

José Carlos Andrade Lopes

O Impacto da Inteligência Artificial na Qualidade de Imagem em Estudos de Joelho por Ressonância Magnética de 3 Tesla

Dissertação no âmbito do Mestrado em Imagem Médica e Radioterapia orientada pelo Professor Doutor Óscar Manuel da Conceição Tavares, pelo Professor Tiago da Costa Cabrita e pelo Professor Rui Miguel da Silva Castro Pereira e apresentada à Escola Superior de Tecnologia da Saúde do Politécnico de Coimbra para obtenção do grau de Mestre.

Março de 2026

José Carlos Andrade Lopes

O Impacto da Inteligência Artificial na Qualidade de Imagem em Estudos de Joelho por Ressonância Magnética de 3 Tesla

Dissertação no âmbito do Mestrado em Imagem Médica e Radioterapia orientada pelo Professor Doutor Óscar Manuel da Conceição Tavares, pelo Professor Tiago da Costa Cabrita e pelo Professor Rui Miguel da Silva Castro Pereira e apresentada à Escola Superior de Tecnologia da Saúde do Politécnico de Coimbra para obtenção do grau de Mestre.

Março de 2026

Agradecimentos

A realização desta dissertação representa o final de um percurso exigente, que não teria sido possível sem o contributo e apoio de diversas pessoas e instituições.

Expresso o meu profundo agradecimento aos meus orientadores, pela disponibilidade, orientação e rigor demonstrado ao longo de todo o processo. O acompanhamento desde o início foi fundamental para a progressão e conclusão, elevando a qualidade desta dissertação.

Dirijo o meu agradecimento à Clínica Joaquim Chaves, Miraflores, pela disponibilidade, colaboração e condições proporcionadas para a realização da componente prática desta dissertação. A todos os profissionais e participantes envolvidos neste estudo que tiveram um papel fulcral para a obtenção dos resultados apresentados, o meu obrigado.

Ao meu orientador Professor Tiago Cabrita, manifesto um agradecimento especial pela sua paciência, dedicação e constante disponibilidade. O seu apoio foi essencial para a orientação científica, mas também, na articulação com a instituição onde decorreu a recolha de dados, contribuindo assim de forma determinante para o sucesso deste estudo.

Ao meu orientador Professor Rui Pereira, agradeço de igual forma toda a disponibilidade demonstrada desde o início deste percurso, pelo apoio e contributo prestado para a conclusão do mesmo.

À minha família e à minha namorada Alexandra, deixo um agradecimento especial por toda a paciência, compreensão e incentivo ao longo do percurso. Foram e são, um pilar essencial nos momentos de maior exigência.

Aos meus amigos, agradeço todo o apoio, motivação e qualquer contributo prestado para a concretização deste trabalho, em especial à Letícia.

Por fim, a todos os que não estão aqui mencionados, mas que de alguma forma contribuíram para a realização desta dissertação, deixo o meu sincero obrigado.

Resumo

A ressonância magnética constitui uma modalidade imagiológica fundamental no diagnóstico, particularmente na área músculo-esquelética devido à ausência de radiação ionizante e à sua elevada resolução de contraste. Todavia os tempos de aquisição de ressonância magnética são prolongados e representam uma limitação relevante podendo comprometer o conforto do doente e aumentar a suscetibilidade a artefactos de movimento. O aparecimento da inteligência artificial, nomeadamente os algoritmos baseados em *deep learning* como o Deep Resolve Boost®, surgem como uma solução para acelerar a aquisição, mantendo ou melhorando a qualidade de imagem, mas necessitam de validação com estudos em contextos clínicos.

O presente estudo teve como objetivo avaliar o impacto de algoritmos de inteligência artificial na qualidade de imagem em exames de ressonância magnética de joelho em equipamentos de 3 Tesla. Desenvolveu-se um estudo prospetivo, observacional e comparativo dividido em duas fases: fase experimental, onde foi utilizado um fantoma, e a fase clínica observacional que envolveu 40 participantes. Na fase experimental avaliou-se objetivamente a relação sinal-ruído e a uniformidade da intensidade do sinal, enquanto que na fase clínica observacional, foi realizada uma avaliação objetiva e subjetiva da qualidade de imagem, recorrendo a escalas de Likert por observadores experientes.

Os resultados demonstram que a utilização do algoritmo de inteligência artificial permite reduzir o tempo de aquisição, mantendo ou melhorando a qualidade de imagem em contexto clínico. Na fase experimental, a análise objetiva verificou uma pequena redução da relação sinal-ruído e da uniformidade da intensidade de sinal comparativamente à não utilização do Deep Resolve Boost®. Contudo em contexto real clínico, a avaliação objetiva evidenciou efeito significativo do Deep Resolve Boost® na uniformidade da intensidade do sinal ($p=0,034$), mas não em tecido ósseo ($p=0,255$), enquanto o fator GRAPPA apresentou efeito significativo na uniformidade da intensidade do tecido ósseo ($p < 0,001$). Na avaliação subjetiva, a utilização do algoritmo demonstrou efeito estatisticamente significativo na definição de estruturas ($p < 0,001$), no ruído percebido ($p < 0,001$) e na qualidade global da imagem ($p < 0,001$). Estes resultados sugerem que o benefício do algoritmo foi mais evidente na perceção clínica da qualidade de imagem do que nas métricas objetivas isoladas.

Conclui-se então que o Deep Resolve Boost® representa uma ferramenta promissora em ressonância músculo-esquelética, nomeadamente no estudo do joelho em equipamentos de 3 Tesla, permitindo aquisições mais rápidas sem comprometer a qualidade de imagem diagnóstica, mas necessita sempre que esta seja implementada cuidadosamente e integrada de forma crítica na prática clínica para garantir que os ganhos tecnológicos se traduzem efetivamente em benefícios clínicos reais.

Palavras-chave: Deep Resolve Boost®; Inteligência Artificial; Qualidade de Imagem; Ressonância Magnética 3T; Tempo de aquisição.

Abstract

Magnetic resonance imaging (MRI) is a fundamental imaging modality in diagnosis, particularly in the musculoskeletal field, due to the absence of ionising radiation and its high contrast resolution. However, MRI scan times are lengthy and represent a significant limitation, which may compromise patient comfort and increase susceptibility to motion artefacts. The emergence of artificial intelligence, notably deep learning-based algorithms such as Deep Resolve Boost®, offers a solution to speed up acquisition whilst maintaining or improving image quality; however, these require validation through clinical studies.

The aim of this study was to assess the impact of artificial intelligence algorithms on image quality in MRI scans of the knee using 3 Tesla scanners. A prospective, observational and comparative study was conducted, divided into two phases: an experimental phase, in which a phantom was used, and an observational clinical phase involving 40 participants. In the experimental phase, the signal-to-noise ratio and signal intensity uniformity were objectively assessed, whilst in the observational clinical phase, an objective and subjective evaluation of image quality was carried out using Likert scales by experienced observers.

The results demonstrate that the use of the artificial intelligence algorithm reduces acquisition time whilst maintaining or improving image quality in a clinical setting. In the experimental phase, the objective analysis revealed a slight reduction in the signal-to-noise ratio and signal intensity uniformity compared with not using Deep Resolve Boost®. However, in a real-world clinical setting, the objective assessment revealed a significant effect of Deep Resolve Boost® on signal intensity uniformity ($p=0.034$), but not on bone tissue ($p=0.255$), whilst the GRAPPA factor showed a significant effect on signal intensity uniformity in bone tissue ($p < 0.001$). In the subjective assessment, the use of the algorithm demonstrated a statistically significant effect on structural definition ($p < 0.001$), perceived noise ($p < 0.001$) and overall image quality ($p < 0.001$). These results suggest that the benefit of the algorithm was more evident in the clinical perception of image quality than in the objective metrics alone.

It can therefore be concluded that Deep Resolve Boost® represents a promising tool in musculoskeletal MRI, particularly in knee imaging using 3 Tesla scanners, enabling faster acquisitions without compromising diagnostic image quality, but it must always be carefully

implemented and critically integrated into clinical practice to ensure that technological advances are effectively translated into real clinical benefits.

Key Words: Acquisition Time; Artificial Intelligence; Deep Resolve Boost®; Image Quality; Magnetic Resonance Imaging.

Lista de Siglas

DL - *Deep Learning*

DRB - *Deep Resolve Boost*

DP – Densidade Protónica

FS – *Fat Saturation*

FOV - *Field of view*

GRAPPA - *Generalized Autocalibrating Partially Parallel Acquisition*

IA – Inteligência Artificial

mSENSE - *Modified Sensitivity Encoding*

NEX - Número de excitações

PIU - *Percent Image Uniformity*

RCR – Relação contraste-ruído

RF - Radiofrequência

RM – Ressonância Magnética

ROI - *Region of interes*

RSR - Relação sinal-ruído

SENSE – *Sensitivity Encoding*

TE - Tempo de eco

TI - Tempo de inversão

TR - Tempo de repetição

Índice de figuras

Figura 2.1. Membro inferior. Representação da anatomia do joelho.....	5
Figura 2.2. Representação anatômica da articulação do joelho, evidenciando as suas principais estruturas.....	6
Figura 2.3. Representação anatômica dos músculos da coxa e região do joelho, em vista anterior (esquerda) e posterior (direita).....	8
Figura 2.4. Representação anatômica dos músculos da perna.	9
Figura 2.5. Momento magnético do núcleo de hidrogênio.....	10
Figura 2.6. Alinhamento dos núcleos de hidrogênio.....	11
Figura 2.7. Movimento de precessão.....	12
Figura 2.8. Alinhamento do campo na presença de um campo magnético.....	13
Figura 2.9. Ângulo de inclinação (flip angle).....	13
Figura 2.10. Magnetização longitudinal e transversal.....	14
Figura 2.11. Os gradientes Y e Z como seletores de cortes.....	15
Figura 2.12. Representação do espaço k.	16
Figura 2.13. Espaço - relação entre RSR e Resolução Espacial.....	17
Figura 2.14. Ilustração de conceitos de Machine Learning, Deep Learning e redes neurais convolucionais.....	23
Figura 3.15. Demonstração da aquisição de imagem em fantoma.....	31
Figura 3.16. Imagem representativa da realização do procedimento para cálculo da RSR.....	32
Figura 3.17. Imagem representativa da realização do procedimento para cálculo do PIU.....	33
Figura 3.18. Exemplo do procedimento efetuado em cada joelho.....	34

Índice de tabelas

Tabela 3.1. Tabela demonstrativa das Escalas de Likert utilizadas.....	29
Tabela 3.2. Protocolo com os parâmetros utilizados para aquisição de imagens.....	29
Tabela 3.3. Tempos de aquisição da sequência de RM do joelho com diferentes fatores de aceleração GRAPPA, com e sem DRB.....	30
Tabela 4.4. Avaliação em fantoma da RSR.....	38
Tabela 4.5. Avaliação em fantoma da Uniformidade da Intensidade do Sinal.....	39
Tabela 4.6. Avaliação de Artefactos em fantoma.....	40
Tabela 4.7. Média das ROI's no osso.....	42
Tabela 4.8. Resultados da ANOVA de medidas repetidas para a uniformidade da intensidade de sinal no tecido ósseo.....	42
Tabela 4.9. Comparações múltiplas para o fator GRAPPA.....	43
Tabela 4.10. Médias dos ROI no músculo.....	44
Tabela 4.11. Resultados da ANOVA de medidas repetidas para a uniformidade da intensidade de sinal no músculo.....	45
Tabela 4.12. Média das ROI's do tecido mole.....	46
Tabela 4.13. Comparação da média de artefactos de cada leitor.....	47
Tabela 4.14. Resultados da ANOVA de medidas repetidas para a percepção de artefactos.....	47
Tabela 4.15. Comparação da média de definição de estruturas.....	48
Tabela 4.16. Resultado da ANOVA de medidas repetidas para a definição de estruturas.....	49
Tabela 4.17. Comparação da média de ruído percebido.....	50
Tabela 4.18. Resultado da ANOVA de medidas repetidas para o ruído percebido.....	51
Tabela 4.19. Comparação da média para a qualidade global da imagem.....	52
Tabela 4.20. Resultado da ANOVA de medidas repetidas para a qualidade global da imagem.....	53

Índice de equações

Equação 1 - Equação de Larmor.....	12
Equação 2 - Cálculo do Desvio Padrão Combinado.....	31
Equação 3 - Cálculo da Relação Sinal-Ruído (RSR) segundo o método ACR.....	32
Equação 4 - Cálculo da Percentagem da uniformidade da intensidade do sinal (Percent Image Uniformity - PIU).....	33

Índice

CAPÍTULO 1 - INTRODUÇÃO	1
1.1. PERTINÊNCIA DO TEMA	2
1.2. OBJETIVOS.....	2
1.3. QUESTÕES DE INVESTIGAÇÃO	3
1.4. ORGANIZAÇÃO DA DISSERTAÇÃO	3
CAPÍTULO 2 - ENQUADRAMENTO TEÓRICO.....	5
2.1 ANATOMIA DO JOELHO	5
2.1.1 Estruturas ósseas	5
2.1.2 Articulação, ligamentos e meniscos.....	6
2.1.3 Músculos do joelho e a sua vascularização.....	7
2.2 RESSONÂNCIA MAGNÉTICA.....	9
2.2.1 Princípios físicos.....	10
2.2.2 Magnetização e comportamento no campo B_0	11
2.2.3 Precessão e frequência de Larmor	11
2.2.4 Fenómeno de ressonância.....	12
2.2.5 Tempos de relaxação	14
2.2.6 Formação de imagem e codificação espacial.....	15
2.2.7 Parâmetros de aquisição e controlo de contraste.....	15
2.2.8 Espaço K.....	16
2.3 TÉCNICAS DE IMAGEM AQUISIÇÃO RÁPIDA.....	18
2.4 QUALIDADE DE IMAGEM EM RM	20
2.5 INTELIGÊNCIA ARTIFICIAL	21
2.5.1 Inteligência artificial na medicina.....	22
2.5.2 Conceitos fundamentais de inteligência artificial.....	23
2.5.3 Aplicações da IA em radiologia.....	23
2.6 DEEP RESOLVE BOOST®	24
CAPÍTULO 3 - METODOLOGIA.....	27
3.1 TIPO DE ESTUDO.....	27
3.2 LOCAL E EQUIPAMENTO.....	27
3.3 AMOSTRA EM ESTUDO.....	28
3.4 RECOLHA E AQUISIÇÃO DE DADOS.....	28
3.5 CONSIDERAÇÕES ÉTICAS	30
3.6 ANÁLISE QUANTITATIVA	30
3.6.1 Relação Sinal-Ruído (RSR)	31
3.6.2 Uniformidade da intensidade do sinal.....	32

3.7 ANÁLISE QUALITATIVA.....	34
3.8 ANÁLISE ESTATÍSTICA.....	34
CAPÍTULO 4 - ANÁLISE E DISCUSSÃO DE RESULTADOS.....	37
4.1 ANÁLISE E DISCUSSÃO DE RESULTADOS DA FASE 1 – FASE EXPERIMENTAL – AVALIAÇÃO OBJETIVA.....	37
4.1.1 <i>Relação sinal-ruído (RSR)</i>	37
4.1.2 <i>Uniformidade da intensidade do sinal</i>	38
4.1.3 <i>Artefactos</i>	39
4.1.4 <i>Discussão geral da Fase experimental</i>	40
4.2 ANÁLISE E DISCUSSÃO DE RESULTADOS DA FASE 2 – FASE CLÍNICA OBSERVACIONAL – AVALIAÇÃO OBJETIVA E	
SUBJETIVA.....	41
4.2.1 <i>Avaliação objetiva</i>	41
4.2.2 <i>Avaliação subjetiva</i>	46
4.2.3 <i>Discussão geral da Fase clínica observacional</i>	53
4.3 LIMITAÇÕES DO ESTUDO.....	55
4.4 IMPLICAÇÕES CLÍNICAS.....	55
CAPÍTULO 5 - CONCLUSÃO.....	57
REFERENCIAS BIBLIOGRÁFICAS.....	59
APÊNDICES.....	65
7.1 APÊNDICE A – TABELAS DE AVALIAÇÃO PELA ESCALA LIKERT.....	65
7.2 APÊNDICE B – PARECER DA COMISSÃO DE ÉTICA.....	66
7.3 APÊNDICE C – CONSENTIMENTO INFORMADO PARTICIPANTES.....	67
7.4 APÊNDICE D - OUTPUTS TESTES ESTATÍSTICOS.....	68
7.4.1 <i>Análise leitores – Artefactos</i>	68
7.4.2 <i>Análise leitores – Definição de estruturas</i>	68
7.4.3 <i>Análise dos leitores – Ruído percebido</i>	70
7.4.4 <i>Análise dos leitores – Qualidade global</i>	71
7.4.5 <i>Osso versus GRAPPA versus DRB</i>	73
7.4.6 <i>Músculo versus GRAPPA versus DRB</i>	75
7.4.7 <i>Tecido mole versus GRAPPA versus DRB</i>	76

Esta página foi propositadamente deixada em branco.

Capítulo 1 – Introdução

A Ressonância Magnética (RM) é uma modalidade imagiológica muito relevante na área do diagnóstico, uma vez que, não recorrendo à radiação ionizante e não sendo invasiva, permite a obtenção de imagens anatómicas tridimensionais detalhadas. O tempo de aquisição elevado é uma das principais desvantagens ao adquirir estas imagens de RM de alta resolução, sendo o principal objetivo das grandes empresas que desenvolvem estes equipamentos diminuir ao máximo o tempo de aquisição, mantendo a qualidade de imagem ou até melhorar e aumentar o conforto do doente e ainda, reduzir os artefactos de movimento e aumentar o rendimento dos equipamentos (Foti & Longo, 2024).

Segundo dados da Organização para a Cooperação e Desenvolvimento Económico, ao longo das últimas décadas observou-se um crescimento significativo do número de equipamentos de RM por milhão de habitantes. Este reflete-se num aumento progressivo do número de exames de RM realizados por mil habitantes. Evidencia-se também uma maior utilização desta modalidade devido à expansão das indicações clínicas da RM e às mais recentes evoluções tecnológicas que proporcionaram uma maior procura por este meio de diagnóstico (Organisation for Economic Co-operation and Development, s.d.)

A modalidade de RM é alvo de um elevado avanço tecnológico, desde logo com o desenvolvimento de novas técnicas de aquisição. A técnica de Imagem Paralela (método de aceleração) surgiu como uma solução para reduzir os tempos de aquisição sem comprometer a resolução espacial ou a qualidade do contraste da imagem. Entre os métodos mais utilizados destaca-se o *Generalized Autocalibrating Partially Parallel Acquisition* (GRAPPA), que atua no domínio do espaço K. Este método baseia-se na diminuição do número de linhas do espaço K adquiridas, sendo adquiridas as linhas mais centrais prevendo as linhas em falta através do cálculo do coeficiente linear (Blaimer et al., 2004; Glockner et al., 2005). No entanto, estes métodos implicam ainda compromissos entre tempo, relação sinal-ruído (RSR), a qualidade de imagem, nomeadamente a presença de artefactos.

