



Otimização e implementação de um protocolo de baixa dose em tomografia computadorizada do tórax

FABIANA MARGARIDA OLIVEIRA SILVA

outubro de 2025

Otimização e implementação de um protocolo de baixa dose em tomografia computadorizada do tórax

Fabiana Margarida Oliveira Silva

**Dissertação para obtenção do Grau de Mestre em
Engenharia Biomédica**

Orientador: António Teixeira Sousa

Co-orientador: Neusa Conceição

Júri:

Presidente:

Joaquim Alves

Vogais:

António Teixeira Sousa

Jorge Mendonça

Resumo

A tomografia computadorizada (TC) é uma técnica fundamental no diagnóstico por imagem, mas está associada a doses elevadas de radiação. Este trabalho teve como objetivo desenvolver e validar um protocolo de baixa dose em TC torácica que reduza a exposição sem comprometer a qualidade diagnóstica.

Foram realizados ensaios em fantoma com diferentes combinações de kV, mAs, Pitch e AIDR. A dose foi avaliada pelo CTDIvol e a qualidade através de métricas objetivas e subjetivas. Ajustaram-se modelos de regressão polinomial, permitindo prever relações entre parâmetros técnicos e desempenho. Com base nas previsões, geraram-se combinações adicionais e identificaram-se protocolos otimizados pela análise de Pareto.

Os resultados mostraram correlações claras entre kV/mAs e aumento da dose, e efeito redutor do Pitch. O modelo final apresentou bom desempenho (R^2 ajustado $\sim 0,80$), permitindo selecionar protocolos com CTDIvol entre 2,7 e 3,9 mGy e qualidade ≥ 10 . A validação clínica em seis doentes confirmou uma redução média de 42% na dose em relação ao protocolo convencional, mantendo a qualidade de imagem aceitável.

Conclui-se que a otimização sistemática de protocolos de TC é eficaz para reduzir a dose mantendo a fiabilidade diagnóstica, em consonância com os princípios de proteção radiológica.

Palavras-chave: Tomografia Computorizada; Otimização de Dose; Regressão Polinomial; Análise de Pareto; Protocolos de Baixa Dose

Abstract

Computed tomography (CT) is a key imaging modality but is associated with high radiation doses. This study aimed to develop and validate a low-dose chest CT protocol that reduces exposure without compromising diagnostic quality.

Phantom experiments were conducted with varying kV, mAs, Pitch, and AIDR. Dose was assessed through CTDIvol and image quality by objective and subjective metrics. Polynomial regression models were fitted to predict the relationships between technical parameters and outcomes. Based on these models, additional combinations were generated and optimized protocols identified through Pareto front analysis.

Results showed clear correlations between kV/mAs and increased dose, and a reducing effect of higher Pitch. The final model performed well (adjusted $R^2 \sim 0.80$), allowing selection of protocols with CTDIvol between 2.7–3.9 mGy and quality ≥ 10 . Clinical validation in six patients confirmed an average 42% dose reduction compared to the conventional protocol, while maintaining clinically acceptable image quality.

In conclusion, systematic CT protocol optimization effectively reduces dose while preserving diagnostic reliability, in line with radiation protection principles.

Keywords: Computed Tomography; Dose Optimization; Polynomial Regression; Pareto Analysis; Low-Dose Protocols

Agradecimentos

Quero expressar a minha sincera gratidão ao meu orientador, António Teixeira Sousa, pela orientação científica, pela disponibilidade constante e pelo rigor transmitido ao longo deste trabalho. À coorientadora Neusa Conceição, agradeço as valiosas sugestões e o acompanhamento próximo, fundamentais para a concretização desta dissertação.

Ao Instituto Superior de Engenharia do Porto (ISEP), manifesto o meu reconhecimento pelo ensino de excelência e pelas condições disponibilizadas para o desenvolvimento deste trabalho. À instituição parceira Unidade Local de Saúde Entre Douro e Vouga (ULSEDV), agradeço a colaboração e o acesso às infraestruturas que permitiram a realização dos ensaios e da validação clínica.

Aos colegas e amigos, deixo o meu apreço pelo apoio, pela motivação e pelos momentos de companheirismo que tornaram este percurso mais leve.

Por fim, à minha família, agradeço o incentivo inabalável, a paciência nos momentos de maior exigência e a confiança que sempre depositaram em mim.

Índice

1	Introdução	17
2	Revisão bibliográfica.....	19
2.1	A evolução da tomografia computadorizada e a exposição à radiação.....	19
2.2	Fundamentos físicos da Tomografia Computorizada	20
2.3	Modelos de dose e dosimetria	21
2.4	Princípios de otimização da dose	22
2.5	Estratégias de redução de dose	22
2.6	Métricas de avaliação da qualidade de imagem	23
2.7	Estudos de caso relevantes	24
2.8	Otimização de protocolos baseada em modelos matemáticos.....	25
2.9	Considerações finais da revisão	26
3	Metodologia	28
3.1	Equipamento utilizado.....	28
3.2	Fantoma utilizado.....	29
3.3	Plano experimental	30

Orientador: António Teixeira Sousa

Co-orientador: Neusa Conceição

Júri:

Presidente:

Joaquim Alves

Vogais:

António Teixeira Sousa

Jorge Mendonça

3.4	Avaliação da qualidade de imagem.....	30
3.4.1	SNR (SIGNAL-TO-NOISE RATIO)	30
3.4.2	CNR (CONTRAST-TO-NOISE RATIO).....	30
3.4.3	FOM (FIGURE OF MERITE)	31
3.4.4	Avaliação subjetiva	31
3.5	Avaliação da dose de radiação	31
3.6	Tratamento dos dados.....	32
3.6.1	Configuração inicial e bibliotecas utilizadas	32
3.6.2	Importação e pré processamento dos dados	33
3.6.3	Modelação (regressão polinomial de 2º grau) e diagnóstico	34
3.6.4	Geração de novas combinações de ensaios.....	37
3.6.5	Seleção da região admissível	38
3.6.6	Cálculo e visualização da fronteira de Pareto	38
3.6.7	Seleção dos melhores ensaios para validação clínica	40
3.6.8	Análise estatística e otimização dos ensaios	40
3.7	Validação Clínica dos protocolos.....	41
3.7.1	Critérios de inclusão:	41
3.7.2	Critérios de exclusão:	42
3.7.3	Considerações éticas e consentimento informado	42
3.8	Impedimentos e limitações experimentais	42
4	Resultados	44
4.1	Ensaio com fantoma	44
4.2	Modelos estatísticos e regressão polinomial	46
4.3	Geração e seleção de combinações	49
4.4	Validação clínica	50
4.4.1	Comparação dos protocolos	50
4.4.2	Relação com as previsões do modelo.....	51
4.4.3	Síntese dos resultados	52
4.5	Interface interativa para exploração dos resultados.....	52
5	Conclusões	56

Lista de Figuras

Figura 1- Tomografo Canon Aquilion Lightning, modelo de 16 cortes	28
Figura 2- Fantoma utilizado nos ensaios.....	29
Figura 3- Imagem gerada pelo fantoma.....	29
Figura 4 - Exemplo de relatório DICOM gerado pelo equipamento	32
Figura 5- Exemplo de matriz de correlação gerada no 1º ensaio	34
Figura 6 - Exemplo de real vs previsto e bandas de confiança e previsão do primeiro ensaio .	36
Figura 7 - Matriz de correlação entre os parâmetros técnicos e as métricas de qualidade/dose	46
Figura 8 - Gráfico Real Vs Previsto 1º Ciclo	47
Figura 9 - Gráfico Real Vs Previsto 2º Ciclo	48
Figura 10 - Gráfico Real Vs Previsto 3º Ciclo	48
Figura 11 – Gráfico gerado da Fronteira de Pareto.	49
Figura 12 - Imagens comparativas entre TC realizada em 2024 com protocolo convencional (primeira imagem) e em 2025 com protocolo otimizado (segunda imagem).	51
Figura 13 - Interface RAD-OPTIM utilizada para visualizar e explorar os resultados da otimização. A tabela apresenta o Top-N de combinações segundo os filtros definidos; o gráfico mostra a fronteira de Pareto, destacando os protocolos não dominados.	53
Figura 14 - Filtros disponíveis para ajustar a região admissível.....	53
Figura 15 – Exemplo de lista Top-N apresentada na aplicação.....	54
Figura 16- Exemplo de gráfico gerado pela aplicação	55

Lista de Tabelas

Tabela 1- Parâmetros técnicos testados em fantoma e respectivos indicadores de dose e qualidade de imagem.....	44
Tabela 2- Resumo estatístico dos modelos por ciclo (número de ensaios, R^2 ajustado, resíduos médios, colinearidade – VIF).....	46
Tabela 3- Top 10 protocolos simulados selecionados pela Fronteira de Pareto.	50
Tabela 4- Comparação entre protocolo convencional e protocolo otimizado nos 6 doentes incluídos.	50

Acrónimos e Símbolos

Lista de Acrónimos

AEC	<i>Automatic Exposure Control</i>
AIDR	<i>Adaptive Iterative Dose Reduction</i>
CNR	<i>Contrast-to-Noise Ratio</i>
TC	Tomografia Computorizada
CTDIvol	<i>Computed Tomography Dose Index volume</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DLP	<i>Dose Length Product</i>
FOM	<i>Figure of Merit</i>
HU	<i>Hounsfield Unit</i>
ROI	<i>Region of Interest</i>
SNR	<i>Signal-to-Noise Ratio</i>

Lista de Símbolos

Kv	Quilovoltagem
mAs	Miliamperagem-segundo
σ	Desvio padrão
μ	Valor médio/coeficiente de atenuação
π	Pi
β	Coefficiente de regressão

1 Introdução

A tomografia computadorizada (TC) revolucionou o diagnóstico médico por imagem, tornando-se indispensável na medicina atual pela sua precisão na deteção e monitorização de diversas patologias clínicas relevantes. Contudo, a crescente utilização da TC está diretamente associada ao aumento da exposição da população à radiação ionizante. Estima-se que os exames de TC representem cerca de 10% de todos os procedimentos radiológicos, mas contribuam com aproximadamente 60% da dose de radiação absorvida pela população em exames médicos (Prata Mourão et al., 2019; Trattner et al., 2014). Diante deste cenário, torna-se imperativo otimizar o processo de obtenção das imagens TC, reduzindo ao máximo a dose a que o paciente está exposto, sem comprometer a qualidade da imagem para diagnóstico médico.

Este aumento expressivo na dose de radiação tem implicações significativas para a saúde pública. De acordo com dados do *National Council on Radiation Protection and Measurements* (NCRP), a dose média anual de radiação per capita nos Estados Unidos mais do que duplicou entre 1980 e 2006, sendo a TC o principal responsável por esse aumento. Em muitos países desenvolvidos, como os EUA, Reino Unido e Alemanha, essa tendência mantém-se estável ou crescente, apesar dos avanços em tecnologia e novos protocolos (Trattner et al., 2014).

No contexto da TC torácica, frequentemente utilizada para avaliação pulmonar, cardiovascular e oncológica, os desafios são acrescidos devido à necessidade de imagens de alta resolução, à variabilidade anatômica dos pacientes e à elevada frequência dos exames em programas de rastreio, como no caso do cancro do pulmão. Por essas razões, torna-se imperativa a adoção de estratégias eficazes de otimização da dose que permitam reduzir significativamente a exposição à radiação sem comprometer a acuidade diagnóstica essencial para a prática clínica.

Diversos trabalhos têm demonstrado que, a variabilidade nos protocolos utilizados na TC torácica, pode originar diferenças significativas nas doses administradas para exames semelhantes, sem que isso se traduza necessariamente em melhorias na qualidade diagnóstica (Kalra et al., 2020; McCollough et al., 2020). Esta heterogeneidade, associada ao facto de a TC do tórax ser uma modalidade amplamente requisitada em programas de rastreio e no seguimento de doenças crónicas, reforça a necessidade de desenvolver metodologias que

permitam padronizar e otimizar os parâmetros técnicos de forma sistemática. Para além do impacto direto na proteção radiológica dos pacientes, esta abordagem contribui ainda para a sustentabilidade dos serviços de saúde, evitando repetições desnecessárias de exames e reduzindo custos associados.

Neste sentido, a aplicação de ferramentas quantitativas de apoio à decisão, como métricas objetivas de qualidade de imagem (SNR, CNR e FOM) e métodos matemáticos de otimização multicritério, apresenta-se como uma estratégia robusta para identificar protocolos que conciliem, de forma eficiente, a redução da dose com a preservação da acuidade diagnóstica. A implementação de tais estratégias está em consonância com as recomendações internacionais da *International Commission on Radiological Protection* e da *American Association of Physicists in Medicine* (Cody et al., 2021), que sublinham a importância da validação de protocolos de baixa dose em diferentes contextos clínicos.

Sendo assim, o objetivo central deste trabalho consiste em otimizar e validar um protocolo de TC torácica de baixa dose que permita reduzir a exposição à radiação mantendo a qualidade diagnóstica necessária à prática clínica. De forma complementar, definem-se como objetivos específicos: avaliar o impacto de diferentes parâmetros técnicos na dose e na qualidade da imagem em fantasmas, comparar os resultados obtidos com protocolos de rotina através de métricas objetivas e subjetivas, aplicar métodos matemáticos de otimização multicritério para seleção dos protocolos mais eficientes e, por fim, proceder à validação clínica dos protocolos selecionados em pacientes, garantindo a sua aplicabilidade e eficácia em ambiente hospitalar.

