



Análise Automática de Imagens Pulmonares de Tomografia Computorizada

Susana Augusta Cardoso Leal Lopes

Mestrado em Engenharia Matemática

Departamento de Matemática

2017


Orientador

André R.S. Marçal

Professor Auxiliar

Departamento de Matemática

Faculdade de Ciências da Universidade Do Porto





Todas as correções determinadas pelo júri, e só essas, foram efetuadas.

O Presidente do Júri,

Porto, ____ / ____ / ____



Agradecimentos

Ao longo de todo o processo desenvolvido nesta dissertação de mestrado, pude contar com o apoio de várias pessoas que contribuíram para que o sucesso fosse alcançado. Quero agradecer ao Professor André Marçal, orientador desta dissertação, por ter aceite este desafio e por toda a dedicação e auxílio prestado ao longo de todo o projeto. Por ter estado sempre disponível a colaborar, dando sugestões para que o projeto fosse, acima de tudo, um crescimento enquanto pessoa e profissional. Não posso deixar de enaltecer o seu lado humano pois, num ano em que os condicionalismos surgiram em catadupa, o Professor fez-me acreditar que era possível.

Aproveito para agradecer a todos os docentes do Mestrado em Engenharia Matemática, da Faculdade de Ciências da Universidade do Porto, que me acompanharam durante estes dois anos de curso, por todo o conhecimento e inspiração que me transmitiram. Gostaria também de agradecer aos meus colegas de curso pelo apoio e força que me transmitiram para concluir esta nova fase com sucesso.

Para finalizar, gostaria de agradecer à minha família, em especial à minha mãe, e aos meus amigos por toda a motivação e apoio que me deram ao longo deste ano de trabalho, incentivando para que fizesse sempre o melhor.

Obrigada a todos pelo apoio,
Susana Cardoso

Resumo

O diagnóstico de tuberculose e de outras doenças pulmonares pode ser difícil, pois há enfermidades com sintomas semelhantes. Portanto, a detecção precoce de nódulos pulmonares é a maneira mais eficiente de identificar as patologias e salvar a vida dos pacientes. As quatro componentes principais do processo de identificação de nódulos são a segmentação pulmonar, a identificação de nódulos candidatos, a classificação e a visualização.

Nesta dissertação é exaltada a importância do passo primordial do processo de identificação: a segmentação. A segmentação das regiões pulmonares a partir do tórax, que constitui a região de interesse (*region of interest*, ROI), é um passo fundamental para a maioria dos sistemas de detecção assistida por computador (*computer aided detection*, CAD) para doenças pulmonares. A tomografia computadorizada (TC) é a técnica de imagem mais comum usada por estes sistemas, sendo necessários métodos rápidos e precisos para permitir uma análise precoce e confiável.

Neste projeto é apresentado um método eficiente e automático para a segmentação e cálculo dos volumes pulmonares em imagens de um conjunto de dados de TC. Este método trata da segmentação inicial do sistema respiratório em que a região pulmonar é extraída das imagens de TC, por aplicação de uma versão modificada do *Thresholding* Global. De seguida extrai os dois maiores objetos da ROI, o pulmão esquerdo e o pulmão direito, calcula os volumes pulmonares e compara com as máscaras fornecidas no conjunto de dados. Além disso, expõem-se uma gama de estruturas anatómicas, incluindo a região pulmonar e os nódulos segmentados, juntamente com os contornos e a projeção das intensidades máximas da ROI.

Desta forma, abre-se a porta para trabalhos futuros, pois uma boa segmentação pulmonar permitirá uma eficiente identificação e classificação de nódulos que são, na grande maioria das vezes, difíceis de reconhecer a partir de imagens de TC.

Palavras chave: tomografia computadorizada, região de interesse, segmentação pulmonar, thresholding, operadores morfológicos, detetor de contornos, CLEF2017

Abstract

The diagnosis of tuberculosis and other lung diseases can be difficult because there are diseases with similar symptoms. Therefore, early detection of pulmonary nodules is the most efficient way to identify pathologies and save patients' lives. The four major components of the nodule identification process are pulmonary segmentation, candidate identification, classification, and visualization.

In this dissertation, the importance of the primordial step of the identification process is highlighted: segmentation. Segmentation of the lung regions from the chest region of interest (ROI) is a critical step in computer aided detection (CAD) systems for lung diseases. The most frequently used technique is computed tomography, which requires fast and accurate methods to allow early and reliable analysis

This project presents an efficient and automatic method for the segmentation and calculation of pulmonary volumes in images of a set of CT data. This method deals with the initial segmentation of the respiratory system in which the lung region is extracted from the CT images, by applying a modified version of Global Thresholding. It then extracts the two largest objects from the ROI, the left lung and the right lung. Calculates lung volumes and compares with the masks provided in the data set. Furthermore, a range of anatomical structures, including the pulmonary region and segmented nodules, are exposed along with the contours and projection of maximal ROI intensities.

In this way, the door is opened for future work, because good pulmonary segmentation will allow an efficient identification and classification of nodules that are, in most cases, difficult to recognize from CT images.