A utilização de ferramentas de Inteligência Artificial (IA) aplicadas à aquisição da imagem de RM veio potenciar a aceleração da aquisição. O *Deep Resolve Boost*® (DRB), é um algoritmo de reconstrução de imagens baseado em *Deep Learning* (DL), desenvolvido pela Siemens Healthineers®. O seu principal objetivo é aumentar significativamente a RSR, permitindo o uso de altos fatores de aceleração na aquisição. Ao contrário das técnicas convencionais (que implicam compromissos entre resolução, RSR e tempo de aquisição), o DRB consegue quebrar este “*trade-off*” clássico, mantendo ou melhorando a qualidade da imagem e reduz substancialmente os tempos de aquisição (Donners et al., 2024; Wilson, 2023).

1.1. Pertinência do tema

Considerando este contexto, a introdução da IA apresenta-se como uma hipótese para melhorar tempos de aquisição, mantendo ou melhorando a qualidade de imagem da RM, o que torna este tema alvo de interesse no âmbito da investigação científica e pertinente para a realização deste estudo.

Em paralelo, e no contexto músculo-esquelético, o joelho é das articulações mais avaliadas por RM, uma vez que é o exame de referência para avaliar lesões ligamentares, meniscais e cartilagueas. Isto deve-se sobretudo à sua elevada resolução de contraste e ao seu poder de definição de tecidos moles (Chien et al., 2020; Sneag et al., 2023).

Durante os últimos anos, tem-se verificado uma concretização elevada de exames de RM do joelho solicitados por diversas razões, como por exemplo o envelhecimento populacional e o aumento da prática desportiva que causa lesões traumáticas (Chien et al., 2020).

Relativamente à evidência científica disponível sobre o tema do presente estudo, esta é ainda é limitada. Existem estudos que mencionam RM e IA, mas maioritariamente em equipamentos de 1.5 Tesla (T) e não em 3 T. Poucos são, também, os que apresentam uma comparação entre as sequências com GRAPPA com versões melhoradas com recurso a IA, através de métodos de avaliação objetivos e por avaliação subjetiva por observadores. Justifica-se assim, por esta lacuna na literatura científica a realização do presente estudo.

Sendo realizado numa RM de 3T, o presente estudo identifica-se como essencial para a avaliação do impacto real destas tecnologias em ambientes clínicos.

1.2. Objetivos

O presente trabalho tem como objetivo geral analisar o impacto da aplicação de um algoritmo de Inteligência Artificial, o DRB, na qualidade de imagem em estudos do joelho realizados em equipamentos de Ressonância Magnética de 3 Tesla.

Para este objetivo, foram ainda formulados os seguintes objetivos específicos:

- Avaliar o impacto da utilização das sequências aceleradas com GRAPPA/DRB no tempo de aquisição de exames de RM do joelho;
- Comparar a qualidade de imagem resultante, através de avaliação subjetiva por observadores de exames realizados com e sem recurso a métodos de IA;

- Analisar comparativamente e de forma objetiva a qualidade de imagem, com base na relação sinal-ruído e a uniformidade da intensidade do sinal, de exames de RM do joelho realizados com e sem recurso a métodos de IA;

1.3. Questões de investigação

Perante os objetivos definidos no ponto anterior, foram elaboradas as seguintes questões de investigação:

- Q1: A utilização da IA pelo algoritmo DRB permite reduzir o tempo de aquisição sem comprometer a qualidade de imagem?
- Q2: Existem diferenças na qualidade de imagem comparando sequências GRAPPA com sequências com recurso a IA, nomeadamente o DRB?
- Q3: A IA melhora a RSR e a qualidade de imagem em exames de joelho por RM 3T?
- Q4: A IA influencia a presença de artefactos na imagem?

1.4. Organização da dissertação

Esta dissertação encontra-se organizada em cinco capítulos: Introdução, Enquadramento teórico, Metodologia, Análise e discussão de resultados e, por último, a conclusão, para além da bibliografia e apêndices que encerrará o documento.

Na Introdução apresenta-se o enquadramento geral do estudo, a pertinência do tema, os objetivos, as questões de investigação e a organização da dissertação.

O Enquadramento teórico aborda o estado atual dos conhecimentos e pretende expor estudos anteriores sobre o tema. Descreve a anatomia do joelho, os fundamentos de Ressonância Magnética, as técnicas de aquisição rápida, a inteligência artificial e o funcionamento do algoritmo DRB.

A Metodologia descreve o tipo de estudo, o local e equipamentos utilizados, a amostragem, os procedimentos de recolha de dados e os métodos de análise qualitativa, quantitativa e estatística.

Na secção Análise e discussão dos resultados são apresentados os dados obtidos bem como as comparações estatísticas realizadas. De seguida, a interpretação dos resultados obtidos, discutindo os mesmos com a evidência existente na literatura, finalizando com a Conclusão, sintetizando os principais resultados alcançados.

Este trabalho foi realizado segundo as normas da *American Psychological Association*, 7ª edição.

Capítulo 2 - Enquadramento teórico

Este capítulo tem como objetivo apresentar os conceitos fundamentais subjacentes ao tema em investigação e demonstrar a sua relevância. Vão ser abordados temas como a anatomia do joelho, a Ressonância Magnética e os seus princípios físicos, técnicas de imagem e aquisição rápida, qualidade de imagem em Ressonância Magnética, Inteligência Artificial e por último, o algoritmo de IA, o DRB.

2.1 Anatomia do joelho


2.1.1 Estruturas ósseas

O joelho é uma articulação do tipo sinovial, que é composto pela porção distal do fémur com os seus côndilos medial e lateral e a tróclea femoral, a tibia componente proximal, perónio componente proximal e a rótula, como evidenciado na Figura 2.1. (Costa, 2016; Netter, 2010).

A tibia oferece suporte através dos seus pratos tibiais côncavos, que sustentam os meniscos e permitem a flexão da articulação do joelho. Na superfície anterior, a tuberosidade anterior da tibia assume uma forma triangular e é essencial para a inserção do ligamento rotuliano, que na sua extremidade oposta conecta-se ao ápice da rótula (Costa, 2016; Seeley et al., 2014; Sobotta, 2006).

Figura 2.1

Membro inferior. Representação da anatomia do joelho.



Fonte: Adaptado de Sobotta atlas of human anatomy (Vol.2, p.264).

O perónio é um osso longo e tubular. Articula-se com a tíbia na sua porção proximal, através da articulação tíbio-peronial proximal e auxilia na inserção de ligamentos e tendões que ajudam a estabilizar a articulação do joelho. Estes não fazem diretamente parte da articulação (Netter, 2010).

A rótula é um osso sesamoide em que na parte superior é inserido o tendão do músculo quadríceps crural. Esta articula-se com a tróclea femoral criando uma superfície articular lisa na extremidade distal anterior do fémur e tem a função de proteger a articulação do joelho e aumentar o seu poder mecânico (Bontrager e Lampignano, 2014; Seeley et al., 2014).


2.1.2 Articulação, ligamentos e meniscos

A articulação do joelho (do tipo sinovial) é crucial para a execução eficiente de movimentos bípedes, tais como andar, correr ou saltar (Gupton et al., 2023). Esta articulação realiza a flexão e a extensão do membro, assim como uma pequena rotação. A estabilidade do joelho provém da junção dos ligamentos com os ossos, sendo estes, auxiliados pelos músculos e pela cápsula articular (Bontrager e Lampignano, 2014; Seeley et al., 2014).

Para interligar o fémur e a tíbia existem quatro importantes ligamentos que controlam o movimento do joelho. Os dois ligamentos colaterais estabilizam o joelho e denominam-se colateral medial e colateral lateral. São constituídos por fortes faixas localizadas nos dois lados do joelho e impedem os movimentos de abdução e adução do joelho. Os dois ligamentos restantes são intra-articulares e identificam-se como o cruzado anterior e o cruzado posterior. Unem-se respetivamente às restantes faces anteriores e posterior da eminência intercondiliana tibial como demonstrado na Figura 2.2 (Bontrager e Lampignano, 2014; Melquiades et al., 2020).

Figura 2.2

Representação anatómica da articulação do joelho, evidenciando as suas principais estruturas.



Fonte: Adaptado de *Articulação do joelho*, por Grupo Articulação.

Além dos mencionados anteriormente, o ligamento rotuliano, ligamento poplíteo, ligamentos coronários, ligamento transverso e ligamento menisco-femoral fazem também parte da articulação do joelho (Netter, 2010; Seeley et al., 2014).

A articulação é revestida pela cápsula articular junção de várias bandas de membranas fibrosas. Uma destas membranas é a membrana sinovial. Esta é muito importante pois reveste o interior da cápsula articular e produz um líquido sinovial que auxilia na manutenção da articulação, lubrificando-a e hidratando-a (Bontrager e Lampignano, 2014; Netter, 2010).

Por último, os meniscos, medial e lateral formados por fibrocartilagem, apresentam-se como estruturas semilunares. Ajudam no movimento dos côndilos femorais diminuindo o impacto do choque ao movimento condiliano e reduzindo o esforço sobre a articulação do joelho. Estes e a membrana sinovial produzem líquido sinovial que como mencionado anteriormente, atua na lubrificação e hidratação das articulações (Netter, 2010).


2.1.3 Músculos do joelho e a sua vascularização

No joelho estão inseridos vários músculos, parte deles são provenientes da coxa e fazem a sua inserção tendinosa no joelho, outros iniciam no joelho e constituem os músculos da perna (Netter, 2010; Drake et al., 2004).

Começamos pelo compartimento anterior da coxa (Figura 2.3), onde estão inseridos o músculo costureiro (sartório) e os quatro grandes músculos do quadríceps: reto femoral, vasto lateral, vasto intermédio e vasto medial. Estes atuam sobre a articulação da bacia e do joelho e são inervados pelo nervo femoral (Netter, 2010; Drake et al., 2004).

Figura 2.3

Representação anatômica dos músculos da coxa e região do joelho, em vista anterior (esquerda) e posterior (direita).



Fonte: Adaptado de *Sobotta Atlas of Human Anatomy* (Vol. 2, pp. 310 e 319).

Quanto ao compartimento medial da coxa, seis são os músculos que estão presentes e que atuam na articulação da bacia: o adutor longo, o adutor curto, o adutor magno, obturador externo, o pectíneo e o grácil. O músculo grácil atua tanto na articulação da bacia como na articulação do joelho e é innervado pelo nervo obturatório (Drake et al., 2004; Netter, 2010; Sobotta, 2006).

No compartimento posterior da coxa (Figura 2.3) os músculos presentes são responsáveis pela flexão da perna na articulação do joelho e estendem desde a coxa na articulação da bacia e são denominados: bicípíte femoral, semitendinoso e semimembranoso. São innervados pelo nervo isquiático (Drake et al., 2004; Netter, 2010).

Relativamente à perna (Figura 2.4) encontram-se vários músculos que estabelecem relação direta com a articulação do joelho e desempenham um papel relevante na sua mobilidade e estabilidade dinâmica. Destaca-se o músculo gastrocnémio, o músculo plantar e o músculo poplíteo. Estes são innervados pelo nervo tibial (Netter, 2010).

Figura 2.4

Representação anatômica dos músculos da perna.



Fonte: Adaptado de *Sobotta Atlas of Human Anatomy* (Vol. 2, pp. 326).

Relativamente à vascularização do joelho, a vascularização arterial é realizada pelas artérias femorais, poplítea, circunflexa tibial e a circunflexa femoral enquanto a vascularização venosa é efetuada pelas veias safenas e pela veia poplítea (Drake et al., 2004; Netter, 2010; Sobotta, 2006).

2.2 Ressonância magnética

A RM é uma modalidade imagiológica não invasiva que produz imagens anatômicas tridimensionais detalhadas. É frequentemente utilizada para realizar diagnóstico de doenças e monitorizações de tratamentos (Vashistha et al, 2024).


2.2.1 Princípios físicos

A RM baseia-se nas propriedades magnéticas de determinados núcleos atômicos. Um átomo é constituído por um núcleo e rodeado pela nuvem eletrónica. O núcleo é composto por prótons (carga positiva) e neutrões (carga neutra) e a nuvem eletrónica é constituída por eletrões (carga negativa) se dispõem em orbitais (Brown & Semelka, 2003; Westbrook et al., 2011).

Para que um núcleo seja capaz de produzir sinal em RM, é necessária a presença de um spin (que se comporta como um pequeno íman), ou seja, é dependente da existência deste elemento, em que corresponde à propriedade física associada ao momento angular dos prótons e neutrões. A composição interna do núcleo e do movimento quântico dos prótons e neutrões dá origem ao spin. Um spin com número de massa ímpar (ex.: ^1H), tem a designação de núcleos ativos em RM. O hidrogénio (^1H) é o elemento crucial para RM. É constituído por apenas um próton e possui o maior momento magnético dentro dos elementos possíveis, o que quer dizer que possui uma maior sensibilidade à técnica de RM. Este é também o elemento de maior abundância no corpo humano, sendo por isso o melhor candidato para ser estudado em RM. Quando os núcleos do átomo de hidrogénio são expostos a um campo magnético externo estático, estes alinham-se de acordo com esse campo magnético, mas fazem-no segundo dois estados distintos, denominados de paralelo ou anti-paralelo, aos quais estão associados níveis de energia diferentes (Figura 2.5) (Brown & Semelka, 2003; Westbrook et al., 2011; Westbrook et al., 2013).

Figura 2.5

Momento magnético do núcleo de hidrogénio.



Fonte: Retirado de *MRI in Practice* (4ª. ed., p.4).


O ^1H comporta-se como um spin, alinhando-se com o campo magnético da RM e emite sinal forte quando excitado por ondas de radiofrequência (RF). Devido também à sua elevada relação giromagnética γ facilita a interação com campos magnéticos externos. A base física para a formação do sinal de RM passa por esta constante que determina a frequência com que o núcleo precessa quando submetido a um campo magnético externo (Brown & Semelka, 2003; Westbrook et al., 2011; Westbrook et al., 2013).

2.2.2 Magnetização e comportamento no campo B_0

Os núcleos encontram-se orientados aleatoriamente, anulando-se mutuamente na ausência de um campo magnético externo. A partir do momento em que um corpo é colocado num campo magnético estático (B_0), ocorre a tendência de um alinhamento dos spins com este mesmo campo, criando dois estados energético: paralelo (baixa energia) e antiparalelo (alta energia) (Figura 2.6). A magnetização longitudinal (M_0), orientada ao longo do eixo do campo B_0 é formada pela ligeira predominância de núcleos no estado de menor energia. A intensidade de M_0 depende de vários fatores como a intensidade do campo magnético B_0 , densidade protónica do tecido, temperatura e as propriedades intrínsecas do núcleo (Westbrook et al., 2011; Westbrook et al., 2013).

Figura 2.6

Alinhamento dos núcleos de hidrogénio.



Fonte: Adaptado de *MRI in Practice* (4ª. ed., p.4).


A razão pela qual sistemas de 3T apresentam uma maior RSR do que sistemas de 1.5T deve-se ao facto de a magnitude M_0 ser diretamente proporcional à intensidade do campo magnético. Contudo, os campos mais elevados aumentam também a suscetibilidade magnética dos tecidos e ampliam artefactos (Westbrook et al., 2011; Westbrook et al., 2013).

2.2.3 Precessão e frequência de Larmor

Os núcleos dos átomos de hidrogénio alinhados com o B_0 não permanecem estáticos. Estes núcleos giram em torno do eixo do campo, numa trajetória cónica denominando-se como precessão (Figura 2.7) (Brown & Semelka, 2003).

Figura 2.7

Movimento de precessão.



Fonte: Adaptado de *MRI at a Glance* (1. ed, p. 17).

A frequência deste movimento denominado de precessão é definida pela equação de Larmor (1):

$$\omega_0 = \gamma B_0 \quad (1),$$

Equação 1 - Equação de Larmor. Onde ω_0 corresponde à frequência de Larmor, γ representa a razão giromagnética do núcleo e B_0 é a intensidade do campo magnético estático.


Nesta equação, γ representa a constante giromagnética específica de cada núcleo. No caso do hidrogénio, $\gamma \approx 42,58 \text{ MHz/T}$, resultando numa frequência de precessão de 127,8 MHz num campo de 3T. Esta relação é fundamental, uma vez que, determina a frequência exata necessária para excitar os núcleos e produzir sinal útil, como os núcleos se comportam durante e após a excitação e a sensibilidade do sistema às homogeneidades do campo (Brown & Semelka, 2003).

2.2.4 Fenómeno de ressonância

O fenómeno de ressonância é o processo físico em que os prótons absorvem e reemitem pulsos de RF, o que acontece apenas quando é exatamente igual à frequência de Larmor. Este fenómeno é o que permite que o tecido produza sinal de RM, sendo por isso, o que está na base da formação da imagem. O pulso de RF fornece energia suficiente para retirar os núcleos do estado de mais baixa energia para o de alta energia (Figura 2.8) (Brown & Semelka, 2003; Westbrook et al., 2011).

Figura 2.8

Alinhamento do campo na presença de um campo magnético.




Fonte: Adaptado de *MRI in Practice* (4.^aed., p.9).

Os núcleos ao passarem para o estado de alta energia, precessão em fase resultando assim na formação da componente transversal de magnetização que é responsável pela indução de corrente na antena recetora através da indução eletromagnética (Lei de Faraday). A amplitude e a duração do pulso de RF influenciam a inclinação da magnetização – o *flip angle* (Figura 2.9) (Brown & Semelka, 2003; Westbrook et al., 2011).

Figura 2.9

Ângulo de inclinação (flip angle).



Fonte: Retirado de *MRI in Practice* (4.^aed., p.9).

A ressonância permite controlar quando e onde se produz a magnetização transversal e o sinal, através da seleção da frequência de RF e da combinação com gradientes, permitindo a codificação espacial e formação de imagem (Brown & Semelka, 2003; Westbrook et al., 2011).

2.2.5 Tempos de relaxação


Após ocorrer o término do pulso de RF (excitação), os núcleos regressam ao estado de equilíbrio através de dois processos, o tempo de relaxação T1 (Longitudinal) e o tempo de relaxação T2 (Transversal) (Figura 2.10) (Brown & Semelka, 2003; Westbrook et al., 2011).

O tempo de relaxação T1 mede a recuperação da componente da magnetização paralela ao campo magnético principal B_0 ao longo do eixo z. A ponderação T1 é, por definição, o tempo necessário para que a magnetização principal M_z recupere 63% do seu valor de equilíbrio após a excitação. A ponderação T1 varia consoante a composição tecidual, em tecidos gordos é curto, enquanto em tecidos ricos em água é mais longo. A ponderação T1 tende a aumentar devido à maior energia dos spins em sistemas 3T (Brown & Semelka, 2003; Westbrook et al., 2011).

Relativamente ao tempo de relaxação T2, esta mede o decaimento da componente da magnetização no plano transversal (x,y), que é o resultado da perda de fase entre os spins que estão a precessar. Comparativamente à ponderação T1, a ponderação T2, por definição, é o tempo necessário para que magnetização transversal diminua até cerca de 37 % do seu valor inicial após o pulso de excitação de 90 graus (Brown & Semelka, 2003; Westbrook et al., 2011).

Figura 2.10

Magnetização longitudinal e transversal.



Fonte: Retirado de *MRI in Practice* (4.ªed., p.15).