2 Revisão bibliográfica

Neste capítulo são revistos os principais aspetos teóricos e práticos que sustentam o presente estudo, incluindo a evolução da tomografia computadorizada, os riscos associados à radiação ionizante, as estratégias de redução de dose e os trabalhos que têm contribuído para a implementação de protocolos de baixa dose em diferentes contextos clínicos. Pretende-se, assim, fornecer um enquadramento geral que permita compreender a relevância e os fundamentos da investigação desenvolvida.

2.1 A evolução da tomografia computadorizada e a exposição à radiação

A tomografia computadorizada surgiu na década de 1970, representando um marco na imagem médica ao permitir a reconstrução de cortes axiais do corpo humano com elevada resolução espacial e contrastes aprimorados. Inicialmente restrita à neuroimagem, a TC expandiu-se para outras regiões anatómicas com o avanço dos detetores e da capacidade computacional (Santos et al., 2023).

Os tomógrafos com multidetetores (MDCT), introduzidos nos anos 1990, permitiram a aquisição volumétrica contínua com dezenas a centenas de cortes por rotação. Com isso, exames como a TC torácica passaram de vários minutos para poucos segundos, aumentando a acessibilidade e a frequência desses procedimentos (El Mansouri et al., 2021).

Esse aumento de velocidade e resolução foi acompanhado de um aumento proporcional na dose de radiação. De acordo com a NCRP (Relatório nº 160), a contribuição da TC para a dose populacional total nos EUA cresceu de menos de 5% em 1980 para mais de 62% em 2006 (*Report No. 160 – Ionizing Radiation Exposure of the Population of the United States (2009) - NCRP | Bethesda, MD, n.d.*). A UNSCEAR (2020) estimou que, mundialmente, a dose média per capita decorrente de exames de TC ultrapassa 1,5 mSv anuais (*UNSCEAR 2020/2021 Report Volume I, n.d.*).

Estudos como o de Trattner et al. (2014) alertam para a necessidade de equilibrar o benefício diagnóstico com os riscos estocásticos da radiação ionizante, especialmente em populações pediátricas ou pacientes submetidos a exames repetidos. A TC torácica, por exemplo, pode resultar numa dose efetiva entre 5 e 7 mSv, o que corresponde a três anos de exposição natural à radiação de fundo (Pandya et al., 2022).

2.2 Fundamentos físicos da Tomografia Computorizada

A tomografia computadorizada baseia-se na atenuação diferencial dos raios X ao atravessar os tecidos do corpo humano. Estruturas com maior número atômico e densidade, como o osso, atenuam mais a radiação do que tecidos de baixa densidade, como o pulmão. Essa variação de atenuação é convertida em valores numéricos denominados unidades Hounsfield (HU), permitindo a diferenciação entre tecidos com pequenas variações de densidade. Este princípio físico constitui a base da elevada sensibilidade da TC para a detecção de alterações estruturais mínimas no organismo (Goldman, 2007).

A qualidade da imagem obtida em TC é determinada por quatro parâmetros principais: contraste, resolução espacial, ruído e artefactos. O contraste depende da diferença de atenuação entre tecidos adjacentes, sendo influenciado pela energia do feixe de raios X. A resolução espacial refere-se à capacidade de distinguir estruturas muito próximas entre si e está diretamente relacionada com o tamanho do pixel, espessura de corte e matriz de reconstrução. O ruído traduz a variação estatística do sinal, manifestando-se como granulação na imagem, e é condicionado pelo número de fótons utilizados. Já os artefactos resultam de limitações técnicas ou fatores anatómicos, podendo prejudicar a interpretação diagnóstica (Raman et al., 2013).

Os parâmetros técnicos de aquisição desempenham um papel determinante neste equilíbrio entre qualidade e dose. A tensão do tubo (kV) define a energia média dos fótons e influencia tanto o contraste da imagem como a dose de radiação administrada; valores mais baixos de kV aumentam o contraste, mas também o ruído. A corrente do tubo e o tempo de exposição (mAs) determinam a quantidade de fótons produzidos, estando diretamente associados à redução do ruído, mas também ao aumento da dose. O pitch, definido como a relação entre o avanço da mesa por rotação e a largura do feixe colimado, controla a sobreposição das projeções e a eficiência da dose. Outros parâmetros, como a espessura de corte e a matriz de reconstrução, permitem ajustar a resolução espacial e o ruído, sendo escolhidos em função da região anatómica e do objetivo clínico (McCollough et al., 2020).

A evolução tecnológica recente trouxe ainda melhorias através da utilização de algoritmos avançados de reconstrução, como as técnicas iterativas, que permitem reduzir significativamente o ruído da imagem e, conseqüentemente, a dose de radiação necessária para manter a qualidade diagnóstica. Além disso, avanços na tecnologia dos detetores, com maior eficiência e menor ruído eletrônico, contribuem para a obtenção de imagens de elevada qualidade com menor exposição, sendo este um dos principais focos de investigação atual em TC (Singh et al., 2011).

2.3 Modelos de dose e dosimetria

A avaliação da dose em TC é um processo complexo, uma vez que depende não apenas dos parâmetros técnicos de aquisição, mas também das características anatômicas e morfológicas de cada paciente. Para permitir uma comparação padronizada entre exames, foram desenvolvidos indicadores baseados em medições realizadas em fantasmas de polimetilmetacrilato (PMMA), associados a câmaras de ionização calibradas. Estes modelos fornecem valores de referência que, embora não representem exatamente a dose absorvida pelo paciente, permitem estimar a exposição e comparar protocolos entre diferentes equipamentos e instituições.

O índice de dose em TC (CTDI) constitui a métrica fundamental para a avaliação da dose em exames clínicos. O CTDI_w (*weighted CTDI*) é obtido pela média ponderada entre medições realizadas no centro e na periferia do fantoma, refletindo a distribuição da dose no campo de radiação. A partir deste índice, calcula-se o CTDI_{vol}, que incorpora a influência do pitch e expressa a dose média por volume examinado. Outro parâmetro amplamente utilizado é o DLP (*Dose Length Product*), obtido pela multiplicação do CTDI_{vol} pelo comprimento do exame, o que permite uma estimativa global da dose depositada ao longo da região anatômica avaliada (Bauhs et al., 2008; Shope et al., 1981)

Embora o CTDI_{vol} e o DLP sejam amplamente usados para monitorização da dose, ambos apresentam limitações significativas, pois não refletem a dose real absorvida por órgãos específicos nem consideram a variabilidade de tamanho e composição corporal entre pacientes. Para contornar essa limitação, foi introduzido o conceito de dose efetiva, que combina o DLP com fatores de conversão específicos para cada região anatômica, estimando o risco biológico global associado ao exame. Contudo, também esta métrica deve ser interpretada com cautela, visto que não representa a dose individual de um paciente, mas sim uma estimativa populacional do risco estocástico (“The 2007 Recommendations of the International Commission on Radiological Protection. ICRP Publication 103,” 2007).

Avanços recentes trouxeram novos modelos de avaliação de dose, como o *Size Specific Dose Estimate* (SSDE), proposto pela AAPM, que ajusta o valor do CTDI_{vol} em função do diâmetro efetivo do paciente, permitindo estimativas mais realistas em adultos e, sobretudo, em crianças (Boone et al., 2011). Adicionalmente, métodos baseados em simulações Monte Carlo permitem calcular a dose em órgãos específicos com elevado grau de precisão, representando o padrão-ouro na estimativa individual de dose em TC. Estes métodos, embora exigentes em termos de recursos computacionais, têm vindo a ser complementados por abordagens baseadas em *machine learning* e *deep learning*, que prometem acelerar os cálculos e viabilizar a personalização da dosimetria em contexto clínico (Giansante et al., 2018; Verfaillie et al., 2024).

2.4 Princípios de otimização da dose

A otimização da dose em tomografia baseia-se em princípios definidos pela Comissão Internacional de Proteção Radiológica (ICRP), em especial no seu relatório (ICRP, 2007) . Os pilares da proteção radiológica médica são: justificação, otimização e limitação. A justificação assegura que um exame deve ser clinicamente necessário, enquanto a otimização visa garantir a menor dose possível compatível com a imagem de qualidade diagnóstica (Prata Mourão et al., 2019).

O princípio ALARA ("*As Low As Reasonably Achievable*") estabelece que a exposição deve ser mantida tão baixa quanto possível, considerando fatores técnicos, económicos e sociais. No contexto da TC, a sua aplicação requer a análise contínua dos parâmetros de aquisição, uso de tecnologias como modulação automática da corrente, algoritmos de reconstrução interativa e protocolos específicos por região anatómica e grupo etário (Aldosari et al., 2019).

A literatura recomenda ainda auditorias clínicas e formação contínua das equipas técnicas para promover a consciencialização e atualização sobre as boas práticas de exposição radiológica (Santos et al., 2023; Trattner et al., 2014).

2.5 Estratégias de redução de dose

A redução da dose em TC, pode ser obtida através de múltiplas abordagens técnicas, muitas das quais já validadas por entidades como a *American Association of Physicists in Medicine* (Lung Cancer Screening CT Protocols Version 6.0 09 November 2023, 2015). Entre as principais estratégias destacam-se:

- Redução de kV: A diminuição da energia do feixe aumenta a atenuação dos tecidos moles e, portanto, o contraste. El Mansouri et al. (2021) demonstraram que a redução de 120 kVp para 100 kVp resulta numa redução de dose de até 45%, com manutenção da CNR em exames abdominais e torácicos (El Mansouri et al., 2021).
- Modulação da corrente (AEC): Ajusta a mA automaticamente com base na densidade atravessada. Segundo Miller-Clemente et al. (2013), esta técnica reduziu em 31% a dose em TC pediátrica da fossa posterior, preservando a qualidade de imagem (Miller-Clemente et al., 2014).
- Reconstrução interativa: Algoritmos como o *ClearView* (Neusoft), *AIDR 3D* (Canon) ou *SAFIRE* (Siemens) permitem reduzir significativamente o ruído. Prabsattroo et al. (2023) demonstraram que com IR a 60%, foi possível obter $CTDI_{vol} < 4$ mGy mantendo a CNR > 2.5 e a SNR > 8 (Prabsattroo et al., 2023).

- Pitch elevado: Mourão et al. (2019) mostraram que o aumento do pitch de 0.8 para 1.2, combinado com 120 kV e modulação, reduziu a dose em 17% em exames torácicos, sem perda de resolução (Prata Mourão et al., 2019).

Cada técnica pode ser utilizada isoladamente, mas os melhores resultados são obtidos através da combinação inteligente de várias estratégias (Trattner et al., 2014).

2.6 Métricas de avaliação da qualidade de imagem

A qualidade de imagem em tomografia computadorizada pode ser avaliada de forma objetiva por métricas físico-matemáticas que relacionam o contraste e o ruído das imagens obtidas, sendo cruciais quando se avalia a eficácia de protocolos de baixa dose.

- SNR (*Signal-to-Noise Ratio*) é calculado dividindo-se o valor médio dos pixels de uma região homogênea (por exemplo, ar nos pulmões ou água no fantoma) pelo desvio padrão dessa mesma região. A SNR fornece uma medida da consistência do sinal e, quanto maior, melhor a nitidez percebida da imagem (Prabsattroo et al., 2023).
- CNR (*Contrast-to-Noise Ratio*) avalia a capacidade de distinguir duas estruturas com atenuações diferentes. É dada pela diferença de média de CT (unidades *Hounsfield*) entre dois tecidos (por exemplo, nódulo pulmonar e parênquima adjacente), dividida pelo ruído médio (desvio padrão). (Prata Mourão et al., 2019).
- FOM (*Figure of Merit*) é uma métrica de eficiência que relaciona a qualidade da imagem com a dose administrada. Esta métrica permite comparar diretamente protocolos de aquisição com diferentes níveis de dose e ruído. Segundo Santos et al. (2023), um protocolo otimizado pode apresentar FOM até 25% superior ao de rotina, mesmo com dose reduzida em 30% (Santos et al., 2023).

Além das métricas objetivas, a qualidade da imagem em TC deve também ser avaliada de forma subjetiva, uma vez que a percepção clínica nem sempre corresponde aos indicadores matemáticos. A avaliação subjetiva é realizada por radiologistas ou profissionais experientes, que classificam a nitidez, o contraste e a presença de artefactos através de escalas visuais. Esta etapa é essencial, pois assegura que a qualidade diagnóstica é preservada mesmo em protocolos de baixa dose (Woeltjen et al., 2022).

Diversas metodologias têm sido propostas para padronizar esta avaliação. Escalas de 3 a 5 pontos ou escalas visuais analógicas permitem quantificar a percepção dos observadores, facilitando a comparação entre diferentes protocolos. Apesar da subjetividade, estudos demonstram que estas escalas são ferramentas práticas e reproduzíveis para validar protocolos otimizados (Tamura et al., 2022)(Tamura et al., 2022).

Um dos principais desafios é a variabilidade inter e intraobservador, pois diferentes avaliadores podem atribuir classificações distintas à mesma imagem, ou até o mesmo observador pode divergir em momentos diferentes. Para reduzir esta limitação, recomenda-se a utilização de grupos de avaliadores e a aplicação de coeficientes de concordância, como o kappa de Cohen, que quantifica a fiabilidade das classificações (Brendlin et al., 2022)(Brendlin et al., 2022).

A integração entre as métricas objetivas (SNR, CNR, FOM) e a avaliação subjetiva é atualmente considerada a abordagem mais robusta. Protocolos com valores inferiores de SNR ou CNR podem ainda assim ser considerados clinicamente aceitáveis, se a avaliação subjetiva confirmar a qualidade diagnóstica. Esta correlação demonstra a importância da avaliação subjetiva como complemento indispensável aos indicadores quantitativos (Xun et al., 2025)(Xun et al., 2025).

2.7 Estudos de caso relevantes

Estudos de caso em diferentes contextos hospitalares reforçam a aplicabilidade e o impacto clínico da otimização de protocolos em TC torácica.

