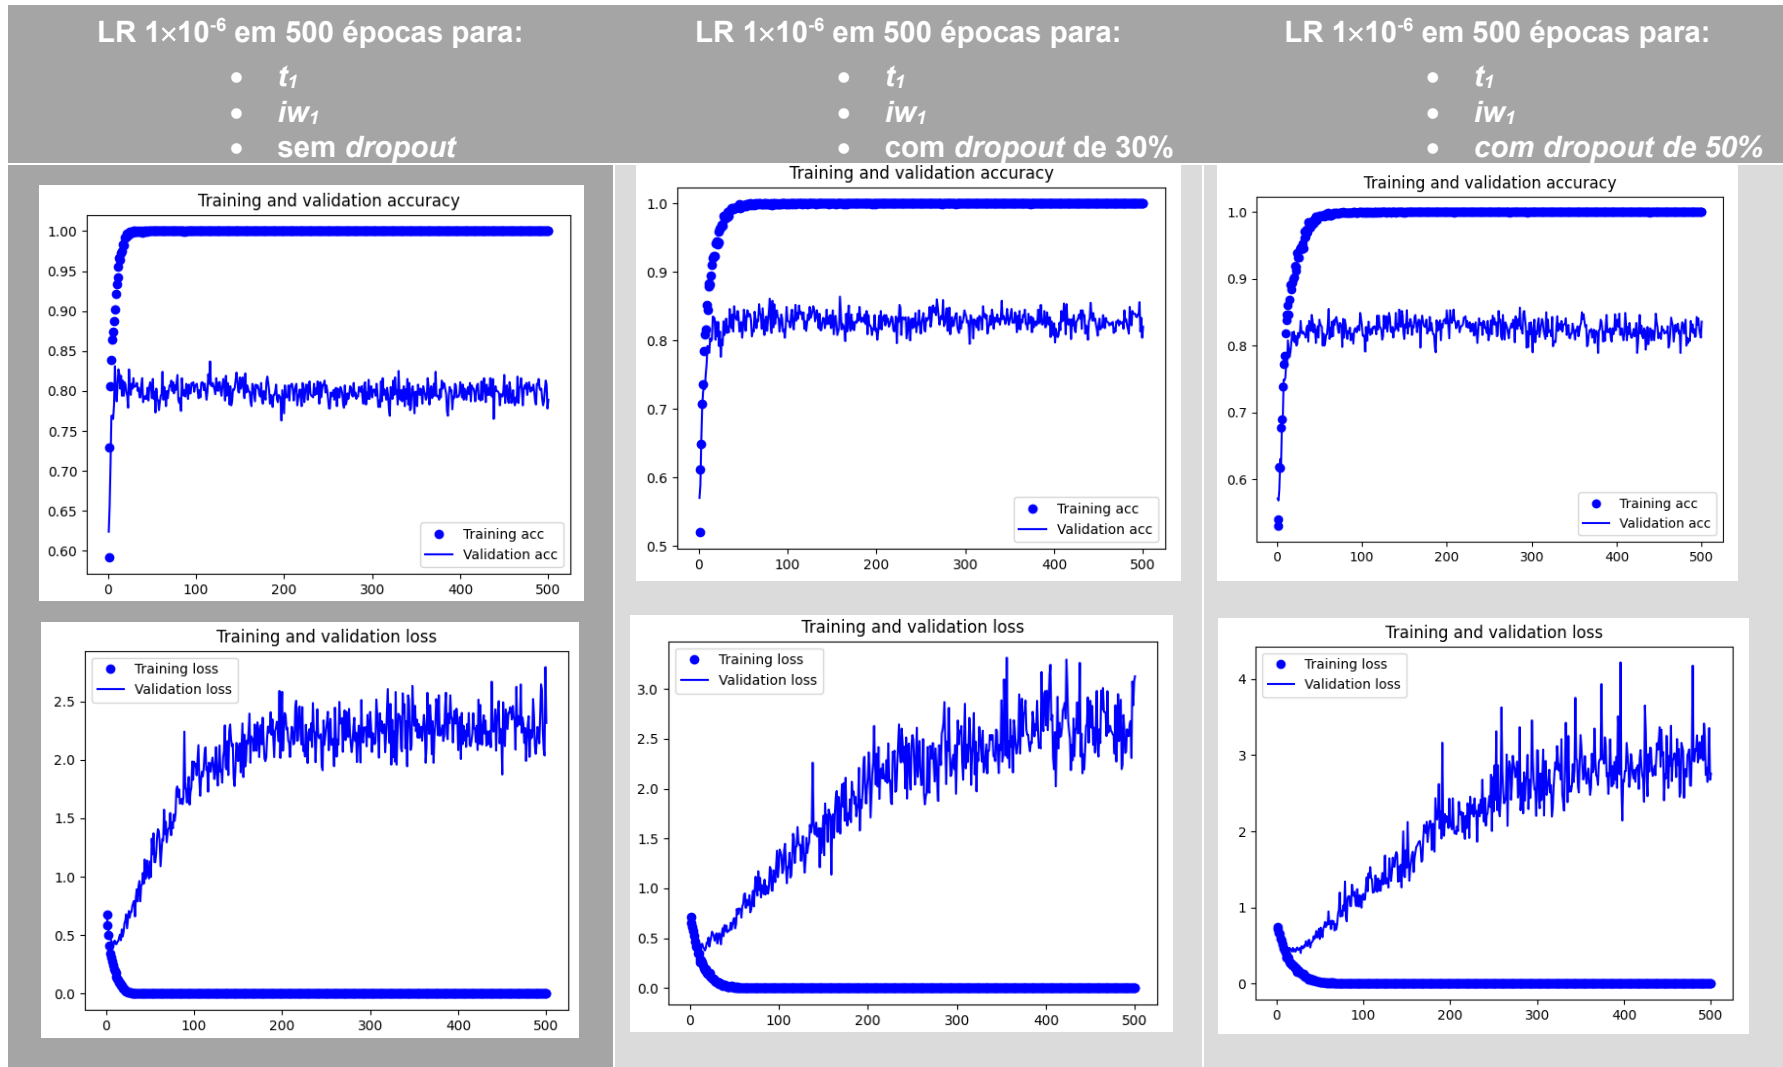


Tabela 6.38: Comparação entre LR de 1×10^{-6} ao longo de **500 épocas** e w_1 , t_1 e com diferente **dropout**.