O tempo de relaxação T2 no geral é mais curto que o tempo de relaxação T1 e depende menos da intensidade de B_0 . Tecidos ricos em água apresentam tempos de relaxação T2 mais longo, enquanto estruturas mais densas e heterogêneas (ex. osso) apresentam tempos de relaxação T2 muito curtos. Mencionando também o tempo de relaxação T2*, que inclui a perda adicional causada por falhas de homogeneidade do campo magnético. A ponderação T2* é muito relevante em sequências


Eco Gradiente e em estudo musculoesqueléticos, onde as interfaces osso - tecidos moles geram fortes variações da suscetibilidade (Brown & Semelka, 2003; Westbrook et al., 2011).

2.2.6 Formação de imagem e codificação espacial

A formação de uma imagem depende da necessidade de localizar o sinal no espaço, o que é conseguido através da aplicação de gradientes, que modificam linearmente o campo B_0 . Estes gradientes são: o gradiente de seleção de corte (*slice selection*), o gradiente de codificação de frequência (*frequency encoding*), gradiente de codificação de fase (*phase encoding*). O primeiro gradiente mencionado define o plano anatómico excitado pelo pulso de RF. O segundo determina a posição no eixo de leitura. Por último, o terceiro distingue os sinais ao longo do eixo ortogonal (Figura 2.11) (Brown & Semelka, 2003; Westbrook et al., 2011).

Figura 2.11

Os gradientes Y e Z como seletores de cortes.



Fonte: Adaptado de *MRI at a Glance* (1. ed, p. 50).

No espaço K ocorre a aquisição dos dados, sendo este, um domínio matemático onde a informação é organizada antes da reconstrução pelo Inverso da Transformada de Fourier (Brown & Semelka, 2003; Westbrook et al., 2011).

2.2.7 Parâmetros de aquisição e controlo de contraste

A combinação do tempo de repetição (TR) (responsável pelo contraste na ponderação T1), o tempo de eco (TE) (responsável pelo contraste na ponderação T2), o tempo de inversão (TI)

(supressão seletiva em inversão-recuperação) e do *Flip angle* (essencial em Eco Gradiente) determina o contraste. Para além disso, a espessura de corte, a matriz, o *Field of view* (FOV), a largura de banda e o número de excitações (NEX) influenciam a RSR, a Relação Contraste-Ruído (RCR), a resolução espacial e o tempo de aquisição (Brown & Semelka, 2003; Westbrook et al., 2011).

O tipo de antena, a intensidade do B_0 , a largura de banda e as técnicas de aceleração influenciam a qualidade de imagem. Tem de existir sempre o compromisso entre a resolução espacial versus RSR, o tempo versus a qualidade e o conforto do paciente versus a complexidade da técnica (Brown & Semelka, 2003; Westbrook et al., 2011).


2.2.8 Espaço K

O espaço K é uma forma de representar matematicamente o sinal obtido durante uma sequência de RM. Ele funciona como um domínio onde ficam armazenadas as informações de frequência espacial, que são essenciais para a posterior reconstrução da imagem. O espaço K organiza os dados como um conjunto bidimensional ou tridimensional (aquisições 3D) de frequências espaciais descrevendo assim a variação do sinal ao longo do objeto, em vez de mostrar diretamente a anatomia (Brown & Semelka, 2003; Bushberg et al., 2012; Westbrook et al., 2011). Westbrook et al. (2011) refere que o espaço K corresponde a um mapa de frequências espaciais, por isso é fundamental compreender que não é uma imagem, mas sim a base matemática que é produzida a partir do espaço K. Cada ponto do espaço K, não contém contributos provenientes de um ponto anatómico, mas contém provenientes de todo o corte ou volume.

Durante a sequência é aplicada a integral temporal das áreas dos gradientes que determina a posição de cada ponto no espaço K. A coordenada k_x define o gradiente de codificação de frequência, já a coordenada k_y define o gradiente de codificação de fase (Figura 2.12) (Brown & Semelka, 2003; Bushberg et al., 2012; Westbrook et al., 2011).

Figura 2.12

Representação do espaço k.




Fonte: Adaptado de *MRI in Practice* (4ªed., p.67).

As frequências espaciais adquiridas são moduladas pela amplitude e pela duração destes gradientes que influenciam diretamente o contraste e a resolução da imagem. Para o aspeto final da imagem, diferentes regiões do espaço K contribuem de forma distinta. Os dados centrais do espaço K apresentam maior amplitude do sinal responsável pelo contraste e as informações de baixa frequência. Quanto às regiões periféricas representam frequências espaciais elevadas responsáveis pela definição de contornos e resolução espacial. A omissão das regiões periféricas conduz a imagens desfocadas, enquanto a supressão experimental das regiões centrais reduz drasticamente o contraste evidenciando assim a importância de cada zona (Figura 2.13) (Bushberg et al., 2012; Westbrook et al., 2011).

Figura 2.13

Espaço - relação entre RSR e Resolução Espacial.



Fonte: Adaptado de *MRI at a Glance* (1. ed, p. 55).

Consoante a sequência utilizada varia a forma que o espaço K é percorrido. Por ordem crescente do gradiente de fase, o preenchimento linear tradicional adquire linhas sucessivas de k_y . Outros métodos de aquisição permitem otimizar o contraste, tempo de exame ou sensibilidade a movimento. Por exemplo, a ordenação centrada preenche primeiro as linhas centrais, ou seja, reforça o contraste dependente de T1 ou T2* em sequências rápidas. Outro método é a segmentação do espaço K que divide a aquisição em blocos, reduzindo o tempo efetivo de cada segmento. Paralelamente, trajetórias não cartesianas (espiral, radial ou técnicas híbridas) reduzem artefactos de movimento e melhoram a eficiência de amostragem, sendo que variam simultaneamente k_x e k_y de forma contínua. O gradiente de codificação espacial controla a terceira coordenada, k_z , em aquisições

3D. Esta determina o contraste volumétrico no centro do espaço K e a resolução adicional nas faces do volume (Liang & Lauterbur, 2000; Westbrook et al., 2011).

É particularmente relevante a compreensão estrutural do espaço K para técnicas avançadas de reconstrução como aquelas que são baseadas em IA. Esta é constituída por algoritmos de DL. Muitos destes algoritmos de DL operam diretamente no espaço K. Também podem utilizar o espaço K para regularização, seja para interpolar dados ausentes, seja para reduzir ruído, para recuperar frequências de alta resolução ou melhorar a eficiência da aquisição de técnicas aceleradas. Determinadas componentes, nomeadamente na imagem músculo-esquelética, a separação natural entre contraste (centro do espaço K) e detalhe fino (periferia) é explorada seletivamente pois estruturas como a cartilagem, meniscos e ligamentos beneficiam de melhor definição espacial sem comprometer o contraste intrínseco (Hammernik et al., 2018; Knoll et al., 2020; Westbrook et al., 2011).

Existem dois requisitos fundamentais que devem ser cumpridos para garantir reconstruções fiéis, tal como a amostragem do espaço K que deve ser contínua e sem lacunas e a densidade de amostragem devem ser uniforme com incrementos constantes em k_x e k_y . Se estas condições não são satisfeitas surgem artefactos como *aliasing*, distorções de resolução ou artefactos de fase, aspetos críticos em todas as técnicas, desde a convencional até aos métodos de reconstrução acelerada ou com ajuda da IA (Bushberg et al., 2012).

2.3 Técnicas de imagem aquisição rápida

A RM tem como uma das principais vantagens a sua elevada capacidade de caracterização tecidual, o que exige elevada resolução espacial em estudos músculo-esqueléticos. Uma das principais limitações é o tempo de aquisição. Foram então desenvolvidas diversas técnicas de aceleração destacando-se as técnicas de imagem paralela que estão atualmente integradas na prática clínica (Deshmane et al., 2012; Fritz et al., 2021).

A técnica de Imagem Paralela surgiu como uma solução para reduzir os tempos de aquisição sem comprometer a resolução espacial ou a qualidade do contraste da imagem. A técnica explora a informação espacial contida nas antenas *phased-array*, permitindo substituir parcialmente a codificação espacial tradicional realizada pelos gradientes. Ao reduzir o número de linhas adquiridas no espaço K, o tempo de aquisição diminui proporcionalmente ao fator de aceleração (R). No entanto, essa redução implica sobreposição, que é corrigida por algoritmos específicos de reconstrução (Blaimer et al., 2004; Glockner et al., 2005).

As técnicas de imagem paralela utilizam antenas multicanais e exploram as diferenças de sensibilidade espacial entre os vários elementos da antena para reconstruir a imagem proveniente

dos dados subamostrados do espaço K. Uma diminuição direta do tempo de aquisição é conseguida pela redução do número de linhas de codificação de fase são adquiridas, sendo este proporcional ao fator de aceleração aplicado (Deshmane et al., 2012).

Existem várias técnicas de aquisição de imagem paralela, como o *Sensitivity Encoding* (SENSE), o GRAPPA, o *Modified SENSE* (mSENSE), o Simultaneous Acquisition of Spatial Harmonics (SMASH), entre outras. O SENSE e o mSENSE atuam no domínio da imagem e o GRAPPA e o SMASH atuam no domínio do espaço K (Deshmane et al., 2012; Yoo, 2025).

Abordando a técnica de imagem paralela GRAPPA, esta foi desenvolvida para que se reconstrua dados subamostrados diretamente no espaço K. Evita assim a necessidade de mapas de sensibilidade explícitos das antenas. De forma a explicar este método, os pontos do espaço K que não foram recolhidos pela antena, são calculados através de combinações lineares ponderadas dos dados recolhidos pelos múltiplos canais de receção (Deshmane et al., 2012; Yoo, 2025).

A densidade da informação é maior no centro do espaço K onde geralmente se adquire os coeficientes de reconstrução utilizados pelo GRAPPA e calculados a partir de dados de calibração automática. Estes coeficientes são posteriormente aplicados às regiões subamostradas, realizando assim a reconstrução das linhas do espaço K em falta, aplicando o Inverso da transformada de Fourier para obtenção da imagem final (Deshmane et al., 2012).

Perante os estudos realizados por Bauer et. al. (2007) e Fritz et al. (2021), o GRAPPA é uma técnica desenvolvida e eficaz que reduz tempo de exame, sem comprometer a qualidade de imagem em exames músculo-esqueléticos. Nestes estudos, foi possível confirmar que o uso do GRAPPA em equipamentos de 3T possibilita aquisições com alta resolução espacial, tempos de exames mais reduzidos e manutenção da RSR e a RCR clinicamente aceitáveis.

Contudo, existem também limitações associadas a utilização das técnicas de Imagem Paralela. Apresentam limitações intrínsecas que se mostram mais evidentes à medida que o fator de aceleração aumenta. Outra das limitações mais importantes é a perda de RSR. Esta é inversamente proporcional à raiz quadrada do fator de aceleração e pode comprometer a visualização de estruturas anatómicas de pequena dimensão (Deshmane et al., 2012; Fritz et al., 2021).

O aparecimento de artefactos com a utilização desta técnica é também uma limitação. Por vezes, artefactos de *aliasing* surgem devido ao número de canais da antena ser inferior ao necessário para o fator de aceleração aplicado e existe também uma possível perda de detalhe anatómico. Os efeitos atrás descritos são mais relevantes em estruturas músculo-esqueléticas, como é exemplo o joelho, uma vez que, é necessário avaliar no exame de RM estruturas como os meniscos ou ligamentos (Bauer et al., 2007; Fritz et al., 2021).

As técnicas de imagem paralela, como o GRAPPA, representam um avanço significativo para que o tempo de exame reduza. Estas apresentam ainda alguns obstáculos que necessitam de ser

ultrapassados, como obter uma adequada RSR e uma boa qualidade de imagem com esse mesmo tempo de exame reduzido, sendo por isso necessário tentar equilibrar esses fatores em protocolos que requerem elevada qualidade diagnóstica (Deshmane et al., 2012; Yoo, 2025).

Este contexto, criou-se a situação perfeita para o desenvolvimento de abordagens relacionadas com a inteligência artificial, como o caso do DRB, que é capaz de ultrapassar algumas destas limitações que são inerentes às técnicas de imagem paralela convencionais. A integração de algoritmos de IA permite compensar o ruído e preservar o detalhe anatómico em aquisições aceleradas. Assim, a combinação de técnicas de imagem paralela com algoritmos de inteligência artificial permite a redução do tempo de exame e mantendo a qualidade de imagem (Hammernik et al., 2018; Knoll et al., 2020).

2.4 Qualidade de imagem em RM

A definição de qualidade de imagem em RM é a capacidade de a imagem produzida representar de forma fidedigna as características e a anatomia dos tecidos, permitindo assim a identificação e caracterização de alterações patológicas existentes. Uma imagem de elevada qualidade deve apresentar um sinal satisfatório, contraste entre tecidos apropriado, resolução espacial adequada com o objetivo clínico e ausência de artefactos que comprometam a interpretação da imagem (American College of Radiology, 2015; Westbrook et al., 2011).

No joelho, estruturas de pequena dimensão como cartilagem, meniscos e ligamentos, exigem imagens com elevado detalhe anatómico e boa diferenciação tecidual, salientando a importância da qualidade de imagem na capacidade diagnóstica. Se as imagens adquiridas forem de qualidade insuficiente podem conduzir a erros diagnósticos, a uma diminuição da sensibilidade e especificidade do exame e ao aumento da variabilidade inter-observador (Brown & Semelka, 2003).

A avaliação da imagem em RM pode ser realizada através de métricas objetivas e de métricas subjetivas. As métricas objetivas permitem uma quantificação reprodutível e independente do observador sendo muito frequentemente utilizado em programas de controlo de qualidade e em investigações científicas (American College of Radiology, 2015; Epistatou et al., 2020)

A RSR é uma das mais importantes na avaliação da qualidade de imagem. Expressa a relação entre a intensidade do sinal proveniente de uma região de interesse e a intensidade de ruído presente na imagem. Imagens mais nítidas estão associados a valores mais elevados de RSR, com menor nível de ruído e maior capacidade de visualização de detalhes anatómicos (MRIQuestions, s.d.). É influenciada por diversos fatores técnicos como o campo magnético principal, o volume do voxel, o NEX, a largura de banda de receção e as características das antenas de RF. Comparativamente aos sistemas de 1.5T, o aumento do campo magnético para 3T, permite na teoria

um aumento da RSR embora possa ser limitado por falhas de homogeneidades do campo e aumento da suscetibilidade a artefactos (Westbrook et al., 2011).

No que concerne à uniformidade da intensidade do sinal, esta é um indicador importante do desempenho global do sistema de RM. A uniformidade corresponde à homogeneidade da intensidade do sinal ao longo da imagem. A existência de variações significativas de uniformidade podem indicar alguns problemas associados às antenas de RF ou a falhas nos sistemas de transmissão e receção (American College of Radiology, 2015). Em campos de 3T, a uniformidade tem muita relevância porque as homogeneidades do campo tendem a ser muito pronunciadas. Face à sua relevância, a homogeneidade é avaliada em fantoma para controlo de qualidade em RM (Epistatou et al., 2020).

As métricas subjetivas são baseadas na perceção visual de observadores experientes. Esta simula o processo real de interpretação diagnóstica logo reflete de forma direta a utilidade clínica da imagem (Westbrook et al., 2011). Estão sempre sujeitas a variabilidade inter e intra observador, mas são amplamente utilizadas em estudos de qualidade de imagem (Epistatou et al., 2020).

A qualidade de imagem em RM é influenciada por vários fatores. Os mais influentes são o tempo de aquisição, o tipo de antena utilizada, os parâmetros da sequência (Brown & Semelka, 2003; Westbrook et al., 2011). Antenas multicanaís e dedicadas à parte anatómica que se deseja estudar, permite melhorar a RSR e a uniformidade da intensidade do sinal, sendo importante em exames do joelho com a antena de joelho dedicada (Brown & Semelka, 2003; Westbrook et al., 2011).

Os algoritmos de reconstrução desempenham um papel fundamental na qualidade de imagem uma vez que influencia o nível de ruído, a nitidez e a presença de artefactos. A utilização dos algoritmos requer a utilização de ambas as métricas, as objetivas e as subjetivas (Epistatou et al., 2020).

2.5 Inteligência artificial

O termo Inteligência Artificial é, em 1955 por John McCarthy, definido como desenvolvedor de máquinas que se comportem como se fossem inteligentes. Este foi um dos pioneiros em IA (Ertel, 2025).

Posteriormente, segundo Elaine Rich, a IA é definida da seguinte forma: “É o estudo de como fazer com que os computadores realizem tarefas nas quais, atualmente, as pessoas são melhores”. De modo a explicar a definição de Rich, tarefas como a execução de um número elevado de cálculos num curto período de tempo é o ponto forte dos computadores digitais. Já, por exemplo,

quando um ser humano entra numa sala desconhecida reconhece o ambiente em que se encontra em milissegundos e se necessário, toma decisões e planeia ações com a mesma rapidez, enquanto para a inteligência artificial ainda é uma tarefa muito exigente (Ertel, 2025).

A IA inclui um grupo amplo de metodologias computacionais dirigidos para a resposta a problemas complexos e destaca-se a sua multidisciplinariedade e a capacidade de adaptação a diferentes contextos (Ertel, 2025).

2.5.1 Inteligência artificial na medicina

Segundo Al Kuwaiti et al. (2023), a IA transformou a área da saúde no que diz respeito aos cuidados médicos. Esta tem um impacto na deteção de condições clínicas através de imagem médica e serviços de diagnóstico, no atendimento virtual ao doente com ferramentas de IA, na gestão de registos eletrónicos da saúde e no aumento da adesão dos doentes aos tratamentos. Tudo isto evidencia um papel crescente da utilização da IA em imagem médica.

Com o avançar dos tempos e da modernização para uma era em que o digital se apresenta como um grande aliado de qualquer pessoa, a disponibilidade crescente de dados em bases de dados digitais e o aumento da capacidade computacional promoveram a integração de algoritmos de IA em múltiplas áreas na medicina (Al Kuwaiti et al., 2023).

Estudos recentes mostram que a aplicação da IA na saúde pode contribuir para diagnóstico precoces, redução de erros clínicos e melhorias na tomada de decisão por clínicos, mas esta deve ser sempre acompanhada por uma governação adequada e de validação científica rigorosa. Contudo, na comunidade científica ainda se discute algumas questões éticas referentes à sua utilização (Al Kuwaiti et al., 2023).

Focando a área da imagem médica, a IA faz cada vez mais parte de todo o processo envolvente para um exame de imagem médica. Sneag et al. (2023), destaca o caso da Radiologia Convencional, da Tomografia Computorizada e da RM, devido à sua amplamente realização, uma vez que, este tipo de exames produzem uma enorme quantidade de dados imagiológicos, cuja análise manual é muito demorada e sujeita a variabilidade inter observador. Neste contexto, a IA surge com uma ferramenta útil para a análise automática de imagens, uma vez que reconhece padrões e extrai informação clinicamente relevante.


Na Radiologia, a IA tem sido implementada em tarefas de deteção, classificação, caracterização de lesões e sobretudo na otimização de protocolos de aquisição de imagens e reconstrução de imagens. Tem demonstrado potencial e consistência diagnóstica para apoiar o médico radiologista, uma vez que esta não substitui o olho clínico humano, apenas auxilia (Al Kuwaiti et al., 2023; Recht et al., 2023).