Pandya et al. (2022) conduziram uma auditoria clínica em três ciclos, no contexto da pandemia de COVID-19. Após intervenção educativa com técnicos e revisão dos parâmetros de aquisição, reduziram o CTDIvol médio de 22,1 mGy para 4,5 mGy, mantendo a aceitabilidade diagnóstica das imagens. A FOM foi aumentada em mais de 60% após ajustes no pitch e introdução de reconstrução iterativa (Pandya et al., 2022)(Pandya et al., 2022).

O protocolo de rastreio de cancro do pulmão da AAPM (2023) recomenda $CTDIvol \leq 3$ mGy e doses efetivas ≤ 1 mSv, com uso de reconstruções interativas e $pitch \geq 1,2$. Estas recomendações foram aplicadas com sucesso em centros nos EUA, resultando em mais de 75% de redução de dose face a protocolos convencionais (Lung Cancer Screening CT Protocols Version 6.0 09 November 2023, 2015)(Lung Cancer Screening CT Protocols Version 6.0 09 November 2023, 2015).

O estudo de El Mansouri et al. (2021), realizado em Marrocos com fantasmas de tórax e abdómen, mostrou que a redução de kVp (de 120 para 100) associada a modulação da corrente (mAs reduzido em 30%) permitiu manter contraste e resolução, com redução média de 50% na dose, validada por CNRs entre 1,8 e 2,5 (El Mansouri et al., 2021)(El Mansouri et al., 2021).

Mourão et al. (2019) compararam fantasmas cilíndricos e oblongos para simular o tórax adulto, avaliando doses com diferentes combinações de pitch e kVp. Através de reconstrução iterativa e ajustes de corrente, observaram uma redução de CTDIvol de 13,3 mGy para menos de 8,2 mGy, com SNR acima de 10 (Prata Mourão et al., 2019)(Prata Mourão et al., 2019).

Prabsattroo et al. (2023) otimizaram protocolos em tomógrafos *Neusoft* com *ClearView IR*. Com IR a 60%, mAs entre 200 e 300, e kVp de 100–120, alcançaram $CTDIvol < 4$ mGy e $CNR > 2$, sem degradação significativa da imagem em fantasmas (Prabsattroo et al., 2023)(Prabsattroo et al., 2023).

Estes exemplos demonstram que a otimização da dose é viável, segura e eficaz, com impactos mensuráveis na redução da exposição dos pacientes, sem sacrificar a capacidade diagnóstica quando aplicadas as métricas corretas e a análise dos parâmetros técnicos.

Nos últimos anos, os avanços na otimização de protocolos em TC torácica têm-se centrado na integração de tecnologias baseadas em inteligência artificial e reconstruções avançadas, capazes de reduzir ainda mais a dose sem comprometer a qualidade diagnóstica. Estudos recentes demonstraram que algoritmos de *deep learning reconstruction* (DLR) conseguem proporcionar reduções de dose adicionais de 30–50% quando comparados com métodos iterativos convencionais, mantendo a resolução espacial e melhorando a relação contraste-ruído (Brendlin et al., 2022; Tamura et al., 2022)(Brendlin et al., 2022; Tamura et al., 2022). Além disso, o desenvolvimento de métricas como o *Size Specific Dose Estimate* (SSDE) e de ferramentas de dosimetria personalizada baseadas em simulações Monte Carlo têm permitido estimativas mais fiéis da dose absorvida pelos órgãos, reforçando a segurança e a individualização do exame (McCollough et al., 2006)(McCollough et al., 2006). Estas inovações apontam para uma tendência clara, de que a otimização da TC deixará de ser apenas uma questão de ajustar parâmetros técnicos, passando a incluir soluções computacionais inteligentes e personalizadas, capazes de combinar redução de dose com diagnósticos de elevada precisão.

2.8 Otimização de protocolos baseada em modelos matemáticos

A crescente sofisticação dos equipamentos de tomografia computadorizada e a multiplicidade de parâmetros técnicos disponíveis colocam um desafio adicional à otimização dos protocolos de aquisição. Para além das abordagens tradicionais empíricas, que se baseiam na experiência clínica ou em tentativa-erro, têm ganho destaque metodologias matemáticas e estatísticas que permitem sistematizar e acelerar esse processo, garantindo simultaneamente robustez e fundamentação científica.

Uma das técnicas mais utilizadas é a regressão polinomial multivariada, especialmente de segundo grau, por permitir modelar relações não lineares e interações entre variáveis técnicas (Kutner, 1996; Montgomery C et al., 2021)(Kutner, 1996; Montgomery C et al., 2021). No contexto da TC, este tipo de modelação tem sido aplicado com sucesso para estimar desfechos como a qualidade subjetiva da imagem, o contraste, a relação sinal-ruído e, em alguns casos, métricas derivadas como a FOM.

Para garantir a qualidade estatística do modelo e evitar efeitos de redundância entre variáveis explicativas, é frequente aplicar-se a centralização das variáveis preditoras (subtração da média), bem como o cálculo do VIF – *Variance Inflation Factor*. Este indicador mede o grau de multicolinearidade entre as variáveis independentes, sendo que valores acima de 5 sugerem uma correlação excessiva que pode inflacionar os erros padrão dos coeficientes, dificultando a interpretação (Galvão et al., 2020; James et al., 2021; Marcoulides & Raykov, 2018)(Galvão et

al., 2020; James et al., 2021; Marcoulides & Raykov, 2018). Em estudos de modelação aplicados a exames de TC, o controlo da colinearidade tem-se mostrado fundamental para assegurar previsões fiáveis e coeficientes estatisticamente significativos.

Associada à modelação estatística, a otimização sequencial guiada por algoritmos computacionais tem sido cada vez mais explorada. Métodos como a otimização Bayesiana permitem a seleção iterativa de novas combinações de parâmetros com base em modelos probabilísticos que atualizam, a cada passo, a estimativa do ponto ótimo. Esta abordagem tem sido eficaz em contextos médicos com custos elevados por aquisição, como é o caso de ensaios com fantasmas ou exames clínicos em pacientes (Cardoso Coelho et al., 2024; Wang et al., 2024)(Cardoso Coelho et al., 2024; Wang et al., 2024).

Uma vez obtidos os resultados experimentais, é possível aplicar métodos de otimização multicritério, com destaque para a fronteira de Pareto. Esta técnica identifica soluções não dominadas, ou seja, aquelas que não podem ser superadas em todos os objetivos simultaneamente. No caso da TC, isso significa identificar configurações em que não é possível reduzir ainda mais a dose (CTDIvol) sem comprometer a qualidade da imagem (por exemplo, avaliação subjetiva, CNR ou SNR). A análise de Pareto permite assim mapear os compromissos entre variáveis clínicas e técnicas, sem impor pesos arbitrários a cada critério, como acontece em modelos de otimização escalar (Ahmadianshalchi et al., 2024)(Ahmadianshalchi et al., 2024).

Na prática, esses métodos têm sido aplicados em estudos com fantasmas e simulações clínicas. Um exemplo recente ajustou o CTDIvol em função do *noise index* e da força de reconstrução iterativa (ASIR-V), alcançando precisão inferior a 15 %, validada em simuladores e dados reais (Scott et al., 2024)(Scott et al., 2024). Outros modelos matemáticos integrados avaliam risco clínico e radiológico para (Santos et al., 2023)(Santos et al., 2023) otimização quantitativa de protocolos abdominais, reforçando como decisões baseadas em modelação oferecem uma abordagem balanceada e justificada (Ria et al., 2024)(Ria et al., 2024).

A aplicação de técnicas analíticas e computacionais no desenvolvimento de protocolos de TC representa uma evolução significativa face às estratégias tradicionais. Estas metodologias aumentam a objetividade da decisão clínica, reduzem o número de ensaios necessários e facilitam a reprodutibilidade em diferentes contextos hospitalares e equipamentos.

2.9 Considerações finais da revisão

Para além dos estudos aqui apresentados, diversos trabalhos internacionais reforçam a importância do processo de otimização da tomografia computadorizada em diferentes contextos clínicos, desde exames pediátricos até rastreios populacionais. A literatura mostra de forma consistente que a adoção de protocolos otimizados resulta em reduções de dose entre 30% e 70%, sem perda de qualidade diagnóstica (Prabsattroo et al., 2023; Santos et al., 2023)(Prabsattroo et al., 2023; Santos et al., 2023).

O impacto da otimização não se limita apenas à dose. Estudos recentes têm demonstrado que protocolos bem definidos contribuem também para a redução do tempo de exame, uma vez que diminuem a necessidade de repetições por falhas de qualidade de imagem. Essa melhoria traduz-se em ganhos de eficiência e num menor desgaste físico e cognitivo das equipas técnicas, que podem manter um fluxo de trabalho mais estável e seguro (El Mansouri et al., 2021)(El Mansouri et al., 2021).

Apesar dos benefícios comprovados, existem ainda barreiras à implementação rotineira da otimização, incluindo resistência à mudança, falta de formação contínua das equipas, heterogeneidade de equipamentos disponíveis e custos iniciais associados à atualização tecnológica. A superação destas barreiras requer não apenas investimento em tecnologia, mas também uma cultura institucional de qualidade e segurança, sustentada por auditorias clínicas periódicas e programas de educação em proteção radiológica (Prata Mourão et al., 2019)(Prata Mourão et al., 2019).

Por fim, importa destacar os benefícios económicos a longo prazo. A otimização contribui para a redução de repetições desnecessárias, menor tempo de ocupação dos equipamentos e aumento da produtividade global dos serviços de imagiologia. Além disso, ao minimizar riscos radiológicos, reduz potenciais custos indiretos associados a efeitos tardios da radiação, reforçando a sustentabilidade do sistema de saúde (Cody et al., 2021)(Cody et al., 2021).

3 Metodologia

A metodologia adotada neste estudo foi desenhada de forma a garantir o rigor científico necessário na otimização de protocolos de tomografia computadorizada do tórax de baixa dose. Nesta secção descrevem-se os equipamentos utilizados, os fantasmas e pacientes incluídos, bem como os procedimentos experimentais que permitiram avaliar a qualidade de imagem e a dose de radiação associada. A abordagem metodológica integra tanto métricas objetivas como subjetivas, assegurando que os protocolos propostos oferecem simultaneamente viabilidade técnica e relevância clínica. Além disso, são apresentadas as estratégias de tratamento de dados e os critérios de seleção baseados na fronteira de Pareto, que possibilitaram identificar os protocolos mais eficientes e adequados à validação clínica.

3.1 Equipamento utilizado

Os ensaios foram realizados num equipamento de tomografia computadorizada *Canon Aquilion Lightning*, modelo de 16 cortes. Este tomógrafo é projetado para aplicações clínicas gerais, com 0,5 mm de espessura mínima de corte, detetores *PUREVISION™* e reconstrução iterativa *AIDR 3D Enhanced (Adaptive Iterative Dose Reduction 3D)* integrada ao sistema. Esta tecnologia permite a redução significativa da dose sem comprometer a qualidade diagnóstica da imagem (Aldosari et al., 2019; Trattner et al., 2014)(Aldosari et al., 2019; Trattner et al., 2014).



Figura 1- Tomógrafo Canon Aquilion Lightning, modelo de 16 cortes

A reconstrução iterativa *AIDR 3D* atua na supressão do ruído de imagem, sendo eficaz na obtenção de exames de baixa dose, especialmente em estudos torácicos e abdominais (Lung Cancer Screening CT Protocols Version 6.0 09 November 2023, 2015)(Lung Cancer Screening CT Protocols Version 6.0 09 November 2023, 2015).

3.2 Fantoma utilizado

Utilizou-se um fantoma de controlo de qualidade com composição homogénea e densidades semelhantes a tecidos corporais. Este fantoma inclui áreas simuladas que permitem a análise de contraste, ruído e variações de sinal, sendo adequado para estudos de validação de protocolos e otimização da dose em tomografia.




Figura 2- Fantoma utilizado nos ensaios




Figura 3- Imagem gerada pelo fantoma

3.3 Plano experimental

Foram realizados 40 testes distintos com o objetivo de avaliar o impacto de diferentes parâmetros técnicos na dose absorvida e na qualidade da imagem. Os parâmetros variaram entre os testes conforme indicado:

- kV: 135, 120, 100 e 80
- mAs: 220 a 100
- Pitch: entre 0,813 e 1,475
- Reconstrução iterativa (AIDR): em modo *Standard*, *Strong* ou *Enhanced*
- Espessura de corte: 0,5x80 ou 1,0x40 mm

Todos os testes foram realizados com modo helicoidal e colimação adequada ao protocolo selecionado.

3.4 Avaliação da qualidade de imagem

3.4.1 SNR (SIGNAL-TO-NOISE RATIO)

A SNR foi medida utilizando uma região de interesse (ROI) circular com cerca de 10 mm de diâmetro, posicionada numa área homogênea de ar dentro do fantoma. Esta abordagem segue a metodologia descrita por Dalmazo et al. (2010). O valor da SNR foi calculado segundo a fórmula:

$$SNR = \frac{|\mu_{ar}|}{\sigma_{ar}} \quad (1)$$

onde:

- μ_{ar} : valor médio dos píxeis na ROI do ar
- σ_{ar} : desvio padrão dos píxeis na mesma ROI

3.4.2 CNR (CONTRAST-TO-NOISE RATIO)

A CNR foi avaliada através da comparação entre duas regiões distintas:

- Uma ROI colocada no ar (como acima)
- Uma segunda ROI colocada na zona que simula gordura no fantoma

O cálculo seguiu a equação:

$$CNR = \frac{|\mu_{ar} - \mu_{gordura}|}{\sigma_{ar}} \quad (2)$$

onde:

- $\mu_{gordura}$: média dos valores de CT na ROI sobre gordura

3.4.3 FOM (FIGURE OF MERITE)

A métrica FOM (Figura de Mérito) foi utilizada para relacionar diretamente a qualidade da imagem com a dose administrada. O índice foi calculado da seguinte forma:

$$FOM = \frac{CNR^2}{CTDIvol} \quad (3)$$

Esta abordagem segue recomendações internacionais para avaliação de protocolos otimizados, conforme utilizado por Santos et al. (2023) e Mourão et al. (2019).