Key words: computed tomography, region of interest, pulmonary segmentation, thresholding, morphological operators, contour detector, CLEF2017

Índice

1. Introdução	1
2. Análise automática de imagens de TC	3
2.1. Concurso ImageCLEF	3
2.2. Conjunto de dados	4
2.3. Técnicas de processamento de imagens	6
2.3.1. Histograma de uma imagem	7
2.3.2. <i>Thresholding</i> Global	8
2.3.3. Operadores morfológicos	10
2.3.4. Identificação de objetos	14
2.3.5. Detecção de contornos	14
2.4. Métodos de análise de imagens pulmonares	17
3. Metodologia	29
3.1. Dados de teste	29
3.2. Segmentação pulmonar	33
3.3. Cálculo de volume pulmonar	39
4. Resultados	41
4.1. Avaliação da segmentação pulmonar	41
4.2. Volume pulmonar	47
5. Conclusão	51
6. Bibliografia	53

Índice de Figuras

Figura 1 – Exemplo de imagens com histogramas diferenciados	7
Figura 2 – Exemplo de imagens com histogramas bimodal e multimodal	8
Figura 3 – Exemplo de um processo de <i>Thresholding</i> Global	9
Figura 4 – Exemplo de um esquema de dilatação numa imagem binária com um objeto retangular	11
Figura 5 – Exemplo de um esquema de erosão numa imagem binária com um objeto retangular	12
Figura 6 – Exemplo de um esquema de abertura (erosão seguida de dilatação) de uma imagem binária, usando como elemento estruturante um quadrado	13
Figura 7 – Exemplo de um esquema de fecho (dilatação seguida de erosão) de uma imagem binária, usando como elemento estruturante um quadrado	14
Figura 8 – Máscaras usadas no operador <i>Roberts</i>	15
Figura 9 – Máscaras usadas no operador <i>Sobel</i>	15
Figura 10 – Máscaras usadas no operador <i>Prewitt</i>	16
Figura 11 – Máscaras do operador <i>Sobel</i> usadas no operador <i>Canny</i>	16
Figura 12 - Projção da intensidade máxima de nódulos pulmonares de diferentes tamanhos	19
Figura 13 – Exemplo de um diagrama de etapas do método CAD	20
Figura 14 – Exemplos das máscaras que são geradas e usadas durante o processo de segmentação pulmonar	20
Figura 15 – Exemplo de diagrama do processo de segmentação pulmonar	22
Figura 16 – Visões tridimensionais das isosuperfícies correspondentes a um nódulo justavascular segmentado	23
Figura 17 – Exemplo de um método de segmentação pulmonar	25
Figura 18 – Histograma de uma imagem de TC do pulmão	25
Figura 19 – Resultados de uma segmentação	28
Figura 20 – Exemplo de metadados de um conjunto de dados de TC	30
Figura 21 – Exemplo de visualização de vários cortes num conjunto de dados de TC	31

Figura 22 – Exemplo da visualização da normalização de uma imagem de um conjunto de dados de TC	32
Figura 23 – Exemplo da visualização de vários cortes num conjunto de dados de TC normalizada	32
Figura 24 – Exemplo de um <i>Thresholding</i> Global	33
Figura 25 - Histograma da imagem de um corte do conjunto de dados de TC normalizada, sem os pixels do fundo	33
Figura 26 – Exemplo da binarização por aplicação da versão modificada do <i>Thresholding</i> Global	34
Figura 27 – Exemplo de aplicação do operador dilatação a uma imagem de um corte do conjunto de dados de TC binária	35
Figura 28 – Exemplo de aplicação do operador erosão a uma imagem de um corte do conjunto de dados de TC binária	35
Figura 29 – Exemplo de aplicação do operador abertura a uma imagem de um corte do conjunto de dados de TC binária	36
Figura 30 – Exemplo de aplicação do operador fecho a uma imagem de um corte do conjunto de dados de TC binária	37
Figura 31 – Exemplo da extração dos dois objetos principais da ROI de uma imagem de um corte do conjunto de dados de TC	38
Figura 32 – Exemplo de aplicação de diferentes operadores de deteção de contornos a uma imagem de um corte do conjunto de dados de TC binária	38
Figura 33 – Representação esquemática de uma imagem de TC constituída por várias secções transversais da zona torácica	39
Figura 34 – Exemplo de imagens de cortes do conjunto de dados de TC usados para estimar os volumes	40
Figura 35 – Esquema de segmentação de uma imagem do conjunto de dados TC, MDR_007	42
Figura 36 – Esquema de segmentação de uma imagem do conjunto de dados TC. MDR_004	43
Figura 37 – Contornos peculiares na imagem MDR_004	44
Figura 38 – Esquema de segmentação de uma imagem do conjunto de dados TC, TBT_443	45
Figura 39 - Esquema de segmentação de uma imagem do conjunto de dados TC, TBT_441	46
Figura 40 – Contornos peculiares na imagem TBT_441	46

Índice de Tabelas

Tabela 1 – Conjunto de dados para a sub tarefa MDR	5
Tabela 2 – Conjunto de dados para a sub tarefa Tipo TB	5
Tabela 3 – Amostra do conjunto de dados de TC	29
Tabela 4 – Volumes pulmonares de imagens do conjunto de dados TC da tarefa MDR	48
Tabela 5 – Percentagens de erro relativo no cálculo dos volumes pulmonares em imagens do conjunto de dados TC da tarefa MDR	48
Tabela 6 – Volumes pulmonares de imagens do conjunto de dados TC da tarefa Tipo TB	49
Tabela 7 – Percentagens de erro relativo no cálculo dos volumes pulmonares em imagens do conjunto de dados TC da tarefa Tipo TB	50
Tabela 8 – Percentagens de erro relativo no cálculo dos volumes pulmonares em imagens do conjunto de dados TC da tarefa Tipo TB, sem o caso particular TBT_441	50

Lista de Acrónimos

ROI – *Region Of Interest* (Região de Interesse)

CAD – *Computer Aided Detection* (Detecção Assistida por Computador)