2.5.2 Conceitos fundamentais de inteligência artificial

Quando se fala em IA, engloba-se conceitos como a *Machine Learning*, o DL e Redes Neurais Convolucionais (Figura 2.14) (Ertel, 2025).

Figura 2.14

Ilustração de conceitos de Machine Learning, Deep Learning e redes neuronais convolucionais.



Fonte: Adaptado de *Introduction to Artificial Intelligence* (3rd ed., p.286 e p.288).

O *Machine Learning* refere-se a algoritmos capazes de aprender a partir de dados já adquiridos e ajusta a sua performance sem necessidade de programação para cada tarefa explícita (Ertel, 2025).

O DL é um subcampo do *Machine Learning* e baseia-se nas redes neuronais artificiais profundas, que são descritas por múltiplas categorias de processamento. As redes são particularmente eficientes na análise de dados complexos e de elevada dimensão (Ertel, 2025).

Relativamente às Redes Neurais Convolucionais, estas representam uma arquitetura de DL principalmente desenvolvida para processar imagens. Utilizam operações de convolução para retirar atributos relevantes como os contornos ou as texturas (Ertel, 2025). Estas redes, são frequentemente utilizadas para segmentação, classificação e reconstrução de imagem devido à robustez e desempenho das mesmas em imagem médica (Al Kuwaiti et al., 2023).

2.5.3 Aplicações da IA em radiologia

Neste ponto, as aplicações da IA que têm uma utilização mais ampla em radiologia são no âmbito da deteção, classificação e caracterização de lesões, na otimização de protocolos de aquisição de imagens e na reconstrução de imagens.

Existem algoritmos capazes de identificar espontaneamente alterações patológicas em relação à anatomia considerada normal em exames de imagem. Funciona como sistema de apoio à decisão clínica e consegue classificar e caracterizar diferentes tipos de patologia e graus de desenvolvimento da patologia. Possibilita também a segmentação, delimita com precisão as estruturas anatómicas ou até mesmo as lesões e tem particular relevância para planeamento de tratamento ou para investigação clínica (Sneag et al., 2023).

A integração da IA tem impacto direto na eficiência clínica uma vez que permite reduzir tempos de aquisição e processamento, diminuindo assim as listas de espera para a realização de exames. Outro contributo dado pela IA com a utilização de algoritmos padronizados é a maior reprodutibilidade, reduzindo a variabilidade associada à interpretação humana e aos parâmetros de aquisição (Al Kuwaiti et al., 2023).

O DRB surge com a evolução da IA aplicada à RM e é uma tecnologia de reconstrução de imagem fundamentada em DL, que está integrada em sistemas clínicos de RM. Este enquadra-se numa evolução tecnológica da imagem médica, onde não substitui os princípios físicos da RM, apenas os complementa para permitir ultrapassar limitações relacionadas com o tempo de aquisição e a qualidade de imagem. A importância da avaliação desta tecnologia é essencial para compreender o seu verdadeiro valor clínico.

O DRB é uma solução de reconstrução de imagem por RM alicerçada com a inteligência artificial. Esta foi desenvolvida pela Siemens Healthineers® e integra algoritmos de DL, a partir dos dados obtidos, no processo de reconstrução da imagem. A tecnologia DRB está inserida na evolução dos sistemas de RM devido à elevada necessidade de redução de tempo de exame, mas sem comprometer a qualidade diagnóstica das imagens. É usado mais amplamente em exames de músculo-esquelético<<<<<<<<<<<<<<< (Siemens Healthineers, s.d.; Sneag et al., 2023).

Devido a atual aumento significativo do volume de exames de RM e também por exigências de eficiência e de sustentabilidade têm sido desenvolvidos mais soluções baseadas em IA e são das principais fontes de inovação tecnológica que um grande impacto na qualidade de imagem e no fluxo de trabalho clínico (Foti & Longo, 2024; Recht et al., 2023).

O DRB utiliza as Redes Neurais Convolucionais, que são amplamente instruídas com grandes conjuntos de dados de RM. Para compensar os efeitos adversos da subamostragem dos dados, o algoritmo atua de forma organizada no espaço K e na imagem reconstruída. Alguns dos efeitos adversos podem ser o aumento do ruído e a degradação na nitidez (Siemens Healthineers, s.d.).

As Redes Neurais Convolucionais aprendem relações não lineares complexas entre os dados adquiridos e a imagem final, enquanto as técnicas clássicas de reconstrução dependem essencialmente de transformadas de Fourier e de modelos lineares. Com este pretexto, as Redes Neurais Convolucionais permitem uma reconstrução de imagens com redução muito considerável de ruído, preserva os contornos anatômicos e mantém a resolução espacial mesmo em protocolos acelerados (Foti & Longo, 2024; Voshenrich et al., 2024).

O DRB pode ser utilizado com outras estratégias de aceleração como por exemplo a técnica de imagem paralela e funciona como um otimizador de qualidade final da imagem após a aquisição (Recht et al., 2023).

A literatura disponível atualmente nas bases de dados não tem um grande número de estudos envolvendo especificamente o DRB. Contudo, existe sim, um elevado número de estudos que tem no seu teor as reconstruções fundamentadas em DL em RM músculo-esquelética. Segundo Kaniewska et al. (2023) e Reschke et al. (2025), vários estudos clínicos recentes demonstram que as técnicas são capazes de reduzir substancialmente o tempo de aquisição e estão associadas a melhorias na RSR, RCR e também são mais favoráveis para os observadores experientes em RM.

Um estudo prospectivo delineado por Reschke et al. (2025), comprovou que a aplicação de reconstrução por DL em sistemas de 3T consegue melhorar ou manter a delineação de pequenas estruturas como a cartilagem, meniscos e ligamentos, podendo estar também ligada a fatores de aceleração. Estes resultados estão de acordo com as revisões recentes que reconhecem que a reconstrução baseada em IA é uma das predisposições futuras para RM músculo-esqueléticas (Recht et al., 2023; Sneag et al., 2023).

A evidência científica atual compreende ainda algumas limitações apesar de ter já demonstrado resultados promissores. Uma das principais limitações é a utilização de várias métricas e diferentes protocolos de aquisição que dificulta a comparação direta dos resultados (Foti & Longo, 2024). Existem também poucos estudos focados em RM do joelho em equipamentos de 3T. Perante a comunidade científica persistem as preocupações em relação com os possíveis efeitos de

suavização excessiva ou então de alteração de textura imagem que podem provocar um mau diagnóstico pois pode dar a entender a existência de lesões muito subtis que reforça a necessidade de validação destas novas tecnologias (Sneag et al., 2023; Vosshehrich et al., 2024).

Neste quadro, o DRB constitui um exemplo representativo da aplicação clínica da reconstrução fundamentada em IA em RM. A sua avaliação sistemática justifica-se pela exigência de quantificar objetivamente o seu impacto na qualidade de imagem e de perceber o desempenho do DRB em exames de músculo-esquelética, mais precisamente do joelho em equipamentos de 3 T com métricas reprodutíveis e avaliações subjetivas estruturadas (Recht et al., 2023).

Como a qualidade de imagem em RM depende de vários fatores como mencionado anteriormente nesta dissertação, a introdução de algoritmos de DL como o DRB representa uma mudança, permitindo aquisições mais rápidas sem comprometer e ao mesmo tempo, potenciar a qualidade diagnóstica.

Capítulo 3 - Metodologia

A metodologia descreve como foi realizado todo o trabalho de investigação, tendo como objetivo facilitar a compreensão do mesmo. Neste capítulo serão abordados os seguintes subcapítulos: tipo de estudo, local e equipamento do estudo, amostra em estudo, recolha e aquisição dos dados, análise qualitativa, análise quantitativa e, por último, a análise estatística.

3.1 Tipo de estudo

A presente dissertação corresponde a um estudo quantitativo e qualitativo, ou seja, misto, observacional, prospetivo e comparativo.

Um estudo prospetivo define-se pela metodologia ser estabelecida previamente à recolha de dados, ou seja, existe uma antecipação e planeamento das ações da investigação. Esta abordagem envolve esclarecer as ações presentes consoante o que possa acontecer no futuro, integrando fatores qualitativos e quantitativos na construção do conhecimento científico (Saragoça, 2012).

Num estudo misto são recolhidos os dois tipos de dados: qualitativos e quantitativos. Os dados qualitativos correspondem a características não numéricas que estão organizadas em categorias, podendo assumir uma escala ordinal como as utilizadas neste estudo, as escalas de Likert. Os dados quantitativos recolhidos consistem em medições numéricas, como é o caso das métricas objetivas da qualidade de imagem avaliadas, nomeadamente neste estudo a RSR e uniformidade da intensidade do sinal (Afonso & Nunes, 2019).

O presente estudo enquadra-se num estudo observacional, uma vez que não envolve manipulação de variáveis, mas limita-se apenas à análise dos dados adquiridos em contexto clínico. Creswell (2014) menciona que estes estudos incluem investigações em que o investigador observa acontecimentos sem controlo sobre as variáveis independentes.

Um dos descritores deste estudo é ser um estudo comparativo. De acordo com Creswell (2014), um estudo comparativo procede à comparação entre diferentes grupos relativamente a variáveis existentes que permitam analisar as diferenças entre os grupos. Este estudo procede à comparação entre diferentes condições de aquisição de imagem e fatores de aceleração distintos.

3.2 Local e equipamento

O presente estudo foi realizado na Clínica Joaquim Chaves Saúde de Miraflores, localizada na Alameda Fernão Lopes 17, 1495-148 em Algés. O equipamento de RM utilizado neste estudo foi

o Magnetom Vida da Siemens Healthineers de 3T, com recurso à antena de joelho “TxRx Knee 18 MR Coil 3T”. Foi também utilizado o fantoma disponibilizado no serviço pela marca do equipamento “Siemens Phantom MR”. É um equipamento com um campo de 3T, que utiliza a IA para acelerar e melhorar o desempenho do mesmo (MAGNETOM Vida – Leading the Field – Siemens Healthineers, s.d.).

Não existe qualquer conflito de interesses.

3.3 Amostra em estudo

Este estudo apresenta um tipo de amostragem não probabilística por conveniência. Segundo Afonso e Nunes (2019), como não se permite calcular com a probabilidade da inclusão dos elementos da população designa-se amostra não probabilística. Esta amostragem está subdividida em vários tipos de amostragem, em que neste caso em específico, recorre-se à amostragem por conveniência dado que os participantes são selecionados com base na sua acessibilidade.

Foram incluídos neste estudo 40 participantes com marcação prévia de RM à região do joelho, com idades superiores a 18 anos de ambos os sexos sendo um critério de exclusão os doentes que apresentem material de osteossíntese na área em estudo.

3.4 Recolha e aquisição de dados

A recolha de imagens foi realizada presencialmente, numa escala temporal entre dezembro de 2025 e março de 2026, e recorreu-se exclusivamente a uma sequência ponderada em densidade protónica com supressão de gordura no plano axial (DP FS axial). Esta sequência é muito importante na RM músculo-esquelética devido à sua sensibilidade de deteção de edema bem como, à adequada caracterização da estrutura em estudo.

O estudo está dividido em duas fases. A **Fase 1 (Fase experimental – avaliação objetiva)** foi utilizado o fantoma para explorar as métricas objetivas como a RSR e a uniformidade da intensidade do sinal. Enquanto a **Fase 2 (Fase clínica observacional – avaliação objetiva e subjetiva)** engloba uma amostra de 40 exames de RM do joelho. Para avaliação subjetiva da qualidade diagnóstica das imagens obtidas, é baseada na perceção visual de observadores experientes e realizada também a uniformidade da intensidade do sinal. Esta avaliação foi realizada por dois técnicos de radiologia com mais de 10 anos de experiência e recorreu a uma escala qualitativa ordinal, a escala de Likert (Tabela 3.1) (Apêndice A – Tabelas de avaliação pela escala Likert).

Tabela 3.1

Tabela demonstrativa das Escalas de Likert utilizadas.

Artefactos (1 a 5)	Definição de Estruturas (1 a 5)	Ruído Percebido (1 a 5)	Qualidade Global (1 a 5)
1 – Sem artefactos	1 – Muito Má	1 – Nenhum	1 – Muito má
2 – Artefactos Mínimos	2 – Má	2 – Pouco	2 – Má
3 – Artefactos Moderados	3 – Moderada	3 – Moderado	3 – Aceitável
4 – Artefactos Relevantes	4 – Boa	4 – Elevado	4 – Boa
5 – Artefactos Graves	5 – Excelente	5 – Muito elevado	5 – Excelente

Fase 1 (Fase experimental – avaliação objetiva)

Em fantoma adquiriu-se a sequência DP FS axial sem o DRB, e sem a aplicação GRAPPA utilizando a antena de joelho. Posteriormente, realizou-se a mesma aquisição variando sistematicamente o fator de aceleração GRAPPA (2,3,4), com e sem a aplicação do DRB, mantendo sempre constantes os restantes parâmetros de aquisição.

Fase 2 (Fase observacional – avaliação objetiva e subjetiva)

Nesta fase, aplicou-se o mesmo protocolo de aquisição da **Fase 1**, mas desta vez aplicado na amostra em estudo, onde se excluiu a sequência GRAPPA 1 sem DRB. Para a realização deste estudo, foi acrescentado ao tempo normal de exame de cada paciente cerca de treze minutos.

Na Tabela 3.2, apresentam-se os parâmetros fixos do protocolo utilizado para adquirir todas as sequências DP FS axial.

Tabela 3.2

Protocolo - Parâmetros									
Número de Cortes (n°)	Gradiente de Codificação de Fase	Phase Oversampling (%)	Matriz	Voxel (mm ³)	FOV (mm)	Espessura de Corte (mm)	TR (ms)	TE (ms)	Tempo de Aquisição
30	Direita -> Esquerda	50	314x448	0,3x0,3x0,3	140	3,0	3150,0	31,00	7min:16s

Protocolo com os parâmetros utilizados para aquisição de imagens.

Na Tabela 3.3, estão ilustrados os parâmetros de aquisição que são alteráveis em cada aquisição. O fator de aceleração (GRAPPA) varia entre 2,3 e 4, a utilização ou não do software de

inteligência artificial e o número de *Averages*. Esta demonstra o tempo de aquisição em cada sequência utilizada neste estudo. Neste sentido, o fator de aceleração GRAPPA a 1 foi utilizado apenas no fantoma, sendo que os restantes fatores (2, 3, 4) foram utilizados em fantoma e na amostra. Na aquisição do fantoma, foi realizada a sequência sem o fator de aceleração GRAPPA e sem DRB, que demorou um total de sete minutos e dezasseis segundos. O número de *Averages* é dois nas sequências onde se utiliza apenas o GRAPPA e apenas um onde é utilizado o GRAPPA e o DRB, uma vez que, o DRB consegue compensar a falta de sinal da aquisição.

Tabela 3.3

Tempos de aquisição da sequência de RM do joelho com diferentes fatores de aceleração GRAPPA, com e sem DRB.

GRAPPA Fator de aceleração (2 a 4)	DRB		<i>Averages</i> (n°)	Tempo de aquisição (min:s)
	Sem	Com		
2	X		2	3:42
2		X	1	1:59
3	X		2	2:45
3		X	1	1:24
4	X		2	2:14
4		X	1	1:05

3.5 Considerações éticas

Este trabalho foi submetido à Comissão de Ética da Joaquim Chaves Saúde, que emitiu parecer favorável nº 01/2025 (Apêndice B – Parecer da comissão de ética). Todos participantes assinaram o consentimento informado sobre o estudo a realizar (Apêndice C – Consentimento informado participantes). Todos os dados dos participantes foram pseudonimizados pelo Responsável de Proteção de Dados da instituição. O estudo foi conduzido de forma a garantir a máxima conduta ética e confidencialidade dos participantes.

3.6 Análise quantitativa

A análise quantitativa teve como objetivo avaliar de forma objetiva em fantoma (Figura 3.15) a qualidade de imagem em RM. Para tal, foram utilizadas métricas objetivas descritas pelo *American College of Radiology* (American College of Radiology, 2015), nomeadamente a RSR e a uniformidade da intensidade do sinal.

A métrica subjetiva avaliada neste estudo foi a presença ou não de artefactos na imagem.

Figura 3.15

Demonstração da aquisição de imagem em fantoma.



3.6.1 Relação Sinal-Ruído (RSR)

A RSR determinou-se com as recomendações do American College of Radiology (2015) utilizando uma imagem axial correspondente ao nível central do fantoma.

Para iniciar o processo de avaliação, foi definida uma *Region of interest* (ROI) abrangendo cerca de 75% da área útil do fantoma, evitando as margens para que fiquem minimizados os efeitos de volume parcial. A média do sinal obtido por a ROI corresponde ao valor de sinal médio do fantoma (*Mean Signal in Phantom*).

Por conseguinte, efetua-se a colocação de uma ROI numa grande região de ar, fora do fantoma obtendo-se o desvio padrão (σ). Neste caso, como não foi possível obter uma grande região fora da área do fantoma, considerou-se a utilização de múltiplas ROI, que combinadas calcula-se o desvio padrão pela seguinte equação (2):


$$\sigma_{combined} = \sqrt{\frac{\sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2}{n}} \quad (2),$$

Equação 2 - Cálculo do Desvio Padrão Combinado. Onde $\sigma_{combined}$ corresponde ao desvio padrão combinado de todos os ROIs, σ_n representa o desvio padrão do ROI n e n corresponde ao número total de ROIs utilizadas.

O desvio padrão do ar corresponde ao ruído na imagem (American College of Radiology, 2015). A Figura 3.16 demonstra o resultado do procedimento efetuado e mencionado anteriormente.

Figura 3.16

Imagem representativa da realização do procedimento para cálculo da RSR.



A RSR foi então calculada através da seguinte equação (3):

$$SNR_{ACR} = \frac{\text{Mean Signal in Phantom}}{\sigma_{air}} \quad (3),$$

Equação 3 - Cálculo da Relação Sinal-Ruído (RSR) segundo o método ACR. Onde SNR_{ACR} corresponde à RSR, Mean Signal in Phantom corresponde ao sinal médio medido no fantoma e σ_{air} é o desvio padrão do ar.

A avaliação da RSR foi realizada apenas na fase experimental (fantoma), uma vez que ao avaliar a RSR em imagens clínicas, pode estar a ser influenciada por heterogeneidades provenientes da composição do corpo humano e também pelas reconstruções pós-processadas das imagens adquiridas (American College of Radiology, 2015).


3.6.2 Uniformidade da intensidade do sinal

A uniformidade da intensidade do sinal foi avaliada através do cálculo da *Percent Image Uniformity* (PIU). A PIU quantifica a variação da intensidade do sinal numa região do fantoma (American College of Radiology, 2015).

Como na avaliação da RSR para se efetuar a avaliação da PIU, foi inicialmente definida uma ROI de grandes dimensões no interior do fantoma numa imagem axial central do fantoma. Após o ajuste da janela de visualização, foram identificadas as regiões correspondentes aos valores máximos e mínimos de intensidade de sinal. Em seguida, colocou-se uma ROI na região de maior intensidade (MaxROI) e uma ROI na região de menor intensidade (MinROI) exemplificado pela Figura 3.17 (American College of Radiology, 2015).