3.4.4 Avaliação subjetiva

Para além da análise objetiva, a qualidade das imagens foi também realizada de forma subjetiva, uma vez que a percepção clínica é determinante para validar a aplicabilidade dos protocolos em contexto real. A avaliação foi realizada por dois técnicos de radiologia com experiência, de forma independente, recorrendo a uma escala de 1 a 10 pontos, onde 1 corresponde a imagem não diagnóstica e 10 a qualidade excelente. A opção por uma escala de 10 níveis permitiu reduzir ambiguidades e oferecer maior granularidade na diferenciação de pequenas variações de qualidade, em contraste com escalas mais curtas, como a de 3 ou 5 pontos, frequentemente utilizadas em estudos semelhantes (Tamura et al., 2022)(Tamura et al., 2022).

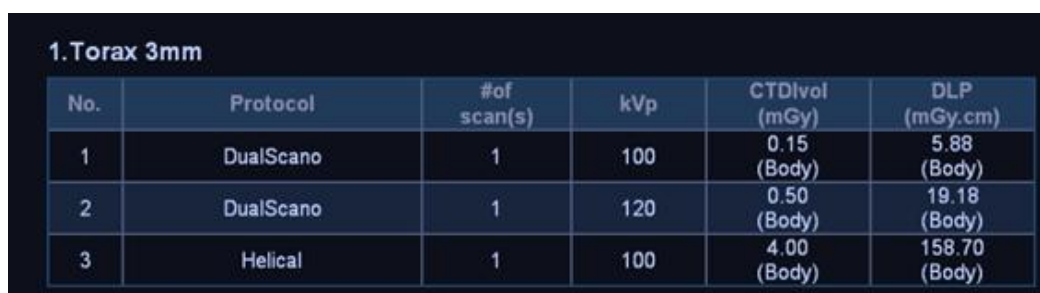
Cada avaliador analisou de forma cega as imagens geradas em todos os protocolos, classificando parâmetros como nitidez, contraste e presença de artefactos. Para reduzir a influência da variabilidade interobservador, as classificações finais foram obtidas pela média das pontuações atribuídas.

3.5 Avaliação da dose de radiação

Os valores de dose utilizados na análise foram obtidos diretamente a partir dos relatórios de dose DICOM gerados pelo equipamento após cada aquisição. Os seguintes indicadores foram extraídos:

- CTDIvol (mGy) – índice volumétrico de dose
- DLP (mGy·cm) – produto dose-comprimento

Estes indicadores foram utilizados para aferir o desempenho dos protocolos em termos de exposição, seguindo as diretrizes estabelecidas pela ICRP e pela legislação nacional.



No.	Protocol	#of scan(s)	kVp	CTDIvol (mGy)	DLP (mGy.cm)
1	DualScano	1	100	0.15 (Body)	5.88 (Body)
2	DualScano	1	120	0.50 (Body)	19.18 (Body)
3	Helical	1	100	4.00 (Body)	158.70 (Body)

Figura 4 - Exemplo de relatório DICOM gerado pelo equipamento

3.6 Tratamento dos dados

O processamento e análise dos dados seguiram uma abordagem estruturada em múltiplas etapas, desde a importação e exploração inicial, passando pela modelação estatística e geração de previsões, até à seleção de protocolos ótimos com base em critérios multicritério e fronteira de Pareto.

A metodologia foi desenvolvida em *Python*, com o suporte de bibliotecas especializadas e guiada por princípios de modelação e otimização multiobjetivo.

3.6.1 Configuração inicial e bibliotecas utilizadas

A análise foi realizada em ambiente *Python*, e as bibliotecas utilizadas são as seguintes:

- Estrutura e EDA: *numpy, pandas, matplotlib.pyplot, seaborn*;
- Modelação: *sklearn.preprocessing.PolynomialFeatures, sklearn.linear_model.LinearRegression, statsmodels.api*;
- Diagnóstico de colinearidade: *statsmodels.stats.outliers_influence.variance_inflation_factor*;
- Otimização Bayesiana: *skopt.gp_minimize e skopt.space.Categorical*

Este bloco inicial (Código 1) importa todas as bibliotecas essenciais para a análise de dados e modelação estatística. O *numpy* e *pandas* são utilizados para manipulação de dados numéricos e estruturas tabulares, enquanto o *matplotlib* e *seaborn* permitem a criação de visualizações gráficas. As bibliotecas *sklearn* fornecem ferramentas para modelação polinomial e regressão linear, e o *statsmodels* oferece análises estatísticas avançadas, incluindo testes de significância e diagnósticos. O *skopt* é específico para otimização Bayesiana, e o *itertools* facilita a geração de combinações de parâmetros.

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
import itertools
from sklearn.preprocessing import PolynomialFeatures
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score
from skopt import gp_minimize
from skopt.space import Categorical
import statsmodels.api as sm
from scipy.stats import t
import os

```

Código 1- Importação das bibliotecas principais

3.6.2 Importação e pré processamento dos dados

Os dados iniciais foram lidos de um ficheiro *Excel*, com informações reais obtidas de 40 ensaios experimentais com fantoma. De seguida foi feita uma análise exploratória que incluiu a geração de uma matriz de correlação entre parâmetros técnicos e avaliação subjetiva, um *pairplot* para visualização da dispersão dos dados e as estatísticas descritivas das variáveis envolvidas.

Foram utilizados quatro preditores centrais: kV, mAs, Pitch e nível de reconstrução AIDR. Todas as variáveis foram centralizadas (subtraída a média) para reduzir a colinearidade entre termos lineares e quadráticos. Posteriormente, foi então criado um modelo polinomial de 2.º grau com interações, através da função *PolynomialFeatures*.

Este segmento (Código 2) realiza a importação dos dados experimentais a partir de um ficheiro Excel contendo ensaios iniciais com fantoma. O `pd.read_excel()` carrega os dados para um DataFrame pandas, seguindo-se uma análise exploratória que inclui visualização das primeiras e últimas linhas (`head()` e `tail()`) e estatísticas descritivas (`describe()`). A matriz de correlação gerada pelo `seaborn.heatmap()` permite identificar relações lineares entre variáveis, enquanto o *pairplot* oferece uma visão global das distribuições e correlações bivariadas entre todos os parâmetros técnicos e métricas de qualidade.

```

df = pd.read_excel("C:\\Users\\Fabiana Silva\\OneDrive\\Ambiente de
Trabalho\\dados tese\\fantoma_250713.xlsx", sheet_name='Dados')
print(df.head(), "\n...", df.tail())
print(df.describe())

plt.figure(figsize=(8,6))
sns.heatmap(df.corr(), annot=True, cmap='coolwarm')
plt.title('Matriz de Correlação')
plt.show()

sns.pairplot(df)
plt.show()

```

Código 2- Carregamento e exploração inicial dos dados




Figura 5- Exemplo de matriz de correlação gerada no 1º ensaio

3.6.3 Modelação (regressão polinomial de 2º grau) e diagnóstico

Dois modelos de regressão linear foram treinados com os dados obtidos: um para prever a avaliação subjetiva da imagem (qualidade), e outro para prever o CTDIvol (dose). Esta abordagem permite analisar a influência dos parâmetros técnicos na qualidade e na dose de forma separada. A par do modelo de regressão da scikit-learn, foi utilizado o modelo OLS da biblioteca statsmodels, que fornece estatísticas adicionais úteis, como os valores de p e o R^2 ajustado.

A centralização das variáveis (Código 3) é uma etapa crucial para evitar problemas de colinearidade em modelos polinomiais. O código subtrai a média de cada variável preditora (kV, mAs, Pitch, AIDR), criando um novo conjunto de dados X com média zero. Esta transformação é essencial porque, sem centralização, os termos lineares e quadráticos estariam altamente correlacionados, inflacionando os fatores VIF e comprometendo a estabilidade do modelo. A centralização não altera as relações entre variáveis, mas melhora significativamente a interpretabilidade dos coeficientes de regressão.

```
print("\n3. Preparação dos Dados para Modelagem")
Xo = df[['kV', 'mAs', 'Pitch', 'AIDR']]
y = df['Avaliação subjetiva']
z = df['CTDIvol']
X = Xo - Xo.mean()
```

Código 3- Features centrais e centralização

O bloco de código em (Código 4) implementa a modelação de regressão polinomial de segundo grau com interações. O `PolynomialFeatures(degree=2)` gera automaticamente termos quadráticos e de interação entre todas as variáveis. Dois modelos separados são ajustados: um para prever a avaliação subjetiva da qualidade (y) e outro para prever o CTDIvol (z). A utilização simultânea do `LinearRegression` da `sklearn` e do `OLS` do `statsmodels` permite obter tanto as previsões quanto estatísticas detalhadas como valores p, intervalos de confiança e R ajustado, essenciais para validar a significância estatística do modelo.

```
poly = PolynomialFeatures(degree=2, include_bias=False)
X_poly = poly.fit_transform(X)
X_poly_df = pd.DataFrame(X_poly,
                          columns=poly.get_feature_names_out(X.columns))
X_poly_df = sm.add_constant(X_poly_df)

ymodelo = LinearRegression()
ymodelo.fit(X_poly, y)
zmodelo = LinearRegression()
zmodelo.fit(X_poly, z)

ymodelo_sm = sm.OLS(y, X_poly_df).fit()
print("\n4.1 Avaliação subjetiva\n")
print(ymodelo_sm.summary())

zmodelo_sm = sm.OLS(z, X_poly_df).fit()
print("\n4.2 CTDIvol\n")
print(zmodelo_sm.summary())
```

Código 4- Ajuste dos modelos preditivos com regressão linear e OLS

A análise de resíduos é fundamental para validar as suposições do modelo de regressão linear. O código listado em (Código 5) calcula os resíduos (diferença entre valores reais e previstos) para ambos os modelos e organiza os resultados numa tabela estruturada. Os resíduos devem apresentar distribuição aproximadamente normal e variância constante para que o modelo seja considerado adequado. Esta análise permite identificar observações atípicas e padrões sistemáticos que possam indicar violações das suposições do modelo.

```
y_pred = ymodelo.predict(X_poly)
z_pred = zmodelo.predict(X_poly)
yresiduos = y - y_pred
zresiduos = z - z_pred
resultados = pd.DataFrame({'Av_Real': y, 'Av_Prevista': y_pred,
                          'Av_Resíduo': yresiduos,
                          'CTDI_Real': z, 'CTDI_Prevista': z_pred,
                          'CTDI_Resíduo': zresiduos})
print(resultados)
```

Código 5- Análise de resíduos

Para avaliar visualmente o desempenho do modelo de qualidade, foi gerado um gráfico de dispersão entre os valores reais e os valores previstos (Código 6).

O gráfico de dispersão entre valores reais e previstos é uma ferramenta visual essencial para avaliar a qualidade do ajuste do modelo pois pontos próximos da linha diagonal ($y=x$) indicam previsões precisas, enquanto desvios sistemáticos revelam tendências de sub ou sobrestimação. Também, o coeficiente de determinação (R^2) pode ser visualmente estimado pela proximidade dos pontos à linha de identidade. Este tipo de gráfico também ajuda a identificar heterocedasticidade (variância não constante) e observações influentes.

```
plt.figure(figsize=(8, 8))
plt.scatter(y, y_pred, alpha=0.7)
plt.plot([y.min(), y.max()], [y.min(), y.max()], color='red', linewidth=2)
plt.xlabel('Valor Real')
plt.ylabel('Valor Predito')
plt.title('Comparação: Valor Real vs Valor Predito')
plt.grid(True)
plt.show()
```

Código 6- Real vs Previsto

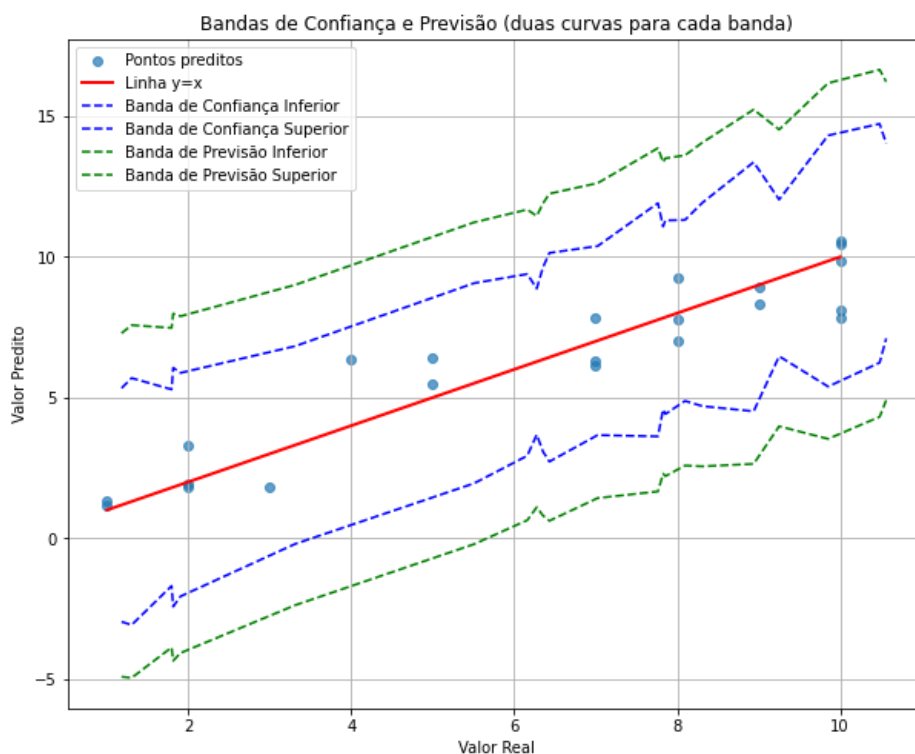


Figura 6 - Exemplo de real vs previsto e bandas de confiança e previsão do primeiro ensaio

Posteriormente, foi realizado o diagnóstico de multicolinearidade (Código 7). Para isso foi calculado o *Variance Inflation Factor* (VIF) para todos os termos do modelo. O Variance Inflation Factor (VIF) mede o grau de colinearidade entre as variáveis preditoras. Valores de VIF superiores a 5 indicam colinearidade problemática que pode inflacionar os erros padrão dos

coeficientes e tornar o modelo instável. Este código calcula o VIF para cada termo do modelo polinomial, permitindo identificar variáveis redundantes. A centralização prévia das variáveis (Código 3) é crucial para manter os VIF em valores aceitáveis, especialmente em modelos polinomiais onde termos lineares e quadráticos tendem a estar correlacionados.