TC – Tomografia Computorizada

CLEF – *Conference and Labs of the Evaluation Forum*

DS – *Drug sensitive* (Sensível a Medicamentos)

MDR – *Multi-Drug Resistant* (Multirresistente a Medicamentos)

HU – *Hounsfield Unit* (unidade *Hounsfield*)

FP – Falsos Positivos

SVM – *Support Vector Machine* (Máquina de Vetores de Suporte)

LIDC – *Lung Image Database Consortium*

GLCM – *Gray-Level Co-Occurrence Matrix* (Matriz de Co-ocorrência de Intensidades de Cinzento)

GLRLM – *Gray Level Run Length Matrix*

PET – *Positron Emission Tomography* (Tomografia por Emissão de Positrões)

SRG – *Seeded Region Growing* (Crescimento da Região Semeada)

1. Introdução

A tomografia computadorizada (TC) do tórax é amplamente utilizada para avaliar numerosas doenças pulmonares, incluindo nódulos pulmonares, enfisema e tuberculose pulmonar, entre outras patologias do pulmão (Skoura E. et al., 2014). A disponibilidade de scanners TC *multidetector-row* aumentou ainda mais o papel da TC na avaliação diagnóstica de pacientes. Essas recolhas de dados, no entanto, produzem uma grande quantidade de dados de imagem. O crescente volume de estudos de TC torácica e o aumento substancial de dados de imagem que esses estudos geraram levaram muitos investigadores a desenvolver métodos de diagnóstico por computador (CAD) para auxiliar os radiologistas na avaliação de imagens de TC. Para fornecer informações úteis e confiáveis, a maioria desses métodos CAD requer a identificação dos limites pulmonares dentro das imagens, um passo de pré-processamento conhecido como segmentação pulmonar.

As condições para a segmentação pulmonar são duas. Em primeiro lugar, as patologias que continuam a motivar o desenvolvimento de esquemas CAD para TC torácica estão predominantemente localizadas dentro ou afetam os pulmões. Conseqüentemente, esses esquemas são projetados para visualizar as regiões pulmonares em imagens TC. Além disso, limitar espacialmente o processamento para os pulmões reduz muito o tempo de computação, porque os pulmões ocupam uma fração do volume total de dados adquiridos durante uma tomografia computadorizada. Em segundo lugar, a segmentação pulmonar deve ser precisa, pois anormalidades como os nódulos pulmonares podem existir na periferia extrema dos pulmões. Se o pulmão inteiro não estiver segmentado, tais anormalidades serão perdidas para análises subsequentes. Além disso, a avaliação quantitativa do volume pulmonar para a avaliação da tuberculose pulmonar, por exemplo, será comprometida por uma segmentação pulmonar desajustada.

A segmentação pulmonar, como etapa do processo de análise automática de imagens, é o principal foco deste projeto e o grande objetivo é avaliar a segmentação pulmonar desenvolvida neste trabalho em comparação com máscaras de referência disponíveis no conjunto de dados de apoio ao concurso CLEF2017 (Conference and Labs of the Evaluation Forum, <http://www.imageclef.org/2017/tuberculosis>). Uma vez que o volume pulmonar é afetado por uma boa ou má segmentação pulmonar, também

será feita uma avaliação quantitativa do volume pulmonar, entre o volume da imagem segmentada e o da máscara fornecida.

A presente dissertação está dividida em cinco capítulos, sendo que neste primeiro são apresentados os objetivos deste projeto e uma contextualização para esta escolha.

No segundo capítulo é apresentado o concurso CLEF2017 que impulsionou este trabalho, são descritas as tarefas promovidas por este concurso e é exposto o conjunto de dados disponibilizados e usados nesta dissertação. Também é descrito neste capítulo as principais técnicas de processamento de imagens e, para terminar, é dado a conhecer o estado da arte, onde são explorados os diferentes métodos de análise de imagens pulmonares.

A metodologia adotada é descrita no terceiro capítulo, onde são apresentados os métodos, as tarefas de processamento da imagem relevantes para a tarefa de segmentação dos pulmões em imagens de TC. É ainda explicado o cálculo do volume pulmonar na última parte deste capítulo.

No quarto capítulo são apresentados os resultados sobre o volume pulmonar e a análise dos erros entre os volumes pulmonares das imagens segmentadas e das máscaras fornecidas. Com base nestes valores, é feita uma avaliação da segmentação, com a exposição de casos práticos, quer para imagens segmentadas quer para as máscaras.

No quinto capítulo são feitas as considerações finais, assim como as conclusões desta dissertação e perspectivas futuras.

2. Análise automática de imagens de TC

Os investigadores da área da Análise e Processamento de Imagem tentam desenvolver algoritmos computacionais para realizar de forma automática, ou semiautomática, operações e tarefas desenvolvidas pelos (complexos) sistemas de visão dos seres vivos. Os algoritmos de Análise e Processamento de Imagem são de elevado interesse para a sociedade, sendo frequentemente usados, por exemplo, em: medicina, biologia, engenharia e indústria, entre outras áreas.

Desde 2000, a CLEF (Conference and Labs of the Evaluation Forum) desempenhou um papel de liderança na estimulação de pesquisas cuja principal missão é promover a investigação, a inovação e o desenvolvimento de sistemas de acesso à informação (<http://clef2017.clef-initiative.eu/>). Também promoveu o estudo e implementação de metodologias de avaliação adequadas para diversos tipos de tarefas. A conferência CLEF inclui a apresentação de trabalhos de pesquisa e uma série de oficinas que apresentam os resultados dos *benchmarks* de avaliação comparativa baseados em laboratório. Ao longo dos anos, foi construída uma comunidade de pesquisa ampla, forte e multidisciplinar, que abrange as diferentes áreas de especialização necessárias para lidar com a disseminação das atividades desenvolvidas para esta conferência.

