



ISEL
INSTITUTO SUPERIOR DE
ENGENHARIA DE LISBOA

Instituto Superior de Engenharia de Lisboa



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

Escola Superior de Tecnologia da Saúde de Lisboa

Sistema automático de análise da qualidade técnica da radiografia frontal do tórax

IVONE CIDADE DE MOURA
(Licenciada em Radiologia)

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

Orientador

Doutor Ricardo Teresa Ribeiro

Júri

Presidente: Mestre Sérgio Rafael Reis Figueiredo

Vogais:

Doutor Sérgio Saraiva Alves

Doutor Ricardo Teresa Ribeiro

Outubro de 2024

Sistema automático de análise da qualidade técnica da radiografia frontal do tórax

IVONE CIDADE DE MOURA
(Licenciada em Radiologia)

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

Orientador

Doutor Ricardo Teresa Ribeiro, Haute École de Santé Vaud

Júri

Presidente: Mestre Sérgio Rafael Reis Figueiredo, Escola Superior de Tecnologias da Saúde de Lisboa

Vogais:

Doutor Sérgio Saraiva Alves, Escola Superior de Saúde da Cruz Vermelha & Unidade Local de Saúde de São José
Doutor Ricardo Teresa Ribeiro, Haute École de Santé Vaud

Outubro de 2024

Agradecimentos

O estudo apresentado é o culminar de mais uma etapa na minha jornada profissional e académica, a qual não seria possível sem o apoio e motivação de um conjunto de pessoas que me inspiram a continuamente procurar superar-me.

O meu primeiro agradecimento é dirigido ao meu orientador, o Professor Doutor Ricardo Teresa Ribeiro, por me desafiar a desenvolver a minha investigação numa área que me permitiu cruzar os conhecimentos que acumulei ao longo da minha prática clínica com a visão da Engenharia. Nesta navegação nem sempre fácil, algumas vezes a sentir que estaria a sair fora de pé, foi o apoio e guia que me auxiliou a clarificar os caminhos a tomar, e sem a sua orientação esta viagem não seria a mesma.

Estou grata à minha família por acreditarem em mim, e por toda a “aldeia” que se reorganizou para que pudesse concretizar este objetivo. Ao meu marido Filipe, que me inspira e instiga a procurar novas formas de realização e conhecimento, e aos meus filhos, Salvador e Lourenço, para quem espero ser um exemplo de que devemos buscar novos conhecimentos ao longo da nossa vida e que uma jornada só é recompensadora se o caminho for desafiante.

Agradeço também à família alargada que são os amigos mais próximos pela motivação, paciência e disponibilidade, e que tantas vezes foram a rede invisível de apoio emocional na montanha russa que foram estes dois anos.

Deixo também uma palavra de estima e agradecimento aos meus colegas da Unidade Local de Saúde Santa Maria (ULSSM), por terem permitido que conseguisse conciliar as exigências das responsabilidades profissionais com este percurso académico, em particular às colegas de equipa no Hospital Pulido Valente (HPV), pela disponibilidade e apoio em facilitar-me esta coordenação.

Por fim, quero agradecer aos professores e colegas com que me cruzei nesta jornada desdobrada entre a primeira casa que foi a Escola Superior de Tecnologias da Saúde de Lisboa (ESTeSL) e a nova casa que se tornou o Instituto Superior de Engenharia de Lisboa (ISEL), e que enriqueceram esta experiência de partilha e crescimento pessoal e profissional.

Resumo

A radiografia do tórax permanece uma pedra angular da imagiologia de diagnóstico em todo o mundo. A sua capacidade de fornecer informações diagnósticas críticas, especialmente nas patologias pneumológicas, combinada com a acessibilidade, relação custo-eficácia e resultados rápidos, realça o seu papel insubstituível nos cuidados de saúde globais. Na radiografia do tórax, o correto posicionamento do paciente e a desprojeção das omoplatas é essencial. A sobreposição aos pulmões pode ocultar detalhes cruciais, potencialmente enganadores para médicos novatos e estudantes de radiologia. Garantir uma técnica de aquisição de imagem clara é fundamental para a deteção precisa de anomalias pulmonares. Ao tirar partido das capacidades da inteligência artificial (IA), este projeto visa desenvolver um modelo para detetar e segmentar a sobreposição da omoplata ao pulmão na radiografia frontal do tórax.

Recorreu-se ao *dataset* público de radiografia do tórax do *NIH*, onde os 28.868 pacientes únicos com imagens de radiografia do tórax foram pré-processados. Posteriormente, um modelo *PSPNet* pré-treinado da biblioteca *Torchxrayvision python* foi utilizado para segmentar as principais estruturas anatómicas identificadas num exame de radiografia do tórax frontal. O algoritmo detetou a omoplata em 99.8% dos exames, sendo que 40% apresentaram sobreposição da omoplata. Verificou-se uma relação linear moderada, $R=0.673$, $p<0.05$, entre os lados esquerdo e direito, sugerindo um aumento simultâneo nas percentagens de sobreposição.

Conclui-se que algoritmo desenvolvido deteta com eficácia a sobreposição da omoplata nas imagens de radiografia do tórax frontal, tornando-o numa valiosa ferramenta educacional e de controlo de qualidade da imagem. A sua sobreposição, muitas vezes mínima, denota a importância crucial do rigor da técnica de posicionamento por parte dos técnicos superiores de radiologia.

Palavras-chave:

Inteligência Artificial, Radiografia, Tórax, Radiologia Convencional, Controlo de Qualidade, Aprendizagem Automática, *Deep Learning*, CAD

Abstract

Chest x-ray remains a cornerstone of diagnostic radiology worldwide. Its ability to provide critical diagnostic information, especially on pneumological medical conditions, combined with its accessibility, cost-effectiveness and rapid results, underscores its irreplaceable role in global healthcare. In chest x-ray image, correct scapula positioning is essential. Overlapping with lungs can hide crucial details, potentially misleading novice clinicians and radiography students. Ensuring clear imaging technique is key for accurate lung anomaly detection. Leveraging AI's capabilities, this project aims to develop a model to detect and segment the scapula-lung overlap in frontal chest x-ray.

Using the NIH chest x-ray public dataset, the 28,868 unique patients with frontal chest x-ray images were pre-processed. Secondly, a pre-trained PSPNet model from Torchxrayvision python library was used to segment the principal anatomic structures identified in a chest x-ray frontal exam. The algorithm detected the scapula in 99.8% of exams, with 40% showing scapula overlay. A moderate linear relationship, $R=0.673$, $p<0.05$, exists between sides, suggesting simultaneous increase in overlap percentages.

The developed algorithm effectively detects scapula overlap in frontal x-ray images, making it valuable for educational and quality assessment tools. Overlap, often minimal, suggests crucial positioning technique consistency from radiographers.

Keywords:

Artificial Intelligence, Radiography, Thorax, Conventional Radiology, Quality Assurance, Machine Learning, Deep Learning, CAD

Índice Geral

Agradecimentos.....	V
Abstract	VIII
Índice de Figuras	X
Índice de Tabelas	XII
Lista de Abreviaturas e Siglas.....	XIII
Introdução.....	1
Enquadramento Teórico	7
Materiais e Métodos.....	23
Resultados e Discussão	31
Conclusão.....	44
Referências Bibliográficas	47
Anexos	53

Índice de Figuras

Figura 1: Posicionamento do paciente em radiografia ao tórax em incidência PA ortostática (Fonte: Tratado de Técnica Radiológica e Base Anatômica)	9
Figura 2: Posicionamento do paciente em radiografia ao tórax em incidência AP semi-ortostática (Fonte: Tratado de Técnica Radiológica e Base Anatômica)	10
Figura 3: Posicionamento do paciente em radiografia ao tórax em incidência AP em decúbito dorsal (Fonte: Tratado de Técnica Radiológica e Base Anatômica)...	10
Figura 4: Posicionamento do paciente em radiografia ao tórax em incidência de perfil (Fonte: Tratado de Técnica Radiológica e Base Anatômica).....	11
Figura 5: Critérios de qualidade de imagem em radiografia ao tórax em incidência PA segundo as guidelines da CE	12
Figura 6: Variações no volume torácico em visão sagital durante os movimentos respiratórios: a) inspiração e b) expiração (Fonte: Encyclopaedia Britannica) .	13
Figura 7: Fórmula de cálculo do coeficiente de Pearson	28
Figura 8: Fórmula de cálculo do teste do qui-quadrado	29
Figura 9: Metodologia seguida para a segmentação das omoplatas e dos campos pulmonares, a partir da radiografia original, conseqüente detecção das omoplatas sobre os campos pulmonares e criação de um heatmap sobreposto à imagem original.....	31
Figura 10: Exemplo de imagens onde a omoplata não foi detetada	32
Figura 12: Percentagem de casos onde foi detetada a sobreposição das omoplatas sobre os campos pulmonares.....	34
Figura 14: Diagrama de dispersão da correlação entre a sobreposição da omoplata à esquerda e da omoplata à direita	36
Figura 15: Percentagem de exames no dataset, por incidência	38
Figura 16: a) Caixas de bigodes da sobreposição das omoplatas sobre o campo pulmonar esquerdo para a incidência PA e AP; b) Caixas de bigodes da sobreposição	

das omoplatas sobre o campo pulmonar direito para a incidência PA e
AP.....41

Índice de Tabelas

Tabela 1: Número de casos onde foi detetada a presença das omoplatas na imagem radiográfica	32
Tabela 2: Número de casos onde foi detetada a sobreposição das omoplatas sobre os campos pulmonares	34
Tabela 3: Dados obtidos da análise estatística na sobreposição da omoplata sobre o campo pulmonar esquerdo e direito	35
Tabela 4: Número total de exames no dataset, por incidência	38
Tabela 5: Detecção e sobreposição de omoplata de acordo com a incidência e percentagem média de sobreposição das omoplatas esquerda e direita ao pulmão	39
Tabela 6: Teste de normalidade de Shapiro-Wilk	40
Tabela 7: Teste de homogeneidade de variâncias de Levene	41
Tabela 8: Teste U de Mann-Whitney	41
Tabela 9: Medidas de tendência central para a sobreposição das omoplatas aos campos pulmonares esquerdo e direito para as incidências AP e PA	42

Lista de Abreviaturas e Siglas

Sigla	Expansão	Tradução
ANN	Artificial Neural Network	Rede Neural Artificial
AP	Antero-posterior	
AUC	Area Under the Curve	Área abaixo da curva
CAD	Computer-aided diagnosis	Diagnóstico auxiliado por computador
CE	Comissão Europeia	
CNN	Convolutional Neural Network	Rede neural Convolutacional
DL	Deep Learning	Aprendizagem Profunda
DPOC	Doença Pulmonar Obstrutiva Crónica	
IA	Inteligência Artificial	
kV	Kilovolts	
mAs	Miliampere segundo	
ML	Machine Learning	Aprendizagem Automática
PA	Postero-anterior	
PACS	Picture Archiving and Communication System	Sistema de Arquivo e Comunicação de Imagens
RC	Radiologia Convencional	
RM	Ressonância Magnética	
ROI	Region of Interest	Região de Interesse
TC	Tomografia Computorizada	
US	Ultrassonografia	

Introdução

No âmbito da imagem médica, a radiografia permanece o estudo mais realizado mundialmente, cerca de mil milhões de exames por ano, sendo o tórax uma das regiões anatómicas mais estudadas por esta técnica. Tal deve-se ao facto de continuar a ser uma ferramenta vital na avaliação da patologia torácica, apesar do desenvolvimento de outras técnicas avançadas de imagem. ^[1,2]

A radiologia convencional (RC), é uma técnica de imagem médica que recorre à radiação X para criar imagens morfológicas (ex. Radiografia) e funcionais (ex. Fluoroscopia) das estruturas anatómicas do corpo, sendo normalmente utilizada para diagnosticar e monitorizar várias condições médicas, permitindo visualizar ossos, órgãos e tecidos. Durante a aquisição da imagem, uma dose controlada de radiação X atravessa a área anatómica em estudo e a imagem resultante é capturada num detetor. ^[1,3]

A radiografia apresenta múltiplas vantagens que incluem a sua acessibilidade, o baixo custo, a menor exposição do paciente à radiação e menor tempo de leitura. Em particular, a radiografia do tórax, tem um profundo impacto económico nos sistemas de saúde em todo o mundo. Além dos seus benefícios clínicos, desempenha um papel fundamental em diagnósticos com eficiência de custos, auxiliando em diagnósticos precisos em tempo necessário, enquanto otimiza a alocação de recursos. ^[3]

O desenvolvimento e acessibilidade a outras técnicas de imagem médica, não reduziu o recurso aos estudos por radiografia convencional, ao permitir não apenas diagnóstico inicial como *follow-up*. Aquando da avaliação de um paciente, em particular em suspeita de patologia pulmonar, a radiografia convencional poderá ser o único exame necessário, contudo em alguns casos, pode ser necessário a tomografia computadorizada (TC), por exemplo, em situações de diagnóstico precoce de doença pulmonar intersticial. *A posteriori*, será possível fazer o acompanhamento do curso da patologia com radiografia convencional. Por oposição, a existência apenas de um estudo por TC sem uma radiografia comparativa, torna difícil o acompanhamento. ^[1,3]

A importância da radiografia ao tórax tornou-se ainda mais evidente durante a pandemia por COVID-19, onde o acesso fácil, aliado a um menor tempo de interpretação para realização de diagnóstico, baixa exposição à radiação como triagem primária e baixo custo na avaliação da pneumonia, conduziram a que esta fosse a técnica de imagem muitas vezes seleccionada para estudo dos pacientes ao longo do curso da doença. ^[4,5] Vários autores continuam a reforçar a importância da radiografia ao tórax nos dias de

hoje, destacando o papel crucial deste exame no diagnóstico e monitorização de anormalidades pulmonares, na avaliação da saúde cardíaca, lesões torácicas traumáticas e no auxílio ao diagnóstico de doenças respiratórias infecciosas. [6,7,8,9] Sendo uma técnica de imagem económica e prontamente disponível, continua a fornecer informações valiosas para otimizar o atendimento ao paciente e orientar decisões de tratamento adequadas.

Os avanços tecnológicos aumentaram significativamente a acessibilidade e a capacidade de produção de exames radiológicos, reduzindo simultaneamente os tempos de exame. [10] O *workload* dos radiologistas (*i.e.*, o produto entre o número e a complexidade dos exames produzidos por unidade de tempo) aumentou consideravelmente nas últimas décadas, associado ao crescimento do número de exames seccionais de imagem médica (como a tomografia computadorizada e a ressonância magnética) e da maior complexidade da interpretação da imagem devido à aquisição de maiores *datasets*. [11] Um estudo recente sugeriu que, em alguns casos, um radiologista deve, em média, interpretar uma imagem a cada 3-4 segundos num dia de trabalho de 8 horas para fazer face à demanda do volume de trabalho. Como a leitura do exame envolve perceção visual bem como tomada de decisão sob incerteza, a ocorrência de erros é inevitável. [12] Aliado a este facto, a maioria dos radiologistas, experienciam volumes de trabalho inesperados pelo menos uma vez por semana. [13]

O crescente volume de exames ultrapassou a disponibilidade dos serviços, o que leva à redução do tempo de interpretação pelos radiologistas e ao aumento da pressão para fornecer exames de qualidade clínica e pareceres clínicos atempados, particularmente em ambiente de urgência médica. [14,15] A pressão para o aumento da produtividade acontece em paralelo com uma restrição à margem financeira para contratar novos profissionais, que conseqüentemente, não só aumenta o volume de trabalho por radiologista como o risco de *burnout* destes profissionais, comprometendo a qualidade e segurança do cuidado ao paciente. [11] Com o objetivo de otimizar a alocação de recursos, os radiologistas tendem a priorizar os exames que exigem interpretação mais especializada e contam com modalidades de imagem mais simples, como a radiografia, para serem lidas por médicos sem ampla experiência radiológica. [14,15] Esta abordagem ajuda a mitigar o risco de má interpretação e garante relatórios precisos em exames mais complexos, salvaguardando, em última análise, os resultados dos pacientes. Contudo, o processo e resultado da análise dos exames radiológicos está dependente da experiência, formação e nível de atenção dos clínicos, e dado o elevado volume diário de exames, é possível que padrões anormais subtis passem despercebidos. [14]

À medida que as técnicas de imagem médica tornam-se mais sofisticadas e a pressão para a produção de resultados aumenta, a garantia da qualidade dos exames torna-se cada vez mais significativa. A avaliação da qualidade nos exames de imagem médica é crucial para garantir que as imagens obtidas sejam de elevada qualidade técnica e clínica e possam oferecer aos médicos as informações necessárias para diagnósticos precisos e tomadas de decisão. Otimizar a precisão diagnóstica, a produtividade do radiologista e a eficiência do fluxo de trabalho são, portanto, essenciais a qualquer serviço de Imagiologia. ^[16]

As métricas de qualidade em radiologia são focadas na precisão diagnóstica e na eficiência do fluxo de trabalho, sendo a mais frequentemente referenciada o tempo de resposta de relatório. A transição digital dos serviços de radiologia facilitou o processo de arquivo, o processamento e extração de informações de cariz clínico dos exames radiológicos, permitindo um acompanhamento e análise longitudinal dos doentes. ^[17] As imagens radiológicas digitais permitem maior qualidade e a possibilidade de utilizar técnicas de pós-processamento e otimizar radiografias após a aquisição, de forma a reduzir a necessidade de repetição e consequentemente a exposição à radiação X. No entanto, a manipulação da imagem não permite corrigir problemas associado ao posicionamento do paciente, baixos volumes pulmonares, sub ou sobre-exposição de partes ou artefactos do corpo, ausência de estruturas anatómicas críticas no estudo pulmonar ou colimação inadequada. ^[17]

As técnicas de imagem radiográfica são vulneráveis à qualidade suboptimal e, portanto, requerem medidas de vigilância e controle de qualidade. O impacto das radiografias ao tórax abaixo do nível de qualidade técnica não é trivial. Por exemplo, num paciente crítico ou instável, a ausência dos ápices pulmonares ou da anatomia subjacente pode limitar a avaliação de um potencial pneumotórax, pneumonia apical ou lesões. De igual forma, uma imagem sub-exposta ou com baixos volumes pulmonares, pode limitar a avaliação das bases e da posição de linhas e tubos. A rotação excessiva do paciente pode afetar a avaliação de anormalidades pulmonares, dos hilos e cardiomediastínicas. Artefactos podem mimetizar lesões, desencadeando exames diagnósticos adicionais ou repetição de exames, podendo causar ansiedade ao paciente. Radiografias abaixo do ideal podem também conduzir a interpretações incorretas resultantes de interpretações falso-positivas ou falso-negativas dos achados radiológicos. ^[18] Exames de qualidade técnica diminuída não só prejudicam a interpretação diagnóstica como também têm impacto económico. O custo médio nacional de radiografia ao tórax nos Estados Unidos da América (EUA) é de US\$ 420, com variações substanciais em diferentes locais e, por

vezes, na mesma região. Dado que por ano, em todo o mundo, 40% dos 3,6 mil milhões de estudos por imagem realizados são radiografias ao tórax, a implicação de custo de exames abaixo do ideal rejeitados e repetidos é enorme. ^[18] A repetição de uma radiografia está associada ao aumento da exposição à radiação, tempo e recursos adicionais, problemas no fluxo de trabalho, atrasos no diagnóstico e possíveis limitações e obstáculos na interpretação com suboptimização persistente. Tecnologias baseadas em inteligência artificial (IA) têm sido desenvolvidas como possíveis soluções para apoiar os radiologistas na gestão do seu *workload*, onde o elevado volume de radiografias realizadas diariamente, faz deste exame um alvo primordial para o desenvolvimento e implementação destas soluções. ^[1,2]

A IA surge como uma das principais plataformas transformadoras nos cuidados de saúde, tendo como posicionamento estratégico apoiar a resolução de diferentes desafios através da utilização de dados clínicos, como a radiografia do tórax, e algoritmos de classificação. Para garantir um impacto positivo, deve-se considerar uma estrutura de cuidados de saúde baseada na criação de valor, assumindo-se como valor o rácio entre os resultados clínicos e os seus custos associados (por exemplo financeiros, éticos, ganhos em saúde). Neste contexto, a IA pode gerar valor reduzindo os custos e/ou melhorando os resultados em termos de saúde. ^[19]

Na radiologia, a IA pode ser utilizada para melhorar a eficiência do fluxo de trabalho, acelerar o tempo de leitura do exame, minimizar a dose de radiação e a utilização de agentes de contraste, melhorar a precisão do diagnóstico para a deteção precoce de doenças e permitir diagnósticos personalizados. ^[20,21,22] Hosny *et al.* (2018) sugere que uma solução de IA perfeitamente integrada no fluxo de trabalho de um serviço de radiologia, permitiria aumentar a eficácia, reduzir erros e alcançar objetivos com contributo manual mínimo, fornecendo radiologistas treinados com imagens pré-selecionadas e características identificadas. ^[12] Avanços significativos em IA foram alcançados devido ao desenvolvimento de abordagens de aprendizagem automática, incluindo *deep learning* que provaram ser particularmente adequadas para estudos baseados em imagens, uma maior capacidade computacional e o aumento dos dados disponíveis para treino de algoritmos, resultando numa revolução de aplicações em interpretação médica. ^[2,23] O número crescente de soluções de IA disponíveis no mercado para análise de radiografia, oferecem novas oportunidades para a radiologia recorrer à IA como forma de acrescentar valor ao fluxo de trabalho clínico e no cuidado ao paciente, ao oferecer maior precisão, eficiência e melhores resultados para os pacientes. Os esforços de desenvolvimento de soluções centraram-se na radiologia

convencional devido não apenas à sua importância na prática clínica, mas também pela grande quantidade de dados de imagem disponíveis para algoritmos de treino e pela sua simplicidade como representação bidimensional de um objeto tridimensional. [2]

Várias soluções comerciais fornecem ferramentas de análise de imagem orientadas por IA que podem detetar e destacar automaticamente anomalias, reduzindo as probabilidades de lapso e permitindo a intervenção precoce. Estas soluções utilizam técnicas de *deep learning* para continuamente otimizar os seus algoritmos a partir de grandes quantidades de dados de imagens, melhorando o seu desempenho ao longo do tempo. As soluções comerciais incorporam, entre outros, sistemas de diagnóstico apoiado por computador (*computer-aided diagnosis* – CAD), que utilizam algoritmos para analisar imagens médicas e fornecer sugestões automatizadas ou segundas opiniões durante o processo de diagnóstico. Ao combinar a experiência dos profissionais de saúde com a eficiência e consistência dos algoritmos, permitem melhorar a precisão e o tempo de diagnóstico. As ferramentas desenvolvidas pelas entidades comerciais podem também ser uma mais-valia no fluxo de trabalho. Ao automatizar e otimizar tarefas de rotina, como segmentação de imagens, extração de medições e produção de relatórios, libertam os radiologistas permitindo que se foquem em casos complexos que exigem a sua *expertise*. Desta forma, é possível aumentar a produtividade e reduzir os tempos de resposta, aumentando a eficiência geral dos serviços de imagiologia. Algumas soluções permitem também análises preditivas e avaliação de riscos. Ao analisar grandes conjuntos de dados, os algoritmos de IA podem identificar padrões, correlações e fatores de risco associados a determinadas patologias. Este recurso auxilia na deteção precoce de doenças, prognóstico e planeamento de tratamento personalizado. [2,18]

Apesar dos desenvolvimentos nas soluções disponibilizadas e dos estudos publicados na área da IA orientada para a radiologia anteriormente referidos, existe uma escassez de conhecimento científico sobre o potencial de técnicas de IA na análise da qualidade técnica de radiografias. A compreensão dos algoritmos e a utilização de IA em imagens médicas é de extrema importância tanto para os técnicos superiores de radiologia como para os médicos radiologistas. A qualidade das imagens utilizadas para treino dos algoritmos desenvolvidos é crucial para garantir a confiança e a precisão clínica dos resultados.