ANEXO IV – SÍNTESE DE RESULTADOS DA REDE VGG19

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_0 • sem <i>dropout</i> • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,75%	0	< 1,4
LR de 1×10^{-5}	1	0,75	0	> 0,7
LR de 1×10^{-6}	0,95	0,75	< 0,3	> 0,5

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_0 • <i>dropout</i> de 30% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,8	0	1,25
LR de 1×10^{-5}	1	0,8	< 0,10	> 0,60
LR de 1×10^{-6}	0,9	~ 0,8	< 0,35	0,55

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_0 • <i>dropout</i> de 50% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	< 0,75	0	< 1,75
LR de 1×10^{-5}	> 0,9	> 0,7	< 0,1	< 0,70
LR de 1×10^{-6}	> 0,85	> 0,7	< 0,4	> 0,60

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_0 • sem <i>dropout</i> • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,9	0	7
LR de 1×10^{-5}	1	> 0,85	0	< 3
LR de 1×10^{-6}	1	> 0,85	0	< 1,75

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_0 • <i>dropout</i> de 30% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	Sem leitura	Sem leitura	Sem leitura	Sem leitura
LR de 1×10^{-5}	1	~ 0,9	0	> 2,5
LR de 1×10^{-6}	1	~ 0,85	0	> 1

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_0 • <i>dropout</i> de 50% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	Sem leitura	Sem leitura	Sem leitura	Sem leitura
LR de 1×10^{-5}	1	> 0,85	0	> 3
LR de 1×10^{-6}	1	> 0,85	0	> 1,4

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_1 • sem <i>dropout</i> • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,7	0	> 1
LR de 1×10^{-5}	1	> 0,75	0	> 0,7
LR de 1×10^{-6}	> 0,9	> 0,7	< 0,3	< 0,6

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_1 • <i>dropout</i> de 30% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,7	0	> 1,75
LR de 1×10^{-5}	1	> 0,7	< 0,1	> 0,80
LR de 1×10^{-6}	> 0,85	> 0,7	< 0,3	> 0,55

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_0 • iw_1 • <i>dropout</i> de 50% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	0,75	0	> 1,20
LR de 1×10^{-5}	> 0,9	> 0,7	< 0,1	> 0,60
LR de 1×10^{-6}	> 0,85	0,7	< 0,4	> 0,55

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_1 • sem <i>dropout</i> • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	1	> 0,9	0	> 4
LR de 1×10^{-5}	1	> 0,85	0	~2,5
LR de 1×10^{-6}	1	> 0,8	0	> 1,25

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_1 • <i>dropout</i> de 30% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	Sem leitura	Sem leitura	Sem leitura	Sem leitura
LR de 1×10^{-5}	1	~ 0,85	0	> 2,5
LR de 1×10^{-6}	1	> 0,8	0	> 0,8

Caraterísticas da Rede: <ul style="list-style-type: none"> • t_1 • iw_1 • <i>dropout</i> de 50% • 100 épocas 	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
LR de 1×10^{-4}	Sem leitura	Sem leitura	Sem leitura	Sem leitura
LR de 1×10^{-5}	1	> 0,85	0	> 3
LR de 1×10^{-6}	1	> 0,8	0	> 1,2

Caraterísticas da rede: <ul style="list-style-type: none"> • t_0 • iW_0 • 500 épocas 	LR de 1×10^{-6}			
	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
sem dropout	1	> 0,8	< 0,1	> 0,5
dropout de 30%	1	> 0,8	< 0,1	~ 0,6
dropout de 50%	> 0,9	0,8	< 0,2	0,5

Caraterísticas da rede: <ul style="list-style-type: none"> • t_1 • iW_0 • 500 épocas 	LR de 1×10^{-6}			
	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
sem dropout	1	> 0,8	0	> 2,5
dropout de 30%	1	> 0,8	0	> 2,5
dropout de 50%	1	> 0,8	0	> 2,5

Caraterísticas da rede: <ul style="list-style-type: none"> • t_0 • iW_1 • 500 épocas 	LR de 1×10^{-6}			
	Accuracy		Função Loss	
	Treino	Validação	Treino	Validação
sem dropout	1	> 0,7	0	> 0,6
dropout de 30%	1	> 0,7	< 0,1	< 0,6
dropout de 50%	> 0,9	> 0,7	< 0,2	< 0,6

Caraterísticas da rede: <ul style="list-style-type: none"> • t_1 • iW_1 • 500 épocas 	LR de 1×10^{-6}			
	<i>Accuracy</i>		Função <i>Loss</i>	
	Treino	Validação	Treino	Validação
<i>sem dropout</i>	1	> 0,8	0	> 2,5
<i>dropout de 30%</i>	1	> 0,8	0	~3
<i>dropout de 50%</i>	1	> 0,8	0	~3