```
print("\n5. Diagnóstico de Multicolinearidade (VIF)")
from statsmodels.stats.outliers_influence import variance_inflation_factor
vif_data = pd.DataFrame()
vif_data['Variável'] = X_poly_df.columns
vif_data['VIF'] = [variance_inflation_factor(X_poly_df.values, i) for i in
range(X_poly_df.shape[1])]
print(vif_data)
```

Código 7- Diagnóstico de colinearidade (VIF)

Os resultados mostraram que, exceto para os termos relacionados ao Pitch, todos os VIF estavam < 5, indicando colinearidade controlada. A centralização foi eficaz nesta mitigação.

3.6.4 Geração de novas combinações de ensaios

Com o modelo treinado, geraram-se todas as combinações possíveis de parâmetros técnicos dentro de limites plausíveis do ponto de vista clínico. Esta abordagem permitiu expandir o espaço de soluções simuladas sem a necessidade de realizar todos os ensaios fisicamente, o que reduziu custos e tempo. Utilizando o `itertools.product()` em (Código 8) geram-se todas as combinações possíveis entre os valores permitidos de kV, mAs, Pitch e AIDR. Esta abordagem sistemática expande o espaço experimental virtual, criando centenas de protocolos potenciais sem necessidade de ensaios físicos adicionais. Os intervalos de valores são definidos com base em limitações clínicas e técnicas do equipamento, garantindo que apenas combinações realizáveis sejam consideradas. Esta estratégia é particularmente eficiente em contextos onde cada ensaio experimental tem custos elevados.

```
valores_permitidos = {
    'kV': [80, 100, 120, 135],
    'mAs': [80+10*i for i in range(15)],
    'Pitch': [1.388, 1.475, 0.813, 0.825],
    'AIDR': [1, 2, 3]
}
combinacoes = list(itertools.product(
    valores_permitidos['kV'],
    valores_permitidos['mAs'],
    valores_permitidos['Pitch'],
    valores_permitidos['AIDR']
))
df_combinacoes = pd.DataFrame(combinacoes, columns=['kV', 'mAs', 'Pitch',
'AIDR'])
```

Código 8- Geração das combinações possíveis de parâmetros técnicos.

Em (Código 9) aplica-se os modelos treinados às novas combinações geradas, produzindo previsões para avaliação subjetiva e CTDIvol. O processo inclui a aplicação das mesmas transformações utilizadas no treino: centralização das variáveis e geração de características polinomiais. A consistência deste pipeline de transformação é crítica para garantir previsões fiáveis. Os resultados permitem identificar rapidamente quais combinações prometem bom desempenho antes de serem testadas experimentalmente. Assim, foram aplicadas as mesmas transformações para prever os valores de Avaliação Subjetiva e CTDIvol. Os resultados permitiram identificar combinações com bom desempenho esperado.

```
df_combinacoes = pd.DataFrame(combinacoes, columns=['kV', 'mAs', 'Pitch',
'AIDR'])
X_combinacoes = df_combinacoes[['kV', 'mAs', 'Pitch', 'AIDR']]
X_combinacoes_centralizado = X_combinacoes - Xo.mean()
X_combinacoes_poly = poly.transform(X_combinacoes_centralizado)

df_combinacoes['Avaliação Prevista'] = ymodelo.predict(X_combinacoes_poly)
df_combinacoes['CTDIvol Prevista'] = zmodelo.predict(X_combinacoes_poly)
```

Código 9- Geração de previsões de ensaios e previsão

3.6.5 Seleção da região admissível

A filtragem com base em critérios clínicos define a região admissível do espaço de soluções. Os limiares utilizados (avaliação subjetiva ≥ 10 e CTDIvol ≤ 4 mGy) refletem requisitos práticos: qualidade mínima aceitável para diagnóstico e dose máxima compatível com proteção radiológica. Esta etapa elimina combinações clinicamente inviáveis, reduzindo drasticamente o número de soluções a considerar na análise de Pareto posterior. Os critérios podem ser ajustados conforme standards clínicos específicos ou guidelines internacionais. Nesse contexto, com base em critérios clínicos definidos, foram selecionadas apenas as combinações que apresentavam Avaliação Prevista ≥ 10 e CTDIvol Previsto ≤ 4 mGy. Estas condições definem a região admissível onde há equilíbrio entre qualidade e segurança (Código 10).

```
admissiveis = df_combinacoes[
    (df_combinacoes['Avaliação Prevista'] >= 10) &
    (df_combinacoes['CTDIvol Prevista'] <= 4)
]
```

Código 10- Filtragem da região admissível com base em critérios clínicos.

3.6.6 Cálculo e visualização da fronteira de Pareto

Dentro da região admissível, foi aplicada a análise de Pareto. A Fronteira de Pareto inclui apenas as soluções não dominadas, isto é, aquelas em que não é possível melhorar a qualidade sem aumentar a dose, ou vice-versa. Esta abordagem é comum em problemas de otimização multiobjetivo. A função `calcular_pareto_front()` (Código 11) implementa o algoritmo para identificar soluções não dominadas. Uma solução é considerada dominada se existe outra que

a supera em todos os objetivos simultaneamente. No contexto deste trabalho, isso significa encontrar protocolos onde não é possível melhorar a qualidade sem aumentar a dose, ou vice-versa. O algoritmo compara cada ponto com todos os outros, mantendo apenas aqueles que não são dominados. Esta abordagem de otimização multicritério evita impor pesos arbitrários aos diferentes objetivos.

```
def calcular_pareto_front(quality, dose):
    points = np.array(list(zip(dose, quality)))
    pareto_points = []
    for i, (d, q) in enumerate(points):
        if not any((dp <= d and qp >= q) and (dp < d or qp > q) for j, (dp,
qp) in enumerate(points) if j != i):
            pareto_points.append(i)
    return np.array(pareto_points)

quality = admissiveis['Avaliação Prevista'].values
dose = admissiveis['CTDIvol Prevista'].values
pareto_idx = calcular_pareto_front(quality, dose)
pareto_sol = admissiveis.iloc[pareto_idx]
```

Código 11- Identificação dos pontos da Fronteira de Pareto.

Posteriormente foi gerado um gráfico que mostra todos os pontos admissíveis (cinzento) e destaca em vermelho os pontos da Fronteira de Pareto. As linhas horizontais e verticais representam os limites clínicos definidos para qualidade e dose. Em (Código 12) o código cria uma representação gráfica da análise de Pareto, mostrando todos os pontos admissíveis em cinzento e destacando a fronteira ótima em vermelho. As linhas tracejadas horizontais e verticais marcam os limiares clínicos definidos (qualidade mínima e dose máxima). Esta visualização é essencial para compreender os compromissos entre qualidade e dose, permitindo identificar visualmente as soluções mais eficientes. O gráfico facilita também a comunicação dos resultados a equipas clínicas.

```
plt.figure(figsize=(8,6))
plt.scatter(admissiveis['CTDIvol Prevista'], admissiveis['Avaliação Prevista'],
alpha=0.4, label='Admissíveis')
plt.scatter(pareto_sol['CTDIvol Prevista'], pareto_sol['Avaliação Prevista'],
color='red', label='Pareto')
plt.axhline(y=10, color='green', linestyle='--')
plt.axvline(x=4, color='orange', linestyle='--')
plt.xlabel('CTDIvol (mGy)')
plt.ylabel('Avaliação Subjetiva')
plt.title('Fronteira de Pareto')
plt.legend()
plt.grid(True)
plt.show()
```

Código 12- Geração do gráfico da Fronteira de Pareto

3.6.7 Seleção dos melhores ensaios para validação clínica

A seleção dos protocolos prioritários para validação clínica (Código 13) baseia-se na ordenação dos pontos da fronteira de Pareto por qualidade prevista decrescente. O `sort_values()` com `ascending=False` organiza os protocolos do melhor para o pior em termos de avaliação subjetiva, mantendo apenas aqueles que oferecem o melhor compromisso qualidade-dose. Esta estratégia prioriza protocolos com maior probabilidade de sucesso clínico, otimizando o uso de recursos limitados para validação com pacientes reais. Nesse sentido, dos pontos da Fronteira de Pareto, foram selecionadas as combinações com maior Avaliação Prevista. Estes ensaios foram considerados prioritários para serem realizados com pacientes reais, dada a sua promessa de desempenho clínico equilibrado.