Enquanto ferramenta integrada nos serviços de imagiologia, a utilização da IA na análise da qualidade da radiografia ao tórax permitiria não só a melhoria contínua das funções

dos profissionais, mas também a possibilidade de um desenvolvimento mais centrado no doente, bem como a integração em equipas de investigação. Este estudo enquadra-se no Mestrado de Engenharia Biomédica, tendo como objetivo principal: desenvolver um sistema de deteção e caracterização automático da sobreposição das omoplatas nos campos pulmonares na análise da qualidade técnica da radiografia frontal do tórax, através de um modelo de *deep learning*. Definiram-se os seguintes objetivos específicos: objetivo 1. Análise da Deteção das Omoplatas; objetivo 2. Análise bilateral entre postero-anterior (PA) e antero-posterior (AP) da sobreposição das omoplatas aos campos pulmonares; objetivo 3. Análise da diferença entre PA e AP no padrão de sobreposição da omoplata dos campos pulmonares.

O documento apresentado está organizado de seguida no Enquadramento Teórico aos temas abordados e as suas motivações e objetivos, seguido pelos Materiais e métodos, onde se descreve a metodologia para o desenvolvimento do sistema automático proposto, os Resultados e discussão, onde se analisa as tabelas, gráficos e *heatmaps* obtidos relacionando com estudos similares e referências bibliográficas, terminando na secção da Conclusão, onde se avaliam as elações retiradas da análise completa do estudo realizado.

Enquadramento Teórico

A imagiologia médica desempenha um papel crucial nos cuidados de saúde modernos, tendo revolucionado o diagnóstico, a monitorização e terapêutica no cuidado ao paciente. Ao permitir visualizar com detalhe não apenas anatomia, mas também morfologia e fisiologia, estas técnicas possibilitam diagnósticos mais precisos, planos de tratamento mais eficazes e melhores resultados, observando-se uma tendência crescente na sua utilização. Nos últimos 50 anos, a comunidade médica experienciou uma evolução tecnológica que impulsionou o uso da radiação ionizante dos equipamentos de radiologia convencional, evoluindo de detetores e plataformas analógicas para digitais, de TC *single slice* para multidetetores, da fluoroscopia a complexos sistemas sofisticados de angiografia e de equipamentos odontológicos intraorais simples a tecnologias panorâmicas e de TC de *cone beam*.^[24] A tendência crescente de recurso às várias técnicas de imagem, em particular devido ao uso crescente de TC, em todos os níveis de cuidados de saúde, ficou demonstrado no relatório do comité científico das Nações Unidas para os efeitos da radiação atómica (UNSCEAR) de 2008, que apresentou resultados de pesquisa entre 1997 e 2007.^[25] Recentemente, o *National Council on Radiation Protection and Measurements* (NCRP) publicou o relatório 184, confirmando um aumento no uso de exames radiológicos nos EUA até 2016, embora menos marcado do que o aumento rápido e dramático do início dos anos 1980 até 2006.^[26,27] De acordo com um estudo recente, que analisou dados de mais de 135 milhões de exames de imagem nos EUA e Ontário, Canadá, no período 2000-2016, o aumento anual de exames de tomografia computadorizada (TC), ressonância magnética (RM) e ultrassonografia (US) foi maior nos anos anteriores (2000 a 2006), mas continuou a aumentar entre 2012 e 2016 em 1-5% ao ano para a maioria das faixas etárias.^[28] Este aumento é justificado não apenas pela sua maior acessibilidade, mas também pelo facto destas técnicas de imagem facilitarem diagnósticos precoces e precisos de uma ampla gama de patologias, permitindo a identificação de anormalidades, deteção de doenças em estadios iniciais, avaliação da eficácia de tratamentos e possibilitando intervenções imediatas. O diagnóstico oportuno conduz a melhores resultados para os pacientes, melhores taxas de sobrevivência e potencial para opções de tratamento menos invasivas.^[24] Desempenham também um papel importante no planeamento e *follow-up* de um tratamento, sendo possível avaliar a extensão e localização de tumores, função de um órgão ou eficácia de terapias em curso. Por exemplo, em casos oncológicos, a imagem médica auxilia a alcançar com precisão a localização de tumores, minimizando os danos nos tecidos saudáveis

envolventes durante os tratamentos com radiação. Na radiologia de intervenção, utiliza a orientação por imagem em tempo real para navegar por estruturas complexas, de forma a realizar procedimentos minimamente invasivos, oferecendo riscos mais reduzidos, diminuindo a necessidade de cirurgias mais invasivas, a duração ou necessidade de internamento pós-intervenção, diminuindo também o tempo de recuperação, com maior conforto do paciente comparativamente com abordagens cirúrgicas tradicionais. A evolução nesta área em particular tem contribuído significativamente para aumentar a segurança do paciente, pois ao fornecer alternativas não invasivas ou minimamente invasivas às cirurgias exploratórias, reduz os riscos associados a procedimentos invasivos como infeções, hemorragias ou internamentos prolongados, minimizando também danos aos tecidos e órgãos circundantes. ^[29] A imagiologia médica tem sido, desta forma, uma força impulsionadora da inovação nos cuidados de saúde, facilitando a descoberta de novos marcadores de diagnóstico, alvos de tratamento e estratégias terapêuticas.

1. O estudo por radiografia do tórax

Permanecendo o exame de imagem médica mais realizado em todo o mundo, é incontornável a importância da radiografia nos cuidados de saúde. Estudos recentes continuam a reafirmar a importância da radiografia ao tórax no diagnóstico de várias patologias, orientando as decisões de tratamento e otimizando o cuidado ao paciente. Na deteção e monitorização de anomalias pulmonares, fornece orientação geral como estudo diagnóstico inicial e é especialmente útil no diagnóstico de pneumonia, neoplasia e doença pulmonar obstrutiva crónica (DPOC). ^[6] Na avaliação da saúde cardíaca e insuficiência cardíaca congestiva, pode demonstrar anormalidades cardíacas, sendo útil como exame primário da distinção da insuficiência cardíaca aguda da doença pulmonar aguda, possuindo também um valor prognóstico. ^[7] No trauma torácico, é a principal modalidade de imagem de triagem e diagnóstico, para pesquisa de fratura de costelas, contusões pulmonares, pneumotórax e hemotórax, podendo também avaliar enfisema subcutâneo e mediastínico, lesão diafragmática e aórtica, ou mau posicionamento de tubos e cateteres. ^[8] Por fim, no rastreio e apoio ao diagnóstico de doenças infecciosas respiratórias, é uma ferramenta essencial nas infeções agudas do trato respiratório ao permitir identificar padrões indicativos de infeções específicas, facilitando a intervenção precoce em caso de pneumonia, tuberculose, bronquiolite ou enfisema. ^[9] O estudo por radiografia do tórax pode ser executado em visão frontal ou lateral.

Para o seu estudo frontal, a imagem pode ser adquirida em incidência antero-posterior (AP) ou postero-anterior (PA). No caso de o paciente permitir a posição ortostática, esta deve ser a posição preferencial de estudo, pois nele é possível que o diafragma desça mais acentuadamente na inspiração profunda e completa, baixando também os órgãos abdominais e permitindo um arejamento completo dos pulmões. Se ar e líquido estiverem presentes nos pulmões ou espaço pleural, o líquido sendo mais pesado, irá depositar-se na porção mais inferior do pulmão por força da gravidade, enquanto que o ar sobe às demais porções. Desta forma, na posição ortostática o líquido localizar-se-á próximo da base do pulmão. Esta posição previne também o ingurgitamento (distensão ou edema devido à acumulação de líquido) e hiperemia dos vasos pulmonares (excesso de sangue resultante parcialmente de um relaxamento dos vasos distais). A desprojeção das omoplatas aos campos pulmonares é também um aspeto crucial para garantir a qualidade das imagens obtidas. A sua presença, sobrepostas aos campos pulmonares, pode obscurecer algumas áreas comprometendo a visualização de estruturas importantes. Na incidência PA, a realização de uma correta técnica de posicionamento do paciente, permite uma melhor desprojeção dessas estruturas.^[3,30] As incidências em ortostatismo são realizadas com os seguintes posicionamentos:


Incidência Tórax PA, paciente deambulante	
Imagem exemplificativa	Posicionamento
	Paciente na posição ortostática, com os membros inferiores um pouco afastados, peso igualmente distribuído sobre os dois pés
	Queixo elevado e apoiado
	Mãos sobre a porção inferior dos quadris, com as regiões palmares para fora e cotovelos ligeiramente flexionados
	Ombros rodados para a frente contra o potter, para permitir que as omoplatas se movam lateralmente, desviando-se dos campos pulmonares. Pressionar os ombros para baixo para que as clavículas se posicionem abaixo dos ápices pulmonares

Figura 1: Posicionamento do paciente em radiografia ao tórax em incidência PA ortostática (Fonte: Tratado de Técnica Radiológica e Base Anatômica)

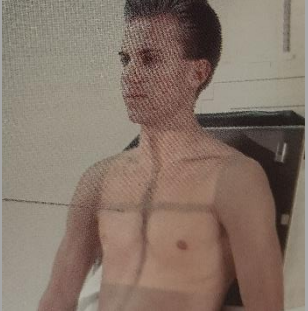
Incidência Tórax AP, paciente sentado	
Imagem exemplificativa	Posicionamento
	<p>Paciente em maca ou leito, deve ficar sentado, com elevação da cabeceira, até que o tronco assuma uma posição semi-ortostática</p>
	<p>Ombros do paciente devem ser elevados para a frente mediante rotação medial ou interna dos membros superiores</p>

Figura 2: Posicionamento do paciente em radiografia ao tórax em incidência AP semi-ortostática (Fonte: Tratado de Técnica Radiológica e Base Anatômica)

Caso o paciente não tolere a posição ortostática ou semi-ortostática, o exame é realizado em decúbito dorsal.


Incidência Tórax AP, paciente deitado	
Imagem exemplificativa	Posicionamento
	<p>Paciente em decúbito dorsal na maca ou leito</p>
	<p>Ombros do paciente devem ser elevados para a frente mediante rotação medial ou interna dos membros superiores</p>

Figura 3: Posicionamento do paciente em radiografia ao tórax em incidência AP em decúbito dorsal (Fonte: Tratado de Técnica Radiológica e Base Anatômica)

Esta última incidência deve apenas ser utilizada quando não estão reunidas as condições para a realização das incidências anteriores, como por exemplo a impossibilidade de cooperação do paciente, pois muitas vezes, um possível derrame pleural neste estudo irá encobrir a rede de vascularização pulmonar, em que o líquido se espalha sobre a superfície posterior do pulmão, deixando uma aparência opacificada em todo o pulmão. Além disso, a inspiração profunda e completa pode não ser alcançada, exibindo apenas oito ou nove costelas posteriores visualizadas acima do

diafragma, podendo os pulmões ser demonstrados mais densos por não estarem completamente arejados. [30]

A distinção entre as incidências de PA e AP torna-se significativa na medida em que pode ser decisiva na interpretação da imagem. Por exemplo, em pacientes que apresentem um pneumotórax ou cardiomegália, o estudo em PA é mais preciso e permite extrair informação mais significativa do que em AP pois obtém-se uma menor magnificação das estruturas anatómicas, como o coração, devido à distância reduzida ao detetor. A incidência de perfil permite complementar o estudo, correlacionando estruturas e achados. [3,30]

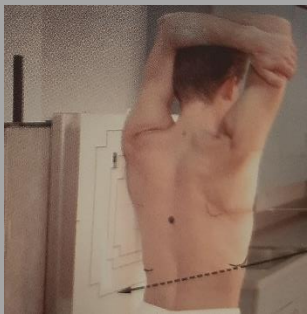
Incidência Tórax Perfil	
Imagem exemplificativa	Posicionamento
	Paciente na posição ortostática, com o lado esquerdo contra o potter, salvo quando a patologia em estudo se encontrar no lado direito. Nesse caso, executar perfil direito
	Se o paciente for deambulante, peso igualmente distribuído sobre os dois pés
	Se o paciente não se puder levantar, sentado na maca, cadeira de rodas ou cadeira sem apoios laterais
	Membros superiores elevados acima da cabeça e queixo levantado

Figura 4: Posicionamento do paciente em radiografia ao tórax em incidência de perfil (Fonte: Tratado de Técnica Radiológica e Base Anatômica)

Uma perspectiva de 90° em relação à incidência frontal permite demonstrar patologias situadas posteriormente ao coração, grandes vasos e esterno, clarificar posição e orientação de lesões ou, por exemplo, o cálculo do grau de achatamento diafragmático, mais fácil de observar neste estudo. [3,30]

2. Critérios de qualidade na análise da radiografia do tórax

O correto posicionamento do paciente é, então, um aspecto fundamental na obtenção de imagem radiográfica do tórax de elevada qualidade, tendo impacto direto no diagnóstico, na minimização da exposição à radiação, melhorando o cuidado ao paciente. Nesta ótica, o American College of Radiology (ACR), a Society of Pediatric Radiology (SPR), a Society of Thoracic Radiology (STR), bem como as *guidelines* publicadas pela Comissão Europeia (CE) estabeleceram recomendações de parâmetros práticos para a execução da radiografia ao tórax e diretrizes sobre critérios de qualidade para as imagens radiográficas de diagnóstico. Estes documentos de orientação definem as radiografias ao tórax ideais como aquelas com exposição ideal, com visualização do parênquima pulmonar num nível de cinzento médio, inclusão dos ápices pulmonares e ângulos costofrênicos, posicionamento ideal sem sobreposição de omoplatas ou membros superiores aos pulmões, centralização da coluna vertebral entre as clavículas, definição adequada das vértebras torácicas inferiores e vasos pulmonares retrocardíacos e colimação de forma a limitar a exposição apenas à região do tórax. [31]

As *guidelines* da Comissão Europeia estabelecem para a incidência de tórax em PA os seguintes critérios de qualidade de imagem: [32]


Incidência Tórax PA	
Imagem Radiográfica	Critérios de Qualidade
	Realizada em inspiração total (avaliada pela posição das costelas acima do diafragma – 6 anteriormente ou 10 posteriormente) e com respiração suspensa
	Reprodução simétrica do tórax demonstrado pela posição central do processo espinhoso entre as extremidades médias das clavículas
	Bordo medial das omoplatas fora dos campos pulmonares
	Visualização de toda a caixa torácica acima do diafragma
	Visualização nítida do padrão vascular em todo o pulmão, particularmente os vasos periféricos
	Visualização nítida de: <ul style="list-style-type: none">○ Traqueia e brônquios proximais○ Bordo cardíaco e aorta○ Diafragma e ângulos costofrênicos laterais
	Visualização do pulmão retrocardíaco e mediastino
	Visualização da coluna através da sombra cardíaca

Figura 5: Critérios de qualidade de imagem em radiografia ao tórax em incidência PA segundo as *guidelines* da CE

A apneia respiratória durante o exame é importante pois qualquer movimento torácico ou pulmonar que ocorra durante a exposição resultará na desfocagem da imagem radiográfica por artefacto de movimento. Os movimentos respiratórios do esqueleto ósseo durante a inspiração e expiração alteram as dimensões do volume torácico. Durante a inspiração, a cavidade torácica aumenta de diâmetro nas três dimensões, aumentando o diâmetro vertical, transversal e ântero-posterior. O diâmetro vertical é aumentado principalmente pela contração e movimento do diafragma para baixo, no diâmetro transversal as costelas oscilam para fora e para cima e o diâmetro ântero-posterior é aumentado também pela elevação das costelas, em especial entre a segunda e a sexta. [30]




Figura 6: Variações no volume torácico em visão sagital durante os movimentos respiratórios: a) inspiração e b) expiração (Fonte: Encyclopaedia Britannica)

Para determinar o grau de inspiração na radiografia ao tórax, deve ser possível identificar e enumerar os pares de costelas, sendo o primeiro e segundo par de localização mais difícil. Para quantificar o movimento diafragmático, contam-se os pares de costelas sobrepostos aos pulmões, acima do diafragma. É aceite que para pacientes adultos com biótipo médio, uma boa inspiração deva exibir no mínimo entre seis a dez pares de costelas numa radiografia de tórax em PA. Tal pode ser determinado pela contagem iniciada na parte superior da imagem, começando na primeira costela até à décima posteriormente. [30, 32]

O incorreto posicionamento do paciente origina rotação do tronco que acarreta a distorção da anatomia observada. A rotação pode ser determinada pela observação de ambas as extremidades esternais das clavículas, procurando-se simetria em relação à

coluna vertebral, onde ambas devem encontrar-se equidistantes da linha central da coluna. A direção da rotação pode ser determinada definindo-se qual extremidade esternal da clavícula está mais próxima do centro da coluna vertebral. ^[30,33] A medição precisa da qualidade do posicionamento na radiografia ao tórax permite melhorar a qualidade da imagem clínica. Nesta ótica, Young *et al* (2020) realizaram um estudo comparativo entre a avaliação subjetiva de especialistas e a classificação objetiva de um algoritmo de IA. Demonstraram uma boa correlação, obtendo 88,2% de sensibilidade para a rotação e de 100% para a inspiração, com uma especificidade de 70% e 73,5%, respetivamente. A evidência de boa correlação aumenta também a confiança nesta abordagem de avaliação de qualidade baseada em IA. ^[33]

A qualidade da imagem radiográfica pode também ser otimizada através da possibilidade do seu processamento digital, que potencializado pela gama dinâmica de detetores digitais, levou a uma redução da dose administrada. Métodos tradicionais de otimização de dose por exame implicam o aumento de kilovolts (kV), diminuição de miliamperes segundo (mAs), redução do tempo de exposição, além do correto posicionamento e colimação à região em estudo já abordados. As imagens digitais podem ser sujeitas a diferentes técnicas de pós-processamento e melhoradas com diversas funções disponíveis, como a inversão de escala de cinzentos, medição de distância e ângulos ou o ajuste de janelas. Às estratégias tradicionais de otimização de imagens radiográficas ideais, somam-se os algoritmos de redução de ruído na imagem, que influenciam a forma como a imagem final é apresentada. ^[24]

A realização do exame é dependente do técnico de radiologia e a sua execução maioritariamente manual. Além da atenção no posicionamento, os técnicos de radiologia adicionam um marcador que identifica a posição do paciente como “em pé/ortostatismo”, “sentado” ou “deitado/decúbito”. Embora esses marcadores permitam que o leitor das imagens, seja o radiologista ou outro médico do paciente, identifique rapidamente o estado da imagem para um grande número de imagens clínicas obtidas, erros humanos podem ocorrer durante este processo, podendo causar graves incidentes por má interpretação sobre a posição do paciente na prática clínica. Metadados incorretos podem, desta forma, levar a erros acrescidos, má qualidade dos dados pesquisados ou em última linha, diagnósticos e tratamentos incorretos, acrescentando potencial risco de erro na rotina de trabalho. ^[5,34]

A efetividade da radiografia ao tórax depende da qualidade da imagem produzida e a aquisição de imagens diagnósticas de elevada qualidade torna-se essencial para diagnósticos precisos e planeamento de tratamentos. Quando as imagens não

alcançam a qualidade diagnóstica, pode resultar numa rejeição do exame, com impacto não só nas instituições de cuidados de saúde, mas também para os pacientes e profissionais de saúde. A repetição de exames para substituição dos exames rejeitados, expõe os pacientes a radiação desnecessária, aumentando o risco potencial de dano induzido pela radiação, ao mesmo tempo que pode atrasar o diagnóstico e tratamento, comprometendo potencialmente o resultado para o paciente e o custo dos cuidados de saúde. As instituições de cuidados de saúde são forçadas a alocar recursos, como o tempo dos profissionais e a utilização de equipamento e materiais, que estreita orçamentos e a eficiência do fluxo de trabalho. Por fim, os pacientes podem sentir frustração ou ansiedade devido à necessidade de repetição de exames, conduzindo a uma potencial redução da satisfação do paciente ou confiança no sistema de saúde. ^[35] Para analisar a taxa de rejeição de exames de radiologia convencional, Foos *et al.* (2009) realizaram um estudo em dois hospitais, um universitário, outro comunitário. As radiografias ao tórax foram os exames mais realizados e obtiveram uma taxa de rejeição de 8,8%, no hospital comunitário, e 9% no hospital universitário. Os motivos de rejeição descritos no estudo incluem anatomia cortada, erros de posicionamento, movimentação do paciente, artefactos, marcadores cortados, marcadores incorretos e índice de exposição baixo e alto. ^[35] A relação entre a qualidade da imagem e o controlo da qualidade radiográfica é inegável. Imagens de alta qualidade são a base do diagnóstico preciso, tornando essencial manter práticas rigorosas e standardizadas de garantia de qualidade. O impacto dos exames rejeitados, que não oferecem a qualidade necessária para o diagnóstico, estende-se muito além do serviço de Imagiologia, afetando pacientes, instituições de saúde e o sistema de saúde como um todo. Portanto, priorizar a garantia da qualidade na radiografia ao tórax não é apenas uma questão de responsabilidade profissional, mas também um aspeto fundamental para a prestação de cuidados de saúde seguros e eficazes.