Figura 3.17

Imagem representativa da realização do procedimento para cálculo do PIU.



A PIU foi calculada utilizando a seguinte equação (4):


$$PIU = 100 \times \left(1 - \frac{\text{Max ROI} - \text{Min ROI}}{\text{Max ROI} + \text{Min ROI}} \right) \quad (4),$$

Equação 4 - Cálculo da Percentagem da uniformidade da intensidade do sinal (Percent Image Uniformity - PIU). Onde MaxROI corresponde à região de maior intensidade e MinROI corresponde à região de menor intensidade.

Na fase clínica, a uniformidade foi adicionalmente avaliada em estruturas anatómicas específicas como o osso (fémur distal), músculo (gastrocnémio) e tecido mole (gordura) como exemplificado pela Figura 3.18. Foram colocadas ROIs com área de 1 cm² em cada estrutura de forma a evitar interfaces anatómicas, artefactos e estruturas vasculares. Esta avaliação na fase clínica permitiu avaliar a consistência do sinal entre diferentes tecidos e comparar o comportamento das sequências com e sem a aplicação do algoritmo de inteligência artificial DRB.

Figura 3.18

Exemplo do procedimento efetuado em cada joelho.



3.7 Análise qualitativa

As imagens adquiridas nesta segunda fase foram pseudonimizadas e submetidas a uma análise subjetiva por dois técnicos de radiologia com mais de 10 anos de experiência em ressonância magnética. A avaliação foi realizada utilizando uma escala de Likert. Foi utilizado o software RadiAnt DICOM Viewer (versão 2025.2; Medixant, Poznań, Polónia) para a visualização destas aquisições. A avaliação foi realizada de forma cega, sem identificação da técnica utilizada. Foi realizada apenas uma observação com tempo de avaliação máximo de três minutos por exame. As condições de ambiente de trabalho foram exatamente iguais e não se detetou intercorrências durante a análise das imagens.

3.8 Análise estatística

No presente trabalho, para realizar a análise estatística, foi realizada no software Microsoft Excel e no software IBM SPSS Statistics (Versão 30.0.1.0).

Atendendo ao facto de a amostra ser superior a 30 casos e pelo Teorema do Limite Central permite deduzir que a amostra segue uma distribuição normal e permite a utilização de testes estatísticos paramétricos (Kline, 2016).

Foi previamente avaliado o pressuposto da esfericidade através do teste de Mauchly. Sempre que este pressuposto não se verificou, foram aplicadas correções apropriadas (Greenhouse-Geisser) de forma a garantir a validade dos resultados (Laureano, 2020).

Para comparação entre as diferentes condições de aquisição foi utilizada a análise de variância ANOVA para medidas repetidas, uma vez que os mesmos elementos foram avaliados sob múltiplas condições. Utilizou-se também esta análise para evitar erros de tipo I (falsos positivos) se fosse realizada a análise individualmente (Laureano, 2020).

Quando a ANOVA revelou diferenças estatisticamente significativas, procedeu-se à realização de testes Post-Hoc com o intervalo de confiança ajustado ao teste Sidák que tem maior poder estatístico (Laureano, 2020).

Os resultados foram considerados estatisticamente significativos para valores de $p < 0.05$.

Esta página foi propositadamente deixada em branco.

Capítulo 4 - Análise e discussão de resultados

O presente capítulo tem como objetivo apresentar e analisar os resultados obtidos no âmbito do estudo desenvolvido. A exposição dos resultados encontra-se estruturada em duas fases distintas: a fase experimental realizada em fantoma e a fase clínica observacional envolvendo 40 amostras de exames de RM.

Numa primeira fase são apresentados os resultados obtidos em fantoma, nomeadamente a RSR, a uniformidade da intensidade do sinal e a presença de artefactos. Posteriormente é seguida da fase clínica onde são apresentados resultados da avaliação objetiva e subjetiva realizada.

Os outputs dos testes estatísticos descritos na dissertação estão representados no Apêndice D - Outputs Testes estatísticos.

4.1 Análise e discussão de resultados da Fase 1 – Fase experimental – avaliação objetiva

A fase experimental foi realizada em fantoma com o objetivo de avaliar, de forma objetiva, o impacto da utilização de diferentes fatores de aceleração de GRAPPA com ou sem a utilização de DRB na qualidade da imagem de RM.

As métricas utilizadas foram a RSR e a uniformidade da intensidade do sinal. Foi também elaborada uma avaliação qualitativa para se verificar a presença ou não de artefactos.

Para realizar esta avaliação, foi considerada como condição de referência a aquisição realizada sem fator de aceleração GRAPPA e sem a aplicação do DRB, comparando posteriormente com as aquisições com GRAPPA 2, GRAPPA 3 e GRAPPA 4, com e sem a aplicação do DRB.

4.1.1 Relação sinal-ruído (RSR)

Os resultados obtidos encontram-se evidenciados na Tabela 4.4. Verifica-se que o valor mais elevado de RSR foi observado na condição de referência, ou seja, sem a aplicação de GRAPPA e DRB.

Tabela 4.4*Avaliação em fantoma da RSR*

GRAPPA	DRB		RSR(dB)
	Sem	Com	
Sem GRAPPA	X		336.22
2	X		252.13
2		X	223.64
3	X		190.23
3		X	172.18
4	X		188.36
4		X	159.49

De forma global, os resultados evidenciam que a RSR diminuiu à medida que aumentou o fator de aceleração GRAPPA, sendo este compatível com o comportamento das técnicas de aceleração de imagem paralela, o que está de acordo com a literatura, que descreve uma relação inversa entre o fator de aceleração GRAPPA e a RSR (Deshmane et al., 2012). Estes resultados demonstram também que para todos os fatores de GRAPPA, a aplicação do DRB esteve associada a valores inferiores de RSR relativamente às aquisições sem DRB. Neste estudo, esperava-se o contrário com base nos estudos descritos por Hammernik et al. (2018) e Knoll et al. (2020).

Relativamente às questões de investigação, os resultados indicam que a utilização do DRB não conduz a um aumento da RSR objetiva em fantoma. Não invalida, assim, o seu impacto positivo na qualidade de imagem, uma vez que esta deve ser avaliada de forma transversal. No entanto, existe um ganho no tempo, uma vez que, o tempo diminui consideravelmente e só existe uma ligeira diminuição da RSR entre cada aquisição.

4.1.2 Uniformidade da intensidade do sinal

Os valores da uniformidade da intensidade do sinal encontram-se apresentados na Tabela 4.5. A condição de referência apresentou um valor de uniformidade mais elevado entre todas as aquisições.

Tabela 4.5*Avaliação em fantoma da Uniformidade da Intensidade do Sinal.*

GRAPPA	DRB		Uniformidade (%)
	Sem	Com	
1	X		74
2	X		73
2		X	70
3	X		72
3		X	71
4	X		72
4		X	68

Nas aquisições com fatores de aceleração associados, os valores mantiveram-se próximos entre si, com uma ligeira diminuição entre a aquisição sem DRB com a aquisição com DRB.

Estes resultados demonstram que a uniformidade da intensidade do sinal se manteve estável, uma vez que teve pequenas variações entre condições. No entanto, o DRB esteve associado a uma ligeira diminuição da uniformidade em todos os fatores de GRAPPA, sendo a mais evidente em GRAPPA 4.

Este comportamento pode ser interpretado à luz dos mecanismos de reconstrução baseados em *deep learning*. Estes algoritmos como o DRB, procuram recuperar informação de alta frequência no espaço K, associada ao detalhe anatómico. Consequentemente, a recuperação de detalhe estrutural pode traduzir-se numa menor homogeneidade do sinal, sem degradação da qualidade diagnóstica (Hammernik et al., 2018; Knoll et al., 2020).

No âmbito das questões de investigação, verifica-se que, embora a utilização da IA não conduza a melhorias significativas na uniformidade da intensidade do sinal, tal não invalida o seu impacto positivo na qualidade global da imagem, conforme evidenciado na fase clínica do estudo.

Deste modo, embora o aumento do GRAPPA não tenha provocado alterações acentuadas na uniformidade, a combinação de fatores de aceleração mais elevados com DRB associa-se a uma redução moderada deste parâmetro.

4.1.3 Artefactos

A avaliação da presença ou ausência de artefactos encontra-se descrita na Tabela 4.6.

Tabela 4.6

Avaliação de Artefactos em fantoma.

GRAPPA	DRB		Artefactos	
	Sem	Com	Não	Sim
1	X		X	
2	X		X	
2		X	X	
3	X			X
3		X		X
4	X			X
4		X		X

Como mostra a tabela, a avaliação de referência e a condição com GRAPPA 2 (com e sem DRB) mostram que não são identificados artefactos nessas imagens. Já nas restantes avaliações mostra que se identificam alguns artefactos. De forma geral, observou-se que o aumento do fator aceleração GRAPPA esteve associado a um aumento da presença de artefactos, comportamento consistente com a literatura, que descreve a subamostragem do espaço K como um fator predisponente para a ocorrência de artefactos de *aliasing* e degradação da qualidade da imagem (Deshmane et., 2012).

Estes resultados sugerem que a presença de artefactos está relacionada com o aumento do fator de aceleração. Com a aplicação do DRB notou-se uma ligeira melhoria dos artefactos da imagem evidenciando o potencial dos algoritmos de *deep learning*. Estes atuam em padrões previamente aprendidos, permitindo recuperar informações ausente e reduzir o impacto visual dos artefactos. O artefacto visualizado é o artefacto de “*aliasing*”

Num modo geral, respondendo às questões de investigação, os resultados obtidos indicam que a utilização do DRB não influencia a presença de artefactos, mas sim o fator de aceleração GRAPPA. O DRB contribui para a sua redução melhorando a qualidade visual da imagem.

4.1.4 Discussão geral da Fase experimental

Todos os achados indicam que em fantoma, o DRB não melhora as métricas objetivas de qualidade de imagem. Este resultado encontra suporte na literatura recente, que questiona a adequação das métricas tradicionais e dos testes realizados em fantoma para a avaliação de algoritmos de inteligência artificial. Segundo White et al. (2025), ainda não está estabelecido se as

medições convencionais em fantoma constituem ferramentas apropriadas para avaliar algoritmos treinados com dados clínicos reais.

Neste estudo, o comportamento demonstrado pelo algoritmo é relevante, pois evidencia que a melhoria da qualidade da imagem associada à IA pode não se refletir diretamente nas métricas objetivas como a RSR e a uniformidade da intensidade do sinal.

4.2 Análise e discussão de resultados da Fase 2 – Fase clínica observacional – avaliação objetiva e subjetiva

Nesta fase, avaliou-se objetivamente os dados recolhidos por dois leitores com mais de 10 anos de experiência em RM. Subjetivamente foram recolhidos dados para verificar a uniformidade da intensidade do sinal em três regiões anatómicas diferentes: osso (fémur distal), músculo (gastrocnémio) e tecido mole (gordura).

4.2.1 Avaliação objetiva

O teste paramétrico ANOVA foi realizado para avaliar o seu efeito na medição das diferentes estruturas (osso, músculo e gordura).

4.2.1.1 Osso versus GRAPPA versus DRB

A ANOVA de medidas repetidas foi realizada com dois fatores intra-sujeitos: fator de aceleração (GRAPPA – GRAPPA 2, GRAPPA 3 e GRAPPA 4) e a utilização de DRB (com DRB versus sem DRB), sendo o objetivo avaliar a uniformidade da intensidade de sinal no osso.

Analisando as médias obtidas para cada sequência na estrutura em estudo (côndilo medial do fémur), podemos observar que se verifica um aumento progressivo da média da uniformidade da intensidade do sinal no osso com o reforço do fator GRAPPA (Tabela 4.7) Sugere-se, então, uma maior homogeneização do sinal. No entanto, a aplicação do DRB apresentou um comportamento dependente do nível de aceleração, evidenciando um ligeiro aumento da uniformidade em GRAPPA 2, mas uma diminuição em GRAPPA 3 e GRAPPA 4. Estes resultados sugerem que o DRB pode reduzir o efeito de suavização induzido pela subamostragem do espaço K, promovendo uma recuperação de detalhe de estruturas e, consequentemente, uma menor homogeneidade do sinal.

Tabela 4.7*Média das ROI's no osso.*

Sequência	Média ROI Osso
Sem DRB G2	48.19
Com DRB G2	49.34
Sem DRB G3	50.51
Com DRB G3	49.61
Sem DRB G4	53.45
Com DRB G4	50.66

O pressuposto da esfericidade foi avaliado através do teste de Mauchly, sendo violado para o fator GRAPPA ($p = 0.029$), tendo sido aplicada a correção de Greenhouse-Geisser na interpretação de resultados. O DRB não tem valor de significância uma vez que a esfericidade só se calcula para variáveis com três níveis e o DRB tem apenas dois (com e sem DRB).

A análise revelou um efeito principal estatisticamente significativo de GRAPPA, $F(1.71, 66.63) = 17.55$, $p < 0.001$, indicando a existência de diferenças entre os diferentes níveis de GRAPPA. Por outro lado, o efeito principal do DRB não foi estatisticamente significativo, $F(1,39) = 1.34$, $p = 0.255$. Sugere-se assim, que a aplicação só do algoritmo não influencia diretamente a uniformidade da intensidade do sinal no tecido ósseo, mas sim reduz o ruído e melhora a definição de estruturas.

No entanto, foi observada uma interação estatisticamente significativa de GRAPPA e o DRB, $F(1.95, 75.92) = 4.62$, $p = 0.013$.

Os resultados anteriormente mencionados estão demonstrados na Tabela 4.8.

Tabela 4.8*Resultados da ANOVA de medidas repetidas para a uniformidade da intensidade de sinal no tecido ósseo.*

Fator/Interação	gI	F	p	Interpretação
GRAPPA	(1.71, 66.63)	17.55	<0.001	Efeito Significativo
DRB	(1, 39)	1.34	0.255	Não significativo
GRAPPA X DRB	(1.95, 75.92)	4.62	0.013	Interação significativa

As comparações múltiplas (Post-Hoc) com correção de Sidák revelaram diferenças estatisticamente significativas entre todos os níveis de aceleração. Observou-se um aumento progressivo da uniformidade da intensidade de sinal com o incremento do GRAPPA, sendo

GRAPPA 4 superior ao GRAPPA 3 e GRAPPA 2 e também o GRAPPA 3 superior ao GRAPPA 2 (Tabela 4.9).

Tabela 4.9

Comparações múltiplas para o fator GRAPPA.

Comparação	Diferença Significativa	<i>p</i>	Interpretação
GRAPPA 2 vs GRAPPA 3	Sim	<0.05	Aumento da uniformidade
GRAPPA 2 vs GRAPPA 4	Sim	<0.001	Aumento da uniformidade
GRAPPA 3 vs GRAPPA 4	Sim	<0.001	Aumento da uniformidade

Este resultado normalmente estaria associado à degradação da qualidade diagnóstica, uma vez que o aumento do fator de aceleração está tipicamente associado à degradação da qualidade diagnóstica. No entanto, a uniformidade da intensidade do sinal representa uma métrica específica relacionada com a homogeneidade do sinal e não com a qualidade diagnóstica de imagem em si.

Como mencionado anteriormente, o aumento da uniformidade poderá refletir um efeito de suavização do sinal decorrente da subamostragem do espaço K, traduzindo uma imagem mais homogênea, ainda que contenha perda de detalhe das estruturas.

Relativamente à interação GRAPPA e DRB, no GRAPPA 2 a utilização de DRB resultou num aumento significativo da uniformidade da intensidade de sinal ($p = 0.006$) e no GRAPPA 3 e GRAPPA 4, não foram observadas diferenças estatisticamente significativas entre as condições com e sem DRB. Sugere-se que o efeito do DRB depende do nível de GRAPPA aplicado. Também se sugere que apresenta maior eficácia em cenários de aceleração moderada (GRAPPA 2). Em contrapartida, em cenário em que a aceleração é mais elevada, o impacto do DRB é menos evidente (GRAPPA 3 e GRAPPA 4).

No âmbito das questões de investigação, estes resultados indicam diferenças entre sequências unicamente com GRAPPA e sequências com GRAPPA e DRB, particularmente no comportamento da uniformidade da intensidade do sinal. Contudo, esta métrica isoladamente não permite inferir diretamente a qualidade de imagem, reforçando a necessidade de integração com a avaliação subjetiva realizada na fase clínica.

4.2.1.2 Músculo versus GRAPPA versus DRB

De forma a analisar a uniformidade da intensidade do sinal do músculo, realizou-se as médias das ROI's no músculo (Tabela 4.10). Os resultados demonstram que a uniformidade da intensidade média do sinal do músculo se mantém globalmente estável entre as diferentes condições de aquisição. Este comportamento sugere que o músculo apresenta uma distribuição de sinal relativamente homogénea e pouco suscetível às variações introduzidas pela subamostragem do espaço K. No que toca ao DRB, observa-se um ligeiro aumento do sinal em GRAPPA 2 e GRAPPA 4 que, como no osso, sugere um efeito de suavização e homogeneização do sinal. No entanto, estas variações são reduzidas e indicam que o impacto do DRB no músculo é limitado quando comparado com outros tecidos.

Tabela 4.10

Médias dos ROI no músculo.

Sequência	Média ROI Músculo
Sem DRB G2	115.31
Com DRB G2	118.81
Sem DRB G3	118.61
Com DRB G3	118.46
Sem DRB G4	117.91
Com DRB G4	118.86

Para a análise da uniformidade da intensidade de sinal no músculo a ANOVA de medidas repetidas revelou que o efeito principal do GRAPPA não foi estatisticamente significativo $F(2,78) = 1.94, p = 0.151, \eta_p^2 = 0.047$, o que sugere que a variação do fator GRAPPA não influencia de forma relevante a homogeneidade do sinal no músculo. O músculo apresenta características com uma distribuição de sinal homogénea, logo não foram observadas diferenças estatisticamente significativas, sugerindo que o músculo apresenta uma relativa estabilidade face à subamostragem do espaço k .

Porém, observou-se um efeito principal significativo do DRB, $F(1,39) = 4.83, p = .034, \eta_p^2 = 0.110$, indicando valores médios superiores de uniformidade quando o DRB é utilizado. Este resultado sugere que o DRB contribui para uma maior homogeneização do sinal no tecido muscular corroborando com o mencionado anteriormente.

Adicionalmente, observou-se uma interação significativa GRAPPA e DRB ($F(2,78) = 3.28, p = 0.043, \eta_p^2 = 0.078$) dando a entender que o impacto do DRB varia em função do GRAPPA.

Todos os resultados explicados anteriormente estão evidenciados na Tabela 4.11.

Tabela 4.11

Resultados da ANOVA de medidas repetidas para a uniformidade da intensidade de sinal no músculo.

Fator/Interação	gl	F	p	Interpretação
GRAPPA	(2, 78)	1.94	0.151	Não Significativo
DRB	(1, 39)	4.83	0.034	Efeito significativo
GRAPPA X DRB	(2, 78)	3.28	0.043	Interação significativa

As comparações Post-Hoc com correção de Sidák indicaram que existe uma diferença estatisticamente significativa entre a utilização ou não do DRB ($\Delta M = 1.54$, $p = 0.034$), sendo observados valores médios mais elevados na utilização com DRB.