```
top_pareto = pareto_sol.sort_values('Avaliação Prevista',  
ascending=False).head(10)  
print(top_pareto)
```

Código 13- Seleção dos melhores ensaios segundo o modelo.

3.6.8 Análise estatística e otimização dos ensaios

A abordagem de otimização adotada neste trabalho foi conduzida em três ciclos iterativos de geração e treino de novos ensaios com fantoma, seguidos de modelação estatística e avaliação de desempenho preditivo. Esta estratégia permitiu expandir progressivamente o espaço experimental, aumentar a robustez do modelo e assegurar que as soluções selecionadas se mantinham clinicamente relevantes.

No primeiro ciclo, partiu-se do conjunto inicial de 22 ensaios. O modelo polinomial de 2.º grau apresentou um R^2 ajustado de 0,664, com resíduos distribuídos de forma aceitável, mas ainda com bandas de previsão relativamente largas. A análise de colinearidade revelou valores de VIF controlados na maioria das variáveis, exceto em termos associados ao *Pitch*, onde se observaram valores mais elevados. Esta primeira etapa foi essencial para validar a metodologia, mas evidenciou margem de melhoria estatística.

No segundo ciclo, foram acrescentados novos ensaios simulados ao conjunto de treino, aumentando o total para 30 observações. O modelo mostrou evolução clara, com R^2 ajustado de 0,752 e intervalos de confiança mais estreitos. As bandas de previsão mostraram maior alinhamento com os valores reais, refletindo menor variabilidade do erro. Os fatores de inflação da variância indicaram redução da colinearidade em vários termos, embora algumas interações ainda apresentassem valores elevados. Estes resultados justificaram a repetição do processo e a introdução de uma terceira iteração.

No terceiro ciclo, o conjunto de dados foi novamente expandido, atingindo 40 observações. O modelo estabilizou com R^2 ajustado de 0,798, evidenciando robustez e boa capacidade explicativa. A dispersão real vs previsto manteve-se próxima da identidade, e as bandas de confiança mostraram consistência estatística, sem ganhos relevantes adicionais em

comparação com o ciclo anterior. Os valores de VIF permaneceram dentro de limites aceitáveis (<5 para a maioria das variáveis centrais), confirmando que a centralização das variáveis foi eficaz na mitigação da colinearidade.

A decisão de encerrar a interação no terceiro ciclo baseou-se, portanto, em critérios objetivos:

- Estabilização do R^2 ajustado, próximo de 0,80, indicando que novos ensaios acrescentariam pouco poder explicativo;
- Bandas de confiança e previsão estáveis, sugerindo menor risco de sobreajuste;
- Colinearidade controlada, garantindo fiabilidade dos coeficientes estimados;

Esta opção metodológica está em consonância com recomendações da literatura sobre otimização em tomografia computadorizada, onde se defende que a geração interativa deve ser limitada a um número de ciclos que assegure robustez estatística sem redundância excessiva. Tal como observado por Pimentel et al. (2013) e Trattner et al. (2014), a relação dose–qualidade estabiliza após determinados pontos de otimização, sendo mais vantajoso aplicar metodologias multiobjetivo, como a Fronteira de Pareto, do que insistir em ciclos adicionais (Pimentel et al., 2013; Trattner et al., 2014)(Pimentel et al., 2013; Trattner et al., 2014).

Assim, a partir do terceiro ciclo procedeu-se à aplicação da análise de Pareto, que permitiu identificar combinações de parâmetros clinicamente admissíveis, equilibrando qualidade de imagem e dose, e selecionar os protocolos mais promissores para validação em contexto clínico.

3.7 Validação Clínica dos protocolos

Para a validação dos protocolos gerados foi realizado um estudo, baseado na análise comparativa de exames obtidos com o novo protocolo e exames anteriores realizados com o protocolo convencional. Foram incluídos 6 pacientes adultos.

3.7.1 Critérios de inclusão:

- Idade entre 18 e 80 anos;
- Índice de Massa Corporal (IMC) entre 18,5 e 30 kg/m²;
- Exames realizados com ambos os protocolos (anterior e novo), no mesmo equipamento (Canon Aquilion Lightning);
- Exames disponíveis nos arquivos do PACS.

3.7.2 Critérios de exclusão:

- Presença de implantes metálicos ou massas torácicas extensas que interfiram na avaliação objetiva;
- Artefactos significativos que comprometam a análise comparativa;
- Alterações clínicas relevantes entre os dois exames (ex: pneumonias ou massas novas) que inviabilizem a comparação direta.

3.7.3 Considerações éticas e consentimento informado

Tal como acontece em qualquer exame que envolve radiação ionizante, foi solicitado o consentimento informado dos doentes antes da realização dos estudos incluídos nesta análise. Todos os participantes foram previamente esclarecidos quanto ao procedimento e ao seu objetivo, garantindo que a participação foi voluntária.

Para assegurar a confidencialidade e proteção da identidade, os dados recolhidos foram anonimizados antes da análise, não sendo possível identificar os doentes a partir dos resultados apresentados. Desta forma, cumpriram-se os princípios éticos fundamentais de proteção dos participantes, salvaguardando a privacidade e a utilização responsável da informação clínica.

3.8 Impedimentos e limitações experimentais

Durante o desenvolvimento do estudo foram identificadas algumas limitações práticas que importa destacar. Uma das principais dificuldades prendeu-se com a obtenção de amostras clínicas que cumprissem todos os critérios de inclusão, o que reduziu o número total de casos disponíveis para análise comparativa.

No que diz respeito à componente experimental com fantoma, existiram também condicionantes no uso do equipamento, nomeadamente a necessidade de compatibilizar a realização dos ensaios com a rotina clínica do serviço. Este aspeto implicou restrições de tempo e obrigou a planear cuidadosamente cada sessão experimental.

Outro ponto relevante foi a calibração periódica do tomógrafo e dos fantasmas utilizados, essencial para assegurar a fiabilidade dos resultados, mas que representou um fator de limitação logística. Apesar destas medidas de controlo, é importante reconhecer que pequenas variações inerentes ao processo de calibração podem introduzir incertezas nos valores de dose e qualidade de imagem registados.

Finalmente, destaca-se que os modelos estatísticos desenvolvidos dependem diretamente da quantidade de dados disponíveis. Embora o número de ensaios realizados tenha sido suficiente para treinar e validar os modelos, um conjunto maior poderia aumentar ainda mais a robustez das previsões.

Apesar destas limitações, considera-se que os resultados obtidos são consistentes e fornecem uma base sólida para a avaliação da relação entre dose e qualidade de imagem. Assim, no capítulo seguinte apresentam-se os resultados experimentais e clínicos, que permitem discutir de forma comparativa o impacto dos diferentes protocolos testados.

4 Resultados

Neste capítulo são apresentados os principais resultados obtidos a partir do trabalho experimental e da validação clínica.

A apresentação dos resultados segue uma sequência lógica: primeiro descrevem-se os ensaios em fantoma, depois a *performance* dos modelos estatísticos e o processo de otimização, e por fim a validação clínica, com destaque para a comparação entre protocolos.

4.1 Ensaios com fantoma

No total foram realizados 40 ensaios distintos em fantoma com diferentes combinações de parâmetros técnicos.

Tabela 1- Parâmetros técnicos testados em fantoma e respectivos indicadores de dose e qualidade de imagem.

ID Teste	kV	mAs	Pitch	AIDR	Avaliação subjetiva	CTDIvol
1	120	150	1,388	1	10	4,1
2	120	100	1,388	2	8	2,7
3	120	150	1,475	1	7	3,9
4	120	120	0,813	2	10	5,6
5	120	100	0,825	2	9	4,6
6	120	120	1,475	2	10	3,1
7	120	150	1,388	3	9	4,1
8	100	190	1,388	1	10	3,2
9	100	160	1,475	2	7	2,5
10	100	140	0,825	3	10	4,2
11	100	130	1,475	3	4	2,1
12	100	180	1,475	2	5	3,4
13	100	120	0,813	2	5	1,9
14	80	220	1,388	1	1	1,5
15	80	190	1,388	2	2	1,6
16	80	170	1,475	3	3	2,2
17	80	160	0,813	2	2	2,4
18	80	150	1,475	3	2	1,2
19	100	120	1,388	2	8	2
20	100	150	1,475	3	7	2,4
21	100	130	1,475	1	1	2,1
22	120	80	1,388	2	8	2,2
23	120	200	0,825	3	10	9,2

24	100	220	1,388	3	10	3,7
25	100	110	1,388	3	7	1,9
26	100	120	1,388	3	9	2
27	100	90	1,388	3	3	1,5
28	120	130	1,475	1	10	3,4
29	100	200	1,475	2	6	3,2
30	80	150	1,388	3	4	1,3
31	100	100	1,388	3	5	1,7
32	100	130	1,388	3	10	2,2
33	100	140	1,388	3	8	2,5
34	100	150	1,388	3	10	2,5
35	100	150	0,825	3	10	4,2
36	120	200	0,825	3	10	9,2
37	120	130	1,475	1	9	3,4
38	100	200	1,475	2	8	3,2
39	100	220	1,388	3	10	3,7
40	80	150	1,388	3	1	1,3

A Figura 5 apresenta o heatmap de correlação entre os parâmetros técnicos e as métricas de dose e qualidade. Observa-se uma correlação forte entre o kV e a avaliação subjetiva, evidenciando que tensões mais elevadas tendem a melhorar a percepção clínica da imagem. Contudo, o kV também mostrou correlação positiva com o CTDIvol, confirmando o seu impacto direto no aumento da dose.

O pitch revelou correlação negativa moderada com o CTDIvol, demonstrando que valores mais elevados contribuem para a redução da dose sem comprometer significativamente a qualidade subjetiva. Já o mAs apresentou correlação fraca com a avaliação subjetiva e correlação negativa com o FOM, sugerindo que o aumento da corrente do tubo não se traduz em ganhos proporcionais de eficiência.

Por fim, a forte associação entre avaliação subjetiva e FOM confirma que a métrica de eficiência reflete adequadamente a percepção clínica de qualidade, reforçando a utilidade do FOM como parâmetro integrador para seleção de protocolos otimizados.




Figura 7 - Matriz de correlação entre os parâmetros técnicos e as métricas de qualidade/dose

4.2 Modelos estatísticos e regressão polinomial

Nos três ciclos de geração de ensaios, foram ajustados modelos polinomiais de 2.º grau com interações, avaliados tanto pela regressão linear da *scikit-learn* como pelo modelo OLS (*Ordinary Least Squares*). A Tabela 2 resume os indicadores principais.

Tabela 2- Resumo estatístico dos modelos por ciclo (número de ensaios, R² ajustado, resíduos médios, colinearidade – VIF).

Ciclo	Nº de ensaios	R ² ajustado	Resíduos médios	Colinearidade (VIF)	Observações principais
1.º ciclo	22	≈ 0,664	Heterogêneos, dispersos	Elevado em termos relacionados ao Pitch	Bandas de previsão largas, modelo ainda instável
2.º ciclo	30	≈ 0,752	Mais distribuídos	Redução clara da colinearidade	Maior precisão preditiva, melhoria global do modelo
3.º ciclo	40	≈ 0,798	Consistentes e controlados	VIF < 5 na maioria das variáveis	Estabilização estatística, modelo robusto

Os gráficos Real vs Previsto de cada ciclo confirmam essa evolução. Observou-se uma aproximação progressiva dos pontos à linha de identidade, traduzindo maior precisão preditiva e menor dispersão dos erros.




Figura 8 - Gráfico Real Vs Previsto 1º Ciclo

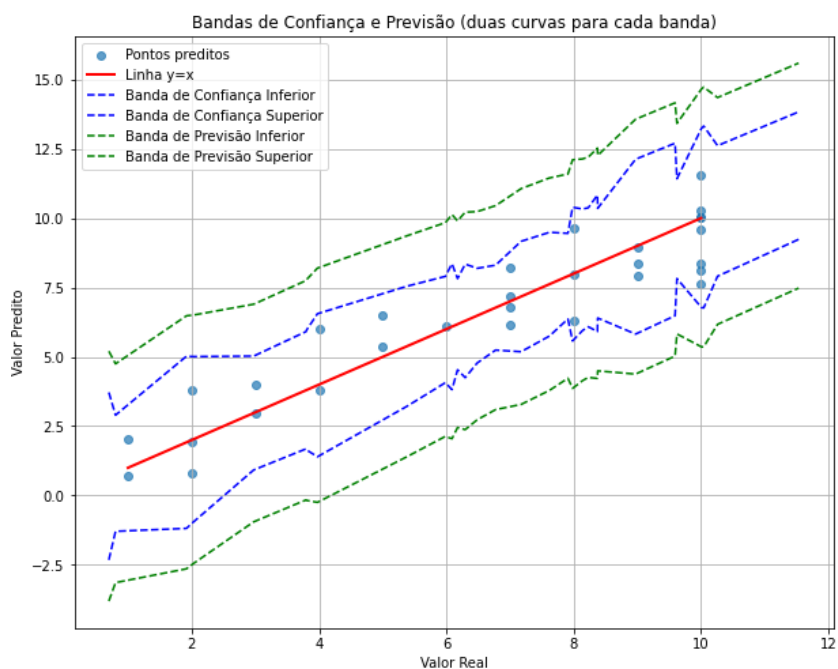


Figura 9 - Gráfico Real Vs Previsto 2º Ciclo




Figura 10 - Gráfico Real Vs Previsto 3º Ciclo

Em síntese, os resultados mostram que a expansão dos ensaios permitiu aumentar gradualmente a qualidade do modelo. O 3.º ciclo representa um ponto de estabilização estatística, fornecendo previsões fiáveis tanto para a avaliação subjetiva da qualidade como para a dose (CTDIvol), o que sustentou as etapas seguintes de simulação de combinações e otimização multicritério.

4.3 Geração e seleção de combinações

A partir dos modelos estatísticos ajustados, foram simuladas todas as combinações possíveis dos parâmetros técnicos no intervalo definido experimentalmente. Esta expansão virtual do espaço experimental originou centenas de protocolos potenciais, para os quais foram calculados os valores previstos de qualidade subjetiva e de dose (CTDIvol).

Aplicando os critérios de inclusão (qualidade subjetiva ≥ 10 e CTDIvol ≤ 4 mGy), apenas uma fração dessas combinações permaneceu na região admissível. Este filtro inicial reduziu drasticamente o número de protocolos a considerar, permitindo concentrar a análise nas soluções com maior relevância clínica.