3. Aplicação da IA na radiografia do tórax

A radiografia foi a primeira modalidade para a qual foram desenvolvidas abordagens auxiliadas por computador em imagem médica. O método de extração de características definidas para cada radiografia, descritas em 1963 por Lodwick *et al.*, como a forma, a densidade e a margem de lesões, abriu caminho para métodos mais sofisticados.^[2] Grande parte do desenvolvimento científico foca-se na deteção automática de patologias nos exames de RM, TC ou RC recorrendo a algoritmos de *deep learning* (DL). Para os implementar, os investigadores utilizam não apenas as imagens, mas também

metadados associados, necessários ao treino e processos de decisão, como por exemplo, a incidência da radiografia. ^[1] Inicialmente foram considerados sistemas CAD, baseado em regras *if-then*. A abordagem baseada em regras tornou-se limitada com a expansão dos casos de uso, do nível de complexidade e dos dados não estruturados. Assim, a tendência mudou para a mineração de dados na década de 1970. ^[36]

Com o aumento do *big data* e da disponibilidade de recursos computacionais, o foco da pesquisa tende para a aprendizagem automática, ou *machine learning* (ML), para alcançar a excelência na área do CAD. O ML tornou-se numa abordagem que aprende padrões de diagnóstico a partir dos dados sem necessidade de codificar regras *if-then* explícitas, requerendo dados adequados tanto em quantidade como em qualidade, com o uso adequado de um algoritmo de aprendizagem. Os algoritmos clássicos de aprendizagem automática das últimas cinco décadas alcançaram melhor desempenho para tarefas de menos complexidade em dados estruturados. No entanto, tornam-se ineficientes para dados não estruturados complexos, por exemplo, para análise de imagens, classificação, deteção de objetos e segmentação, o que gerou a necessidade de um subcampo mais avançado de aprendizagem automática designado *deep learning* (DL). ^[36,37]

O DL é uma abordagem de ML que usa maioritariamente redes neuronais artificiais (*artificial neural network* - ANN) como componente principal. As ANN simulam o sistema cerebral humano para resolver problemas gerais de aprendizagem. No entanto, entre as décadas de 80 e 90, foi equipado com um algoritmo de retropropagação de aprendizagem, mas permaneceu sem aplicação prática devido à indisponibilidade de dados e recursos computacionais adequados. Com o avanço em paralelo da computação e das unidades de processamento gráfico, ganhou popularidade na década de 2000 como abordagem de ML. No DL, o algoritmo ensina um computador como conectar entrada e saída por meio de camadas ocultas para previsões baseadas em dados de treino. O DL teve um desempenho superior em todas as tarefas de visão para imagens não médicas nos últimos dez anos, enquanto que para as imagens médicas, as técnicas de ponta alcançaram desempenho de nível humano especializado no diagnóstico de certas patologias nas áreas da dermatologia, cardiologia e radiologia. ^[36] Uma das principais razões para estes resultados deve-se à aquisição de dados rotulados.

Os dados rotulados compreendem duas partes: imagem e etiqueta. Para imagens de radiografia, a catalogação de anormalidade pode, por exemplo, ser normal, pneumonia ou cardiomegalia. Além disso, a etiqueta pode conter informações limitadas ou extensas

sobre a imagem. Por exemplo, a tarefa de classificação requer apenas rótulo, enquanto que a detecção requer informações adicionais como x, y, largura e altura do objeto-alvo. Isto acresce ainda mais quando se lida com tarefas de segmentação, onde a segregação de nível de pixel é o alvo. No *DL*, a segmentação tornou-se uma técnica interessante, ao permitir que os algoritmos interpretem e compreendam imagens ao nível granular. A segmentação envolve a fragmentação de uma imagem em vários segmentos ou regiões, cada um representando objetos ou estruturas de interesse, que são semanticamente significativas. O objetivo é classificar cada pixel da imagem de acordo com sua categoria, como identificar os limites de um objeto, delinear diferentes estruturas ou isolar regiões de interesse na imagem. A segmentação pode ser dividida em dois tipos: a segmentação semântica e de instâncias. A primeira atribui um rótulo de classe a cada pixel da imagem, onde todos os objetos da mesma classe (por exemplo, todos os pixels dos campos pulmonares) são tratados como um só. Na segmentação de instâncias, não rotula apenas cada pixel, mas também diferencia instâncias individuais da mesma classe. Por exemplo, numa imagem médica de múltiplos tumores, cada tumor seria tratado como um objeto separado, mesmo que pertencesse à mesma classe de “tumores”. Juntamente com a classificação, os profissionais preferem a assistência para destacar anormalidades do sistema de CAD como segunda opinião. Estes destaques auxiliam os médicos no diagnóstico final, ajudando a superar casos de falsos negativos. De acordo com a literatura, o DL estabeleceu uma boa reputação para classificação de imagens médicas, formação de *bounding box* e segmentação. A pesquisa em DL nas imagens médicas enfrenta muitos desafios, onde a disponibilidade de dados de qualidade em grande volume, falta de interpretabilidade, gestão de recursos (memória, velocidade, espaço) ou a seleção de hiperparâmetros são alguns dos principais obstáculos. [36,37] Desde 2012, o DL tornou-se a abordagem dominante para análise de imagens médicas. Em contraste com as abordagens anteriores, o DL na análise radiológica é geralmente baseado em redes neuronais convolucionais (*convolutional neural network* - CNN) que servem como extratores e classificadores de características. Usando as imagens como *input* (sem características definidas *a priori*), camadas intermédias numa CNN extraem características que se destacam na imagem. A camada final da rede realiza a classificação. Embora os métodos de *deep learning* tenham demonstrado desempenho superior para muitas tarefas de análise de imagens, quantidades substanciais de dados rotulados são necessárias para treinar as redes e otimizar o desempenho. A disponibilidade de dados rotulados de alta qualidade de populações representativas é considerada um requisito fundamental. [2]

A IA aplicada à radiografia ao tórax possui já inúmeras ferramentas desenvolvidas que auxiliam na sua execução. Os algoritmos de algumas entidades comerciais, visam aspectos qualitativos, que podem ser utilizados antes e depois da aquisição da imagem. As unidades fixas podem recorrer a duas câmaras RGBD (Red, Green, Blue, Depth) para recolher informações do paciente e transmiti-las a um algoritmo e classificador de detecção de posicionamento baseado em IA, que ajudam a ajustar automaticamente a altura do equipamento ao paciente e comunica aspectos essenciais, como o contacto com o equipamento, o alinhamento central, orientação do paciente, inclinação e posição das mãos. Os algoritmos podem também determinar o tamanho do paciente e ajustar ou adaptar configurações de controle automático de exposição em algumas unidades fixas para garantir a qualidade adequada. ^[18] Outro uso combinado de câmara e IA envolve o reconhecimento das articulações dos ombros para determinar o tamanho e as configurações corretas do campo de colimação. O recurso a esta colimação inteligente permite reduzir a dose de radiação nas regiões além do tórax, economiza tempo e diminui a subjetividade do ajuste de colimação manual. Algoritmos de redução de ruído baseados numa CNN treinada para prever o ruído da imagem de entrada, permitem uma redução do ruído de 2 a 4 vezes sem perda de nitidez das estruturas anatómicas, permitindo reduzir a dose de exposição até duas vezes. ^[18,38] Fukui *et al* (2013) relataram o potencial de redução de dose de radiação de até 72% para a radiografia ao tórax digital portátil com o uso de software de redução de ruído para melhorar a qualidade da imagem de baixa dose de radiação.^[38] As soluções comerciais de IA estão a impulsionar a pesquisa e o desenvolvimento na imagiologia, facilitando a análise de dados em larga escala e os esforços colaborativos. Essas soluções permitem que investigadores tenham acesso a extensos conjuntos de dados, apliquem algoritmos avançados e desenvolvam técnicas de imagem inovadoras. Estes algoritmos podem auxiliar em ensaios clínicos, desenvolvimento de medicamentos e estudos de saúde da população, acelerando os avanços médicos e abrindo caminho para a medicina personalizada. ^[18]

Recentemente, outra técnica oriunda da engenharia de *computer vision* tem vindo a ganhar destaque, aplicada com sucesso na radiologia. Em 2012, Lambin P. propôs o conceito de “*Radiomics*” pela primeira vez e definiu-o como a extração de um grande número de características de imagem médica com uma abordagem de alto rendimento. A definição foi atualizada em 2014, para a extração automática, ou semiautomática, de alto rendimento de grandes quantidades de informações quantificáveis – ou características de imagem – de uma região de interesse (*region of interest* - ROI) em imagens radiográficas. ^[39] Tendo sido projetada para descodificar a heterogeneidade

intrínseca de uma lesão, as suas características genéticas e de outros fenótipos de forma a melhorar a sua gestão, é um produto da combinação da imagem digital com vários tipos de técnicas avançadas. De acordo com as *guidelines* Quantitative Imaging Network (QIN), estabelecidas pelo National Cancer Institute (NCI), as principais tecnologias e etapas de implementação de radiómica incluem a aquisição e reconstrução de imagens padronizadas, segmentação de lesões, extração de características e análises quantitativas de dados. ^[40] Esta abordagem permite a conversão das imagens radiográficas convencionais em dados de diferentes dimensões e reproduzíveis, fornecendo informações correlacionáveis com o diagnóstico de doenças, prognóstico e resposta ao tratamento. Ao contrário da imagem médica tradicional, que depende principalmente da avaliação visual, ao focar-se na extração de características, como intensidade, forma, textura ou relação espacial, e na análise dos recursos extraídos recorrendo a ML e IA, os algoritmos permitem identificar padrões e alterações subtis que seriam impercetíveis ao olho humano. A correlação com dados clínicos torna-se uma mais-valia na deteção precoce de doenças e na predição da sua evolução, permitindo também uma medicina personalizada ao possibilitar a adaptação dos planos de tratamento às necessidades individuais. ^[19,40] A compreensão da técnica de extração de características e a utilização de IA em imagem médica é de extrema importância, sendo esta uma técnica que contribuirá para a melhoria dos cuidados prestados ao doente e da tomada de decisões clínicas.

O desenvolvimento de algoritmos de IA para análise de radiografia ao tórax foi significativamente auxiliado pelo desenvolvimento de grandes bases de dados de radiografia ao tórax. Embora a deteção de nódulos pulmonares tenha sido uma das primeiras aplicações de IA para análise de radiografias, casos de utilização que recentemente receberam atenção significativa de grupos de pesquisa e fornecedores incluem os de deteção de pneumotórax, deteção de derrame pleural, triagem de tuberculose e algoritmos mais gerais que detetam múltiplas patologias. A avaliação de cateteres em radiografias é também uma área emergente de investigação. Estes algoritmos são geralmente utilizados como sinalizador e/ou *heatmap* que indicam possíveis patologias ou áreas nas quais o utilizador se poderá focar. Existe um potencial significativo nesta fase para utilizar estas soluções para triagem de estudos de imagem para revisão urgente de radiologista e como um segundo leitor ao interpretar radiografias.^[2] Park *et al* (2019) avaliaram o potencial da IA para demonstrar desempenho superior à interpretação dos radiologistas de radiografia ao tórax utilizando uma base de dados definida com referência à TC recente, quando disponível. Na deteção de lesão, o modelo superou todos os 9 leitores.^[41] Prevê-se que os algoritmos

de IA possam alcançar cada vez melhor desempenho, superando a capacidade de diagnóstico dos radiologistas para tarefas específicas e dirigidas, se os algoritmos forem treinados com bases de dados com correlação de imagens seccionais e diagnósticos de patologias. No entanto, as comparações do desempenho dos algoritmos devem ter em consideração que, em alguns estudos, as radiografias interpretadas pelos radiologistas tenham menor resolução do que em condições clínicas típicas, diminuindo potencialmente o desempenho dos radiologistas e diminuindo o padrão a que os algoritmos de IA são comparados. ^[41] Wang *et al.* (2017) desenvolveram um modelo de DL, denominado ChestX-ray8, para classificar automaticamente doenças comuns do tórax. O seu modelo obteve resultados promissores, com uma *Area Under the Curve* (AUC) multirrótulo de 0,809 e superou as abordagens tradicionais de aprendizagem automática.^[34] Seguindo os múltiplos estudos desenvolvidos durante a pandemia de COVID-19, Yao *et al.* (2020) utilizaram um modelo de *deep learning* denominado COVID-Net para detetar casos de COVID-19 em radiografias de tórax. A sua abordagem alcançou uma sensibilidade de 94,1% e uma especificidade de 92,7% na deteção da COVID-19, mostrando potencial para ajudar no diagnóstico desta doença específica.^[42]

A qualidade da imagem pode ter um enorme impacto no desempenho do algoritmo de DL e nas técnicas necessárias para otimizar a sua precisão. Desenvolver uma solução de DL com imagens de diferente qualidade pode resultar numa degradação substancial no desempenho. Por exemplo, alguns investigadores acreditam que não utilizar imagens desfocadas e de baixa qualidade para treino de um algoritmo de DL terá um impacto negativo no desempenho da rede na aplicação na vida real. A dificuldade em transferir soluções de algoritmos de DL de imagens de alta qualidade para imagens de qualidade inferior levanta a questão em como as imagens médicas de diagnóstico se comparam, em qualidade ou em outra medida, com as várias imagens utilizadas inicialmente para desenvolvimento e treino das CNN que os investigadores médicos e empresas de tecnologia médica retreinam nas várias modalidades de imagem médica. Se as imagens médicas de diagnóstico diferirem significativamente em qualidade ou complexidade das imagens utilizadas para treino inicial, considerações especiais podem ser necessárias ao retreinar com imagens médicas. ^[23] Blaivas *et al* (2021), utilizando uma técnica de avaliação quantitativa de qualidade de imagem (BRISQUE), compararam matematicamente imagens disponíveis numa base de dados pública (*ImageNet*) com imagens médicas de radiografia ao tórax, TC, RM e US. A comparação foi feita com base no desfoque da imagem, complexidade de pixels, relacionamento com pixels vizinhos, variação de pixel e de fundo e características distintivas. As imagens de radiografia ao tórax, que se antecipava que seriam interpretadas pelo modelo

matemático como de baixa qualidade quando em comparação com outras modalidades de imagem médica, resultou na melhor qualidade de imagem média obtida no estudo, de 13,2, tendo as imagens de radiografia ao tórax obtido melhor classificação qualitativa do que as imagens disponibilizadas na base de dados pública.^[23]

Nesta ótica, a qualidade das imagens disponibilizadas nas bases de dados públicas, ao qual se recorre para treino dos algoritmos desenvolvidos, é de máxima importância, mas atendendo ao número de imagens disponibilizadas nesses conjuntos, é muitas vezes demasiado moroso ou impraticável validar cada imagem manualmente por um especialista para cada tipo de estudo. ^[1] Hosch *et al.* (2020), conceberam e treinaram uma CNN para extrair a posição de visualização correta de radiografias ao tórax a partir dos próprios dados da imagem, corrigindo desta forma metadados inseridos erroneamente. Para o processo de treino, recorreram à base de dados do “Pneumonia Detection Challenge” da Radiological Society of North America (RSNA). Para o processo de teste e desempenho do modelo gerado, compilaram um conjunto de dados independentes. O modelo demonstrou uma precisão de 96%, com uma AUC de 0,99 na extração da posição, permitindo uma correção automática dos metadados, potenciando uma redução de erros de custo, melhoria da qualidade dos dados de pesquisa e reduzindo diagnósticos e tratamentos errados. ^[1]

Assistimos a avanços notáveis da IA no campo da imagem médica. Os algoritmos desenvolvidos têm o potencial de aumentar a precisão e eficiência do diagnóstico médico através da classificação dessas imagens. A investigação tem demonstrado que o desempenho da IA é comparável ou superior a um leitor especializado na deteção de anormalidades específicas em radiologia torácica. A IA pode ser implementada como primeiro, segundo ou leitor concomitante. A combinação sinérgica da IA juntamente com um leitor humano é uma abordagem ideal e promissora para aumentar a precisão da interpretação e a redução de erros. ^[43] No entanto, o seu desenvolvimento e treino depende da disponibilidade de conjuntos de dados médicos de elevada qualidade. Em particular, os conjuntos de dados públicos, que desempenham um papel fundamental na promoção da investigação, inovação e melhoria dos cuidados prestados ao paciente, ao oferecer diversidade e representatividade, pois agregam imagens de diversas fontes, pacientes e condições médicas. Sem dados representativos, os algoritmos podem obter um bom desempenho em ambientes controlados, mas que diminuirá quando confrontados com as variações dos dados do mundo real. A representatividade garante, desta forma, que os modelos desenvolvidos sejam robustos e fiáveis. A utilização de bases de dados de baixa qualidade para desenvolvimento de algoritmos a aplicar em imagem médica terá impacto na precisão, na capacidade de adaptação do algoritmo a

novos dados, representando, em última instância, tomadas de decisão incorretas ou danos ao paciente, que resultam em problemas de responsabilidade e confiança nos sistemas de IA.^[36] O desenvolvimento de soluções que permitam melhorar e refinar a qualidade das radiografias ao tórax presentes nas bases de dados públicas disponibilizadas torna-se imperativo, não apenas para assegurar a robustez e fiabilidade dos algoritmos desenvolvidos a partir dessas bases de dados, mas também numa aplicação destes sistemas de classificação onde a acessibilidade ao expertise humano é menor. ^[43]

Materiais e Métodos

A metodologia de classificação supervisionada através da segmentação de estruturas anatómicas de radiografias do tórax proposta neste trabalho tem os seguintes passos principais:

1. Base de dados: um conjunto de radiografias do tórax é extraído e organizado num formato adequado para análise e reprodutibilidade dos resultados.
2. Bibliotecas específicas de python: é selecionada uma biblioteca especializada com conjuntos de funções e métodos na linguagem python.
3. Pré-processamento: são aplicadas transformações nas imagens para as preparar e uniformizar.
4. Segmentação da região de interesse: A região de interesse (ROI) é segmentada a partir das imagens radiográficas.
5. Detecção da sobreposição das omoplatas nos campos pulmonares.
6. Análise dos resultados.

Base de Dados

Recorreu-se ao *dataset* de radiografia ao tórax do NIH. O conjunto de dados de radiografia ao tórax do NIH foi extraído do PACS do *National Institutes of Health Clinical Center* e contém aproximadamente 60% de todos os exames de radiografia ao tórax frontal na instituição. Sendo um dos maiores conjuntos de dados disponíveis publicamente e contendo mais de 100.000 imagens desidentificadas de radiografias ao tórax, torna-se mais representativo para as distribuições reais da população de pacientes. Está associado a uma ampla variedade de 14 rótulos diferentes de patologia torácica. Essas imagens foram anotadas manualmente por radiologistas, tornando o *dataset* um recurso valioso para treino e avaliação de modelos de *machine learning* em imagens médicas. O conjunto de dados é versátil e tem sido utilizado para diversas tarefas, incluindo classificação e localização de patologias. ^[44]

Realizou-se a classificação manual de um conjunto de mais de 500 imagens retiradas do *dataset* NIH, classificando-se de acordo com o posicionamento (frente ou perfil), incidência (PA ou AP), rotação e decúbito ou ortostatismo, e guardadas como *dataset* PC. Como critério de seleção, foram escolhidas imagens de radiografia ao tórax, e como fator de exclusão, exames pediátricos, de outras regiões anatómicas ou que não estivessem corretamente orientados.