A partir de 2010, a CLEF assumiu a forma de um evento independente, constituído por uma conferência, organizada conjuntamente com um conjunto de laboratórios de avaliação (<http://clef2017.clef-initiative.eu/>).

2.1. Conferências ImageCLEF

A ImageCLEF é uma modalidade de avaliação estruturada como parte dos laboratórios da iniciativa CLEF. Esta iniciativa oferece várias tarefas de pesquisa que recebem a participação de equipas em todo o mundo. Para a edição de 2017, uma das tarefas desta proposta foi a identificação/classificação do tipo tuberculose a partir de imagens de TC (ImageCLEFtuberculosis). O objetivo desta é determinar os subtipos de tuberculose e as resistências aos medicamentos, tanto quanto possível automaticamente, a partir da informação de imagem volumétrica (principalmente análise

de textura) e com base em informações clínicas disponíveis, como idade, género, etc. Ser capaz de extrair o tipo de tuberculose e as resistências aos medicamentos com base nos dados da imagem isoladamente podem permitir limitar a lavagem pulmonar e as análises laboratoriais para determinar o tipo de tuberculose e as resistências aos medicamentos. Isso pode levar a decisões mais rápidas sobre a melhor estratégia de tratamento, menor uso de antibióticos e menor impacto no paciente (ImageCLEF a)).

Cerca de 130 anos após a descoberta da tuberculose (*Mycobacterium tuberculosis*), a doença continua a ser uma ameaça persistente e uma das principais causas de morte em todo o mundo (ImageCLEF b)). O pior que pode acontecer a um paciente com tuberculose é o seu organismo tornar-se resistente a dois ou mais medicamentos padrão (ImageCLEF b)). Em contraste com a tuberculose sensível a medicamentos (*drug sensitive*, DS), a sua forma multirresistente a medicamentos (*multi-drug resistant*, MDR) é muito mais difícil e dispendiosa de se recuperar (ImageCLEF b)). Assim, a deteção precoce do estado da resistência a medicamentos é de grande importância para um tratamento eficaz. Os métodos mais utilizados de deteção de resistência a medicamentos são caros ou demoram muito tempo (até vários meses) (ImageCLEF b)). Portanto, há uma necessidade de métodos rápidos e ao mesmo tempo baratos de deteção desta resistência. Uma das abordagens possíveis para esta tarefa é baseada na análise de imagem de Tomografia Computorizada (TC).

Deste modo, dentro da tarefa ImageCLEF foram criadas duas subtarefas (ImageCLEF b)):

- ❖ **Deteção MDR:** o objetivo desta sub tarefa é avaliar a probabilidade de um paciente tuberculoso ter uma tuberculose multirresistente a medicamentos, com base na análise de tomografia computadorizada de tórax.
- ❖ **Deteção do Tipo TB:** o objetivo desta sub tarefa é categorizar automaticamente cada caso de tuberculose num dos cinco tipos seguintes: Infiltrativo, Focal, Tuberculoma, Miliário, Fibro-cavernoso.

2.2. Conjunto de dados

Para as duas subtarefas propostas no ImageCLEFtuberculosis, Deteção MDR, para avaliar a probabilidade de um paciente tuberculoso ter uma tuberculose multirresistente a medicamentos, e Deteção do Tipo TB, para categorizar automaticamente cada caso de tuberculose num dos cinco tipos, foram fornecidas imagens de TC 3D com tamanho de fatia de 512x512 pixels e o número de fatias a variar

entre 50 e 400. Todas as imagens de TC são armazenadas em formato de arquivo NIFTI com extensão de arquivo.nii.gz (g-zipped.nii arquivos). Este formato de arquivo armazena intensidades brutas de voxel, menor ponto tridimensional de uma imagem digital, em unidades Hounsfield (HU), bem como os metadados de imagem correspondentes, como dimensões de imagem, tamanho de voxel em unidades físicas, espessura de fatia, etc. (ImageCLEF b)). Atualmente, existem várias ferramentas disponíveis para ler e escrever arquivos NIFTI. Entre eles, existem funções load_nii e save_nii para a biblioteca Matlab (software usado nesta dissertação) (ImageCLEF b)).

Para a subtarefa **MDR**, o conjunto de dados inclui apenas pacientes HIV-negativos sem reincidências e com uma das duas formas de tuberculose: sensível a medicamentos (*DS*) ou multirresistente a medicamentos (*MDR*) (ImageCLEF b)).

Pacientes	Dados	Teste	Referência
DS	134	67	67
MDR	96	48	48
Total doentes	230	115	115

Tabela 1 – Conjunto de dados para a subtarefa MDR

Para a subtarefa **Tipo TB**, inclui tomografia computadorizada de tórax de pacientes com tuberculose juntamente com o tipo de tuberculose: tipo 1, infiltrativa, tipo 2, focal, tipo 3, tuberculoma, tipo 4, miliar, e tipo 5, fibrocavernosa (ImageCLEF b)).

Pacientes	Dados	Teste	Referência
Tipo 1	140	70	70
Tipo 2	120	60	60
Tipo 3	100	50	50
Tipo 4	80	40	40
Tipo 5	60	30	30
Total doentes	500	250	250

Tabela 2 – Conjunto de dados para a subtarefa Tipo TB

Além disso, para todos os pacientes em ambas as subtarefas, são fornecidas máscaras extraídas automaticamente dos pulmões. Este material pode ser adquirido juntamente com as imagens TC dos pacientes.