Ao nível da interação GRAPPA e DRB, verificou-se que apenas em GRAPPA 2 existem diferenças significativas entre a utilização ou não do DRB ($|\Delta M| = 3.500$, $p = 0.010$), não se observando diferenças significativas entre GRAPPA 3 e GRAPPA 4 ($p = 0.689$ e $p = 0.346$, respetivamente). Este comportamento sugere que o DRB apresenta maior eficácia em cenários de aceleração com o fator GRAPPA a 2 e em contrapartida, em GRAPPA 3 e GRAPPA 4 o benefício do DRB torna-se menos evidente.

Relativamente às questões de investigação, os resultados indicam diferenças que o impacto da IA na qualidade da imagem pode ser dependente do tipo de tecido analisado. No caso do músculo, a utilização do DRB não demonstrou alterações relevantes na uniformidade da intensidade do sinal.

4.2.1.3 Tecido mole versus GRAPPA versus DRB

No caso do tecido mole (gordura), os resultados das médias apresentados demonstram que a uniformidade da intensidade do sinal no tecido adiposo se mantém globalmente estável (Tabela 4.12). As variações observadas são de reduzida magnitude e não apresentam um padrão definido. Sugere que o tecido mole é pouco suscetível às alterações introduzidas pela subamostragem do espaço K e pela reconstrução baseada em IA.

Tabela 4.12

Média das ROI's do tecido mole.

Sequência	Média ROI Tecido Mole
Sem DRB G2	85.49
Com DRB G2	85.37
Sem DRB G3	81.92
Com DRB G3	84.97
Sem DRB G4	84.81
Com DRB G4	84.50

Neste caso do Tecido Mole (Gordura), o teste de Mauchly indicou que o pressuposto da esfericidade foi violado tendo sido aplicada a correção de Greenhouse-Geisser na interpretação dos resultados da ANOVA de medidas repetidas.

A ANOVA demonstrou que o efeito principal de GRAPPA não foi estatisticamente significativo na uniformidade da intensidade de sinal da gordura $F(1.72, 67.04) = 1.06, p = 0.345, \eta_p^2 = 0.026$. Do mesmo modo, não se verificou um efeito significativo do DRB $F(1,39) = 0.68, p = 0.416, \eta_p^2 = 0.017$. Por último, no mesmo contexto a interação entre o GRAPPA e o DRB não foi significativa $F(1.73, 67.62) = 0.92, p = 0.390, \eta_p^2 = 0.023$. Estes resultados indicam que, no caso dos tecidos moles, não foram observadas diferenças estatisticamente significativas, sugerindo uma relativa estabilidade da uniformidade do sinal no tecido independentemente das condições de aquisição e da utilização do DRB corroborando com o que foi mencionado anteriormente.

Como não foram identificadas diferenças estatisticamente significativas, não se procedeu à análise das comparações Post-Hoc.

No âmbito das questões de investigação, os resultados indicam que o impacto da IA na qualidade da imagem não demonstrou um impacto significativo na uniformidade da intensidade de sinal no tecido mole. Reforça, assim, a ideia de que a IA em RM é dependente do tecido analisado.

4.2.2 Avaliação subjetiva

4.2.2.1 Análise leitores – Artefactos

A ANOVA de medidas repetidas revelou um efeito principal significativo do fator Leitor, $F(1,39) = 43.51, p < 0.001, \eta_p^2 = 0.527$, o que indica diferenças na avaliação de artefactos entre os dois leitores. As comparações Post-Hoc com correção de Sidák revelaram diferenças significativas entre os leitores, sendo que o Leitor 2 apresentou valores de artefacto significativamente superiores ao Leitor 1 ($p < 0.001$). Para corroborar estes resultados, está presente na Tabela 4.13, as médias obtidas por cada leitor em cada sequência.

Tabela 4.13

Comparação da média da avaliação de artefactos de cada leitor.

Sequência	Média Leitor 1	Média Leitor 2
Sem DRB G2	1.90	2.40
Com DRB G2	2.0	2.55
Sem DRB G3	1.83	2.90
Com DRB G3	1.92	2.60
Sem DRB G4	2.07	2.58
Com DRB G4	2.13	2.38

Este resultado demonstra uma variabilidade interobservador, sugerindo que a percepção de artefactos não é homogênea entre profissionais, mesmo quando estes possuem experiência clínica semelhante. As análises Post-Hoc confirmaram a diferença, uma vez que o Leitor 1 atribuiu classificações de artefactos significativamente superiores ao Leitor 2. Isto pode refletir diferentes critérios de exigência, sensibilidade à presença de artefactos ou padrões individuais de interpretação.

Não foram observados efeitos significativos do DRB, $F(1,39) = 0.07$, $p = 0.787$, $\eta_p^2 = 0.002$, nem para o fator GRAPPA $F(2,78) = 1.24$, $p = 0.294$, $\eta_p^2 = 0.031$, que sugere que nenhuma das técnicas teve impacto direto na percepção global de artefactos pelos observadores. Este resultado demonstra que a introdução do algoritmo de inteligência artificial não aumenta nem reduz a presença de artefactos percebidos.

No entanto, verificou-se uma interação significativa entre o Leitor e o DRB, $F(1,39) = 5.77$, $p = 0.021$, $\eta_p^2 = 0.129$, bem como uma interação tripla significativa entre o Leitor, o DRB e o GRAPPA, $F(1.72, 67.07) = 20.78$, $p < 0.001$, $\eta_p^2 = 0.348$.

Os resultados mencionados estão descritos na Tabela 4.14.

Tabela 4.14

Resultados da ANOVA de medidas repetidas para a percepção de artefactos.

Fator/Interação	gI	F	p	Interpretação
Leitor	(1, 39)	43.51	<0.001	Efeito Significativo
GRAPPA	(2, 78)	1.24	0.294	Não Significativo
DRB	(1, 39)	0.07	0.787	Não Significativo
Leitor X DRB	(2, 78)	5.77	0.021	Interação significativa

O efeito do DRB na percepção de artefactos depende do observador e das condições de aquisição. Estes resultados sugerem que o DRB pode influenciar a imagem de forma diferenciada,

sendo interpretada de forma distinta por cada leitor consoante o fator GRAPPA, respondendo diretamente à questão de investigação 4.

Por outro lado, a interpretação dos efeitos principais deve ser realizada com atenção, uma vez que, as diferenças entre leitores variam em função da presença de DRB e do fator de aceleração do GRAPPA. Reforça-se, assim, a importância de integrar múltiplos observadores.

4.2.2.2 Análise leitores – Definição de estruturas

A ANOVA de medidas repetidas demonstrou efeitos principais significativos do Leitor, $F(1,39) = 13.42$, $p < 0.001$, $\eta_p^2 = 0.256$, indicando diferenças entre avaliadores. Existe, então, uma variabilidade interobservador na perceção da qualidade da delineação de estruturas das imagens demonstrado também pela Tabela 4.15.

Tabela 4.15

Comparação da média de definição de estruturas.

Sequência	Média Leitor 1	Média Leitor 2
Sem DRB G2	3.10	3.85
Com DRB G2	3.88	3.60
Sem DRB G3	2.72	3.47
Com DRB G3	4.05	3.90
Sem DRB G4	2.08	2.53
Com DRB G4	4.10	4.18

O fator DRB apresentou um efeito significativo, $F(1,39) = 306.99$, $p < 0.001$, $\eta_p^2 = 0.887$, evidenciando uma melhoria global e estatisticamente significativa na definição de estruturas com a utilização do DRB, embora modulada pelo nível do fator aceleração. Este achado constitui de forma substancial para a melhoria da nitidez e da delineação anatómica. Estas duas melhorias mencionadas são alguns dos aspetos críticos na avaliação músculo-esquelética, particularmente na avaliação em estruturas como meniscos, cartilagem e ligamentos e reponde diretamente às questões de investigação 2 e 3.

Adicionalmente, verificou-se um efeito significativo do Fator de Aceleração (GRAPPA) $F(2,78) = 17.40$, $p < 0.001$, $\eta_p^2 = 0.308$. Isto indica que valores mais elevados do fator de aceleração, observou-se uma diminuição progressiva da definição de estruturas com o aumento do fator de aceleração, sendo significativamente inferior em GRAPPA 4. Mencionando a teoria descrita anteriormente, este resultado está de acordo pois fatores de aceleração mais elevados implicam maior

subamostragem do espaço perdendo assim detalhe das estruturas e degradação da qualidade da imagem.

Foram também identificadas três interações significativas. A primeira entre o Leitor e o DRB, $F(1,39) = 57.15$, $p < 0.001$, $\eta_p^2 = 0.594$. A segunda entre o DRB e o GRAPPA, $F(2,78) = 66.51$, $p < 0.001$, $\eta_p^2 = 0.630$. A última é uma interação tripla significativa entre o Leitor, o DRB e o GRAPPA, $F(2,78) = 5.47$, $p = 0.006$, $\eta_p^2 = 0.123$. Estes dados sugerem que o DRB atua de forma diferenciada na definição consoante o nível de GRAPPA, podendo ter maior benefício em determinados níveis de GRAPPA. Estas interações indicam também que o DRB não é uniforme na definição de estruturas, dependendo do nível de GRAPPA que é utilizado e do observador. A interação tripla revela a complexidade da interpretação destes resultados e mostra que a perceção da melhoria proveniente do DRB varia entre leitores e as condições de aquisição.

Estes resultados anteriores são corroborados pela Tabela 4.16.

Tabela 4.16

Resultado da ANOVA de medidas repetidas para a definição de estruturas.

Fator/Interação	gl	F	p	Interpretação
Leitor	(1, 39)	13.42	<0.001	Efeito Significativo
GRAPPA	(2, 78)	17.40	<0.001	Efeito Significativo
DRB	(1, 39)	306.99	<0.001	Efeito Significativo
Leitor X GRAPPA	(2, 78)	0.12	0.886	Interação não significativa
Leitor X DRB	(1, 39)	57.15	<0.001	Interação significativa
GRAPPA X DRB	(2, 78)	66.51	<0.001	Interação significativa
Leitor X GRAPPA X DRB	(2, 78)	5.47	0.006	Interação significativa

As comparações múltiplas (Post-Hoc com correção de Sidák) revelaram que não existem diferenças estatisticamente significativas entre GRAPPA 2 e GRAPPA 3 ($p = 0.706$), mas existe diferenças significativas entre GRAPPA 2 e GRAPPA4 ($p < 0.001$) e entre GRAPPA 3 e GRAPPA 4 ($p < 0.001$).

Os resultados indicam que o fator de aceleração mais elevado (GRAPPA 4) está associado a valores inferiores de definição de estruturas, comparativamente a GRAPPA 2 e a GRAPPA 3. Estes resultados sugerem que o DRB é capaz de mitigar parcialmente os efeitos negativos associados à aceleração da aquisição, mas pode não ser suficiente para evitar a degradação da imagem em fatores de GRAPPA mais elevados.

4.2.2.3 Análise dos leitores – Ruído percebido

Na análise ANOVA de medidas repetidas verificou-se um efeito principal significativo do fator Leitor, $F(1,39) = 95.75$, $p < 0.001$, $\eta_p^2 = 0.711$, que demonstra diferenças consistentes na percepção de ruído entre avaliadores. Este achado reforça, mais uma vez, a existência de variabilidade interobservador. Reflete, assim, que diferentes leitores têm diferentes níveis de sensibilidade à detecção de ruído (Tabela 4.17).

Tabela 4.17

Comparação da média de ruído percebido.

Sequência	Média Leitor 1	Média Leitor 2
Sem DRB G2	1.20	2.23
Com DRB G2	1.48	2.33
Sem DRB G3	1.95	2.80
Com DRB G3	1.15	2.05
Sem DRB G4	4.23	4.07
Com DRB G4	1.10	1.95

O fator DRB apresentou igualmente um efeito significativo, $F(1,39) = 280.26$, $p < 0.001$, $\eta_p^2 = 0.878$, evidenciando uma redução significativa do ruído percebido com a aplicação de reconstrução de IA, o DRB. Para esta dissertação, este achado é particularmente relevante, uma vez que confirma que o DRB atua na supressão de ruído observado e contribui para uma melhor qualidade de imagem, dando resposta às questões de investigação 2 e 3.

O fator GRAPPA revelou também um efeito significativo, $F(2,78) = 148.38$, $p < 0.001$, $\eta_p^2 = 0.792$. Isto indica que o aumento do fator aceleração está associado a um aumento progressivo do ruído percebido na imagem.

Observaram-se também três interações estatisticamente significativas: entre o Leitor e o DRB, $F(1,39) = 10.44$, $p < 0.003$, $\eta_p^2 = 0.211$; entre o Leitor e o GRAPPA, $F(2,78) = 18.92$, $p < 0.001$, $\eta_p^2 = 0.327$ e entre o DRB e o GRAPPA $F(2,78) = 212.17$, $p < 0.001$, $\eta_p^2 = 0.845$. Nesta última, indica que o DRB contribui significativamente para a redução de ruído, embora o seu efeito seja dependente do fator aceleração. Sugere-se, então, que o algoritmo apresenta maior relevância em cenários de maior degradação da imagem, ou seja, em GRAPPA mais elevados.

Crucialmente, observou-se uma interação tripla significativamente entre o Leitor, o DRB e o GRAPPA, $F(2,78) = 15.65$, $p < 0.001$, $\eta_p^2 = 0.286$, indicando que o efeito do DRB na relação entre GRAPPA e ruído percebido difere entre leitores e das condições de aquisição.

Na Tabela 4.18, encontra-se um resumo de todos os resultados obtido para o ruído percebido.

Tabela 4.18

Resultado da ANOVA de medidas repetidas para o ruído percebido.

Fator/Interação	gI	F	p	Interpretação
Leitor	(1, 39)	95.75	<0.001	Efeito Significativo
GRAPPA	(2, 78)	148.38	<0.001	Efeito Significativo
DRB	(1, 39)	280.26	<0.001	Efeito Significativo
Leitor X GRAPPA	(2, 78)	18.92	<0.001	Interação significativa
Leitor X DRB	(1, 39)	10.44	0.003	Interação significativa
GRAPPA X DRB	(2, 78)	212.17	<0.001	Interação significativa
Leitor X GRAPPA X DRB	(2, 78)	15.65	<0.001	Interação significativa

As comparações Post-Hoc com correção de Sidák verificaram-se diferenças estatisticamente significativas entre todos os fatores GRAPPA, sendo que o aumento deste fator está associado a um aumento progressivo do ruído percebido. Evidencia-se, assim, que o aumento da velocidade da aquisição da sequência de RM está associado a um aumento do ruído percebido. Este efeito é atenuado pela aplicação do DRB que permite diminuir, significativamente, o ruído percebido e funciona como um mecanismo de compensação da degradação da qualidade da imagem. Sustenta-se assim, que a utilização do DRB é uma estratégia para otimizar protocolos de RM, permitindo reduzir tempos de aquisição sem comprometer a qualidade diagnóstica.

4.2.2.4 Análise dos leitores – Qualidade global

A análise ANOVA de medidas repetidas verificou um efeito principal significativo do fator Leitor, $F(1,39) = 6.93$, $p = 0.012$, $\eta_p^2 = 0.151$. Indica a existência de diferenças entre avaliadores na apreciação global da qualidade das imagens (Tabela 4.19).

Tabela 4.19

Comparação da média para a qualidade global da imagem.

Sequência	Média Leitor 1	Média Leitor 2
Sem DRB G2	3.20	3.85
Com DRB G2	3.88	3.75

Sem DRB G3	2.88	3.37
Com DRB G3	4.05	3.95
Sem DRB G4	2.07	2.28
Com DRB G4	4.15	4.32

O fator DRB apresentou um efeito significativo, $F(1,39) = 331.29$, $p < 0.001$, $\eta_p^2 = 0.895$, o que indica uma melhoria global da qualidade da imagem com a utilização de reconstrução com a IA, o DRB. Este resultado confirma que o DRB tem um impacto na perceção global da qualidade e como foi comprovado anteriormente, terá menos ruído e melhor definição de estruturas. Esta afirmação responde diretamente às questões de investigação 1, 2 e 3.

O fator de aceleração GRAPPA revelou também que tem um efeito significativo $F(2,78) = 17.70$, $p < 0.001$, $\eta_p^2 = 0.312$. A degradação da qualidade global da imagem é particularmente evidente em níveis mais elevados de aceleração, nomeadamente em GRAPPA 4, não se verificando diferenças significativas entre GRAPPA 2 e GRAPPA 3.

As interações estatisticamente significativas foram entre o Leitor e o DRB $F(1,39) = 22.89$, $p < 0.001$, $\eta_p^2 = 0.370$; entre DRB e GRAPPA $F(2,78) = 79.50$, $p < 0.001$, $\eta_p^2 = 0.671$ e por último, a interação tripla significativamente entre o Leitor, o DRB e o GRAPPA $F(2,78) = 8.14$, $p = 0.001$, $\eta_p^2 = 0.173$. No que toca a estas interações, podemos observar que existe um impacto do DRB na qualidade global da imagem, mas este, está dependente do observador e do fator GRAPPA. A interação do DRB com o GRAPPA sugere que o benefício do DRB é mais acentuado em condições de maior degradação da imagem, particularmente em GRAPPA 4.

Não se verificou uma interação significativamente entre o Leitor e o GRAPPA, uma vez que $F(2,78) = 0.16$, $p = 0.850$, $\eta_p^2 = 0.004$. Este resultado indica que o efeito de GRAPPA na qualidade da imagem é consistente entre observadores, ao contrário do que se verificou em outros parâmetros.

Os resultados descritos anteriormente corroboram com a Tabela 4.20.

Tabela 4.20

Resultado da ANOVA de medidas repetidas para a qualidade global da imagem.

Fator/Interação	gl	F	p	Interpretação
Leitor	(1, 39)	6.93	0.012	Efeito Significativo
GRAPPA	(2, 78)	17.70	<0.001	Efeito Significativo
DRB	(1, 39)	331.29	<0.001	Efeito Significativo
Leitor X GRAPPA	(2, 78)	0.16	0.850	Interação não significativa

Leitor X DRB	(1, 39)	22.89	<0.001	Interação significativa
GRAPPA X DRB	(2, 78)	79.50	<0.001	Interação significativa
Leitor X GRAPPA X DRB	(2, 78)	8.14	<0.001	Interação significativa

As comparações múltiplas (Post-Hoc com correção de Sidák) demonstram que não existem diferenças significativas entre GRAPPA 2 e GRAPPA 3 ($p = 0.389$), mas existem diferenças significativas da qualidade global da imagem entre GRAPPA 2 e GRAPPA 4 ($p < 0.001$) e entre GRAPPA 3 e GRAPPA 4 ($p < 0.001$). Este achado indica que GRAPPA 4 apresenta uma degradação significativa da qualidade de imagem quando comparando com os restantes níveis. Quanto maior for a subamostragem do espaço K maior a perda de informação e degradação da qualidade da imagem como está descrito no enquadramento teórico desta dissertação.