Bibliotecas específicas de python

A “TorchXrayVision” é uma biblioteca projetada especificamente para conjuntos de dados e modelos de radiografias ao tórax. Contém uma coleção de *datasets* pré-processados e modelos pré-treinados. A biblioteca tem como objetivo facilitar pesquisadores e profissionais para trabalharem com dados de radiografia ao tórax recorrendo ao Pytorch. Alguns recursos notáveis são:

- Conjunto de dados: o TorchXrayVision ^[45] oferece suporte a vários *datasets* de radiografias populares, incluindo o NIH, CheXpert e MIMIC, entre outros. Isto simplifica o carregamento e pré-processamento de dados.
- Modelos: fornece diversos modelos pré-treinados, que podem ser utilizados tanto para tarefas de classificação como para segmentação. Esses modelos foram treinados com grandes quantidades de dados e servem como linha de base sólidas.
- Transformações: oferece transformações personalizadas à medida das imagens de radiografia. Podem ser utilizados para pré-processar os dados de forma eficiente.

Pré-processamento

As transformações de imagem são etapas essenciais de pré-processamento em tarefas de visão computacional. Pode afetar fortemente o desempenho de um modelo, tanto em tempo de treino como em precisão. Foram aplicadas as seguintes transformações:

- Corte central: esta transformação corta a porção central de uma imagem. É frequentemente utilizado para remover partes não essenciais da imagem, especialmente quando a região de interesse está tipicamente localizada ao centro. Nas radiografias ao tórax, isto pode auxiliar a focar nos campos pulmonares e omoplatas, ao mesmo tempo que remove a área periférica excedente na imagem, auxiliando a reduzir a sua dimensão para facilitar a computação.

```
xrv.datasets.XRayCenterCrop()
```

- Redimensionador: redimensionar uma imagem altera as suas dimensões para o tamanho especificado. Na aprendizagem automática é comum redimensionar todas as imagens para um tamanho padrão para que possa alimentar uma rede

neuronal que espera uma entrada de tamanho fixo. Aqui, as imagens são redimensionadas para 244x244 pixels.

```
xrv.datasets.XRayResizer(244)
```

Juntas, essas transformações garantem que as imagens tenham tamanho consistente e foquem na região de interesse.

Segmentação da Região de Interesse

Aplicámos um modelo pré-treinado para segmentação fornecidos pela biblioteca *TorchXrayVision*, mais especificamente o *PSPNet*.

```
seg_model = xrv.baseline_models.chestx_det.PSPNet()
```

PSPNet – “*Pyramid Scene Parsing Network*” é uma arquitetura de rede neuronal proeminente projetada para tarefas de segmentação semântica. A segmentação semântica envolve a classificação de cada pixel de uma imagem numa categoria predefinida, tornando-a mais granular do que a classificação de imagens, embora não tão detalhada quanto a segmentação de instância, que identifica objetos separados da mesma classe. A principal inovação do *PSPNet* é a integração de um módulo de agrupamento em pirâmide, que agrupa recursos em diferentes escalas, fundindo-os *a posteriori*. Esta abordagem permite que a rede considere características em diversas resoluções, capturando informações globais e locais.

O *Pyramide Pooling Module* é uma marca registada da *PSPNet*^[46]. Este módulo divide o mapa de recursos em diferentes sub-regiões e realiza o agrupamento em cada uma. Resulta em mapas de características de diferentes escalas que representam várias regiões da imagem original. Ao considerar estas diferentes regiões, a *PSPNet* tanto pode capturar informações detalhadas de regiões menores como informações contextuais mais amplas de regiões maiores.

Este processo de agrupamento é feito em diversas escalas de grelha (por exemplo, 1x1, 2x2, 3x3, 6x6). Após o agrupamento em cada escala, os recursos são ampliados para o

tamanho original e concatenados. Isto resulta numa representação de recursos em várias escalas.

- *Backbone network*: o *PSPNet* é construído sobre um extrator de características robusto ou *Backbone Network*. As escolhas comuns para a rede estrutural são arquiteturas como ResNet ou VGG. Esta rede estrutural é responsável pela extração de características hierárquicas da imagem de entrada.
- Predição: usando o modelo treinado, foi feito um avanço para cada imagem para prever as partes segmentadas.
- Visualização do *heatmap*: nesta etapa, o código fornece uma visualização opcional das áreas segmentadas..
- Ativação sigmoide: para garantir que as previsões estejam entre 0 e 1, foi aplicada uma ativação sigmoide.

Deteção da sobreposição das omoplatas nos campos pulmonares

Nesta etapa, o principal objetivo é detetar a sobreposição das omoplatas na região pulmonar. O modelo de segmentação fornece partes segmentadas da radiografia ao tórax, de entre as quais as omoplatas e os pulmões são de interesse.

Das partes segmentadas, estabeleceram-se 4 máscaras: omoplata esquerda, omoplata direita, pulmão esquerdo e pulmão direito. Para a máscara da omoplata esquerda definiu-se o índice [0,2], para a máscara da omoplata direita definiu-se o índice [0,3], para a máscara do pulmão esquerdo definiu-se o índice [0,4] e para a máscara do pulmão direito definiu-se o índice [0,5].

Presença de omoplata: o código verifica a presença de omoplata esquerda e direita, considerando a adição das máscaras das omoplatas bilateralmente, onde caso o valor seja superior a 0, é considerada presente.

```
if torch.sum((pred[0,2]+pred[0,3])) > 0:  
    scapula_detected = 1  
else:  
    scapula_detected = 0
```

Deteção de sobreposição: calculamos a sobreposição das omoplatas aos campos pulmonares adicionando as partes segmentadas. Qualquer sobreposição entre os dois é considerada uma sobreposição.

```
left_sobreposition = pred[0,2] + pred[0,4]
right_sobreposition = pred[0,3] + pred[0,5]
```

Definiu-se que, na análise da sobreposição ao campo pulmonar esquerdo, é considerada a adição da máscara da omoplata esquerda com a máscara do pulmão esquerdo e, na análise da sobreposição ao campo pulmonar direito, é considerada a adição da máscara da omoplata direita com a máscara do pulmão direito.

Visualização dos Resultados

- Armazenamento de resultados: todos os resultados, incluindo o ID da imagem, se a omoplata foi detetada, o estado da sobreposição e a percentagem de sobreposição para a omoplata esquerda e direita são armazenados numa lista.

```
results_scapula.append([image_id, scapula_detected, Scapula_overlay,
                        Left_Area_Sobreposition, Right_Area_sobreposition])
```

- Armazenamento de máscaras: as máscaras de sobreposição de cada imagem são armazenadas no diretório especificado.

Compilação de Dados

Por fim, os resultados foram compilados e agrupados num *pandas dataframe* e guardados em formato Excel, para posterior análise.

Seguindo esta metodologia, pretendemos identificar com eficácia os casos em que omoplata se sobrepõe aos pulmões nas radiografias de tórax, o que pode ser crucial para um diagnóstico clínico preciso.

Análise da diferença entre PA e AP no padrão de sobreposição da omoplata dos campos pulmonares

Os dados foram organizados numa tabela com as seguintes colunas:

1. Filename: Identificador ou nome dado ao ficheiro de imagem.
2. Projection: Tipo de projeção ou incidência (PA ou AP).
3. Scapula_detected: Indicador binário (1 se detetado, 0 se não detetado) que demonstra se a omoplata foi detetada na imagem radiográfica.
4. Scapula_overlay: Indicador binário (1 se sobreposição está presente, 0 se não está presente) que demonstra se existe sobreposição na imagem radiográfica.
5. Left sobreposition %: Percentagem de omoplata com sobreposição ao pulmão à esquerda.
6. Right sobreposition %: Percentagem de omoplata com sobreposição ao pulmão à direita.

Para analisar estatisticamente os dados obtidos procedeu-se ao estudo comparativo de das variáveis contínuas. Para isso utilizou-se o coeficiente de correlação de Pearson, que o *pandas* utiliza por defeito na função “corr()”, por forma a medir a relação linear entre as variáveis em estudo, a percentagem de sobreposição da omoplata à esquerda e a percentagem de sobreposição da omoplata à direita. Este coeficiente varia entre os valores -1 e 1. O valor 0 (zero) significa que não existe relação linear, o valor 1 indica uma relação linear perfeita e o valor -1 também indica uma relação linear perfeita, mas inversa, ou seja, quando uma das variáveis aumenta a outra diminui. Quanto mais próximo estiver de 1 ou -1, mais forte é a associação linear entre as duas variáveis. O coeficiente de correlação de Pearson é normalmente representado pela letra *r* e a sua fórmula de cálculo é a seguinte:

$$r = \frac{\sum (x_i - \bar{x}) (y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}$$

r = correlation coefficient

x_i = values of the x-variable in a sample

\bar{x} = mean of the values of the x-variable

y_i = values of the y-variable in a sample

\bar{y} = mean of the values of the y-variable

Figura 7: Fórmula de cálculo do coeficiente de Pearson

Para determinar se existem diferenças estatísticas entre as incidências de AP e PA em relação à sobreposição da omoplata e percentagem de sobreposição, recorreu-se ao teste de chi-quadrado de Pearson. Trata-se de um teste de hipóteses que se destina a encontrar um valor de dispersão para duas variáveis categóricas nominais e avaliar a associação existente entre variáveis qualitativas. Sendo um teste não paramétrico, não depende da média e da variância, procurando possíveis divergências entre as diferenças observadas e esperadas para um determinado evento. O qui-quadrado é obtido somando-se razões dadas pelos quadrados das diferenças entre frequências observadas e as esperadas, divididos pelas frequências esperadas.

$$\chi_c^2 = \sum \frac{(O_i - E_i)^2}{E_i}$$

c = degrees of freedom

O = observed value(s)

E = expected value(s)

Figura 8: Fórmula de cálculo do teste do qui-quadrado

Para determinar se existe uma diferença significativa entre as médias de duas amostras independentes, para o caso, a sobreposição das omoplatas aos campos pulmonares à direita e à esquerda para as incidências de AP e PA, pretende-se recorrer ao teste t de Student. O teste t de Student é baseado em duas hipóteses: a hipótese nula (H_0) e a hipótese alternativa (H_1). A hipótese nula acontece quando duas amostras têm médias iguais, enquanto a hipótese alternativa verifica-se quando as duas amostras têm médias diferentes. O teste t de Student calcula o valor t, que traduz a diferença entre as médias das duas amostras dividida pelo erro padrão dessa diferença. Esse valor t é então comparado a uma distribuição t de Student com um certo grau de liberdade, que depende do tamanho das amostras e do nível de significância escolhido. Se o valor t calculado for maior do que o valor crítico na distribuição t, a hipótese nula é rejeitada e conclui-se que há uma diferença significativa entre as médias das duas amostras. Para o aplicar, é necessário que dois pressupostos se verifiquem: que a distribuição seja Normal e exista Homogeneidade das variâncias entre os dois grupos.

Para se estudar a normalidade da distribuição, utilizou-se o teste de Shapiro-Wilk. teste de normalidade para uma amostra de valores, utilizado nas seguintes situações:

- Não se conhece o modelo Normal subjacente, isto é, não se inclui a média e a variância na formulação da hipótese em teste, testando-se apenas que a amostra provém de uma distribuição normal, onde:
 - Hipótese nula H_0 : a amostra provém de uma população Normal
 - Hipótese alternativa H_1 : a amostra não provém de uma população Normal
- Teste bastante eficaz para amostras pequenas, de entre 10 e 50 indivíduos;
- Quando comparado com outros testes, é geralmente superior na deteção de situações de não normalidade, em condições de amostras simétricas ou não simétricas, concentradas em torno dos valores centrais ou dispersas para valores extremos. ^[47]

Para se estudar a homogeneidade de variâncias, utilizou-se o teste de Levene, que compara a variância das amostras com a variância geral. Testa-se a hipótese nula de que existe homogeneidade de variâncias entre as amostras. Não se verificando os pressupostos para aplicar o teste t de student, recorreremos ao teste U de Mann-Whitney, uma alternativa não paramétrica para comparação da média de dois conjuntos.

Resultados e Discussão

Análise da Detecção das Omoplatas

Na imagem de radiografia ao tórax, a estrutura óssea presente nessa região torna difícil para um radiologista examinar minuciosamente os órgãos e avaliar a presença de doença com precisão ou detecção de anormalidades, aumentando essa dificuldade quanto maior for a sua sobreposição. A caixa torácica oferece proteção e é composta por 12 pares de costelas, 12 vértebras torácicas, esterno, 2 clavículas e 2 omoplatas.^[30]

Analisámos a presença de sobreposição das omoplatas sobre os campos pulmonares das imagens de radiografia ao tórax presentes na base de dados utilizada e avaliámos a sua sobreposição, medindo a percentagem de sobreposição bilateral, de acordo com o esquema apresentado na figura 9.

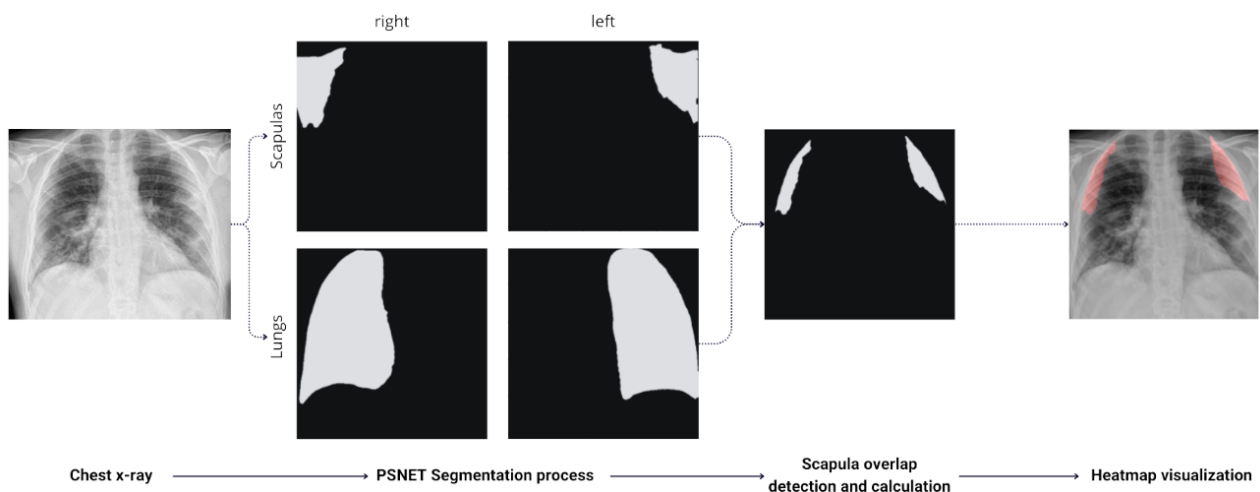


Figura 9: Metodologia seguida para a segmentação das omoplatas e dos campos pulmonares, a partir da radiografia original, conseqüente detecção das omoplatas sobre os campos pulmonares e criação de um heatmap sobreposto à imagem original

A sobreposição das omoplatas no campo pulmonar pode criar sombras e artefactos que podem ser confundidos por padrões suspeitos ou ocultar patologia, em especial quando é interpretada por um leitor menos experiente. Os padrões suspeitos mimetizam potenciais lesões localizadas no parênquima pulmonar, pleura ou a nível ósseo.^[48]

O algoritmo de segmentação utilizado detetou a presença das omoplatas na quase totalidade dos casos, 99,81%, que correspondeu a 28.810 imagens, tal como demonstrado na tabela 1.

Tabela 1: Frequência e percentagem de casos onde foi detetada a presença das omoplatas na imagem radiográfica

Deteção da Omoplata

	Frequência	Percentagem
<i>Detetada</i>	28.810	99,81%
<i>Não detetada</i>	11.547	0,19%



Figura 100: Exemplo de imagens onde a omoplata não foi detetada

Após a análise das imagens onde não foi detetada a presença de omoplatas, elaborou-se uma lista de possíveis causas para esta não deteção.




Figura 11: Causas para não detecção da omoplata na imagem radiográfica

O gráfico de barras na figura 11 ilustra a análise para as possíveis causas para a não detecção da omoplata pelo algoritmo de detecção. No eixo das abcissas, foram categorizadas as causas: "abdómen", "pediátrico", "perfil" e "rodada". O eixo das ordenadas descreve a frequência das mesmas. De um total de 55 casos detetados, a categoria "Pediátrico" apresenta a maior frequência, com mais de 25 ocorrências. Sendo um exame ao tórax com presença de omoplata com a variante de pertencer a uma faixa etária diferente, é indicativo de que o algoritmo falhou frequentemente em detetar as omoplatas quando a anatomia do paciente não correspondeu à de um adulto. A categoria seguinte com frequência significativa é "Perfil", com 21 ocorrências, seguida por "Rodada" com uma frequência menor ($n=7$), e "abdómen" com a frequência mais baixa ($n=2$).

Os resultados indicam que a base de dados não foi corretamente filtrada e analisada antes de ser disponibilizada quanto à qualidade técnica que apresenta. Existe referência a exames do abdómen e pediátricos quando deveriam constar apenas exames do tórax de adultos. Verificam-se também exames de perfil quando deveriam estar presentes apenas exames frontais. A presença de exames com rotações ("Rodada"), sugere que o algoritmo precisa ser melhorado para lidar com imagens de tórax que foram rodadas, talvez através de uma etapa de "augmentation" que inclua imagens com diferentes graus de rotação.

Após a detecção das omoplatas, procedeu-se à análise da sobreposição das mesmas sobre os campos pulmonares, onde apenas se verificou essa sobreposição em 39,79% das imagens. (tabela 2, figura 12).

Tabela 2: Percentagem de casos onde foi detetada a sobreposição das omoplatas sobre os campos pulmonares

Sobreposição da Omoplata	
Detetada	39,79%
Não detetada	60,21%




Figura 112: Percentagem de casos onde foi detetada a sobreposição das omoplatas sobre os campos pulmonares

Para os casos em que foi detetada sobreposição das omoplatas, procedeu-se à criação de um *heatmap* sobre a imagem radiológica original na qual é evidenciado (a vermelho) a referida sobreposição, conforme exemplo na figura 13.



Figura 13: Exemplo de deteção da sobreposição das omoplatas sobre os campos pulmonares

Da análise estatística de primeira ordem da sobreposição da omoplata sobre o campo pulmonar unilateral esquerdo e direito, obteve-se os seguintes resultados:

Tabela 3: Dados obtidos da análise estatística na sobreposição da omoplata sobre o campo pulmonar esquerdo e direito

Sobreposição da omoplata sobre o campo pulmonar		
	Campo pulmonar esquerdo	Campo pulmonar direito
<i>Contagem</i>	28,794	28,794
<i>Média</i>	~ 8,6%	~ 9,1%
<i>Desvio-padrão</i>	~ 11,8%	~ 11,0%
<i>Mínimo</i>	0%	0%
<i>Quartil 1</i>	0%	1%
<i>Mediana</i>	3%	5%
<i>Quartil 3</i>	12%	14%
<i>Máximo</i>	100%	100%
<i>Amplitude interquartil</i>	0,12 (12%)	0,13 (13%)

Da análise estatística da percentagem de sobreposição da omoplata ao campo pulmonar esquerdo e direito, observa-se que a maioria dos dados está agrupada em torno das percentagens mais baixas, indicando que, para muitas entradas, a sobreposição tanto à esquerda como à direita, é bastante baixa, demonstrado também pelas medianas reduzidas de 3 e 5%, respetivamente. Verificaram-se casos em que as percentagens de sobreposição são mais elevadas, mas sem expressão na sua frequência. O valor máximo para ambos é de 100%, mas essas percentagens de sobreposição são discrepantes, conforme indicado pelos quartis de 75%, de 12% à esquerda e 14% à direita, observado na tabela 3. As médias de ambos os lados são próximas, sendo a sobreposição média ligeiramente superior no lado direito (9,1%). Relativamente à amplitude interquartil para a sobreposição das omoplatas ao campo pulmonar esquerdo e direito verificou-se uma variação de 12% à esquerda e de 13% à direita.

Para avaliar a correlação entre estas duas variáveis contínuas utilizámos o coeficiente de correlação de Pearson, que o *pandas* utiliza por defeito na função “corr()”, por forma a medir a relação linear entre a percentagem de sobreposição da omoplata à esquerda e a percentagem de sobreposição da omoplata à direita. Obteve-se uma correlação positiva de aproximadamente 0,673, o que indica uma relação linear moderada a forte entre as duas variáveis, ou seja, à medida que a percentagem de sobreposição à esquerda aumenta, a percentagem de sobreposição à direita também aumenta, e vice-versa. Da análise do gráfico de dispersão entre estas duas variáveis, figura 14, podemos observar a sua correlação positiva, demonstrado pela aglomeração dos pontos em tendência crescente. Os aglomerados de pontos nas percentagens mais baixas, demonstra mais uma vez que, para muitas entradas, tanto a sobreposição à esquerda como à direita, ocorrem com baixa frequência.