Como o foco deste projeto é a segmentação das imagens de TC, fornecidas neste conjunto de dados, um dos objetivos é comparar a imagem obtida pela segmentação com a máscara fornecida no conjunto de dados. Este processo de análise

e processamento de imagem pulmonares de TC será descrito nas próximas secções e baseado na revisão bibliográfica feita ao longo de todo o projeto.

2.3. Técnicas de processamento de imagens

A segmentação é uma das principais técnicas utilizadas para a análise de imagens e tem como objetivo a separação das regiões ou objetos nela representados mediante algumas propriedades de descontinuidade e similaridade. Esta técnica aplicada à prática clínica evita a árdua tarefa do especialista em segmentar as imagens manualmente, podendo concentrar-se apenas no órgão em análise.

A segmentação de imagem consiste em dividir a imagem em regiões (segmentos) que dizem respeito ao mesmo conteúdo e aplicação. Qualquer pixel pertencente à imagem pertence necessária e unicamente a uma dessas partições, não há espaços vazios numa segmentação, daí que a união de todos os segmentos permita a reconstrução da imagem original. Cada segmento tem características específicas, ou seja, todos os pixels que a constituem têm algumas propriedades comuns, que podem estar relacionadas com a tonalidade, cor, textura, etc. Uma aproximação geral em muitos dos métodos de segmentação é agrupar, de alguma forma, os pixels com as mesmas propriedades, isto é, mesma intensidade, cor ou região com textura semelhante. A separação dos pixels relativos a cada objeto, ou região, é uma etapa fundamental para o sucesso do processo de análise da imagem. Embora o ser humano possa facilmente identificar regiões com as mesmas características ou objetos presentes numa imagem, para se realizar a mesma tarefa de forma automática deve-se implementar algoritmos que analisem as características de cada pixel ou da distribuição da população de pixels.

Muitos autores propõem diferentes classificações para os algoritmos de segmentação de imagens de TC. Estes são classificados mediante a técnica usada para criar os segmentos.

2.3.1. Histograma de uma imagem

O histograma de uma imagem digital com k níveis de cinzento é definido por uma função:

$$p(k) = \frac{n_k}{n}$$

onde o argumento k representa os níveis de intensidade de cinzento, n_k representa o número de pixels da imagem com intensidade k e n é o número total de pixels da imagem. De forma simplificada, pode-se afirmar que o histograma de uma imagem representa a contagem dos níveis de cinzento da imagem, podendo informar a distribuição dos pixels dentro dos k níveis possíveis. O histograma pode ser considerado como uma função densidade de probabilidade, obedecendo aos axiomas e teoremas da teoria de probabilidades, isto é, que $\sum_k p(k) = 1$.

O histograma da imagem digital é uma ferramenta bastante útil na etapa de pré-processamento, fornecendo uma visão estatística sobre a distribuição dos pixels, sobre o contraste da imagem e os níveis de iluminação. Na figura 1 são apresentadas duas imagens e os seus histogramas que mostram a diversidade de tonalidades de cinzento, em que a imagem _a) é uma imagem de baixo contraste, enquanto a imagem (b) possui um maior contraste.




Figura 1 – Exemplo de imagens com histogramas diferenciados. (a) Imagem de baixo contraste e o respetivo histograma; (b) Imagem de alto contraste e respetivo histograma (Adaptado de Gonzalez, R. C.; Woods, R. E. (2008))

A figura 2 apresenta outras duas imagens com histogramas de tipos bimodal e multimodal. O histograma bimodal é classificado desta forma devido à presença de dois

picos, ou duas regiões, na escala de intensidades de cinzento, com maior incidência de pixels da imagem. Este é o caso típico de imagens que apresentam objetos e fundo de maneira bem definida, como a imagem da figura 2a). O histograma multimodal apresenta os pixels distribuídos em mais de duas regiões de níveis de cinzento, o que se pode perceber através dos picos no histograma em torno destes valores de intensidade. Este é o caso da imagem da figura 2b), que apresenta três picos bem definidos.




Figura 2 – Exemplo de imagens com histogramas bimodal e multimodal. (a) Imagem com histograma bimodal, com a presença de dois picos bem definidos; (b) Imagem com histograma do tipo multimodal, apresentando mais de duas regiões de concentração dos pixels da imagem (Adaptado de Gonzalez, R. C.; Woods, R. E. (2008))

2.3.2. *Thresholding Global*

A identificação de um objeto de interesse numa imagem, ou de uma ROI no caso das imagens de TC, pode ser vista como um problema de segmentação ou como um problema de classificação binária.

A segmentação envolve a separação de uma imagem em regiões. É usual denominar objetos da imagem os grupos de pixels de interesse e, da mesma forma, a denominação fundo da imagem é utilizada para o grupo de pixels que podem ser desprezados. Essas denominações objeto e fundo possuem uma conotação bastante subjetiva, podendo referir-se a grupos de pixels que formam determinadas regiões na imagem sem que representem um objeto, de modo literal, presente na imagem processada.