Na análise à qualidade global da imagem, verifica-se que níveis mais elevados de aceleração (GRAPPA 4) estão associados a uma diminuição significativa da qualidade global da imagem, sendo que este efeito é colmatado pela utilização do DRB que melhora a perceção global da qualidade de imagem. Fica assim evidenciado que existe um potencial da inteligência artificial em compensar as limitações inerentes às técnicas de aquisição acelerada como o GRAPPA. Permite, assim, otimizar o equilíbrio entre tempo de exame e qualidade diagnóstica.

4.2.3 Discussão geral da Fase clínica observacional

Em resposta à questão de investigação 1, os resultados obtidos sugerem que a utilização do DRB permite reduzir o tempo de aquisição sem comprometer a qualidade de imagem para os leitores.

As métricas subjetivas, sugerem que o DRB com GRAPPA 2 apresenta maior eficácia, ou seja, é mais evidente que o DRB auxilia na aquisição e que mantém ou aumenta a qualidade de imagem diagnóstica, respondendo assim à questão de investigação 2. Estes achados estão em concordância com a literatura recente, que descreve as técnicas de reconstrução baseadas em *deep learning* como capazes de reduzir significativamente o tempo de aquisição, mantendo ou melhorando simultaneamente a qualidade de imagem e o desempenho diagnóstico (Vosshenrich et al., 2024; Yoo, 2025).

Utilizando o DRB com GRAPPA 3 ou GRAPPA 4 não se torna tão evidente o seu benefício, mas é evidente que o DRB auxilia e melhora a qualidade da imagem quando comparado com a sequência realizada apenas com GRAPPA. Esta observação pode ser explicada pelo facto de as técnicas de imagem paralela, como o GRAPPA, apresentarem uma diminuição progressiva da RSR, sendo proporcional ao aumento do fator de aceleração, bem como maior suscetibilidade a artefactos (Deshmane et al., 2012; Vosshenrich et al., 2024). Deste modo, embora o DRB consiga

mitigar parcialmente estas limitações, não elimina completamente os efeitos adversos associados a níveis elevados de subamostragem.

Neste contexto, os resultados obtidos sugerem que o DRB atua como mecanismo de reconstrução avançada capaz de compensar, em parte, a degradação da imagem introduzida pelas técnicas de aquisição acelerada como demonstram os estudos de Hammernik et al. (2018) e Knoll et al. (2020).

Nas métricas objetivas, os resultados são semelhantes, mas descrevem que o DRB consegue colmatar as limitações associadas às técnicas de aquisição acelerada como o GRAPPA. Permite, assim, DRB com o GRAPPA otimizar e equilibrar tempo de exame e qualidade diagnóstica.

A qualidade de imagem e a RSR em exames de RM 3T do joelho com DRB, em contexto clínico, é mais evidente que existe melhoria em GRAPPA 2 com DRB do que com GRAPPA 3 e GRAPPA 4 com DRB, existindo sim melhoria de sinal no osso e músculo enquanto que o tecido mole se manteve estável. Mas em fantoma, a RSR não se comprovou que melhorou com a utilização do DRB com o GRAPPA, respondendo à questão de investigação 3. Esta discrepância pode ser explicada pelo facto de os algoritmos de *deep learning* serem otimizados para melhorar a perceção clínica da imagem e não exclusivamente métricas físicas isoladas, sendo mais eficazes em contextos reais onde existe maior complexidade anatómica e variabilidade de sinal (Yoo, 2025).

Adicionalmente, os resultados do presente estudo são consistentes com investigações recentes em RM do joelho, demonstrando que a IA permite reduzir o tempo de aquisição mantendo ou até melhorando a qualidade de imagem e a delineação anatómica em comparação com protocolos convencionais (Reschke et al., 2025).

A IA, nomeadamente o DRB, não influencia a presença de artefactos, mas pode contribuir para a sua atenuação visual, respondendo à questão de investigação 4. Esta observação sugere que a IA não elimina artefactos, melhora apenas a sua perceção através da redução do ruído e da suavização de imagem, estando em concordância com a literatura que aponta para um potencial das técnicas de *deep learning* na mitigação de artefactos em RM (Knoll et al., 2020).

O melhor compromisso entre a eficiência e qualidade de imagem foi observado em GRAPPA 2 com DRB uma vez que o GRAPPA 2 não acelera em demasia a aquisição e o DRB melhora a qualidade da imagem e consegue reduzir o tempo de aquisição comparado com a utilização única do GRAPPA 2.

4.3 Limitações do estudo

O presente estudo apresentou algumas limitações que devem ser consideradas. Na fase experimental, a avaliação objetiva está limitada apenas a duas métricas específicas (RSR e a uniformidade da intensidade do sinal). A avaliação está focada a apenas uma sequência (DP FS axial). A amostra é por conveniência e o número de participantes limitado. Como existe variação entre observadores, poderia ser uma solução a existência de mais observadores.

4.4 Implicações Clínicas

Os resultados obtidos na concretização deste estudo reforçam o potencial da inteligência artificial, neste caso o DRB, na otimização dos protocolos de RM, permitindo reduzir o tempo de exame, aumentando a eficiência dos serviços de imagiologia e melhorando a qualidade de imagem diagnóstica.

No entanto, a ausência de melhoria em alguns dos tópicos abordados indica que a utilização destes algoritmos de IA devem ser cuidadosamente avaliados e integrados de forma crítica na prática clínica.

Esta página foi propositadamente deixada em branco.

Capítulo 5 - Conclusão

A presente dissertação teve como principal objetivo o impacto da aplicação de um algoritmo de inteligência artificial, o DRB, na qualidade de imagem em estudos do joelho por RM de 3T, integrando métricas objetivas e subjetivas.

Os resultados obtidos permitem concluir que a utilização do DRB constitui uma ferramenta eficaz para a otimização dos protocolos de RM. Permite também concluir que se consegue reduzir o tempo de aquisição de cada sequência sem comprometer a qualidade de diagnóstico das imagens, embora a sua utilização deva ser cuidadosamente avaliada e integrada de forma crítica na prática clínica. De forma mais objetiva, o GRAPPA 2 combinado com o DRB apresenta o melhor equilíbrio entre a eficiência e a qualidade de imagem como demonstrado pela avaliação objetiva e subjetiva na fase clínica observacional.

Os resultados, relativamente à qualidade de imagem e a RSR, evidenciam que o DRB contribui para a manutenção ou melhoria de ambas, em osso e em músculo. O tecido mole manteve o seu sinal estável. A partir deste momento conclui-se que o impacto do DRB pode variar consoante o tecido avaliado. Importante salientar que na fase experimental, em fantoma, não foi possível demonstrar manutenção ou melhoria da RSR com a utilização de DRB, pelo contrário, uma pequena redução da mesma. Isto reforça que a avaliação em contexto clínico foi essencial neste estudo.

No que concerne à presença de artefactos, conclui-se que o DRB não aumenta a sua ocorrência, e sim o oposto, pode contribuir para a sua suavização, sem introduzir distorções relevantes que comprometam a avaliação diagnóstica clínica.

De forma global os resultados, sugerem que o DRB consegue atenuar algumas das limitações das técnicas de imagem paralela como a utilizada nesta dissertação, GRAPPA, mantendo sempre um compromisso entre o tempo de aquisição e a qualidade de imagem diagnóstica. Contribui, assim, para a otimização mais eficiente de protocolos de RM em contexto músculo-esquelético.

Devem ser ainda consideradas as limitações deste estudo, nomeadamente, a dimensão da amostra, as métricas objetivas utilizadas e a utilização de apenas uma sequência (DP FS axial). Demonstra a necessidade de estudos futuros com amostras amplas, várias sequências e a inclusão de outras métricas de qualidade de imagem.

Em conclusão, a utilização do DRB em RM do joelho em sistemas de 3T apresenta-se como uma estratégia promissora para a otimização de protocolos e otimização da qualidade de imagem. Pode conduzir para aumentar a eficiência dos serviços de imagiologia e melhorar a experiência do doente. É um avanço relevante, mas necessita sempre que esta seja implementada cuidadosamente e integrada de forma crítica na prática clínica para garantir que os ganhos tecnológicos se traduzem efetivamente em benefícios clínicos reais.

Esta página foi propositadamente deixada em branco.

Referências bibliográficas

- Afonso, A., & Nunes, C. (2019). *Probabilidades e estatística: Aplicações e soluções em SPSS* (versão revista e aumentada). Universidade de Évora.
- Al Kuwaiti, A., Nazer, K., Al-Redaey, A., Al-Shehri, S., Al-Muhanna, A., Subbarayalu, A. V., Al-Muhanna, D., & Al-Muhanna, F. A. (2023). *A review of the role of artificial intelligence in healthcare. Journal of Personalized Medicine*, 13(6), 951. <https://doi.org/10.3390/jpm13060951>
- American College of Radiology. (2015). *Magnetic resonance imaging quality control manual*. American College of Radiology.
- Bauer, J. S., Banerjee, S., Henning, T. D., Krug, R., Majumdar, S., & Link, T. M. (2007). *Fast high-spatial-resolution MRI of the ankle with parallel imaging using GRAPPA at 3 T. American Journal of Roentgenology*, 189(1), 240–245. <https://doi.org/10.2214/AJR.07.2066>
- Blaimer, M., Breuer, F., Mueller, M., Heidemann, R. M., Griswold, M. A., & Jakob, P. M. (2004). *SMASH, SENSE, PILS, GRAPPA: how to choose the optimal method. Topics in Magnetic Resonance Imaging*, 15 (4), 223-236. <https://doi.org/10.1097/01.rmr.0000136558.09801.dd>
- Bontrager, K.L., & Lampignano. J.P. (2014). *Textbook of radiographic positioning and related anatomy* (8th ed.). Elsevier.
- Brown, M. A., & Semelka, R. C. (2010). *MRI: Basic principles and applications* (3^{er} ed.). Wiley-Blackwell.
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., Jr., & Boone. J.M. (2012). *The essential physics of medical imaging* (3^{er} ed.) Lippincott Williams & Wilkins.
- Chien, A., Weaver, J.S., Kinne, E., & Omar, I. (2020). *Magnetic resonance imaging of the knee. Polish Journal of Radiology*, 85, e509-e531. <https://doi.org/10.5114/pjr.2020.99415>
- Costa, S. I. G. da. (2016). *Relações patelofemorais por tomografia computadorizada: Análise da variabilidade das medições* [Dissertação de mestrado, Instituto Superior de Engenharia do Porto].
- Creswell, J. W. (2014). *Research design: Qualitative, quantitative, and mixed methods approaches* (4th ed.). SAGE Publications.
- Deshmane, A., Gulani, V., Griswold, M. A., & Seiberlich, N. (2012). *Parallel MR imaging. Journal of Magnetic Resonance Imaging*, 36(1), 55–72. <https://doi.org/10.1002/jmri.23639>

- Donners, R., Vosschenrich, J. Gutzeit, A., Bach, M., Schlicht, F., Obmann, M. M., Harder, D., & Breit, H.-C. (2024). *New-generation 0.55 T MRI of the knee-Initial clinical experience and comparison with 3 T MRI*. *Investigative Radiology*, 59(4), <https://doi.org/10.1097/rli.0000000000001016>
- Drake, R.L., Vogl, A. W., & Mitchell, A. W. M. (2004). *Gray's anatomy for students*. Elsevier Churchill Livingstone
- Epistatou, A. C., Tsalafoutas, I. A., & Delibasis, K. K. (2020). *An automated method for quality control in MRI systems: Methods and considerations*. *Journal of Imaging*, 6(11), 111. <https://doi.org/10.3390/jimaging6110111>
- Ertel, W. (2017). *Introduction to artificial intelligence* (3rd ed.). Springer.
- Foti, G., & Longo, C. (2024). *Deep learning and AI in reducing magnetic resonance imaging scanning time: Advantages and pitfalls in clinical practice*. *Polish Journal of Radiology*, 89, e443-e451. <https://doi.org/10.5114/pjr/192822>
- Fritz, J., Guggenberger, R., & Del Grande, F. (2021). *Rapid musculoskeletal MRI in 2021: Clinical application of advanced accelerated techniques*. *American Journal of Roentgenology*, 216(3), 718–733. <https://doi.org/10.2214/AJR.20.22902>
- Glockner, J. F. Hu, H. H., Stanley, D. W., Angelos, L., & King, K. (2005). *Parallel MR imaging: A user's guide*. *Radiographics*. 25(5), 1279-1297. <https://doi.org/10.1148/rg.255045202>
- Grupo Articulação. (2024). *Joelho: Anatomia, funcionalidade e possíveis causas de dor*. <https://grupoarticulacao.com.br/joelho/>
- Gupton, M., Imonugo, O., Black, A. C., Launico, M. V., & Terreberry, R. R. (2023). *Anatomy, bony pelvis and lower limb, knee*. In StatPearls. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK500017/>
- Hammernik, K., Klatzer, T., Kobler, E., Recht, M. P., Sodickson, D. K., Pock, T., & Knoll, F. (2018). *Learning a variational network for reconstruction of accelerated MRI data*. *Magnetic Resonance in Medicine*, 79(6), 3055-3071. <https://doi.org/10.1002/mrm.26977>
- Kaniewska, M., Deininger-Czermak, E., Getzmann, J. M., Wang, X., Lohezic, M., & Guggenberger, R. (2023). *Application of deep learning-based image reconstruction in MR imaging of the shoulder joint to improve image quality and reduce scan time*. *European Radiology*, 33(3), 1513–1525. <https://doi.org/10.1007/s00330-022-09151-1>
- Kline, R. B. (2016). *Principles and practice of structural equation modeling* (4th ed.). Guilford Press.

- Knoll, F., Hammernik, K., Zhang, C., Moeller, S., Pock, T., Sodickson, D. K., & Akçakaya, M. (2020). *Deep-learning methods for parallel magnetic resonance imaging reconstruction: A survey of the current approaches, trends, and issues*. *IEEE Signal Processing Magazine*, 37(1), 128-140. <https://doi.org/10.1109/MSP.2019.2950640>
- Laureano, R. M. S. (2020). *Testes de hipóteses e regressão: O meu manual de consulta rápida* (3.^a ed.). Edições Sílabo.
- Liang, Z.-P., & Lauterbur, P. C. (2000). *Principles of magnetic resonance imaging: A signal processing perspective*. IEE Press.
- Melquiades, R. O., Nunes, M.R., Garcia, A. C. C., Assunção, A. L. P., & Vieira, V.R. (2020). *Crítérios diagnósticos para pesquisa de fatores predisponentes da instabilidade femoropatelar: Uma revisão de literatura*. *Brazilian Journal of Health Review*, 3(2), 2742-2751. <https://doi.org/10.34119/bjhrv3n2-119>
- MRI Questions (s.d.). *Signal-to-noise ratio (SNR)*. <https://mriquestions.com/signal-to-noise.html>
- Netter, F.H. (2010). *Atlas de anatomia humana* (5.^a ed., edição em português)
- Organisation for Economic Co-operation and Development (s.d.). *Magnetic resonance imaging (MRI) exams*. <https://www.oecd.org/en/data/indicators/magnetic-resonance-imaging-mri-exams.html>
- Putz, R., & Pabst, R. (Eds.). (2006). *Sobotta: Atlas de anatomia humana (Vol. 2: Tronco, vísceras e extremidade inferior)* (21.^a ed.). Guanabara Koogan.
- Recht, M. P., White, L. M., Fritz, J., & Resnick, D. L. (2023). *Advances in musculoskeletal imaging: Recent developments and predictions for the future*. *Radiology*, 308(2), e230615. <https://doi.org/10.1148/radiol.230615>
- Reschke, P., Gotta, J., Gruenewald, L. D., Ait Bachir, A., Strecker, R., Nickel, D., Booz, C., Martin, S. S., Scholtz, J.-E., D'Angelo, T., Dahm, D., Solim, L. A., Konrad, P., Mahmoudi, S., Bernatz, S., Al-Saleh, M., Le Hong, Q. A., Sommer, C. M., Eichler, K., Vogl, T. J., Haberkorn, S. M., & Koch, V. (2025). *Deep learning in knee MRI: A prospective study to enhance efficiency, diagnostic confidence and sustainability*. *Academic Radiology*, 32(3), 3585–3596. <https://doi.org/10.1016/j.acra.2025.03.018>
- Saragoça, J. (2012). *Diagnóstico e prospectiva social*. Universidade de Évora.
- Seeley, R. R., Stephens, T.D., & Tate, P. (2011). *Anatomia e fisiologia* (6.^a ed.). Lusociência.
- Siemens Healthineers. (s.d.). *Deep Resolve Boost*. <https://www.siemens-healthineers.com/magnetic-resonance-imaging/options-and-upgrades/clinical-applications/deep-resolve-boost>

- Siemens Healthineers. (s.d.). *MAGNETOM Vida – 3T MRI scanner*. <https://www.siemens-healthineers.com/pt/magnetic-resonance-imaging/3t-mri-scanner/magnetom-vida>
- Sneag, D.B., Abel, F., Potter, H. G., Fritz, J., Koff, M.F., Chung, C.B., Pedoia, V., & Tan, E. T. (2023). *MRI advancements in musculoskeletal clinical and research practise*. *Radiology*, 308 (2), e230531. <https://doi.org/10.1148/radiol.230531>
- Vashistha, R., Almuqbel, M. M., Palmer, N. J., Keenan, R.J., Gilbert, K., Wells, S., Lynch, A., Lynch, A., Kingston-Smith, S., Melzer, T.R., Koerzdorfer, G., & O'Brien, K. (2024). *Evaluation of deep-learning TSE images in clinical musculoskeletal imaging*. *Journal of Medical Imaging and Radiation Oncology*, 68(4). 556-563. <https://doi.org/10.1111/1754-9485.13714>
- Vosshenrich, J., Koerzdorfer, G., & Fritz, J. (2024). *Modern acceleration in musculoskeletal MRI: Applications, implications, and challenges*. *Skeletal Radiology*, 53(9), 1799–1813. <https://doi.org/10.1007/s00256-024-04634-2>
- Westbrook, C. (2002). *MRI at a glance* (1ed.). Wiley-Blackwell.
- Westbrook, C. Roth, C. K., & Talbot, J. (2011). *MRI in practise* (4th ed.). Wiley-Blackwell.
- Westbrook, C., Roth, C.K., & Talbot, J. (2013). *Ressonância Magnética: Aplicações práticas* (4^a ed.). Guanabara Koogan.
- Wilson, R. (2023) *Artificial intelligence, machine learning, deep learning and MRI*. *The Newsletter of the British Association of MR Radiographers*, 60, 10-11
- White, O. A., Shur, J., Castagnoli, F., Charles-Edwards, G., Whitcher, B., Collins, D. J., Cashmore, M. T. D., Hall, M. G., Thomas, S. A., Thompson, A., Harrison, C. A., Hopkinson, G., Koh, D.-M., & Winfield, J. M. (2025). Quantitative image quality metrics enable resource-efficient quality control of clinically applied AI-based reconstructions in MRI. *Magnetic Resonance Materials in Physics, Biology and Medicine*, 38, 547–560. <https://doi.org/10.1007/s10334-025-01253-3>
- Yoo, H. J. (2025). *Deep learning-based image reconstruction in musculoskeletal MRI*. *Journal of the Korean Society of Radiology*, 86(5), 567–586. <https://doi.org/10.3348/jksr.2025.0015>

Esta página foi propositadamente deixada em branco.