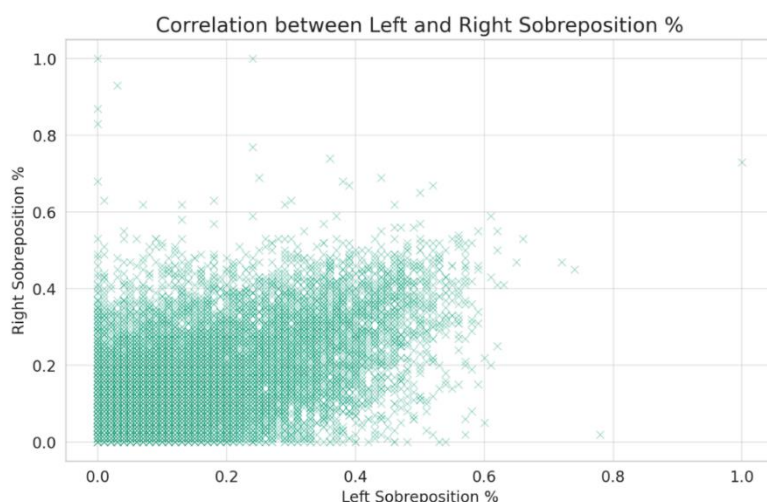


Figura 124: Diagrama de dispersão da correlação entre a sobreposição da omoplata à esquerda e da omoplata à direita

A sobreposição das omoplatas aos campos pulmonares é uma dificuldade inerente ao posicionamento efetuado pelo técnico de radiologia. Young-Cheol *et al.* (2016) compararam três posicionamentos para a radiografia de tórax em PA aplicados na prática clínica para analisar a sobreposição das omoplatas aos campos pulmonares de forma a obter a menor sobreposição possível. O posicionamento clássico é mais difícil para pacientes pediátricos, pacientes com limitações de mobilidade nas articulações dos ombros ou cotovelos e outras limitações de estabilidade. Nesta ótica, e recorrendo aos acessórios de posicionamento, como pegas laterais, que acompanham os equipamentos atuais, estudou-se a desprojeção obtida das omoplatas quando

comparado com o posicionamento tradicional e concluíram que, ainda que o posicionamento tradicional ofereça maior desprojeção independentemente do género, tal já não se verifica nas restantes posições, obtendo-se maior desprojeção das omoplatas sobre o parênquima pulmonar nos pacientes do sexo masculino. [49]

A dificuldade na desprojeção das omoplatas pode ser mais desafiante em situações particulares, por exemplo, em doentes com pneumoconiose. A pneumoconiose é uma patologia ocupacional do interstício pulmonar associada à inalação de poeiras de carbono nas minas de carvão e o seu estudo por radiografia ao tórax em mineiros torna-se mais desafiante pelas patologias associadas da coifa do rotador (ombro) ou queixas vertebrais. O seu posicionamento exige mais atenção por parte dos técnicos de radiologia para que não se observe a sobreposição das omoplatas sobre os campos pulmonares. Esta problemática levou à publicação de um conjunto de *guidelines* em 2017 emitidas pelo Departamento de Recursos Naturais e Minas de Queensland, Austrália. [50] Para evitar a negligência de achados clínicos que normalmente passam despercebidos devido a estas sobreposições, Gefter *et al.* (2023) propuseram uma abordagem prática de estratégia de pesquisa visual sistemática e abrangente através de uma *checklist* de controlo de qualidade na interpretação de imagem radiográfica ao tórax. [43]

A necessidade de obter imagens de radiografia ao tórax livres da sobreposição das omoplatas aos campos pulmonares é essencial para que se consiga maior precisão na sua interpretação. Perante os resultados obtidos na análise das imagens radiográficas classificadas pelo modelo na sobreposição das omoplatas aos campos pulmonares, levantamos duas hipóteses. A primeira é de que poderá existir um mau posicionamento aquando da realização do exame, que potencialmente conduza a uma sobreposição bilateral das omoplatas aos campos pulmonares, em especial atenção nas doentes do sexo feminino. Noutras situações, o doente pode apresentar limitações de mobilidade ou fenómenos de dor (unilateral), que por incapacidade ou por ato de defesa resulte numa sobreposição da omoplata no lado de dor, justificando a sobreposição de apenas um dos campos pulmonares.

Análise da diferença entre PA e AP no padrão de sobreposição da omoplata dos campos pulmonares

A incidência realizada, em PA ou AP, altera o posicionamento do paciente, o que poderá influenciar a presença de sobreposição óssea ao campo pulmonar, em particular no que refere ao posicionamento das omoplatas. Uma incidência em PA correta deverá demonstrar o parênquima pulmonar livre, sem sobreposição das omoplatas. A incidência em AP é realizada quando o paciente se encontra imobilizado, debilitado ou incapaz de colaborar para a realização de uma radiografia em PA. Nesta situação, as omoplatas são geralmente visíveis nos campos pulmonares por impossibilidade de desprojeção.^[51]

Para a análise do impacto do posicionamento do doente na incidência PA versus AP na sobreposição da omoplata nos campos pulmonares foi utilizado o *dataset* PC, como ferramenta de treino para a classificação da incidência PA e AP. Esta opção deveu-se ao facto desta base de dados não conter à disposição os metadados referentes ao posicionamento do doente. Obteve-se os seguintes resultados, para um total de 63838 exames contidos no *dataset*:

Tabela 4: Percentagem de exames no dataset, por incidência

Exames no dataset por incidência

Incidência PA	97,38%
Incidência AP	2,62%

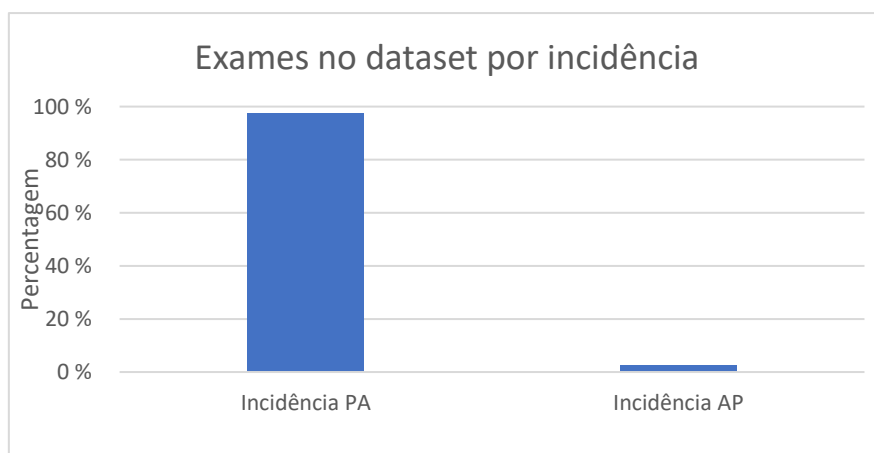


Figura 135: Percentagem de exames no dataset, por incidência

Tabela 5: Detecção e sobreposição de omoplata de acordo com a incidência e percentagem média de sobreposição das omoplatas esquerda e direita ao pulmão

	Incidência AP	Incidência PA
Nr. total de deteção de omoplata	1574	60765
Nr. total de sobreposição de omoplata	1445	23124
Percentagem média de sobreposição da omoplata esquerda ao pulmão	0.2888 (28.88%)	0.0893 (8.93 %)
Percentagem média de sobreposição da omoplata direita ao pulmão	0.3012 (30.12 %)	0.0832 (8.32 %)

Da análise da tabela 5 podemos constatar que, apesar do número absoluto de observações tanto de deteção como de sobreposição das omoplatas na imagem radiográfica ser superior para a incidência PA, a percentagem média de sobreposição ao pulmão tanto à esquerda como à direita é maior na incidência AP - 28,88% e 30,12% *versus* 8,93% e 8,32% - do que na incidência PA. Isto vai de encontro ao que está descrito na bibliografia, onde o posicionamento em PA permite uma maior desprojeção das omoplatas sobre o pulmão enquanto que o AP, pelas especificidades inerentes à seleção desta incidência e à proximidade do ecrã, se traduz numa maior sobreposição ao campo pulmonar.

Para determinar se existem diferenças estatísticas entre as incidências AP e PA em relação à sobreposição da omoplata e percentagem de sobreposição, recorreu-se ao teste de chi-quadrado de Pearson. Avaliou-se a independência das duas variáveis categóricas, testando-se a hipótese nula de que a incidência (AP ou PA) é estatisticamente independente da presença de sobreposição das omoplatas, obtendo-se χ^2 : 1675,47 no teste qui-quadrado

Dado que o valor p é virtualmente 0, para uma significância de 0,05, rejeitamos a hipótese nula, verificando-se que existe uma associação significativa entre a incidência (AP ou PA) e a presença de sobreposição das omoplatas. Os resultados obtidos demonstram efetivamente que a escolha da incidência (PA ou AP) e as variações no posicionamento têm impacto ao nível da sobreposição das omoplatas, corroborando a bibliografia.

De seguida avaliou-se a proporção de sobreposição para ambas as omoplatas à direita e à esquerda aos respetivos campos pulmonares. Para tal, fez-se a gestão dos *missing*

values nas colunas relacionadas com a sobreposição das omoplatas, onde se sinalizou 602 *missing values* para a sobreposição ao campo pulmonar esquerdo e 621 *missing values* para a sobreposição ao campo pulmonar direito. Estes valores estão relacionados com a ausência de sobreposição, pelo que se procedeu à sua exclusão, removendo estas linhas do *dataset*.

Pretendendo-se determinar se existe uma diferença significativa entre as médias de duas amostras independentes, para o caso, a sobreposição das omoplatas aos campos pulmonares à direita e à esquerda para as incidências AP e PA, pretende-se recorrer ao teste t de Student. Para o aplicar, é necessário que dois pressupostos se verifiquem: que a distribuição seja normal e exista homogeneidade das variâncias entre os dois grupos.

Avaliou-se a normalidade da distribuição através do teste de Shapiro-Wilk, testando-se a hipótese nula de que a amostra apresenta uma distribuição normal, obtendo-se os seguintes resultados:

Tabela 6: Teste de normalidade de Shapiro-Wilk

Teste de normalidade de Shapiro-Wilk

		Incidência	
		AP	PA
Sobreposição da omoplata ao campo pulmonar	Esquerdo	4.61 x 10 ⁻¹⁸	0.0
	Direito	8.67 x 10 ⁻¹⁷	0.0

Perante os *p-value* obtidos, para uma significância de 0.05, rejeitou-se a hipótese nula e concluímos que os dados para a sobreposição da omoplata ao campo pulmonar tanto esquerdo como direito não apresentam uma distribuição normal para ambas as incidências AP e PA.

Analisou-se a homogeneidade das variâncias, recorrendo-se ao teste de Levene, testando-se a hipótese nula de que existe homogeneidade das variâncias da amostra, obtendo-se os seguintes resultados:

Tabela 7: Teste de homogeneidade de variâncias de Levene

Teste de homogeneidade de variâncias de Levene

	<i>p-value</i>
Sobreposição da omoplata ao campo pulmonar esquerdo	9.82x10 ⁻¹³¹
Sobreposição da omoplata ao campo pulmonar direito	6.88x10 ⁻¹³⁸

Perante os *p-value* obtidos, para uma significância de 0.05, rejeitou-se a hipótese nula e concluímos que os dados para a sobreposição da omoplata ao campo pulmonar tanto esquerdo como direito não apresentam homogeneidade de variâncias.

Como os dados obtidos não correspondem aos pressupostos necessários para aplicar o teste t de student, recorreremos ao teste Mann-Whitney para comparar as distribuições entre as incidências AP e PA para a sobreposição das omoplatas aos campos pulmonares esquerdo e direito. Testou-se a hipótese nula de que não existe diferença significativa entre distribuições e obtiveram-se os seguintes resultados:

Tabela 8: Teste U de Mann-Whitney

Teste U de Mann-Whitney

<i>Sobreposição da omoplata ao campo pulmonar esquerdo</i>	Teste estatístico	75,047,022
	<i>p-value</i>	0.0
<i>Sobreposição da omoplata ao campo pulmonar direito</i>	Teste estatístico	78,262,722
	<i>p-value</i>	0.0

Dado os *p-value* serem aproximadamente 0, para um nível de confiança de 95%, rejeitamos a hipótese nula e concluímos que existe uma diferença significativa na distribuição dos dados para a sobreposição das omoplatas ao campo pulmonar esquerdo e direito para as incidências AP e PA.

Os resultados até agora obtidos demonstram que existe uma associação significativa entre as incidências AP e PA em relação à presença de sobreposição das omoplatas aos campos pulmonares (baseado no teste Chi-quadrado) e que existe uma diferença

significativa na distribuição da sobreposição das omoplatas aos campos pulmonares (baseado no teste U de Mann-Whitney).

Para uma análise visual e mais descritiva, comparámos as distribuições e tendências centrais da sobreposição das omoplatas para ambas as incidências AP e PA.

Tabela 9: Medidas de tendência central para a sobreposição das omoplatas aos campos pulmonares esquerdo e direito para as incidências AP e PA

	Incidência AP		Incidência PA	
	Sobreposição das omoplatas Esquerda	Sobreposição das omoplatas Direita	Sobreposição das omoplatas Esquerda	Sobreposição das omoplatas Direita
Média	29.18%	30.37%	8.92%	8.31%
Mediana	30.00%	32.00%	3.00%	3.00%
Desvio-padrão	18.27%	17.73%	12.41%	11.52%

Observou-se que a média e mediana para a sobreposição das omoplatas aos campos pulmonares são consideravelmente mais elevadas para a incidência AP comparativamente à incidência PA, para ambos os lados esquerdo e direito, e que a dispersão é também mais elevada em incidência AP, o que sugere uma maior variabilidade para a sobreposição das omoplatas nesta incidência (tabela 9).

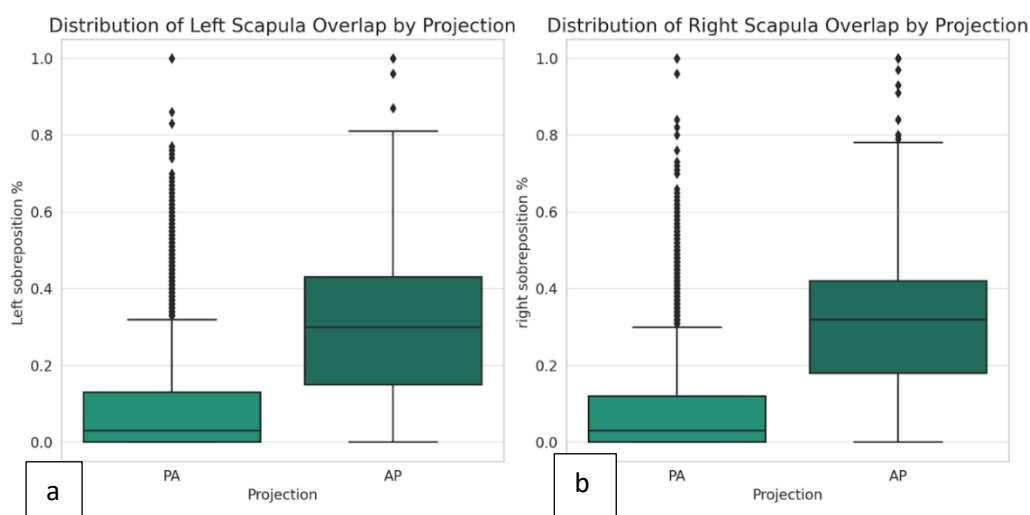


Figura 16: a) Caixas de bigodes da sobreposição das omoplatas sobre o campo pulmonar esquerdo para a incidência PA e AP; b) Caixas de bigodes da sobreposição das omoplatas sobre o campo pulmonar direito para a incidência PA e AP

A análise das caixas de bigodes da sobreposição das omoplatas sobre os campos pulmonares esquerdo e direito para a incidência PA e AP reforça os resultados observados anteriormente.

Relativamente à sobreposição da omoplata à esquerda, figura 16a), observamos que a mediana (representada pela linha dentro da caixa) é mais elevada na incidência AP do que na incidência PA e a amplitude interquartil (representada pela caixa) é também maior na incidência AP, indicando maior variabilidade dos dados.

Em relação à sobreposição da omoplata ao campo pulmonar direito, figura 16b), tal como observado na sobreposição à esquerda, a mediana é consideravelmente mais elevada para a incidência AP do que para a PA e a variabilidade é também maior nesta incidência comparativamente com a incidência PA.

Em suma, ao observar a sobreposição da omoplata ao campo pulmonar, verificou-se que ela tende a ser mais pronunciada na incidência AP em comparação com a incidência PA. Esta diferença sugere que a posição anteroposterior aumenta a probabilidade da omoplata se sobrepor aos pulmões, dificultando a visualização clara das estruturas torácicas.

Os resultados obtidos reforçam a evidência de que a incidência AP é a que mais apresenta sobreposição das omoplatas aos campos pulmonares, sendo que, quando está presente, ocorre em maior proporção em comparação com a incidência PA. Estas constatações são cruciais para que o modelo seja uma mais valia no apoio aos profissionais de saúde que dependem das imagens radiográficas para diagnóstico e acompanhamento de condições pulmonares já que pode influenciar a interpretação clínica e a deteção de possíveis patologias, permitindo uma análise mais precisa das estruturas torácicas e uma interpretação clínica mais confiável.

Conclusão

A radiografia permanece o estudo mais realizado mundialmente, onde o tórax é uma das regiões anatómicas mais estudadas por esta técnica, relevando a sua incontornável importância nos cuidados de saúde. O correto posicionamento do paciente, em especial das omoplatas, é um aspeto fundamental na obtenção de imagem radiográfica do tórax de elevada qualidade, tendo impacto direto no diagnóstico, na minimização da exposição à radiação, melhorando o cuidado ao paciente. A sua sobreposição com os campos pulmonares pode ocultar detalhes cruciais, potencialmente ludibriando médicos menos experientes e estudantes de radiologia.

Este estudo procurou desenvolver um sistema de deteção e caracterização automático da sobreposição das omoplatas nos campos pulmonares na análise da qualidade técnica da radiografia frontal do tórax, através de um modelo de *deep learning*. Desta forma, procurou desenvolver-se um modelo que servisse de ferramenta para garantir a qualidade clínica das imagens radiográficas nas bases de dados públicas, mas também no ato da execução do exame, servindo de apoio aos profissionais de saúde, com maior impacto nos serviços onde o *expertise* humano é menor. Este estudo ganhou mais pertinência num contexto pós-pandémico, onde a radiografia ao tórax teve a maior relevância.

O modelo desenvolvido permitiu a análise da deteção das omoplatas, a análise bilateral entre PA e AP da sobreposição das omoplatas aos campos pulmonares, bem como a análise da diferença entre PA e AP no padrão de sobreposição da omoplata dos campos pulmonares. O algoritmo detetou a omoplata em 99,8% dos exames, onde 40% apresentaram sobreposição da omoplata aos campos pulmonares. Ambos os lados apresentam valores agrupados nas percentagens mais baixas, com medianas para sobreposição esquerda de 3% e direita de 5%. O intervalo interquartil da esquerda é de 12% e o da direita é de 13%, com os quartis de 75% sendo 12 e 14%, respetivamente. Existe uma moderada relação linear (0,673) entre os lados, sugerindo aumentos simultâneos nas percentagens de sobreposição. As imagens radiográficas ao tórax em incidência PA foram as que apresentaram um maior número absoluto de deteção de sobreposição das omoplatas ao campo pulmonar, tanto no lado esquerdo como direito, quando comparada com a incidência AP. No entanto, ao observar a sobreposição da omoplata aos campos pulmonares, demonstrou-se que ela tende a ser mais pronunciada na incidência AP, sobrepondo-se em média 28,88% ao campo pulmonar

esquerdo e 30,12% ao campo pulmonar direito, quando comparado com a incidência PA, onde a sobreposição apresentada é de 8,93% e 8,32%, respetivamente.

Os resultados experimentais obtidos reforçam a evidência de que a incidência AP é a que apresenta uma probabilidade aumentada das omoplatas se sobrepossem aos campos pulmonares esquerdo e direito, demonstrando que o modelo proposto é adequado para avaliação da qualidade radiográfica, sendo uma ferramenta promissora e uma mais valia no apoio aos profissionais de saúde que dependem das imagens radiográficas para diagnóstico e acompanhamento de condições pulmonares. A sobreposição das omoplatas aos campos pulmonares, ainda que muitas vezes seja mínima, sugere que a consistência na técnica de posicionamento é crucial. Este estudo reforça também que o *deep learning* apresenta potencial para ser utilizado na prevenção de erros, diagnósticos ou tratamentos incorretos, bem como aumentar a qualidade dos dados de investigação, podendo ser uma opção para a monitorização automática da qualidade das imagens produzidas e, caso necessário, correção de metadados inseridos incorretamente durante a realização do exame.