A segmentação é considerada, entre todas as etapas do processamento de imagens, a etapa mais crítica do tratamento da informação. É na etapa de segmentação

que são definidas as regiões de interesse para processamento e análise posteriores. Como consequência deste facto, quaisquer erros ou distorções presentes nesta etapa refletem-se nas demais etapas, podendo condicionar a eficiência de todo o processamento. Deve ser ressaltado que não existe um modelo formal para a segmentação de imagens. Este um processo empírico e adaptativo, procurando sempre adequar-se às características particulares de cada tipo de imagem e aos objetivos que se pretendem alcançar. Apesar de existir uma grande diversidade de técnicas de segmentação de imagens, ainda assim existe atualmente, um grande interesse no estudo e desenvolvimento de novas técnicas.

Uma das formas mais simples e mais utilizadas na segmentação de uma imagem digital consiste na partição do histograma em duas ou mais partes, utilizando-se um ou mais valores de corte T_i , nas intensidades – *Thresholding* Global.

O resultado deste processo (segmentação ou classificação) pode ser uma imagem binária onde a cada pixel é atribuído um valor 0 ou 1 conforme ele pertença ao objeto ou ao fundo. Em geral, usa-se apenas um valor de corte T (*threshold*), resultando numa imagem binária, em que é atribuída uma cor ao fundo da imagem e uma cor diferente ao objeto. Se a $f(x, y)$ se aplicar um *Thresholding* Global de valor T , obtém-se $g(x, y)$ da forma:

$$g(x, y) = \begin{cases} 0 & \text{se } f(x, y) < T \\ 1 & \text{se } f(x, y) \geq T \end{cases}$$

Na figura 3 pode-se visualizar um exemplo de segmentação usando a técnica *Thresholding* Global, uma binarização. A imagem (a) é a imagem original em tons de cinzento e a imagem (b) foi segmentada por binarização.




Figura 3 – Exemplo de um processo de *Thresholding* Global. (a) Imagem original em tons de cinzento, (b) Imagem segmentada através de uma binarização. (Adaptado de Gonzalez, R. C.; Woods, R. E. (2008))

O principal problema da técnica de *Thresholding* Global é que se considera apenas a intensidade e não qualquer outra relação entre os pixels. Não há garantia de que os pixels identificados por este processo sejam contíguos. Assim, pode-se facilmente incluir pixels estranhos que não fazem parte da região desejada e pode-se, analogamente, perder pixels isolados dentro da região (especialmente perto dos limites da região).

Deste modo, depois de se obter a imagem binária é habitualmente necessário aplicar processos de simplificação da imagem, como por exemplo:

- ❖ Eliminar objetos pequenos;
- ❖ Eliminar buracos;
- ❖ Fechar linhas;

Os operadores morfológicos são muito utilizados para esta tarefa.

2.3.3. Operadores morfológicos

Nesta etapa os principais defeitos ou imperfeições da segmentação são devidamente corrigidos. Normalmente, estes defeitos da segmentação são corrigidos através de técnicas de morfologia matemática, com a aplicação em sequência de filtros morfológicos que realizam uma análise quantitativa dos pixels da imagem.

A morfologia matemática é o estudo quantificado da forma e estrutura de conjuntos de pontos (no caso de imagens, conjunto de pixels), cujo principal objetivo é revelar a estrutura dos objetos formados pelos pontos através da transformação dos conjuntos que os modelam. Isto é realizado através de operadores morfológicos. A partir desta estreita relação da morfologia matemática com a forma, torna-se natural aplicá-la como técnica de processamento de imagens. A aplicação da morfologia matemática a imagens é definida por um conjunto de operações nas quais se modificam as estruturas espaciais de um objeto numa imagem. Existe um conjunto básico de operações – Erosão, Dilatação, Abertura e Fecho. Nas aplicações mais simples, os operadores morfológicos utilizam-se apenas da imagem em estudo e de um elemento estruturante. O elemento estruturante é formado por determinado conjunto de pixels e é usado para investigar a imagem durante a aplicação do operador morfológico. Caso o elemento estruturante coincida com alguma estrutura da imagem, uma determinada transformação é realizada ou não, dependendo do operador aplicado, ou seja, um elemento estruturante é aplicado bit a bit a uma imagem e o bit resultante é '1' se o elemento for completamente encontrado na imagem ou '0' se não. Logo, a forma e o

tamanho do elemento estruturante devem ser adaptados às propriedades geométricas dos objetos que serão estudados na imagem. Os operadores utilizados no processamento morfológico de imagem formam uma ampla classe de operadores não-lineares. De seguida descreve-se o efeito produzido por cada uma das operações morfológicas.

❖ **Dilatação**

A dilatação é uma transformação morfológica que combina dois conjuntos usando adição vetorial. Esta pode ser vista como a reunião de todas as translações da imagem original pelo vetor e do elemento estruturante. Deste modo, os efeitos da dilatação podem ser: “engordar” objetos; preencher pequenos “buracos” da imagem; conectar pixels próximos. A dilatação é comutativa e associativa.

Seja $f(x, y)$ uma imagem binária onde x é o número de linha e y o número de coluna. O contradomínio de $f(x, y)$ é $\{0,1\}$. Numa imagem binária $f(x, y)$ o objeto é definido como $A = \{(x, y): f(x, y) = 1\}$ e o fundo $\bar{A} = \{(x, y): f(x, y) = 0\}$.

A dilatação de A por E é definida como:

$$A \oplus E = \{(x + i, y + j): (x, y) \in A, (i, j) \in E\}$$

onde A e E são imagens binárias, A é a imagem a ser operada e E é o elemento estruturante e a sua composição define a natureza específica da dilatação, sendo assim a dilatação expande uma imagem. Deste modo, diz-se que a dilatação é o conjunto de todos os deslocamentos tais que E se sobrepõe a A em pelo menos um elemento não nulo. A figura 4 representa um esquema da operação dilatação em imagens binárias.