Dentro dessa região admissível, foi realizada a análise de Pareto. O resultado encontra-se ilustrado na Figura 11, onde os pontos a vermelho representam os protocolos não dominados. Estes constituem a fronteira ótima: qualquer tentativa de reduzir ainda mais a dose implicaria perda de qualidade, e qualquer melhoria adicional na qualidade acarretaria aumento de dose.

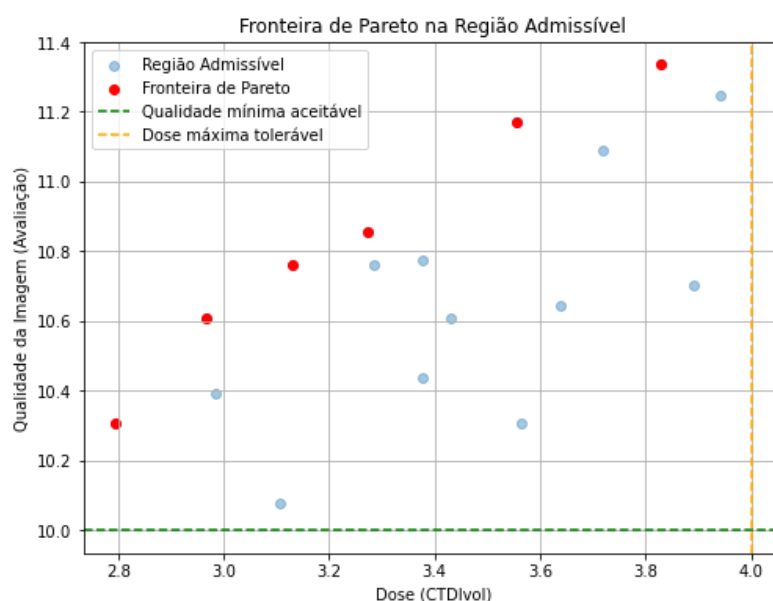


Figura 11 – Gráfico gerado da Fronteira de Pareto.

Da análise desta fronteira resultou uma lista de protocolos otimizados, apresentada na Tabela 3, ordenada por compromisso entre qualidade e dose. Os valores previstos situam-se entre 2,7 e 3,9 mGy de CTDIvol, com qualidade subjetiva entre 10,1 e 11,4, confirmando a possibilidade de redução significativa da dose em relação aos protocolos de rotina, mantendo-se a qualidade dentro de limites clínicos aceitáveis.

Tabela 3- Top 10 protocolos simulados selecionados pela Fronteira de Pareto.

	kV	mAs	Pitch	AIDR	Avaliação Prevista	CTDIvol Prevista
1	120	140	1.388	1	11,335	3,829
2	120	130	1.388	1	11,172	3,556
3	120	120	1.388	1	10,857	3,274
4	100	180	1.388	3	10,759	3,130
5	100	170	1.388	3	10,608	2,966
6	100	160	1.388	3	10,306	2,794

A análise das combinações revelou que os protocolos mais promissores se concentram em valores de kV intermédios (100–120 kV), associados a pitches mais elevados, que contribuem para a redução do CTDIvol sem perda significativa de qualidade. A utilização de reconstrução iterativa em modos Enhanced (3) mostrou-se vantajosa, ao compensar o aumento de ruído típico dos cenários de baixa dose. Já o mAs deve ser ajustado para o valor mínimo que garanta a qualidade subjetiva aceitável.

Estes resultados reforçam a possibilidade de definir protocolos de baixa dose que conciliem a redução da exposição com a manutenção da qualidade diagnóstica, constituindo uma base sólida para futuras validações clínicas.

4.4 Validação clínica

Para validar os protocolos otimizados foram incluídos 6 doentes adultos que já tivessem realizado exames de TC torácica com o protocolo convencional e, posteriormente, com o protocolo de baixa dose desenvolvido.

4.4.1 Comparação dos protocolos

A Tabela 4 apresenta os valores individuais de dose (CTDIvol), SNR e avaliação subjetiva obtidos nos exames dos seis doentes incluídos.

Tabela 4- Comparação entre protocolo convencional e protocolo otimizado nos 6 doentes incluídos.

Doente	CTDIvol Convencional (mGy)	CTDIvol Otimizado (mGy)	SNR (Otimizado)	Avaliação subjetiva (0–15)
1	6,4	4,1	88,6	10
2	6,1	3,6	81,4	10
3	6,2	3,6	78,6	10

4	5,8	3,4	78,0	10
5	5,2	2,9	73,0	10
6	5,4	2,7	70,8	10

Os resultados mostraram uma redução média do CTDIvol de $5,85 \pm 0,43$ mGy para $3,38 \pm 0,47$ mGy, correspondendo a uma diminuição relativa de aproximadamente 42% da dose. Importa destacar que esta redução foi consistente em todos os doentes incluídos, não se tratando de um efeito pontual.

No que respeita à qualidade da imagem, verificou-se que o SNR médio se manteve elevado ($78,4 \pm 6,1$) e a avaliação subjetiva permaneceu estável (10 em todos os casos), confirmando que a perceção diagnóstica não foi comprometida. A Figura 7 exemplifica esta constatação, apresentando imagens comparativas do mesmo doente com ambos os protocolos. Aqui é possível ver que, a redução de dose não resultou em perda visível de detalhe anatómico ou aumento significativo de ruído.




Figura 12 - Imagens comparativas entre TC realizada em 2024 com protocolo convencional (primeira imagem) e em 2025 com protocolo otimizado (segunda imagem).

4.4.2 Relação com as previsões do modelo

Embora nesta secção tenham sido apresentados apenas os valores clínicos reais, é relevante notar que os resultados obtidos estão em linha com as previsões do modelo discutidas na secção 4.3. Tal como antecipado pela análise da Fronteira de Pareto, o protocolo otimizado conseguiu reduzir significativamente a dose mantendo a qualidade dentro dos limites clínicos. Esta concordância entre previsões e resultados reais reforça a robustez do processo de otimização desenvolvido.

4.4.3 Síntese dos resultados

Os resultados obtidos permitem destacar:

- Os modelos estatísticos melhoraram progressivamente até estabilizar no 3.º ciclo, com R^2 ajustado $\approx 0,80$.
- A geração de combinações e a análise de Pareto permitiram selecionar protocolos equilibrados entre qualidade e dose.
- A validação clínica em 6 doentes confirmou a aplicabilidade prática, demonstrando redução significativa da dose sem comprometer a qualidade diagnóstica.

Estes resultados reforçam a utilidade da metodologia adotada, alinhada com os princípios de otimização da dose descritos na literatura (Kalra et al., 2020; Trattner et al., 2014)(Kalra et al., 2020; Trattner et al., 2014)e constituem a base para a discussão crítica apresentada no capítulo seguinte.

4.5 Interface interativa para exploração dos resultados

Com o objetivo de complementar a análise estatística e tornar os resultados mais acessíveis, foi desenvolvida a aplicação RAD-OPTIM — Otimização de Protocolos CT. Esta *interface*, implementada em *Python*, apresenta de forma integrada os principais *outputs* do modelo:

- Lista Top-N de protocolos segundo critérios definidos (dose máxima e qualidade mínima), ordenada por melhor compromisso entre qualidade e dose.
- Resumo do modelo OLS, exibindo coeficientes, valores de p e R^2 ajustado, garantindo transparência estatística.
- Gráfico Qualidade vs Dose, onde os pontos admissíveis são apresentados juntamente com a fronteira de Pareto, destacando os protocolos não dominados.

A Figura 6 ilustra a *interface* desenvolvida, com o painel lateral de controlo (filtros e exportação), a tabela Top-N de combinações e o gráfico da fronteira de Pareto.

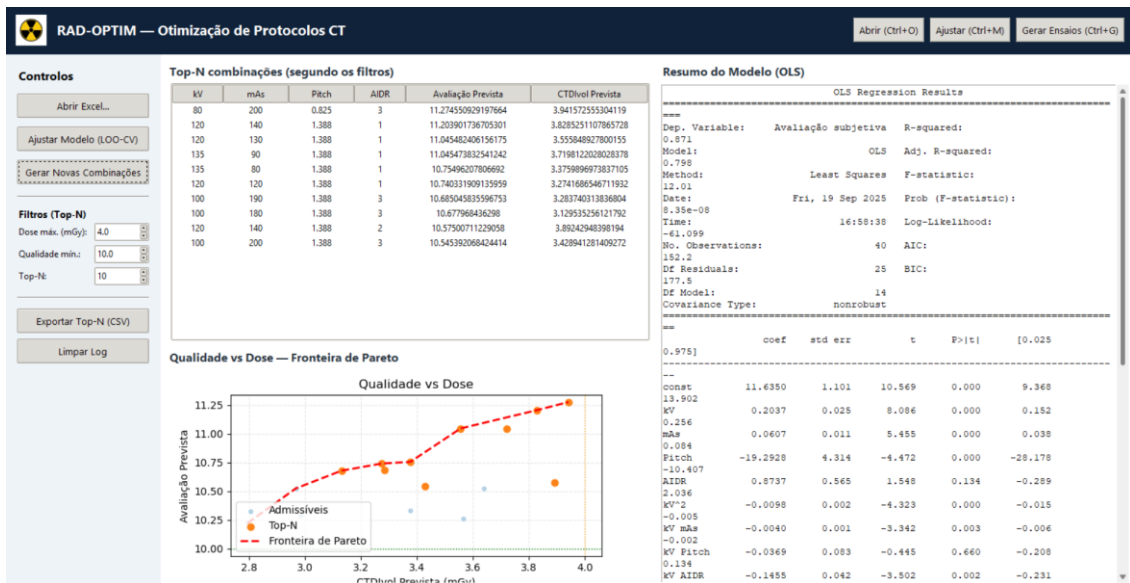


Figura 13 - Interface RAD-OPTIM utilizada para visualizar e explorar os resultados da otimização. A tabela apresenta o Top-N de combinações segundo os filtros definidos; o gráfico mostra a fronteira de Pareto, destacando os protocolos não dominados.

A aplicação permite ainda que o utilizador ajuste dinamicamente os filtros definidos para a região admissível. Através do painel lateral, é possível alterar em tempo real:

- O valor máximo de dose (CTDIvol, em mGy);
- A qualidade mínima exigida;
- O número de protocolos a incluir no Top-N.



Figura 14 - Filtros disponíveis para ajustar a região admissível

Sempre que estes parâmetros são modificados, a tabela central é imediatamente atualizada, apresentando os protocolos que cumprem os critérios definidos. Da mesma forma, o gráfico Qualidade vs Dose é reconstruído, mostrando a nova distribuição de pontos admissíveis e ajustando a fronteira de Pareto correspondente. Esta atualização automática confere grande flexibilidade, permitindo testar diferentes cenários clínicos de forma quase instantânea, sem necessidade de repetir cálculos externos.

Outro aspeto importante é a integração do resumo do modelo OLS, apresentado na mesma *interface*. Esta funcionalidade garante que, a par da lista de protocolos otimizados, é sempre possível consultar os indicadores estatísticos do modelo utilizado (coeficientes, significância, R² ajustado). Desta forma, o utilizador tem acesso não apenas ao resultado final (protocolos sugeridos), mas também à fundamentação estatística que sustenta essas previsões.

A aplicação inclui ainda a possibilidade de exportar o Top-N diretamente em formato CSV, criando registos que podem ser usados em auditorias clínicas ou replicação futura.

Top-N combinações (segundo os filtros)

kV	mAs	Pitch	AIDR	Avaliação Prevista	CTDIvol Prevista
80	200	0.825	3	11.274550929197664	3.941572555304119
120	140	1.388	1	11.203901736705301	3.8285251107865728
120	130	1.388	1	11.045482406156175	3.555848927800155
135	90	1.388	1	11.045473832541242	3.7198122028028378
135	80	1.388	1	10.75496207806692	3.3759896973837105
120	120	1.388	1	10.740331909135959	3.2741686546711932
100	190	1.388	3	10.685045835596753	3.283740313836804
100	180	1.388	3	10.677968436298	3.129535256121792
120	140	1.388	2	10.57500711229058	3.89242948398194
100	200	1.388	3	10.545392068424414	3.428941281409272

Figura 15 – Exemplo de lista Top-N apresentada na aplicação

Qualidade vs Dose — Fronteira de Pareto

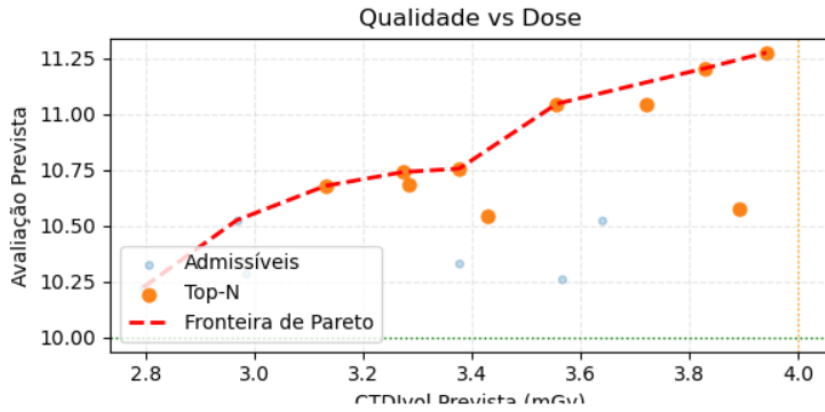


Figura 16- Exemplo de gráfico gerado pela aplicação

Assim, a RAD-OPTIM poderá funcionar bem como uma ferramenta de apoio à decisão, transformando os resultados da modelação em informação de fácil interpretação e manipulação. A possibilidade de explorar diferentes cenários em tempo real, ajustando limiares de dose e qualidade, mostra-se essencial para seleccionar protocolos equilibrados de forma transparente e reprodutível.

5 Conclusões

O presente trabalho teve como objetivo central a otimização e validação de um protocolo de TC torácica de baixa dose, procurando reduzir a exposição à radiação sem comprometer a qualidade diagnóstica. Para tal, recorreu-se a uma metodologia integrada que incluiu ensaios em fantoma, modelação estatística com regressão polinomial de 2.º grau, aplicação de técnicas de otimização multicritério através da Fronteira de Pareto e, finalmente, a validação clínica em doentes. Esta abordagem seguiu os princípios de proteção radiológica estabelecidos pela ICRP (2007) e as recomendações de boas práticas da AAPM para gestão e revisão de protocolos em TC (Cody et al., 2021)(Cody et al., 2021).

Os resultados demonstraram que os protocolos otimizados permitiram reduzir a dose em cerca de 42%, mantendo a qualidade da imagem dentro dos limites diagnósticos. Os modelos estatísticos apresentaram R^2 ajustado próximo de 0,80 no terceiro ciclo, valor que traduz robustez e capacidade explicativa adequadas, em consonância com estudos de regressão aplicados a exames de TC(Marcoulides & Raykov, 2018; Montgomery C et al., 2021)(Marcoulides & Raykov, 2018; Montgomery C et al., 2021). A utilização da Fronteira de Pareto mostrou-se eficaz para identificar combinações de parâmetros clinicamente equilibradas, alinhando-se com o reportado em estudos internacionais sobre otimização multicritério em imagiologia médica (Ahmadianshalchi et al., 2024; Trattner et al., 2014)(Ahmadianshalchi et al., 2024; Trattner et al., 2014).

Na validação clínica, realizada em seis doentes com exames comparativos, verificou-se que os resultados reais se mantiveram consistentes com as previsões do modelo. A redução significativa de dose, sem degradação da qualidade subjetiva ou do SNR, confirma a aplicabilidade prática do protocolo otimizado, em linha com evidências apresentadas em outros contextos de otimização da TC torácica (El Mansouri et al., 2021; Prabsattroo et al., 2023)(El Mansouri et al., 2021; Prabsattroo et al., 2023).

Ainda assim, algumas limitações devem ser reconhecidas. O número reduzido de doentes incluídos na validação clínica condiciona a generalização dos resultados, sendo necessária a aplicação em amostras maiores e em diferentes centros, tal como já defendido em estudos de auditoria clínica (Pandya et al., 2022)(Pandya et al., 2022). Além disso, o trabalho foi desenvolvido com um único equipamento (Canon Aquilion Lightning), o que pode limitar a extrapolação dos resultados para outros modelos de tomógrafos. Também a variabilidade interobservador na avaliação subjetiva não foi explorada de forma aprofundada, constituindo um aspeto que merece atenção em trabalhos futuros (Tamura et al., 2022)(Tamura et al., 2022)(Tamura et al., 2022)(Tamura et al., 2022).

Do ponto de vista prático, este estudo reforça que é possível implementar protocolos de baixa dose em TC torácica sem comprometer a prática clínica, em conformidade com as recomendações internacionais. Para além do impacto na proteção radiológica dos doentes, a