Devem ser consideradas limitações a este estudo. Em primeiro lugar, a utilização de uma base de dados pública para o treino de uma rede deve ser tida em conta como uma limitação. Para estudos futuros, seria essencial compilar uma base de dados de treino com imagens internas de uma instituição ou de um conjunto de instituições selecionadas para estudo, não apenas para um maior controlo da qualidade das imagens, mas também para maior acessibilidade aos metadados associados. Nesta base de dados, uma limitação foi a ausência de metadados associados à classificação e distinção da imagem em AP ou PA. Apesar de ser possível afirmar que o treino e os testes foram suficientes, para uma maior e melhor generalização dos resultados seria aconselhável que ambos fossem aumentados. Outra limitação é o facto de apenas a incidência frontal (AP/PA) ter sido considerada para classificação. Do ponto de vista clínico, a incidência frontal é normalmente complementada pela incidência lateral, cuja distinção não foi possível neste *dataset*. Como estudos futuros, propomos que o modelo seja alargado à incidência lateral para uma maior complementaridade na análise da imagem radiográfica ao tórax. Propomos também que sejam desenvolvidos para extração o nível de inspiração e a rotação do tórax, para que a qualidade da imagem radiográfica possa ser avaliada em todas as suas características essenciais

Como contributo do desenvolvimento deste estudo, foi publicado um artigo científico na revista Roentgen, vol.4 nr2, com o título *Algoritmo de Aprendizagem Automática na Classificação de Radiografia ao Tórax em Incidência frontal como “normais” ou*

“patológicos”, disponível para consulta em Anexo 1. Foi também aceite para o *European Congress of Radiology* de 2024, a comunicação *Deep Learning-Based Detection and Segmentation of the Overlap Between the Lung and the Scapula in Chest X-ray Imaging*, sob a forma de poster, disponível para consulta em Anexo 2.

Referências Bibliográficas

- [1] Hosch, R., Kroll, L., Nensa, F., & Koitka, S. (2021). Differentiation Between Anteroposterior and Posteroanterior Chest X-Ray View Position With Convolutional Neural Networks. Unterscheidung der Anterior-posterior und Posterior-Anterior Röntgen-Thoraxaufnahme mit Convolutional Neural Networks. *RoFo: Fortschritte auf dem Gebiete der Röntgenstrahlen und der Nuklearmedizin*, 193(2), 168–176. <https://doi.org/10.1055/a-1183-5227>
- [2] Adams, S. J., Henderson, R. D. E., Yi, X., & Babyn, P. (2021). Artificial Intelligence Solutions for Analysis of X-ray Images. *Canadian Association of Radiologists journal = Journal l'Association canadienne des radiologistes*, 72(1), 60–72. <https://doi.org/10.1177/0846537120941671>
- [3] Raof, S., Feigin, D., Sung, A., Raof, S., Irugulpati, L., & Rosenow, E. C., 3rd (2012). Interpretation of plain chest roentgenogram. *Chest*, 141(2), 545–558. <https://doi.org/10.1378/chest.10-1302>
- [4] Islam, R., & Tarique, M. (2022). Chest X-Ray Images to Differentiate COVID-19 from Pneumonia with Artificial Intelligence Techniques. *International journal of biomedical imaging*, 2022, 5318447. <https://doi.org/10.1155/2022/5318447>
- [5] Oura D, Sato S, Honma Y, Kuwajima S, Sugimori H. (2023) Quality Assurance of Chest X-ray Images with a Combination of Deep Learning Methods. *Applied Sciences*; 13(4):2067. <https://doi.org/10.3390/app13042067>
- [6] Wielpütz, M. O., Heußel, C. P., Herth, F. J., & Kauczor, H. U. (2014). Radiological diagnosis in lung disease: factoring treatment options into the choice of diagnostic modality. *Deutsches Arzteblatt international*, 111(11), 181–187. <https://doi.org/10.3238/arztebl.2014.0181>
- [7] Siwik D, Apanasiewicz W, Żukowska M, Jaczewski G, Dąbrowska M. (2023). Diagnosing Lung Abnormalities Related to Heart Failure in Chest Radiogram, Lung Ultrasound and Thoracic Computed Tomography. *Advances in Respiratory Medicine*. 91(2):103-122. <https://doi.org/10.3390/arm91020010>
- [8] Aukema, T. S., Beenen, L. F., Hietbrink, F., & Leenen, L. P. (2012). Initial assessment of chest X-ray in thoracic trauma patients: Awareness of specific injuries. *World journal of radiology*, 4(2), 48–52. <https://doi.org/10.4329/wjr.v4.i2.48>
- [9] Cao, A. M., Choy, J. P., Mohanakrishnan, L. N., Bain, R. F., & van Driel, M. L. (2013). Chest radiographs for acute lower respiratory tract infections. *The Cochrane database of systematic reviews*, 2013(12), CD009119. <https://doi.org/10.1002/14651858.CD009119.pub2>

- [10] Willemink, M. J., Persson, M., Pourmorteza, A., Pelc, N. J., & Fleischmann, D. (2020). Automatic exposure control in CT: The effect of patient size, anatomical region, and clinical task on tube current modulation. *Medical Physics*, 47(2), 643-658
- [11] Kwee, T. C., & Kwee, R. M. (2021). Workload of diagnostic radiologists in the foreseeable future based on recent scientific advances: growth expectations and role of artificial intelligence. *Insights into imaging*, 12(1), 88. <https://doi.org/10.1186/s13244-021-01031-4>
- [12] Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. W. L. (2018). Artificial intelligence in radiology. *Nature reviews. Cancer*, 18(8), 500–510. <https://doi.org/10.1038/s41568-018-0016-5>
- [13] Zha, N., Neuheimer, N., & Patlas, M. N. (2021). Etiology of Burnout in Canadian Radiologists and Trainees. *Canadian Association of Radiologists journal = Journal l'Association canadienne des radiologistes*, 72(1), 128–134. <https://doi.org/10.1177/0846537120904452>
- [14] Krishnaraj, A., Conover, D. L., & Do, S. (2021). Physician extenders in radiology: Current roles and future directions. *Journal of the American College of Radiology*, 18(1 Pt B), 162-166.
- [15] Rehani, M. M. (2017) Need for speed in radiology: Why it matters. *Journal of Medical Imaging and Radiation Sciences*. 48(2), 125-126.
- [16] Chong, S. T., Robinson, J. D., Davis, M. A., Bruno, M. A., Roberge, E. A., Reddy, S., Pyatt, R. S., Jr, & Friedberg, E. B. (2019). Emergency Radiology: Current Challenges and Preparing for Continued Growth. *Journal of the American College of Radiology: JACR*, 16(10), 1447–1455. <https://doi.org/10.1016/j.jacr.2019.03.009>
- [17] Shiraishi, J., & Katsuragawa, S. (2018). Radiomics in medical imaging. *Journal of Medical Imaging*. 5(1), 011005.
- [18] Dasegowda, G., Kalra, M. K., Abi-Ghanem, A. S., Arru, C. D., Bernardo, M., Saba, L., Segota, D., Tabrizi, Z., Viswamitra, S., Kaviani, P., Karout, L., & Dreyer, K. J. (2023). Suboptimal Chest Radiography and Artificial Intelligence: The Problem and the Solution. *Diagnostics (Basel, Switzerland)*, 13(3), 412. <https://doi.org/10.3390/diagnostics13030412>
- [19] Lambin, P., Leijenaar, R. T. H., Deist, T. M., Peerlings, J., de Jong, E. E. C., van Timmeren, J., Sanduleanu, S., Larue, R. T. H. M., Even, A. J. G., Jochems, A., van Wijk, Y., Woodruff, H., van Soest, J., Lustberg, T., Roelofs, E., van Elmpt, W., Dekker, A., Mottaghy, F. M., Wildberger, J. E., & Walsh, S. (2017). Radiomics: the bridge between medical imaging and personalized medicine. *Nature reviews. Clinical oncology*, 14(12), 749–762. <https://doi.org/10.1038/nrclinonc.2017.141>

- [20] van Leeuwen KG, de Rooij M, Schalekamp S, van Ginneken B, Rutten MJCM. (2022) How does artificial intelligence in radiology improve efficiency and health outcomes?. *Pediatr Radiol*. 52(11):2087-2093. doi:10.1007/s00247-021-05114-8
- [21] Ehteshami Bejnordi B, Veta M, Johannes van Diest P, et al. (2017) Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. *JAMA*. 318(22):2199-2210. doi:10.1001/jama.2017.14585
- [22] Litjens G, Kooi T, Bejnordi BE, et al. (2017) A survey on deep learning in medical image analysis. *Med Image Anal*. 42:60-88. doi: 10.1016/j.media.2017.07.005
- [23] Blaivas, L., & Blaivas, M. (2021). Are Convolutional Neural Networks Trained on ImageNet Images Wearing Rose-Colored Glasses?: A Quantitative Comparison of ImageNet, Computed Tomographic, Magnetic Resonance, Chest X-Ray, and Point-of-Care Ultrasound Images for Quality. *Journal of ultrasound in medicine: official journal of the American Institute of Ultrasound in Medicine*, 40(2), 377–383. <https://doi.org/10.1002/jum.15413>
- [24] Tsapaki V. (2020). Radiation dose optimization in diagnostic and interventional radiology: Current issues and future perspectives. *Physica medica: PM: an international journal devoted to the applications of physics to medicine and biology: official journal of the Italian Association of Biomedical Physics (AIFB)*, 79, 16–21. <https://doi.org/10.1016/j.ejmp.2020.09.015>
- [25] United Nations Scientific Committee on the Effects of Atomic Radiation (UNSCEAR) 2008 Report to the General Assembly. (2013) “Sources and effects of ionizing radiation” Volume I; Annex A - Medical radiation exposures; United Nations, New York.
- [26] National Council on Radiation Protection and Measurements (NCRP). (2009). Ionizing radiation exposure of the population of the United States. Report No 160. Bethesda, Md: National Council on Radiation Protection and Measurements.
- [27] National Council on Radiation Protection and Measurements (NCRP). (2019). Medical Radiation Exposure of Patients in the United States. Report No 184. Bethesda, Md: National Council on Radiation Protection and Measurements.
- [28] Smith-Bindman R, Kwan ML, Marlow EC, et al. (2019) Trends in use of medical imaging in US health care systems and in Ontario, Canada, 2000–2016. *JAMA*. 322(9): 843–56. <https://doi.org/10.1001/jama.2019.11456>.
- [29] Maingard, J., Kok, H. K., Ranatunga, D., Brooks, D. M., Chandra, R. V., Lee, M. J., & Asadi, H. (2017). The future of interventional and neurointerventional radiology: learning lessons from the past. *The British journal of radiology*, 90(1080), 20170473. <https://doi.org/10.1259/bjr.20170473>

- [30] Bontrager, K. L. (2001). *Tratado de Técnica Radiológica e Base Anatómica* (5ª edição). Guanabara Koogan.
- [31] ACR-SPR-STR Practice Parameter for the Performance of Chest Radiography. 2017. [(accessed on 12 August 2021)]. Available online: <https://www.acr.org/-/media/ACR/Files/Practice-Parameters/ChestRad.pdf>
- [32] Carmichael J., Moores B., Maccia C., Moores B.M., Oestmann J.W., Schibilla H., Teunen D., Van-Tiggelen R., Wall B. *European Guidelines on Quality Criteria for Diagnostic Radiographic Images*. Office for Official Publications of the European Communities; Luxembourg: 2000. European Commission, Directorate-General for Research and Innovation.
- [33] Young, S., Kotnik, M., Lin, L., Sevenster, M., Wieberneit, N., Harder, T. Krönke, S., Bystrov, D., Lamb, H.J. (2020). Measuring patient positioning quality in clinical chest radiographs. *European Society of Radiology*, Poster ECR 2020/C-12328. <http://dx.doi.org/10.26044/ecr2020/C-12328>
- [34] Wang X, Peng Y, Lu L et al. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In: Proceedings of the IEEE conference on computer vision and pattern recognition 2017: 2097–2106 <https://doi.org/10.48550/arXiv.1705.02315>
- [35] Foos D.H., Sehnert W.J., Reiner B., Siegel E.L., Segal A., Waldman D.L. Digital radiography reject analysis: Data collection methodology, results, and recommendations from an in-depth investigation at two hospitals. *J. Digit. Imaging*. 2009;22:89–98. doi: 10.1007/s10278-008-9112-5.
- [36] Aasem, M., Iqbal, M. J., Ahmad, I., Alassafi, M. O., & Alhomoud, A. (2022). A Survey on Tools and Techniques for Localizing Abnormalities in X-ray Images Using Deep Learning. *Mathematics*, 10(24), 4765. <https://doi.org/10.3390/math10244765>
- [37] Yang, R., & Yu, Y. (2021). Artificial Convolutional Neural Network in Object Detection and Semantic Segmentation for Medical Imaging Analysis. *Frontiers in oncology*, 11, 638182. <https://doi.org/10.3389/fonc.2021.638182>
- [38] Fukui R., Ishii R., Kodani K., Kanasaki Y., Suyama H., Watanabe M., Nakamoto M., Fukuoka Y. Evaluation of a noise reduction procedure for chest radiography. *Yonago Acta Med*. 2013;56:85–91.
- [39] Mitra S, Shankar BU. (2014) Integrating radio imaging with gene expressions toward a personalized management of cancer. *IEEE Trans Human-Mach Syst*. 44:664–77. DOI:10.1109/THMS.2014.2325744
- [40] Chen, B., Zhang, R., Gan, Y., Yang, L., & Li, W. (2017). Development and clinical application of radiomics in lung cancer. *Radiation oncology (London, England)*, 12(1), 154. <https://doi.org/10.1186/s13014-017-0885-x>

- [41] Park S, Lee SM, Lee KH, et al. Deep learning-based detection system for multiclass lesions on chest radiographs: comparison with observer readings. *Eur Radiol.* 2019;30(3):1359–1368. doi:10.1007/s00330-019-06532-x
- [42] Yao, L., Zhang, C., Zhang, H., Chen, X., Zhou, H., & Zhang, D. (2020). A deep learning system for COVID-19 diagnosis from chest CT using weak label. *Medical Image Analysis.* 67, 101851.
- [43] Gefter, W. B., & Hatabu, H. (2023). Reducing Errors Resulting From Commonly Missed Chest Radiography Findings. *Chest*, 163(3), 634–649. <https://doi.org/10.1016/j.chest.2022.12.003>
- [44] Machine Learning and Medicine - mlmed.org, NIH Chest X-rays dataset [consultado em março 2023], https://mlmed.org/torchxrayvision/datasets.html#torchxrayvision.datasets.NIH_Dataset
- [45] Machine Learning and Medicine - mlmed.org, TorchXrayVision [consultado em março 2023], <https://mlmed.org/torchxrayvision/>
- [46] Machine Learning and Medicine - mlmed.org, PSPnet [consultado em março 2023], https://mlmed.org/torchxrayvision/models.html#torchxrayvision.baseline_models.chestx_det.PSPNet
- [47] Ferreira, A. M. (1994). Testes de Normalidade – Ajustamento à função de distribuição normal. Repositório IPCB. https://repositorio.ipcb.pt/bitstream/testes_normalidade.pdf
- [48] Cheng, S. G., & Stern, E. J. (2002). That darn scapula: a common pitfall in interpreting the chest radiograph. *Respiratory care*, 47(8), 910–914.
- [49] Young-Cheol, J., Cheong-Hwan L., Hwan-Seung L., Woo-Taek L., Hee-Jin K., Hong-Rayng J., In-Gyu Y. (2016). Comparison with Overlap Area of Scapular and Lung Field according to Position on Chest Radiography. *Indian Journal of Science and Technology*, 9(25), DOI: 10.17485/ijst/2016/v9i25/97229
- [50] Department of Natural Resources and Mines, State of Queensland. (2017) *Standards for digital chest radiography images for medical surveillance of Queensland coal mine workers – Including technical quality grading guidelines for ILO classifications.* CS7315. 9/17. [standards-for-digital-chest-radiography-images-for-medical-surveillance-of-queensland-coal-mine-workers](https://www.dnr.qld.gov.au/standards-for-digital-chest-radiography-images-for-medical-surveillance-of-queensland-coal-mine-workers)
- [51] Bharati, S., Podder, P., & Mondal, M. R. H. (2020). Hybrid deep learning for detecting lung diseases from X-ray images. *Informatics in medicine unlocked*, 20, 100391. <https://doi.org/10.1016/j.imu.2020.100391>

[52]Britannica.com [consultado em fevereiro 2024],
<https://www.britannica.com/science/human-respiratory-system/The-mechanics-of-breathing>

Anexos

Anexo 1

Algoritmo de Aprendizagem Automática na Classificação de Radiografia ao Tórax em Incidência frontal como “normais” ou “patológicos”

Machine Learning Algorithm in the Classification of frontal view Chest x-ray as “normal” or “pathological”

Ivone Cidade de Moura¹, Luis Mesquita², Ricardo Teresa Ribeiro³

¹ Técnica Superior de Radiologia - Centro Hospitalar Universitário Lisboa Norte, Instituto Superior de Engenharia de Lisboa

Email: ivonecidade@gmail.com

² Técnico de Electromedicina – Multipore, Instituto Superior de Engenharia de Lisboa

³ H&TRC – Health & Technology Research Center, ESTeSL – Escola Superior de Tecnologia da Saúde de Lisboa, Instituto Politécnico de Lisboa.

Resumo

A crescente procura de exames radiológicos pressiona os serviços de imagiologia que enfrentam desafios devido à escassez de radiologistas, exigindo uma interpretação mais rápida com um maior potencial de erro. Em paralelo, as técnicas de *radiomics* e inteligência artificial (IA) têm-se verificado ferramentas importantes no campo da radiologia, revolucionando a própria prática clínica. Através destas técnicas, este artigo desenvolveu um classificador de detecção de patologia para radiografias do tórax, da base-de dados pública ChestXray14, com o objetivo de realçar o papel crucial que a compreensão das técnicas de *radiomics* e IA na profissão do técnico de radiologista.

Foram analisadas 1662 radiografias (50% com patologia) ao tórax, tendo sido aplicadas duas estratégias para seleção de 5 características *radiomics*: (i) análise de componentes principais (PCA) e (ii) “*information gain ratio*” (Rank), utilizando o software Orange. Com o método PCA, com redução para 5 componentes e 73% de variância explicada, o melhor classificador foi o *Neural Network*, com 0,987 de *Area Under the Curve* (AUC). No *Information Gain Ratio* também o *Neural Network* foi o melhor classificador com 0,972 AUC, na qual se verificou uma sensibilidade de 97,8%, especificidade de 92,9% e precisão de 93%.

Ao utilizar técnicas de IA e tirar partido de um grande conjunto de dados, o nosso estudo demonstra a viabilidade da utilização de classificadores automáticos para ajudar na interpretação de radiografias ao tórax, indicando o seu potencial como uma ferramenta valiosa na triagem, priorização de exames, e otimização no fluxo de trabalho nos departamentos de radiologia.

Palavras-chave: inteligência artificial, computer-aided detection, classificadores de aprendizagem automática, radiografia tórax, principal component analysis, rank

Abstract

The growing demand for radiological exams puts pressure on imaging services that face challenges due to the shortage of radiologists, requiring faster interpretation with a higher potential for error. In parallel, radiomics and artificial intelligence (AI) techniques have proven to be important tools in the field of radiology, revolutionizing clinical practice itself. Using these techniques, this paper developed a pathology detection classifier for chest radiographs, from the public database CestXray14, in order to highlight the crucial role that understanding radiomics techniques and AI play in the radiographer's profession.

We analysed 1662 chest radiographs (50% with pathology) and applied two strategies for selecting 5 radiomics features: (i) principal component analysis and (ii) information gain ratio, using the Orange software. With the PCA method, with reduction to 5 components and 73% of variance explained, the best classifier was the Neural Network, with 0.987 of Area Under the Curve (AUC). In Information Gain Ratio also the Neural Network was the best classifier with 0.972 AUC, in which a sensitivity of 97.8%, specificity of 92.9% and accuracy of 93% were found.

By using AI techniques and taking advantage of a large dataset, our study demonstrates the feasibility of using automatic classifiers to aid in the interpretation of chest radiographs, indicating their potential as a valuable tool in screening, prioritizing exams, and optimizing workflow in radiology departments.