Figura 4 – Exemplo de um esquema de dilatação numa imagem binária com um objeto retangular (Adaptado de Gonzalez, R. C.; Woods, R. E.; Eddins, S. L. (2004))

❖ **Erosão**

A erosão é uma transformação morfológica que combina dois conjuntos usando vetores de subtração. Esta pode ser vista como a intersecção de todas as translações da imagem original pelo vetor $-e$ do elemento estruturante. Deste modo, os efeitos da

erosão podem ser: eliminar componentes menores que o elemento estruturante; diminuir partículas; aumentar “buracos” da imagem; permitir a separação de componentes de áreas próximos conectados. A erosão não é comutativa nem associativa.

Seja $f(x, y)$ uma imagem binária onde x é o número de linha e y o número de coluna. O contradomínio de $f(x, y)$ é $\{0,1\}$. Numa imagem binária $f(x, y)$ o objeto é definido como $A = \{(x, y): f(x, y) = 1\}$ e o fundo $\bar{A} = \{(x, y): f(x, y) = 0\}$.

A erosão de A por E é definida como:

$$A \ominus E = \{(x - i, y - j): (x, y) \in A, (i, j) \in E\}$$

onde A e E são imagens binárias, A é a imagem a ser operada e E é o elemento estruturante e a sua composição define a natureza específica da erosão, sendo assim a erosão reduz a imagem. Deste modo, diz-se que a erosão é o conjunto de translações de E que alinham E sobre o conjunto de pixels de A . Isso significa que só são consideradas as translações que inicialmente localizam a origem de E num elemento de A . A figura 5 representa um esquema da operação erosão em imagens binárias.




Figura 5 – Exemplo de um esquema de erosão numa imagem binária com um objeto retangular
 (Adaptado de Gonzalez, R. C.; Woods, R. E.; Eddins, S. L. (2004))

Neste momento, já se sabe que a erosão e a dilatação podem corrigir defeitos numa imagem. Entretanto, aplicações alternadas da dilatação e da erosão levam à formação de duas novas operações denominadas abertura e fecho.

❖ **Abertura**

A abertura é uma operação de erosão seguida imediatamente de uma dilatação utilizando o mesmo elemento estruturante. A abertura é uma operação morfológica que geralmente suaviza o contorno de uma imagem, quebra estreitos e elimina proeminências finas, sendo também usada para remover ruídos da imagem (pontos brancos no fundo preto). Deste modo, os efeitos da abertura podem ser: separar componentes; eliminar pequenas partículas; não devolve, de forma geral, o conjunto

inicial; o conjunto aberto é mais regular que o conjunto inicial; o conjunto aberto é menos rico em detalhes que o conjunto inicial.

A abertura de A por E é definida como:

$$A \circ E = (A \ominus E) \oplus E$$

onde A é a imagem a ser operada e E é o elemento estruturante e a sua composição define a natureza específica da abertura.

A figura 6 mostra um esquema da operação abertura em imagens binárias.




Figura 6 – Exemplo de um esquema de abertura (erosão seguida de dilatação) de uma imagem binária, usando como elemento estruturante um quadrado de 3x3. (Adaptado de Gonzalez, R. C.; Woods, R. E.; Eddins, S. L. (2004))

❖ Fecho

O fecho é uma operação de dilatação seguida imediatamente de uma erosão utilizando o mesmo elemento estruturante. O fecho é uma operação morfológica que suaviza as fronteiras pelo exterior pois, geralmente, elimina pequenos buracos e preenche fendas nos contornos. Se uma abertura cria pequenos vazios na imagem, um fecho irá preencher ou fechar os vazios, estas operações podem remover muitos dos pixels brancos com ruído. De uma forma geral, o objetivo deste processo é reestabelecer conexões sem modificar radicalmente o tamanho e a forma dos conjuntos iniciais. Deste modo, os efeitos do fecho podem ser: preencher os “buracos” (no interior do conjunto) inferiores ao tamanho do elemento estruturante; emendar partículas próximas; o conjunto fechado é mais regular e menos rico em detalhes do que o conjunto original.

O fecho de A por E é definida como:

$$A \bullet E = (A \oplus E) \ominus E$$

onde A é a imagem a ser operada e E é o elemento estruturante e a sua composição define a natureza específica do fecho.

A figura 7 mostra um esquema da operação fecho em imagens binárias.




Figura 7 – Exemplo de um esquema de fecho (dilatação seguida de erosão) de uma imagem binária, usando como elemento estruturante um quadrado de 3x3. (Adaptado de Gonzalez, R. C.; Woods, R. E.; Eddins, S. L. (2004))

2.3.4. Identificação de objetos

Esta é a etapa chamada labelização ou rotulação. Após a etapa de segmentação obtém-se uma imagem onde as regiões correspondentes aos objetos estão separadas daquelas correspondentes ao fundo da imagem. Neste ponto do sistema de processamento, as regiões de interesse estão contiguamente agrupadas por pixels que se tocam, dado um critério de vizinhança. O próximo passo é dar um rótulo (ou label) para cada um desses grupos de pixels. Esta identificação permitirá posteriormente parametrizar os objetos segmentados calculando para cada região de pixels contíguos um parâmetro específico, como área, perímetro ou volume, por exemplo.

2.3.5. Detecção de contornos

O interesse na detecção de contornos advém da redução da quantidade de informação a processar e por poderem corresponder a limites físicos dos objetos observados. Os contornos revelam nas imagens variações bruscas dos níveis de luminosidade e, por corresponderem muitas vezes fenómenos importantes em 3D (descontinuidade na orientação ou estrutura de uma superfície) são importantes na perceção.