Apêndices

7.1 Apêndice A – Tabelas de avaliação pela escala Likert

ID:

Leitor:

Sequência	Artefactos (1 a 5)	Definição de estruturas (1 a 5)	Ruído Percebido (1 a 5)	Qualidade Global (1 a 5)
1				
2				
3				
4				
5				
6				

ID

Leitor:

Sequência	Artefactos (1 a 5)	Definição de estruturas (1 a 5)	Ruído Percebido (1 a 5)	Qualidade Global (1 a 5)
1				
2				
3				
4				
5				
6				

Artefactos (1 a 5)

- 1 - Sem Artefactos
- 2 - Artefactos Mínimos
- 3 - Artefactos Moderados
- 4 - Artefactos Relevantes
- 5 - Artefactos Graves

Definição de estruturas (1 a 5)

- 1 - Muito má
- 2 - Má
- 3 - Moderada
- 4 - Boa
- 5 - Excelente

Ruído percebido (1 a 5)

- 1 - Nenhum
- 2 - Pouco
- 3 - Moderado
- 4 - Elevado
- 5 - Muito Elevado

Qualidade Global (1 a 5)

- 1 - Muito má
- 2 - Má
- 3 - Aceitável
- 4 - Boa
- 5 - Excelente

7.2 Apêndice B – Parecer da comissão de ética



COMISSÃO DE ÉTICA PARA A SAÚDE DA JCS

PARECER 01/2025

Foi submetido à Comissão de Ética para a Saúde da Joaquim Chaves Saúde (CES-JCS) o pedido de parecer identificado com o número de processo: nº 01-2025-Clínico para que a mesma se pronunciasse sobre as questões de ética suscitadas no protocolo de investigação em que a Joaquim Chaves Saúde está envolvida.

O protocolo de investigação insere-se no Âmbito do projeto: “ **O impacto da IA na qualidade de imagem em estudos de joelho por RM de 3T**”, sendo o investigador, na qualidade de coorientador deste projeto, associado à Joaquim Chaves Saúde: Tiago Costa Cabrita, Técnico Superior de Radiologia e o PI do projeto: José Carlos Andrade Lopes, Técnico Superior de Radiologia na Unidade Local de Saúde de Loures / Odivelas, E.P.E. - Hospital Beatriz Ângelo.

O Investigador associado ao Projeto em avaliação e com vínculo à Joaquim Chaves Saúde compromete-se a assegurar que durante o estudo serão respeitadas todas as disposições legais em vigor e as recomendações constantes da Declaração de Helsínquia, da OMS e demais disposições no que se refere à investigação que envolva seres humanos.

A CES-JCS conclui que os objetivos do estudo são relevantes e que o mesmo é conduzido por uma equipa de investigação competente e a ponderação ética benefício/risco é positiva. Esta conclusão reflete na íntegra a posição dos relatores que avaliaram o processo em causa, a qual foi aceite por todos os elementos que compõem a CES-JCS.

De acordo com os parâmetros avaliados por esta Comissão e a documentação entregue pelos investigadores e em conformidade com a legislação em vigor, a CES-JCS concede **parecer positivo/favorável** relativamente à realização do presente protocolo de investigação. A CES-JCS recomenda, deste modo, à Administração da JCS a apreciação final favorável e a respetiva homologação do presente protocolo de investigação em avaliação.

Carnaxide, 19 de dezembro de 2025.

O Presidente da CES-JCS

Assinado por: Rui Manuel Amaro Pinto
Num. de Identificação: 07413420
Data: 2025.12.22 23:06:55+00'00'

(Prof. Doutor Rui Manuel Amaro Pinto)

7.3 Apêndice C – Consentimento informado participantes

Consentimento Informado Para Participação Em Estudo de Investigação

Investigador Responsável: José Carlos Andrade Lopes (Estudante de Mestrado em Imagem Médica e Radioterapia – Escola Superior De Tecnologias da Saúde Da Universidade De Coimbra)

Orientadores: Prof. Óscar Manuel da Conceição Tavares; Prof. Tiago da Costa Cabrita e Prof. Rui Miguel da Silva Castro Pereira.

Instituição onde decorre o estudo: Clínica Joaquim Chaves - Miraflores

Título do estudo: O impacto da IA na qualidade de imagem em estudos de joelho por RM de 3T.

Enquadramento e objetivos: Desenvolvimento de um estudo científico com o objetivo de analisar o impacto de um software de inteligência artificial em estudos de ressonância magnética do joelho, avaliando a qualidade de imagem, tempo de aquisição e possíveis artefactos presentes em equipamentos de 3 Tesla.

Procedimento: O exame é realizado de acordo com o protocolo clínico habitual. São adquiridas as imagens para posterior análise. As imagens e os dados serão todos anonimizados (sem qualquer identificação). O seu exame terá um aumento do tempo de exame em 13 minutos.

Riscos: A participação não envolve riscos adicionais a um exame de ressonância magnética normal.

Benefícios: Não existe benefício direto para o utente, mas poderá contribuir para uma melhoria futura da qualidade de imagens e eficiência de exames de ressonância magnética.

Confidencialidade dos dados: Todos os dados recolhidos serão tratados de forma confidencial e anónima. Nenhum elemento de identificação pessoal será associado às imagens analisadas. O armazenamento e tratamento dos dados cumpre o Regulamento Geral de Proteção de Dados (RGPD – UE 2016/679).

Voluntariedade e direito de desistência: A sua participação é totalmente voluntária. Pode recusar ou retirar o consentimento a qualquer momento, sem qualquer prejuízo na sua relação com a instituição nem impacto no seu tratamento clínico.

Declaração de consentimento: Li e compreendi as informações acima apresentadas sobre o estudo "O impacto da IA na qualidade de imagem em estudos de joelho por RM de 3T." Tive a oportunidade de colocar todas as minhas dúvidas e estas foram esclarecidas de forma clara. Compreendo que a minha participação é voluntária e que posso desistir a qualquer momento, sem qualquer consequência para a minha situação clínica.

Declaro que aceito participar neste estudo.

Data: ____/____/____ Assinatura do participante: _____

Nome do investigador que recolheu o consentimento: _____

Assinatura do investigador que recolheu o consentimento: _____

7.4 Apêndice D - Outputs Testes estatísticos

7.4.1 Análise leitores – Artefactos

7.4.1.1 Post-Hoc – Leitores

Comparações por Método Pairwise

Medida: MEASURE_1

G	(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^a	95% Intervalo de Confiança para Diferença ^a	
						Limite inferior	Limite superior
1	1	2	-,112	,075	,141	-,264	,039
	2	1	,112	,075	,141	-,039	,264
2	1	2	-,050	,117	,672	-,287	,187
	2	1	,050	,117	,672	-,187	,287
3	1	2	,113	,108	,305	-,106	,331
	2	1	-,113	,108	,305	-,331	,106

Baseado em médias marginais estimadas

a. Ajustamento para diversas comparações: Sidak.

7.4.2 Análise leitores – Definição de estruturas

7.4.2.1 Post-Hoc – Leitores

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Leitor	(J) Leitor	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	-,267 [*]	,073	<,001	-,414	-,119
2	1	,267 [*]	,073	<,001	,119	,414

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

Comparações por Método Pairwise

Medida: MEASURE_1

(I) G	(J) G	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	,069	,070	,706	-,107	,245
	3	,387 [*]	,072	<,001	,209	,566
2	1	-,069	,070	,706	-,245	,107
	3	,319 [*]	,068	<,001	,149	,489
3	1	-,387 [*]	,072	<,001	-,566	-,209
	2	-,319 [*]	,068	<,001	-,489	-,149

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.2.2 Post-Hoc - DRB

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	-,992 [*]	,057	<,001	-1,106	-,877
2	1	,992 [*]	,057	<,001	,877	1,106

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

Comparações por Método Pairwise

Medida: MEASURE_1

G	(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
						Limite inferior	Limite superior
1	1	2	-,262 [*]	,088	,005	-,440	-,085
	2	1	,262 [*]	,088	,005	,085	,440
2	1	2	-,875 [*]	,101	<,001	-1,079	-,671
	2	1	,875 [*]	,101	<,001	,671	1,079
3	1	2	-1,838 [*]	,103	<,001	-2,047	-1,628
	2	1	1,838 [*]	,103	<,001	1,628	2,047

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.3 Análise dos leitores – Ruído percebido

7.4.3.1 Post-Hoc – Leitores

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Leitor	(J) Leitor	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	-,721 [*]	,074	<,001	-,870	-,572
2	1	,721 [*]	,074	<,001	,572	,870

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.3.2 Post-Hoc – DRB

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	1,071 [*]	,064	<,001	,941	1,200
2	1	-1,071 [*]	,064	<,001	-1,200	-,941

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.3.3 Post-Hoc – GRAPPA

Comparações por Método Pairwise

Medida: MEASURE_1

(I) G	(J) G	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	-,181 [*]	,061	,015	-,333	-,030
	3	-1,031 [*]	,066	<,001	-1,196	-,867
2	1	,181 [*]	,061	,015	,030	,333
	3	-,850 [*]	,065	<,001	-1,012	-,688
3	1	1,031 [*]	,066	<,001	,867	1,196
	2	,850 [*]	,065	<,001	,688	1,012

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.3.4 Post-Hoc – GRAPPA * DRB

Comparações por Método Pairwise

Medida: MEASURE_1

G	(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
						Limite inferior	Limite superior
1	1	2	-,188 [*]	,077	,020	-,344	-,031
	2	1	,188 [*]	,077	,020	,031	,344
2	1	2	,775 [*]	,107	<,001	,558	,992
	2	1	-,775 [*]	,107	<,001	-,992	-,558
3	1	2	2,625 [*]	,118	<,001	2,385	2,865
	2	1	-2,625 [*]	,118	<,001	-2,865	-2,385

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.4 Análise dos leitores – Qualidade global

7.4.4.1 Post-Hoc – Leitores

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Leitor	(J) Leitor	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	-,217 [*]	,082	,012	-,383	-,050
2	1	,217 [*]	,082	,012	,050	,383

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.4.2 Post-Hoc – DRB

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	-1,075 [*]	,059	<,001	-1,194	-,956
2	1	1,075 [*]	,059	<,001	,956	1,194

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.4.3 Post-Hoc – GRAPPA

Comparações por Método Pairwise

Medida: MEASURE_1

(I) G	(J) G	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
					Limite inferior	Limite superior
1	2	,106	,073	,389	-,075	,288
	3	,462 [*]	,091	<,001	,235	,690
2	1	-,106	,073	,389	-,288	,075
	3	,356 [*]	,080	<,001	,158	,555
3	1	-,462 [*]	,091	<,001	-,690	-,235
	2	-,356 [*]	,080	<,001	-,555	-,158

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.4.4 Post-Hoc – GRAPPA*DRB

Comparações por Método Pairwise

Medida: MEASURE_1

G	(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^b	95% Intervalo de Confiança para Diferença ^b	
						Limite inferior	Limite superior
1	1	2	-,287 [*]	,095	,004	-,479	-,096
	2	1	,287 [*]	,095	,004	,096	,479
2	1	2	-,875 [*]	,104	<,001	-1,085	-,665
	2	1	,875 [*]	,104	<,001	,665	1,085
3	1	2	-2,063 [*]	,106	<,001	-2,277	-1,848
	2	1	2,063 [*]	,106	<,001	1,848	2,277

Baseado em médias marginais estimadas

*. A diferença média é significativa no nível ,05.

b. Ajustamento para diversas comparações: Sidak.

7.4.5 Osso versus GRAPPA versus DRB

7.4.5.1 Teste de Esfericidade de Mauchly

Teste de esfericidade de Mauchly^a

Medida: MEASURE_1

Efeito dentre-sujeitos	W de Mauchly	Aprox. Qui-quadrado	df	Sig.	Epsilon ^b		
					Greenhouse-Geisser	Huynh-Feldt	Limite inferior
G	,829	7,114	2	,029	,854	,889	,500
Boost	1,000	,000	0	.	1,000	1,000	1,000
G * Boost	,973	1,057	2	,589	,973	1,000	,500

Testa a hipótese nula para a qual a matriz de covariâncias de erro das variáveis transformadas ortonormalizadas é proporcional em relação a uma matriz identidade.

a. Design: Intercepto

Design Dentre-Sujeitos: G + Boost + G * Boost

b. Pode ser usado para ajustar os graus de liberdade dos testes de significância dentro da média. Os testes corrigidos são exibidos na tabela Testes de efeitos dentre-sujeitos.

7.4.5.2 Teste ANOVA

Testes de efeitos dentro-sujeitos

Medida: MEASURE_1

Origem		Tipo III Soma dos Quadrados	df	Quadrado Médio	F	Sig.
G	Esfericidade considerada	440,033	2	220,016	17,552	<,001
	Greenhouse-Geisser	440,033	1,708	257,580	17,552	<,001
	Huynh-Feldt	440,033	1,779	247,380	17,552	<,001
	Limite inferior	440,033	1,000	440,033	17,552	<,001
Erro(G)	Esfericidade considerada	977,738	78	12,535		
	Greenhouse-Geisser	977,738	66,625	14,675		
	Huynh-Feldt	977,738	69,372	14,094		
	Limite inferior	977,738	39,000	25,070		
Boost	Esfericidade considerada	42,935	1	42,935	1,337	,255
	Greenhouse-Geisser	42,935	1,000	42,935	1,337	,255
	Huynh-Feldt	42,935	1,000	42,935	1,337	,255
	Limite inferior	42,935	1,000	42,935	1,337	,255
Erro(Boost)	Esfericidade considerada	1252,497	39	32,115		
	Greenhouse-Geisser	1252,497	39,000	32,115		
	Huynh-Feldt	1252,497	39,000	32,115		
	Limite inferior	1252,497	39,000	32,115		
G * Boost	Esfericidade considerada	155,645	2	77,822	4,623	,013
	Greenhouse-Geisser	155,645	1,947	79,957	4,623	,013
	Huynh-Feldt	155,645	2,000	77,822	4,623	,013
	Limite inferior	155,645	1,000	155,645	4,623	,038
Erro(G*Boost)	Esfericidade considerada	1313,093	78	16,835		
	Greenhouse-Geisser	1313,093	75,917	17,296		
	Huynh-Feldt	1313,093	78,000	16,835		
	Limite inferior	1313,093	39,000	33,669		

7.4.5.3 Comparações Post-Hoc

Comparações por Método Pairwise

Medida: MEASURE_1

(I) Boost	(J) Boost	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^a	95% Intervalo de Confiança para Diferença ^a	
					Limite inferior	Limite superior
1	2	,846	,732	,255	-,634	2,326
2	1	-,846	,732	,255	-2,326	,634

Baseado em médias marginais estimadas

a. Ajustamento para diversas comparações: Sidak.

7.4.6 Músculo versus GRAPPA versus DRB

7.4.6.1 Teste ANOVA

Testes de efeitos dentre-sujeitos

Medida: MEASURE_1

Origem		Tipo III Soma dos Quadrados	df	Quadrado Médio	F	Sig.
G	Esfericidade considerada	96,597	2	48,298	1,936	,151
	Greenhouse-Geisser	96,597	1,883	51,312	1,936	,154
	Huynh-Feldt	96,597	1,975	48,913	1,936	,152
	Limite inferior	96,597	1,000	96,597	1,936	,172
Erro(G)	Esfericidade considerada	1945,774	78	24,946		
	Greenhouse-Geisser	1945,774	73,419	26,502		
	Huynh-Feldt	1945,774	77,020	25,263		
	Limite inferior	1945,774	39,000	49,892		
Boost	Esfericidade considerada	141,281	1	141,281	4,827	,034
	Greenhouse-Geisser	141,281	1,000	141,281	4,827	,034
	Huynh-Feldt	141,281	1,000	141,281	4,827	,034
	Limite inferior	141,281	1,000	141,281	4,827	,034
Erro(Boost)	Esfericidade considerada	1141,415	39	29,267		
	Greenhouse-Geisser	1141,415	39,000	29,267		
	Huynh-Feldt	1141,415	39,000	29,267		
	Limite inferior	1141,415	39,000	29,267		
G * Boost	Esfericidade considerada	135,644	2	67,822	3,278	,043
	Greenhouse-Geisser	135,644	1,841	73,682	3,278	,047
	Huynh-Feldt	135,644	1,928	70,360	3,278	,045
	Limite inferior	135,644	1,000	135,644	3,278	,078
Erro(G*Boost)	Esfericidade considerada	1613,955	78	20,692		
	Greenhouse-Geisser	1613,955	71,796	22,480		
	Huynh-Feldt	1613,955	75,186	21,466		
	Limite inferior	1613,955	39,000	41,383		

7.4.6.2 Comparações Post-Hoc

Comparações por Método Pairwise

Medida: MEASURE_1

(I) G	(J) G	Diferença média (I-J)	Estatística do teste Padrão	Sig. ^a	95% Intervalo de Confiança para Diferença ^a	
					Limite inferior	Limite superior
1	2	-1,469	,797	,203	-3,456	,519
	3	-1,174	,868	,456	-3,339	,990
2	1	1,469	,797	,203	-,519	3,456
	3	,294	,695	,965	-1,440	2,029
3	1	1,174	,868	,456	-,990	3,339
	2	-,294	,695	,965	-2,029	1,440

Baseado em médias marginais estimadas

a. Ajustamento para diversas comparações: Sidak.

7.4.7 Tecido mole versus GRAPPA versus DRB

7.4.7.1 Teste ANOVA

Testes de efeitos dentro-sujeitos

Medida: MEASURE_1

Origem		Tipo III Soma dos Quadrados	df	Quadrado Médio	F	Sig.
G	Esfericidade considerada	159,953	2	79,976	1,055	,353
	Greenhouse-Geisser	159,953	1,719	93,049	1,055	,345
	Huynh-Feldt	159,953	1,791	89,322	1,055	,347
	Limite inferior	159,953	1,000	159,953	1,055	,311
Erro(G)	Esfericidade considerada	5911,712	78	75,791		
	Greenhouse-Geisser	5911,712	67,042	88,179		
	Huynh-Feldt	5911,712	69,839	84,647		
	Limite inferior	5911,712	39,000	151,582		
Boost	Esfericidade considerada	45,371	1	45,371	,677	,416
	Greenhouse-Geisser	45,371	1,000	45,371	,677	,416
	Huynh-Feldt	45,371	1,000	45,371	,677	,416
	Limite inferior	45,371	1,000	45,371	,677	,416
Erro(Boost)	Esfericidade considerada	2613,962	39	67,025		
	Greenhouse-Geisser	2613,962	39,000	67,025		
	Huynh-Feldt	2613,962	39,000	67,025		
	Limite inferior	2613,962	39,000	67,025		
G * Boost	Esfericidade considerada	142,186	2	71,093	,923	,401
	Greenhouse-Geisser	142,186	1,734	82,001	,923	,390
	Huynh-Feldt	142,186	1,807	78,665	,923	,393
	Limite inferior	142,186	1,000	142,186	,923	,343
Erro(G*Boost)	Esfericidade considerada	6005,619	78	76,995		
	Greenhouse-Geisser	6005,619	67,624	88,809		
	Huynh-Feldt	6005,619	70,492	85,196		
	Limite inferior	6005,619	39,000	153,990		