Keywords: artificial intelligence, computer-aided detection, machine learning classifiers, chest x-ray, principal component analysis, rank

Introdução

Os avanços tecnológicos aumentaram significativamente a acessibilidade e a capacidade de produção de exames radiológicos, reduzindo simultaneamente os tempos de exame.¹ A transição digital dos serviços de radiologia facilitou ainda mais o arquivo, o processamento e extração de informações de cariz clínico dos exames radiológicos, permitindo o acompanhamento e análise longitudinal dos doentes.² Contudo, o crescente volume de exames ultrapassou a disponibilidade dos serviços, levando à redução do tempo de interpretação e ao aumento da pressão para fornecer pareceres clínicos atempados, particularmente em ambiente de urgência médica.^{3,4}

Com o objetivo de otimizar a alocação de recursos, os radiologistas geralmente priorizam os exames que exigem interpretação mais especializada e contam com modalidades de imagem mais simples, como a radiografia, para serem lidas por médicos sem ampla experiência radiológica.^{3,4} Esta abordagem ajuda a mitigar o risco de má interpretação e garante relatórios precisos em exames mais complexos, salvaguardando, em última análise, os resultados dos pacientes. De facto, o processo e resultado da análise dos exames radiológicos está dependente da experiência, formação e níveis de atenção dos radiologistas. Dado o elevado volume de exames diários, é possível que padrões anormais subtis passem despercebidos. Assim, a integração de métodos de inteligência artificial (IA) na prática clínica tem o potencial de aumentar a eficiência da deteção de anomalias e reduzir o tempo de resposta.^{3,5}

A IA surge como uma das principais plataformas transformadoras nos cuidados de saúde, mantendo como estratégia apoiar a resolução de diferentes desafios clínicos através da utilização de dados clínicos (ex. radiografia tórax) e algoritmos de classificação. Para garantir um impacto positivo, deve-se considerar uma estrutura de cuidados de saúde baseada na criação de valor, assumindo-se como valor o rácio entre os resultados clínicos e os seus custos associados. Neste contexto, a IA pode gerar valor reduzindo os custos e/ou melhorando os resultados em termos de saúde.⁶ Na radiologia, a IA pode ser utilizada para melhorar a eficiência do fluxo de trabalho, acelerar o tempo de leitura do exame, minimizar a dose de radiação e a utilização de agentes de contraste, melhorar a precisão do diagnóstico para a deteção precoce de doenças e permitir diagnósticos personalizados.⁷⁻⁹

Diversos estudos têm demonstrado aplicações bem sucedidas de IA na classificação de radiografias ao tórax, na qual se salienta o seu potencial para melhorar a precisão do diagnóstico e ajudar os profissionais de saúde no seu processo de tomada de decisões. Por exemplo, Wang *et al.* (2017) desenvolveram um modelo de aprendizagem profunda denominado ChestX-ray8 para classificar automaticamente doenças comuns do tórax. O seu modelo obteve resultados promissores com uma AUC multirrótulo de 0,809 e superou as abordagens tradicionais de aprendizagem automática. Rajpurkar *et al.* (2017) introduziram a CheXNet, uma rede neural convolucional (CNN), que demonstrou uma elevada precisão na identificação de 14 patologias diferentes em radiografias do tórax, superando o desempenho dos radiologistas. Do mesmo modo, Yao *et al.* (2020) utilizaram um modelo de aprendizagem profunda denominado COVID-Net para detetar casos de COVID-19 em radiografias de tórax. A sua abordagem alcançou uma sensibilidade de 94,1% e uma especificidade de 92,7% na deteção da COVID-19, mostrando potencial para ajudar no diagnóstico desta doença específica. Num estudo recente, Dyer *et al.*, demonstrou que um algoritmo de Deep Learning foi capaz de classificar 15% de radiografias ao tórax como “normais” com uma precisão de 97,7% e uma taxa de erro de 0,33%, removendo 24,9% dos estudos normais confirmados pelo radiologista do fluxo de trabalho.^{5,10}

Mais recentemente outra técnica – *radiomics* – oriunda da área de *computer vision* da engenharia tem vindo a ser aplicada com sucesso na área da radiologia. *Radiomics* refere-se à extração e análise de uma vasta gama de características quantitativas de imagens médicas.⁶ Permite a conversão de imagens radiográficas convencionais em dados de diferentes dimensões e reprodutíveis, fornecendo informações correlacionáveis com o diagnóstico de doenças, o prognóstico e a resposta ao tratamento. Ao compreender a mais-valia da

extração de características *radiômicas*, os técnicos de radiologia podem tirar partido do poder destas características correlacionando os padrões técnicos e semiológicos de análise das imagens radiográficas, contribuindo assim para melhorar os cuidados prestados aos doentes e a tomada de decisões clínicas.¹¹

Com base nos desenvolvimentos observados, a compreensão da técnica de extração de características radiômicas e a utilização de IA em imagens médicas é de extrema importância para os técnicos de radiologia, não só para a melhoria contínua das suas funções enquanto profissionais de saúde, mas também na capacidade de um desenvolvimento mais centrado no doente, bem como a integração em equipas de investigação, tornando-se assim como colaboradores indispensáveis na área em constante evolução da imagem médica. Este artigo tem assim como objetivos (i) desenvolver um classificador de deteção de patologia para a radiografias do tórax, da base-de-dados pública CestXray14, e (ii), com base nos resultados, realçar o papel crucial que a compreensão das técnicas de radiomics e IA podem ter na profissão do técnico de radiologia.

Materiais e Métodos

A metodologia de classificação supervisionada através da extração de características radiomics de radiografias do tórax proposta neste artigo tem os seguintes passos principais:

7. Base-de-dados: Um conjunto de radiografias do tórax é extraído e organizado num formato adequado para análise e reprodutibilidade dos resultados.
8. Segmentação da região de interesse: A região de interesse (ROI), que neste caso é o parênquima pulmonar, é segmentada a partir das imagens radiográficas.
9. Extração de características *radiomics*: Diversas características radiomics são extraídas da região de interesse segmentada.
10. Seleção de características: Com base nas características extraídas, um processo de seleção é realizado para identificar as características mais relevantes para a classificação das radiografias do tórax.
11. Treino de diferentes modelos de classificação: diferentes algoritmos de classificação supervisionada são treinados utilizando as características selecionadas e as classes ("patológico" e "normal") associadas a cada radiografia do tórax. O processo de treino envolve "alimentar" o modelo com diferentes partições de dados e ajustar seus parâmetros para otimizar a capacidade de prever corretamente as classes.
12. Avaliação da performance modelo: O modelo treinado é avaliado usando um conjunto de dados de teste separado. Isso permite verificar o desempenho do modelo em radiografias do tórax não vistas durante o treino. Métricas de desempenho, como AUC, sensibilidade e especificidade, são calculadas para avaliar a capacidade de classificação do modelo.

Base de dados

Foi utilizada a base-de-dados pública ChestX-ray14, obtida através do *website Kaggle*, possuindo 112120 imagens de radiografia do tórax em incidência frontal de 30805 pacientes.¹²


ChestX-ray14

Edit

Introduced by Wang et al. in ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases

ChestX-ray14 is a medical imaging dataset which comprises 112,120 frontal-view X-ray images of 30,805 (collected from the year of 1992 to 2015) unique patients with the text-mined fourteen common disease labels, mined from the text radiological reports via NLP techniques. It expands on ChestX-ray8 by adding six additional thorax diseases: Edema, Emphysema, Fibrosis, Pleural Thickening and Hernia.

Source: <https://nihcc.app.box.com/v/ChestXray-NIHCC/file/220660789610>



Source: <https://nihcc.app.box.com/v/ChestXray...>

Figura 14 - Base de dados ChestX-ray14.

A ChestX-ray14 apresenta algumas limitações: (i) diferentes faixas etárias - contém exames de crianças, jovens e adultos; (ii) apesar de todas serem um exame frontal ao tórax, a aquisição varia entre em incidência antero-posterior (AP) como postero-anterior (PA), o que se traduz numa variação das dimensões da anatomia e na sua proporção na relação com as restantes estruturas.

Para ultrapassar estas limitações, as imagens selecionadas foram analisadas por uma técnica de radiologia com mais de 15 anos de experiência, levando assim a uma forte redução da quantidade de imagens analisadas. Foram assim selecionadas 2000 radiografias ao tórax em posição frontal, onde 984 estavam identificadas com a presença de pelo menos uma patologia.

Seleção das Radiografias ao Tórax

A ChestX-ray14 é disponibilizada com informação acerca de cada uma das radiografias, nomeadamente: número de identificação (ID), categorização da patologia(s) identificadas e coordenadas da ROI (bounding box). As patologias estão organizadas nas seguintes categorias: Atelectasia, Perfusão, Massa, Nódulo, Pneumonia e Cardiomegália. A categoria “Cardiomegalia” foi excluída do estudo por duas razões: (i) ao tratar-se de um aumento do aumento da sombra cardíaca, calculado através do rácio cardiotorácico, não é expectável que existam alterações no parênquima pulmonar; (ii) a avaliação da silhueta cardíaca pode não permitir um diagnóstico diferencial entre as causas do aumento do contorno cardiomediastínico com o aumento da silhueta cardíaca e, em última análise, não se trata de uma patologia pulmonar.¹³ Esta exclusão reduziu a quantidade de imagens patológicas a analisar para 839, das 984 imagens patológicas inicialmente selecionadas.




Figura 15 - Exemplo de imagens patológicas a) Atelectasia b) Perfusão.




Figura 2 - Exemplo de imagens patológicas c) Infiltração d) Massa.




Figura 2 - Exemplos de imagens patológicas e) Nódulo f) Pneumonia.

A seleção das imagens normais foi realizada através da aplicação de um algoritmo que extraiu aleatoriamente 900 imagens a partir do ficheiro que acompanha a BD e que estavam identificadas como normais. Procedeu-se a uma pré-análise na qual foram retiradas as imagens com algumas evidências patológicas ou alterações anatómicas muito significativas. Este processo reduziu as imagens patológicas para 813.




Figura 3 - Exemplos de imagens sem patologia.

Segmentação da Região de Interesse das Radiografias ao Tórax

As imagens patológicas e normais foram alvo de processamento. Em relação às imagens patológicas, iniciou-se pelo cálculo e determinação da máscara, que é necessário para a aplicação da função que irá extrair as features. A bounding box de cada imagem está identificada em coordenadas xywh. Para a criação da máscara binária, que vai segmentar a área do parênquima pulmonar que vai ser estudado, foram criados os limites left, right, top e bottom, tendo sido necessário converter a bounding box conforme descrito na figura 4.

$$\text{left} = x, \text{ top} = y$$

$$\text{bottom} = y - h, \text{ right} = x + w$$




Figura 4 - Conversão de xywh para left, right, top e bottom para criação da Bounding box (ROI) que irá segmentar o parênquima pulmonar identificado com as diferentes patologias.

As imagens sem patologia não possuem bounding box. De forma a poder aplicar a extração de features criou-se uma máscara ou ROI genérica para ser aplicada em todas as 813 imagens normais. A ROI define a região do apex pulmonar direito, por ser mais fácil de isolar da restante anatomia e permitir maior

contraste entre estruturas anatómicas, diferenciando-se melhor das regiões mais suscetíveis a vestígios patológicos. A ROI aplicada às radiografias normais pode ser visualizada na figura seguinte.




Figura 5 - ROI aplicada às imagens normais, na qual a região a branco será aquela que irá segmentar o parênquima pulmonar normal.

Extração de características radiomics das ROI selecionadas

Radiomics é um processo automático ou semiautomático de extração uma grande quantidade quantificável de características de uma região de interesse em imagens radiográficas. Este método atribui valores numéricos às características extraídas, sendo estas relacionadas com intensidade, textura, forma e análises em frequência. Assim podemos agrupar as referidas características em 3 grandes grupos: ¹⁴

1. Características de primeira ordem

Estas descrevem a distribuição da intensidade dos pixels da região de interesse, estando assim associadas ao histograma da imagem. Estão incluídas neste grupo a média, mediana e desvio padrão da intensidade dos pixels, bem como outras grandezas como energia (avalia a grandeza dos valores dos pixels), entropia (mede a incerteza na imagem, ou seja, quanto maior o valor, mais heterogéneo é o ROI), kurtosis (descreve a probabilidade de distribuição dos valores na ROI, ou seja, se se aproxima do valor médio ou não) e a skewness (mede a assimetria da probabilidade de distribuição do ROI em relação ao valor médio). ^{14,15}

2. Características morfológicas

As características de forma 2D e 3D englobam métodos descritivos da forma e volume da região de interesse, que são calculados a partir da imagem segmentada. Incluem o cálculo do volume, área, diâmetro máximo e outros parâmetros relacionados à geometria da ROI. A relação superfície-volume elevada indica uma área de estudo com geometria irregular ou espiculada, enquanto um valor mais baixo indica uma área de estudo com forma mais arredondada. ¹⁴

3. Características de textura

O termo "textura da imagem" refere-se à variação espacial dos níveis de cinza presentes na imagem. O conceito de textura intratumoral, que representa a heterogeneidade de uma área de interesse, foi introduzido por Halarick em 1973. ¹¹

As características de textura são calculadas por meio da aplicação de matrizes que avaliam as relações espaciais entre as intensidades de dois pixels, considerando uma determinada distância e direção. Essas matrizes permitem quantificar a homogeneidade ou heterogeneidade da distribuição dos níveis de cinza, fornecendo informações sobre a textura da imagem, tendo sido extraídas as seguintes: ¹⁴⁻¹⁶

- Gray Level Co-occurrence Matrix (GLCM) - Avalia a distribuição espacial dos níveis de cinza, baseado na ocorrência repetida de alguns níveis de cinza. Permite calcular 24 características.
- Gray Level Run Length Matrix (GLRLM) - avalia o número consecutivo de pixels com o mesmo nível de cinza. Permite calcular 16 características.

- Gray Level Size Zone Matrix (GLSZM) permite avaliar o número de pixels consecutivos com o mesmo valor de nível de cinzento, ou seja, quantifica zonas homogêneas de cinzento.
- Gray Level Dependence Matrix (GLDM) avalia o número de pixels consecutivos dependentes do pixel central e quantifica o nível de cinzentos dependentes na ROI. Permite extrair 14 características.
- Neighbouring Gray Tone Difference Matrix (NGTDM) calcula a diferença do valor de cinzento entre um pixel e os seus vizinhos. Permite calcular 5 características.

Foram assim extraídas 123 características para cada uma das ROI selecionadas. Devido ao número elevado de características (ou *features*) e com o objetivo de evitar *overfitting*, foi necessário proceder a uma metodologia de redução do espaço de características.

Seleção das características

A etapa de seleção de características é crucial para evitar *overfitting* do modelo a ser desenvolvido, assim após a extração das características realizou-se uma pré-análise dos dados com o objetivo de reduzir a dimensionalidade do espaço de características: (i) análise de correlação - utilizando o coeficiente de correlação de Pearson obtou-se por retirar uma das características que se relacionavam entre si com um coeficiente superior a 0.95 (p value < 0.01); de seguida procedeu-se a uma (ii) análise de outliers – optou-se pelo método Local Outlier Factor (15% de contaminação, 20 vizinhos e métrica euclidiana) através da função outliers do programa Orange.

A partir das 46 características resultantes do processo de pré-análise, foram selecionadas as cinco características com maior importância, recorrendo a duas técnicas de seleção de características:

(i) Ranking estatístico information gain ratio. Este indicador considera tanto a relevância da característica em relação à variável de interesse como a quantidade de informações que ela fornece em relação a outras características. É calculado através da entropia dos dados calculada antes e depois de considerar cada uma das características, fornecendo uma medida da qualidade de informação ganha ao se adicionar uma determinada característica ao modelo.¹⁷ Foi utilizado a função “Rank” no programa Orange 3 (ver Fig. 6).

(ii) Análise por Componentes Principais (PCA) – Método que realiza diferentes rotações ao conjunto de características de forma a que as características rodadas não estejam estatisticamente correlacionadas. Esta rotação é seguida da seleção de um subconjunto de novas características, de acordo com a sua importância para a explicação dos dados.¹⁸ Neste projeto, optou-se por reduzir de 46 features para 5 componentes, com uma variância explicada de 73%. Foi utilizada a função “PCA” no programa Orange 3 (ver Fig. 6).

Processo de classificação e indicadores de performance

Para os diferentes conjuntos de características selecionados (Rank e PCA), e tratando-se de um processo de classificação supervisionado com duas classes, “normal”, “patológico”, foram testados diferentes classificadores: kNN, SVM, Random Forest e Neural Network.

não-paramétrico que avalia a distância entre classes em relação aos k vizinhos mais próximos. O número de vizinhos utilizado foi de 5. O classificador *Random Forest* combina o resultado de múltiplas árvores de decisão, tendo como objetivo diminuir a variância entre os resultados através da criação de diferentes ligações entre as várias árvores de decisão com diversas ramificações. Neste projeto utilizaram-se 10 árvores de decisão. O classificador SVM (*Support Vector Machine*) é um robusto classificador baseado no princípio de kernels, que procura definir o hiper-plano que melhor separa os vetores de suporte de cada uma das classes consideradas.¹⁹ Foi utilizado o kernel RBF. O classificador Neural Network utilizado é um algoritmo multi-layer-perception (MLP) com backpropagation implementado no Orange 3. Foi parametrizado com um máximo de 200 iterações e 100 camadas de neurónios.

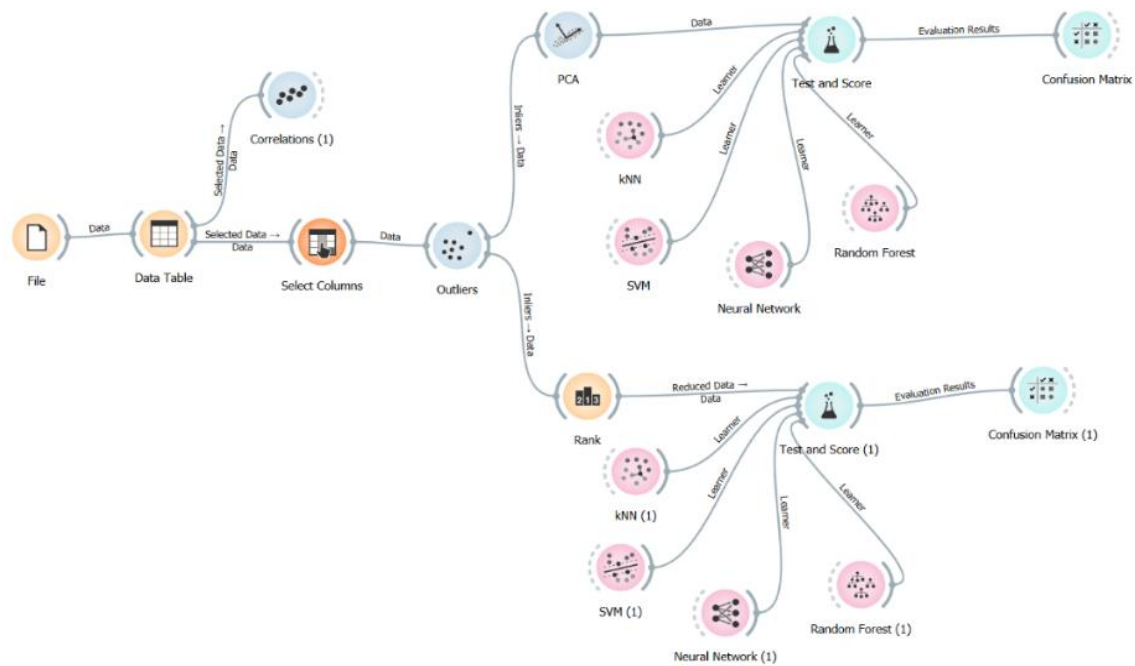


Figura 6 - Workflow de pre-análise e seleção de características, classificação e avaliação da performance dos diferentes classificadores, no programa Orange3.

Indicadores de performance utilizados

A AUC está associada à curva ROC (Receiver Operating Characteristic) e ambas são ferramentas de medição e comparação do desempenho de modelos de classificação binários. A curva ROC é uma ferramenta estatística em que as curvas são representadas num gráfico bidimensional, com a ordenada a representar a fração de verdadeiros positivos ou sensibilidade e a abcissa a representar a fração de falsos positivos ou 1-especificidade. A especificidade representa a proporção de casos negativos que foram corretamente identificados. A AUC é uma medida de área que facilita a comparação entre curvas ROC, sendo um indicador primário da performance dos classificadores. Quanto maior o AUC, melhor a performance do classificador.¹⁹

A avaliação da performance dos classificadores é realizada através da análise da matriz de confusão, nomeadamente de duas frações, relativas aos verdadeiros negativos (Fração de Verdadeiros Negativos, FVN) e aos falsos negativos (Fração de Falsos Negativos, FFN). No processo de classificação em diagnóstico médico, a FFN e a FFP são importantes devido a serem erros e consequentemente trazerem graves implicações para o indivíduo. Sob esta perspetiva, um falso negativo terá sempre mais impacto que um falso positivo, pois um “doente” ao ser inferido como um falso negativo não será sujeito a qualquer tipo de tratamento o que pode em casos extremos, levar à sua morte. Já um falso positivo não expressa consequências tão graves, pois a longo prazo o paciente terá menos sequelas que um falso negativo, por este necessitar de uma intervenção médica que não lhe foi fornecida.¹⁹ Após a definição dos métodos de PCA e Rank, avaliaram-se a performance de 4 modelos de classificação: kNN, SVM, Random Forest e Neural Network. Para a análise da matriz de confusão, centramo-nos em 3 parâmetros: a sensibilidade (taxa de verdadeiros positivos), a especificidade (taxa de verdadeiros negativos) e precisão (valor preditivo positivo). Os cálculos a efetuar estão exemplificados na figura seguinte:

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Negative Predictive Value $\frac{TN}{(TN + FN)}$	Accuracy $\frac{TP + TN}{(TP + TN + FP + FN)}$

Figura 7 - Cálculo da Precisão, Sensibilidade e Especificidade através da matrix de confusão.
(Fonte: <https://hengapher.medium.com>)

Resultados e Discussão

Este artigo desenvolveu um classificador de detecção de patologia para radiografias do tórax, da base-de-dados pública ChestXray14, com o objetivo de realçar o papel crucial que a compreensão das técnicas de radiomics e IA na profissão do técnico de radiologista.

Foram analisadas 1662 radiografias (50% com patologia) ao tórax, tendo sido aplicadas duas estratégias para seleção de 5 características radiomics: (i) análise de componentes principais (PCA) e (ii) “information gain ratio” (Rank), utilizando o software Orange.

Os resultados obtidos pelo conjunto de características extraídas pelo método PCA encontram-se resumidos na tabela 1 e figura 8.