otimização de protocolos contribui para a sustentabilidade dos serviços de saúde, reduzindo repetições desnecessárias, tempo de exame e custos associados (Santos et al., 2023)(Santos et al., 2023)(Santos et al., 2023)(Santos et al., 2023).

Por fim, este trabalho abre caminho para perspectivas futuras. Destaca-se a necessidade de validação multicêntrica com amostras maiores, bem como a aplicação da metodologia a outros equipamentos e regiões anatómicas. Recomenda-se também a exploração de reconstruções baseadas em inteligência artificial, que têm demonstrado potencial para reduzir ainda mais a dose mantendo a qualidade de imagem (Brendlin et al., 2022)(Brendlin et al., 2022)(Brendlin et al., 2022)(Brendlin et al., 2022). Outra vertente promissora é a integração de métricas como o *Size Specific Dose Estimate* (SSDE) e o uso de simulações *Monte Carlo*, que permitem uma dosimetria mais personalizada e precisa (Boone et al., 2011; Verfaillie et al., 2024)(Boone et al., 2011; Verfaillie et al., 2024)(Boone et al., 2011; Verfaillie et al., 2024)(Boone et al., 2011; Verfaillie et al., 2024).

Em conclusão, este trabalho demonstrou que a otimização de protocolos em tomografia computadorizada é não só possível como necessária para equilibrar qualidade diagnóstica e proteção radiológica. Mais do que um exercício técnico, esta investigação representa um contributo concreto para práticas clínicas mais seguras, eficientes e sustentáveis. Acredita-se que os resultados aqui apresentados possam servir de base a estudos futuros e inspirar a implementação de soluções semelhantes noutros contextos clínicos.

Referências

- Ahmadianshalchi, A., Belakaria, S., & Doppa, J. R. (2024). Pareto Front-Diverse Batch Multi-Objective Bayesian Optimization. *Proceedings of the AAAI Conference on Artificial Intelligence*, 38(10), 10784–10794. <https://doi.org/10.1609/AAAI.V38I10.28951>
- Aldosari, S., Jansen, S., & Sun, Z. (2019). Optimization of computed tomography pulmonary angiography protocols using 3D printed model with simulation of pulmonary embolism. *Quantitative Imaging in Medicine and Surgery*, 9(1), 53–62. <https://doi.org/10.21037/qims.2018.09.15>
- Bauhs, J. A., Vrieze, T. J., Primak, A. N., Bruesewitz, M. R., & McCollough, C. H. (2008). CT dosimetry: comparison of measurement techniques and devices. *Radiographics : A Review Publication of the Radiological Society of North America, Inc*, 28(1), 245–253. <https://doi.org/10.1148/RG.281075024>
- Boone, J., Strauss, K., Cody, D., McCollough, C., McNitt-Gray, M., Toth, T., Goske, M., & Frush, D. (2011). *Size-Specific Dose Estimates (SSDE) in Pediatric and Adult Body CT Examinations*. <https://doi.org/10.37206/143>
- Brendlin, A. S., Schmid, U., Plajer, D., Chaika, M., Mader, M., Wrazidlo, R., Männlin, S., Spogis, J., Estler, A., Esser, M., Schäfer, J., Afat, S., & Tsiflikas, I. (2022). AI Denoising Improves Image Quality and Radiological Workflows in Pediatric Ultra-Low-Dose Thorax Computed Tomography Scans. *Tomography 2022, Vol. 8, Pages 1678-1689*, 8(4), 1678–1689. <https://doi.org/10.3390/TOMOGRAPHY8040140>
- Cardoso Coelho, R. P., Carvalho Alves, A. F., & Andrade Pires, F. M. (2024). Efficient constitutive parameter identification through optimisation-based techniques: A Comparative analysis and novel composite Bayesian optimisation strategy. *Computer Methods in Applied Mechanics and Engineering*, 427, 117039. <https://doi.org/10.1016/J.CMA.2024.117039>
- Cody, D. D., Dillon, C. M., Fisher, T. S., Liu, X., McNitt-Gray, M. F., & Patel, V. (2021). AAPM Medical Physics Practice Guideline 1.b: CT protocol management and review practice guideline. *Journal of Applied Clinical Medical Physics*, 22(6), 4. <https://doi.org/10.1002/ACM2.13193>
- El Mansouri, M., Choukri, A., Talbi, M., & Khallouki, H. (2021). Computed Tomography Scan Optimization of Chest and Abdomen Protocols. *Moscow University Physics Bulletin*, 76, S88–S94. <https://doi.org/10.3103/S0027134922010155>
- Galvão, R. K. H., de Araújo, M. C. U., & Soares, S. F. C. (2020). 3.13 - Linear Regression Modeling: Variable Selection. *Comprehensive Chemometrics: Chemical and Biochemical Data Analysis, Second Edition: Four Volume Set*, 3, 249–293. <https://doi.org/10.1016/B978-0-12-409547-2.14706-7>

- Giansante, L., Martins, J. C., Nersissian, D. Y., Kiers, K. C., Kay, F. U., Sawamura, M. V. Y., Lee, C., Gebrim, E. M. M. S., & Costa, P. R. (2018). Organ doses evaluation for chest computed tomography procedures with TL dosimeters: Comparison with Monte Carlo simulations. *Journal of Applied Clinical Medical Physics*, 20(1), 308. <https://doi.org/10.1002/ACM2.12505>
- Goldman, L. W. (2007). Principles of CT: Radiation Dose and Image Quality. *Journal of Nuclear Medicine Technology*, 35(4), 213–225. <https://doi.org/10.2967/JNMT.106.037846>
- ICRP. (2007). *Annals of the ICRP Published on behalf of the International Commission on Radiological Protection*.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning*. <https://doi.org/10.1007/978-1-0716-1418-1>
- Kalra, M. K., Homayounieh, F., Arru, C., Holmberg, O., & Vassileva, J. (2020). Chest CT practice and protocols for COVID-19 from radiation dose management perspective. *European Radiology*, 30(12), 6554–6560. <https://doi.org/10.1007/S00330-020-07034-X>
- Kutner, M. (1996). Applied linear regression models. *Technometrics*, 39(3), 342–342. <https://doi.org/10.1080/00401706.1997.10485142>
- Lung Cancer Screening CT Protocols Version 6.0 09 November 2023*. (2015).
- Marcoulides, K. M., & Raykov, T. (2018). Evaluation of Variance Inflation Factors in Regression Models Using Latent Variable Modeling Methods. *Educational and Psychological Measurement*, 79(5), 874. <https://doi.org/10.1177/0013164418817803>
- McCollough, C. H., Boedeker, K., Cody, D., Duan, X., Flohr, T., Halliburton, S. S., Hsieh, J., Layman, R. R., & Pelc, N. J. (2020). Principles and applications of multienergy CT: Report of AAPM Task Group 291. *Medical Physics*, 47(7), e881–e912. <https://doi.org/10.1002/MP.14157>
- McCollough, C. H., Bruesewitz, M. R., & Kofler, J. M. (2006). CT Dose Reduction and Dose Management Tools: Overview of Available Options1. <https://doi.org/10.1148/Rg.262055138>, 26(2), 503–512. <https://doi.org/10.1148/RG.262055138>
- Miller-Clemente, R., Pérez-Díaz, M., Lores Guevara, M., Ortega Rodríguez, O., Nepite Haber, R., Griñán Hernández, O., & Guillama Llossas, A. (2014). Optimización de protocolo en tomografía computerizada pediátrica con control automático de exposición. *Imagen Diagnostica*, 5(1), 10–16. <https://doi.org/10.1016/j.imadi.2013.09.003>
- Montgomery C, D., Peck A, E., & Vining, G. G. (2021). *Introducing To Linear Regression Analysis* (5th ed.). *John Wiley and Sons*, 642. <https://www.wiley.com/en-us/Introduction+to+Linear+Regression+Analysis%2C+6th+Edition-p-9781119578727>

- Pandya, R. H., Shinde, M. K., Patel, V. B., Phatak, A. G., & Pandya, H. V. (2022). Development and implementation of optimized chest CT protocol in COVID-19. *Journal of Family Medicine and Primary Care*, *11*(7), 3705–3710. https://doi.org/10.4103/jfmpe.jfmpe_2214_21
- Pimentel, J., Finatto, J. D., Froner, A. P. P., & Silva, A. M. M. da. (2013). Otimização de dose em exames de pacientes adultos em um serviço de tomografia computadorizada. *Revista Brasileira de Física Médica*, *7*(2), 79–80. <https://doi.org/10.29384/RBFM.2013.V7.N2.P79-80>
- Prabsattroo, T., Wachirasirikul, K., Tansangworn, P., Punikhom, P., & Sudchai, W. (2023). *Dose Optimization and Evaluation of Image Quality in Adult Brain Protocol of Multislice Computed Tomography: A Phantom Study*. <https://doi.org/10.20944/preprints202311.0443.v1>
- Prata Mourão, A., Namen Aburjaile, W., & Stephanie Santos, F. (2019). Dosimetry and Protocol Optimization of Computed Tomography Scans using Adult Chest Phantoms. *Int J Radiol Imaging Technol*, *5*(1), 50. <https://doi.org/10.23937/2572-3235.1510050>
- Raman, S. P., Mahesh, M., Blasko, R. V., & Fishman, E. K. (2013). *CT Scan Parameters and Radiation Dose: Practical Advice for Radiologists*. <https://doi.org/10.1016/j.jacr.2013.05.032>
- Report No. 160 – Ionizing Radiation Exposure of the Population of the United States (2009) - NCRP | Bethesda, MD. (n.d.). Retrieved March 21, 2025, from <https://ncrponline.org/shop/reports/report-no-160-ionizing-radiation-exposure-of-the-population-of-the-united-states/>
- Ria, F., Zhang, A. R., Lerebours, R., Erkanli, A., Abadi, E., Marin, D., & Samei, E. (2024). Optimization of abdominal CT based on a model of total risk minimization by putting radiation risk in perspective with imaging benefit. *Communications Medicine*, *4*(1), 1–9. <https://doi.org/10.1038/S43856-024-00674-W>;TECHMETA=59;SUBJMETA=1421,1846,2771,2772,478,692,700;KWRD=COMPUTED+TOMOGRAPHY,POPULATION+SCREENING
- Santos, F. A., Campos, L., & Ferreira, C. C. (2023). Optimization of Protocols used in the Clinical Routine of a Tomographer in a University Hospital. *Revista Brasileira de Física Médica*. <https://doi.org/10.29384/rbfm.2023.v16.19849001681>
- Scott, A. W., Alancherry, A. S. P., Lee, C., Eastman, E., & Zhou, Y. (2024). Computed tomography dose index determination in dose modulation prospectively involving the third-generation iterative reconstruction and noise index. *Journal of Applied Clinical Medical Physics*, *25*(4). <https://doi.org/10.1002/ACM2.14167>,

- Shope, T. B., Gagne, R. M., & Johnson, G. C. (1981). A method for describing the doses delivered by transmission x-ray computed tomography. *Medical Physics*, *8*(4), 488–495. <https://doi.org/10.1118/1.594995>
- Singh, S., Kalra, M. K., Gilman, M. D., Hsieh, J., Pien, H. H., Digumarthy, S. R., & Shepard, J. A. O. (2011). Adaptive statistical iterative reconstruction technique for radiation dose reduction in chest CT: a pilot study. *Radiology*, *259*(2), 565–573. <https://doi.org/10.1148/RADIOL.11101450>
- Tamura, A., Mukaida, E., Ota, Y., Nakamura, I., Arakita, K., & Yoshioka, K. (2022). Deep learning reconstruction allows low-dose imaging while maintaining image quality: comparison of deep learning reconstruction and hybrid iterative reconstruction in contrast-enhanced abdominal CT. *Quantitative Imaging in Medicine and Surgery*, *12*(5), 2977–2984. <https://doi.org/10.21037/QIMS-21-1216/COIF>
- The 2007 Recommendations of the International Commission on Radiological Protection. ICRP publication 103. (2007). *Annals of the ICRP*, *37*(2–4), 1–332. <https://doi.org/10.1016/J.ICRP.2007.10.003>
- Trattner, S., Pearson, G. D. N., Chin, C., Cody, D. D., Gupta, R., Hess, C. P., Kalra, M. K., Kofler, J. M., Krishnam, M. S., & Einstein, A. J. (2014). Standardization and optimization of CT protocols to achieve low dose. *Journal of the American College of Radiology*, *11*(3), 271–278. <https://doi.org/10.1016/j.jacr.2013.10.016>
- UNSCEAR 2020/2021 Report Volume I. (n.d.). Retrieved March 21, 2025, from https://www.unscear.org/unscear/en/publications/2020_2021_1.html
- Verfaillie, G., Rutten, J., D’Asseler, Y., & Bacher, K. (2024). Accuracy of patient-specific CT organ doses from Monte Carlo simulations: influence of CT-based voxel models. *Physical and Engineering Sciences in Medicine*, *47*(3), 989. <https://doi.org/10.1007/S13246-024-01422-Z>
- Wang, H., Yang, K., & Affenzeller, M. (2024). *Probability Distribution of Hypervolume Improvement in Bi-objective Bayesian Optimization*.
- Woeltjen, M. M., Niehoff, J. H., Michael, A. E., Horstmeier, S., Moeninghoff, C., Borggreffe, J., & Kroeger, J. R. (2022). Low-Dose High-Resolution Photon-Counting CT of the Lung: Radiation Dose and Image Quality in the Clinical Routine. *Diagnostics (Basel, Switzerland)*, *12*(6). <https://doi.org/10.3390/DIAGNOSTICS12061441>
- Xun, S., Li, Q., Liu, X., Huang, P., Zhai, G., Sun, Y., de With, P. H. N., Wu, M., & Tan, T. (2025). Charting the path forward: CT image quality assessment - an in-depth review. *Journal of King Saud University - Computer and Information Sciences*, *37*(5), 1–24. <https://doi.org/10.1007/S44443-025-00085-4/FIGURES/7>