Tabela 1 – Resultados obtidos de AUC, Precisão, Sensibilidade e Especificidade em PCA

MODEL	AUC	PRECISÃO	SENSIBILIDADE	ESPECIFICIDADE
A) KNN	0,781	69,2 %	77,3 %	66,6 %
B) RANDOM FOREST	0,976	91,2 %	95,2 %	91 %
C) SVM	0,897	85,7 %	70 %	88,7 %
D) NEURAL NETWORK	0,987	93 %	97,8 %	92,9 %

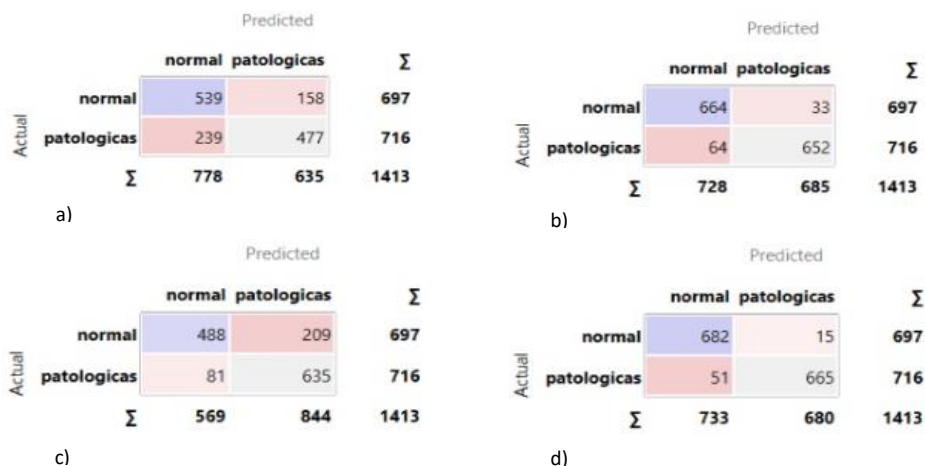


Figura 8 – Matrizes de confusão obtidas na análise PCA: a) kNN; b) Random Forest; c) SVM. D) Neural Network

Avaliando as matrizes de confusão obtidas dos classificadores no método PCA, verificamos que o Neural Network apresenta maior sensibilidade, sendo capaz de identificar verdadeiros positivos em 97,8% dos casos, e uma especificidade elevada, em que 93% das classificações são verdadeiros negativos, traduzindo-se numa precisão, de 92,9%, e numa maior AUC, de 0,987. Já o KNN é o pior classificador apresentando uma precisão mais baixa, de 69,2%, com sensibilidade de 77,3% e especificidade de 66,6%, e uma AUC de 0,781.

Tabela 10 - Resultados obtidos de AUC, Precisão, Sensibilidade e Especificidade em Rank

MODEL	AUC	PRECISÃO	SENSIBILIDADE	ESPECIFICIDADE
A) KNN	0,932	85,7 %	93,5 %	84,8 %
B) RANDOM FOREST	0,967	90 %	95,3 %	89,8 %
C) SVM	0,727	54,8 %	16,4 %	86,9 %
D) NEURAL NETWORK	0,972	89,5 %	98,7 %	88,7 %

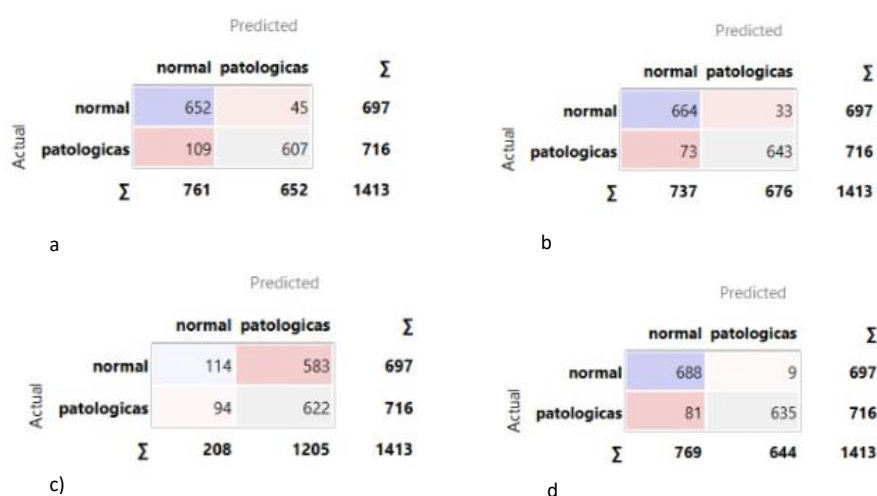


Figura 11 - Matrizes de confusão obtidas na análise Rank: a) kNN; b) Random Forest; c) SVM. d) Neural Network

Avaliando as matrizes de confusão obtidas dos classificadores no método Rank, verificamos que o Neural Network apresenta uma maior sensibilidade, sendo capaz de identificar verdadeiros positivos em 98,7% dos casos, e uma especificidade elevada, em que 88,7% das classificações são verdadeiros negativos, traduzindo-se numa precisão de 89,5%, com uma AUC de 0,972. Já o SVM é o pior classificador, apresentando uma precisão mais baixa, de 54,8%, com sensibilidade de 16,4% e especificidade de 86,9%, com uma AUC de 0,727.

Comparando os classificadores nos dois métodos, verificamos que o Neural Network tem melhor comportamento no método PCA. O classificador Random Forest tem valores de classificações semelhantes em ambos os métodos. O KNN apresenta melhor comportamento no método Rank, enquanto o SVM obtém melhores resultados no método PCA.

Verifica-se assim que com o método PCA, com redução para 5 componentes e 73% de variância explicada, o melhor classificador foi o *Neural Network*, com 0,987 de *Area Under the Curve* (AUC). No método Rank também o *Neural Network* foi o melhor classificador com 0,972 AUC, na qual se verificou uma sensibilidade de 97,8%, especificidade de 92,9% e precisão de 93%. Os resultados obtidos vão em linha com o observado na literatura, na qual a utilização de características *radiomics* para a classificação de radiografias de tórax tem mostrado resultados promissores.

Na ótica do técnico de radiologia, é importante compreender que o potencial destas técnicas de processamento de exames radiológicos vão para além da radiografia do tórax. Como exemplo, verificamos aplicações a nível da RM cardíaca, onde Avendi *et al.* (2017) propuseram uma abordagem combinada de IA e um modelo deformável para a segmentação automatizada do ventrículo esquerdo, aplicações a nível da redução de dose em TC. Hwang *et al.* (2020) desenvolveram um método para a deteção e segmentação de nódulos pulmonares em exames de TC de baixa dose, enquanto Sharma *et al.* (2018) e Yao *et al.* (2019) discutiram este conceito a partir da radiografia do tórax. Por outro lado, Zhang *et al.* (2019) propuseram uma abordagem por redes neurais 3D para a classificação de imagens histopatológicas de cancro do pulmão, aliando o conceito de *radiomics* aos classificadores por redes neuronais como um conceito multidisciplinar e agregador de diferentes áreas médicas.

É importante referir que os métodos de IA são tão bons quanto a qualidade dos dados utilizados para treinar, ou como referenciado pelos cientistas de dados e engenheiros informáticos, o desempenho e validade dos métodos IA seguem o princípio “garbage in”, “garbage out”.²⁰ Assim é necessário reconhecer os desafios associados à implementação de estratégias de *radiomics* e IA na profissão de Técnicos de Radiologia, já que, em última instância será sobre o produto do nosso trabalho que estas metodologias se vão basear. É necessário abordar questões como a qualidade dos dados, a normalização, as preocupações com a privacidade e considerações éticas.

Tendo por base as preocupações referidas, Malamateniou *et al.*, 2021, apresentam algumas prioridades para a o desenvolvimento do técnico de radiologia nestas áreas, bem como integração orgânica da IA no ecossistema da Radiologia, nomeadamente:

1. Validação robusta das atuais ferramentas de IA em dados reais ainda não testados;
2. Estudos de investigação interdisciplinares mais prospetivos no domínio da Radiologia;
3. Regulamentação mais abrangente e amplamente aceite nos produtos AI para salvaguardar a sua utilização segura e eficaz;
4. Maior participação dos utilizadores dos serviços, incluindo os profissionais de saúde, doentes e respetivos prestadores de cuidados, na conceção e aplicação de ferramentas IA;
5. Esforços concertados com a indústria para encontrar soluções de IA explicáveis, a fim de permitir uma melhor compreensão e adoção para profissionais de saúde, bem como os utilizadores dos serviços;
6. Definição da responsabilização e de direito médico no caso de resultados erróneos resultantes da utilização de software e hardware baseado em IA;
7. Maior transparência nos processos de decisão para aumentar a confiança e ganhar aceitabilidade dos doentes;
8. Definição de competências profissionais claras e estratégias de desenvolvimento da extensão de funções para os profissionais de saúde, incluindo os técnicos de radiologia, num futuro em que a IA será fundamental.

As soluções de IA que proporcionam uma automatização semelhante da tomada de decisões para as tarefas radiográficas não são diferentes dos dispositivos radiológicos, na medida em que requerem provas clínicas e a aceitação e supervisão dos técnicos de radiologia antes de poderem ser amplamente implementadas. No entanto, um fator diferenciador fundamental é que os novos sistemas de IA têm o potencial de automatizar uma gama mais vasta de tarefas cognitivas de nível superior e, por conseguinte, pode argumentar-se que deve ser exigida uma maior diligência e provas antes da sua adoção.²¹

O estudo piloto que levou ao desenvolvimento deste artigo demonstra que é possível, através de processos educativos adequados (tanto a nível de pós-graduação, mestrado ou doutoramento), que os profissionais de saúde possam desenvolver, e mais importante, compreender, todo o processo metodológico que leva às soluções IA que utilizamos já hoje nos serviços de Radiologia. É importante, conforme referido por Hardy, M., (2020), compreender que os técnicos de radiologia terão um papel cada vez mais importante na realização de auditoria e revisões regulares dos resultados e decisões de um sistema de avaliação de radiografias por IA. É provável a necessidade de um sistema “peer-review” ou de verificação pós-decisão dos sistemas automáticos baseados em IA, com o objetivo de estabelecer a sensibilidade, especificidade e

exatidão do sistema, e são os técnicos de radiologia que devem aproveitar esta oportunidade para se apropriarem do processo e, talvez no futuro, estabelecerem sistemas de revisão e auditorias de IA na análise de exames radiológicos.

Conclusão

É essencial que os técnicos de radiologia possuam conhecimentos avançados sobre o funcionamento e a funcionalidade dos sistemas de IA, a fim de liderar e aproveitar as oportunidades proporcionadas por essa tecnologia. A necessidade de programas de formação e desenvolvimento profissional contínuo para apoiar a evolução dos técnicos de radiologia e sua adaptação aos novos serviços baseados em IA é de extrema importância e não pode ser negligenciada. A capacidade de aproveitar todo o potencial da IA na prática radiológica requer uma força de trabalho qualificada e capacitada.

No estudo piloto realizado neste artigo, propusemos o desenvolvimento de uma metodologia de extração de características técnicas de *radiomics* e de classificação por métodos IA com base nos dados da ChestX-ray14, onde foram selecionadas 831 imagens patológicas e 813 imagens sem evidências de patologia. Dos diferentes métodos utilizados, verificou-se que o classificador Neural Network através do método PCA, apresentou uma precisão de 93%, com uma sensibilidade de 97,8% e uma especificidade de 92,9%.

Com base nestes resultados e na discussão associada ao papel do Técnico de Radiologia propomos como estudos futuros a aplicações destas metodologias na avaliação da qualidade técnica das radiografias presentes nas bases-de-dados públicas, mas também procurando desenvolver estratégias de integração destas tecnologias no dia-a-dia dos serviços de radiologia.

Referências

1. Willemink, M. J., Persson, M., Pourmorteza, A., Pelc, N. J., & Fleischmann, D. Automatic exposure control in CT: The effect of patient size, anatomical region, and clinical task on tube current modulation. *Medical Physics*. 2020. 47(2), 643-658.
2. Shiraishi, J., & Katsuragawa, S. Radiomics in medical imaging. *Journal of Medical Imaging*. 2018. 5(1), 011005.
3. Krishnaraj, A., Conover, D. L., & Do, S. (2021). Physician extenders in radiology: Current roles and future directions. *Journal of the American College of Radiology*, 18(1 Pt B), 162-166.
4. Rehani, M. M. Need for speed in radiology: Why it matters. *Journal of Medical Imaging and Radiation Sciences*. 2017. 48(2), 125-126.
5. Kvak D, Chromcová A, Biroš M, Hrubý R, Kvaková K, Pajdaković M, Ovesná P. Chest X-ray Abnormality Detection by Using Artificial Intelligence: A Single-Site Retrospective Study of Deep Learning Model Performance. *BioMedInformatics*. 2023; 3(1):82-101. <https://doi.org/10.3390/biomedinformatics3010006>
6. Lambin P, Leijenaar RTH, Deist TM, et al. Radiomics: the bridge between medical imaging and personalized medicine. *Nat Rev Clin Oncol*. 2017;14(12):749-762. doi:10.1038/nrclinonc.2017.141
7. van Leeuwen KG, de Rooij M, Schalekamp S, van Ginneken B, Rutten MJCM. How does artificial intelligence in radiology improve efficiency and health outcomes?. *Pediatr Radiol*. 2022;52(11):2087-2093. doi:10.1007/s00247-021-05114-8
8. Ehteshami Bejnordi B, Veta M, Johannes van Diest P, et al. Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. *JAMA*. 2017;318(22):2199-2210. doi:10.1001/jama.2017.14585
9. Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60-88. doi:10.1016/j.media.2017.07.005

10. Dyer T, Dillard L, Harrison M, et al. Diagnosis of normal chest radiographs using an autonomous deep-learning algorithm. *Clin Radiol.* 2021;76(6):473.e9-473.e15. doi:10.1016/j.crad.2021.01.015
11. Chen B, Zhang R, Gan Y, Yang L, Li W. Development and clinical application of radiomics in lung cancer. *Radiat Oncol.* 2017;12(1):154. Published 2017 Sep 15. doi:10.1186/s13014-017-0885-x
12. Homepage/Website: Kaggle.com [consultado 2022, 8 Nov]. Disponível em: <https://paperswithcode.com/dataset/chestx-ray14>
13. Homepage/Website: Radiopaedia.org [consultado em 2023, 29 Jan]. Radswiki T, Niknejad M, Suyama D, et al. Cardiomegaly. Reference article, Disponível em: <https://doi.org/10.53347/rID-12661>
14. Zwanenburg A, Leger S, Vallières M, Löck S. Image biomarker standardisation initiative. 2016. *ArXiv:1612.07003*. <http://dx.doi.org/10.1148/radiol.2020191145>
15. Novikov AA, Lenis D, Major D. Fully Convolutional Architectures for Multi-Class Segmentation in Chest Radiographs. *ArXiv*.2018;1–13. <https://doi.org/10.48550/arXiv.1701.08816>
16. Prevedello LM, Halabi SS, Shih G, Wu CC, Kohli MD, Chokshi FH, et al. Challenges Related to Artificial Intelligence Research in Medical Imaging and the Importance of Image Analysis Competitions. *Radiol Artif Intell.* 2019;1(1):e180031.
17. Mladenic, D., Brank, J., Grobelnik, M., & Milic-Frayling, N. Feature selection using linear classifier weights. *SIGIR'04*.2004. <https://doi.org/10.1145/1008992.1009034>
18. Müller, A., & Guido, S. Introduction to Machine Learning with Python: A Guide for Data Scientists. *O'Reilly Media*.2016. ISBN 9352134575, 9789352134571, <http://cds.cern.ch/record/2229831>
19. Quintas J, Análise através da curva ROC: que ferramentas utilizar?. Dissertação de Mestrado em Bioinformática. Repositorium.sdum.uminho, 2020
20. Malamateniou, C., Knapp, K. M., Pergola, M., Hardy, M., & Hardy, M. A. Artificial intelligence in radiography: Where are we now and what does the future hold? *Radiography.* 2021. 27, S58–S62. <https://doi.org/10.1016/j.radi.2021.07.015>
21. Hardy, M., & Harvey, H. Artificial intelligence in diagnostic imaging: impact on the radiography profession. *British Journal of Radiology.* 2020. 93(1108), 20190840. <https://doi.org/10.1259/bjr.20190840>
22. Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In *Proceedings of the IEEE conference on computer vision and pattern recognition* 2017. (pp. 2097-2106).
23. Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Langlotz, C. CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning. *arXiv preprint arXiv*. 2017.1711.05225.
24. Yao, L., Zhang, C., Zhang, H., Chen, X., Zhou, H., & Zhang, D. A deep learning system for COVID-19 diagnosis from chest CT using weak label. *Medical Image Analysis*.2020. 67, 101851.
25. Avendi, M. R., Kheradvar, A., & Jafarkhani, H. A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI. *Medical Image Analysis*, 2017. 30, 108-119.
26. Hwang, E. J., Park, S., Jin, K. N., Kim, J. I., Choi, S. H., & Kim, S. T. Deep learning-based fully automated detection and segmentation of pulmonary nodules on ultralow-dose CT: Retrospective cohort study. *Medical Imaging*.2020. 7(2), e15991.
27. Sharma, A., Mazurowski, M. A., & Poplin, R. Deep learning in chest radiography: An overview. *Journal of Medical Imaging.* 2018. 5(3), 031303.
28. Zhang, Q., Wang, J., Wu, F., & Tang, L. Deep learning-based classification of lung cancer histopathology images using 3D convolutional neural networks. *Computers in Biology and Medicine.* 2019. 109, 157-166.

29. Malamateniou, C., Knapp, K. M., Pergola, M., Hardy, M., & Hardy, M. A. Artificial intelligence in radiography: Where are we now and what does the future hold? *Radiography*. 2021. 27, S58–S62. <https://doi.org/10.1016/j.radi.2021.07.015>
30. Park SH, Han K. Methodologic Guide for Evaluating Clinical Performance and Effect of Artificial Intelligence Technology for Medical Diagnosis and Prediction. *Radiology*. 2018;286(3):800-809. doi:10.1148/radiol.2017171920
31. Lu, L., Pu, J., Zhang, S., & Li, H. Radiomics in chest imaging: Techniques and clinical applications. *European Journal of Radiology*, 2020. 127, 108996.

Anexo 2

ECR 2024 / C-13499

Deep Learning-Based Detection and Segmentation of the Overlap Between the Lung and the Scapula in Chest X-ray Imaging

Congress:

ECR 2024

Poster Number:

C-13499

Type:

Scientific Exhibit

Keywords:

Artificial Intelligence, Radiographers, Thorax, Conventional radiography, Computer Applications-Detection, diagnosis, Education and training, Quality assurance

Authors:

R. S. T. Ribeiro, I. Moura

DOI:

10.26044/ecr2024/C-13499

DOI-Link:

<https://dx.doi.org/10.26044/ecr2024/C-13499>

Purpose

In chest radiographs, correct scapula positioning is essential. Overlapping with lungs can hide crucial details (Cheng & Stern, 2002), potentially misleading novice clinicians and radiography students. Ensuring clear imaging technique is key for accurate lung anomaly detection. Leveraging AI's capabilities, this project aims to develop a model to detect and segment the scapula-lung overlap in frontal chest X-rays.

[Read more](#)

Methods and materials

Using the NIH chest X-ray public dataset (Wang et al., 2017), the 28,868 unique patients with frontal chest x-ray images were pre-processed via centre cropping and resizing to 244x244. Secondly, a pre-trained PSPNet model from torchxrayvision python library (Cohen et al., 2021) was used to segment the principal anatomic structures identified in a chest x-ray frontal exam. If the scapulas were detected, the next step was to identify the presence of overlap and if present calculate the overlapping percentage of scapula in the lungs, for...

[Read more](#)

Results

The algorithm detected the scapula in 99.8% (28,810) of exams, with 40% (11,547) showing scapula overlay. From the analysis of the possible causes for the algorithm's failure to detect the scapula, we identified four categories of x-ray images: paediatric exams (n=25); chest lateral view (n=21); and rotated image (n=7); abdomen exams (n=2), as exemplified by fig. [Fig 2]. These findings suggest from that the chest x-ray quality assessment was not correctly performed before the dataset is made available for AI studies, which aligns with (Pham...

[Read more](#)

Conclusion

The developed algorithm effectively detects scapula overlap in X-rays, making it valuable for educational and quality assessment tools. Overlap, often minimal, suggests crucial patient positioning technique consistency. A limitation of this study was the lack of information regarding PA vs AP positioning due to the dataset's information limitations.

[Read more](#)

Personal information and conflict of interest

R. S. T. Ribeiro: Nothing to disclose I. Moura: Nothing to disclose

[Read more](#)

References

Cheng, S. G., & Stern, E. J. (2002). That darn scapula: A common pitfall in interpreting the chest radiograph. *Respiratory Care*, 47(8), 910–914. Cohen, J. P., Viviano, J. D., Bertin, P., Morrison, P., Torabian, P., Guarrera, M., Lungren, M. P., Chaudhari, A., Brooks, R., Hashir, M., & Bertrand, H. (2021). TorchXRyVision: A library of chest X-ray datasets and models (arXiv:2111.00595). arXiv. <https://doi.org/10.48550/arXiv.2111.00595> Joo, Y. C., Lim, C. H., Lee, H. S., Lim, W. T., Kim, H. J., & You, H. R. J. and I. G. (2016). Comparison...

[Read more](#)




Fig 1: Methodological design




Fig 2: Examples of x-ray images based on the analysis of algorithmic failures in...




Fig 3: Distributions of the detected scapula percentage overlapped in the right and...




Fig 4: Right and left side correlation analysis