Uma vez que a detecção de contornos é a etapa inicial na extração de limite de objeto e no reconhecimento de objetos, é importante conhecer as vantagens e desvantagens dos diferentes operadores de detecção de contornos.

Nesta subsecção, são apresentados alguns operadores de deteção de contornos no processamento de imagens: *Roberts*, *Sobel*, *Prewitt* e *Canny*.¹

❖ **Roberts**

O operador *Roberts* executa uma medida de gradiente espacial 2-D simples, rápida a aplicar computacionalmente numa imagem. Na deteção de contorno de *Roberts*, os contornos verticais e horizontais aparecem individualmente e depois juntos para a deteção de contornos resultante. Os valores de cada pixel na saída representam a magnitude absoluta estimada do gradiente espacial da imagem de entrada nesse ponto. A magnitude, ou a força da contorno, do gradiente é então aproximada usando a fórmula: $|G| = |G_x| + |G_y|$. O operador consiste num par de máscaras de convolução 2x2 como se mostra na figura 8.

+1	0
0	-1

G_x

0	+1
-1	0

G_y

Figura 8 – Máscaras usadas no operador *Roberts*

O ângulo de orientação do contorno que dá origem ao gradiente espacial (em relação à orientação da grade de pixels) é dado por: $\theta = \arctg(G_y/G_x) - 3\pi/4$.

❖ **Sobel**

O operador *Sobel* tem um efeito de suavização no ruído. Este consiste num par de máscaras de convolução 3x3 como mostrado na figura 9. Estas máscaras são projetados para responder ao máximo de contornos que correm verticalmente e horizontalmente em relação à grade de pixels, uma máscara para cada uma das duas orientações perpendiculares. O ângulo de orientação do contorno que dá origem ao gradiente espacial é dado por: $\theta = \arctg(G_y/G_x)$.

-1	0	+1
-2	0	+2
-1	0	+1

G_x

+1	+2	+1
0	0	0
-1	-2	-1

G_y

Figura 9 – Máscaras usadas no operador *Sobel*

¹ Adaptado de: Raman Maini & Dr. Himanshu Aggarwal, International Journal of Image Processing (IJIP), Volume (3): Issue (1), Study and Comparison of Various Image Edge Detection Techniques

❖ **Prewitt**

O operador *Prewitt* é semelhante ao operador *Sobel* e é usado para detetar contornos verticais e horizontais nas imagens. As máscaras de deteção de contorno do operador *Prewitt* são um dos métodos mais antigos e melhor compreendidos para detetar bordas nas imagens. O detetor de borda *Prewitt* usa a seguinte máscara, figura 10, para aproximar digitalmente as primeiras derivadas G_x e G_y .

-1	0	+1
-1	0	+1
-1	0	+1

G_x

+1	+1	+1
0	0	0
-1	-1	-1

G_y

Figura 10 – Máscaras usadas no operador *Prewitt*

❖ **Canny**

O algoritmo de deteção de contorno *Canny* é conhecido por muitos como o detetor de contornos ideal. O detetor de contorno *Canny* primeiro suaviza a imagem para eliminar o ruído.

O algoritmo de deteção de contornos *Canny* percorre os seguintes passos:

Passo 1 – O primeiro passo é filtrar qualquer ruído na imagem original antes de tentar localizar e detetar os contornos. Como o filtro gaussiano pode ser calculado usando uma máscara simples, este é usado exclusivamente no algoritmo de *Canny*.

Passo 2 – Depois de suavizar a imagem e eliminar o ruído, o próximo passo é encontrar a magnitude do contorno ($|G| = |G_x| + |G_y|$). Usando as máscaras de convolução 3x3 do operador *Sobel*, uma estima o gradiente na direção x (colunas) e a outra estima o gradiente na direção y (linhas).

-1	0	+1
-2	0	+2
-1	0	+1

G_x

+1	+2	+1
0	0	0
-1	-2	-1

G_y

Figura 11 – Máscaras do operador *Sobel* usadas no operador *Canny*

Passo 3 – A orientação do contorno é calculada usando o gradiente nas direções x e y. A fórmula para encontrar a direção do contorno é apenas: $\theta = \arctg(G_y/G_x)$.

Passo 4 – Uma vez conhecida a orientação do contorno, o próximo passo é relacionar a direção do contorno com uma direção que pode ser percorrida numa imagem. Assim, se os pixels de uma imagem 5x5 estiverem alinhados da seguinte forma:

```

x   x   x   x   x
x   x   x   x   x
x   x   a   x   x
x   x   x   x   x
x   x   x   x   x

```

pode-se verificar que o pixel **a** tem apenas quatro direções possíveis ao descrever os pixels circundantes – 0 graus (na direção horizontal), 45 graus (ao longo da diagonal positiva), 90 graus (na vertical direção), ou 135 graus (ao longo da diagonal negativa).

Passo 5 – Após serem conhecidas as instruções de contorno, a supressão não máxima é aplicada (supressão de valores de pixels que não forem máximos locais na direção transversal à borda). A supressão não máxima é usada para analisar ao longo do contorno, na direção do contorno, e suprimir qualquer valor de pixel (define-se igual a 0) que não é considerado um contorno. Isso dará uma linha fina na imagem de saída.

Passo 6: - Finalmente, a histerese é usada como um meio de eliminar tracejados. Estes tracejados são quebras no contorno causados pela saída do operador flutuando acima e abaixo do limiar. Se um único limiar, T1, é aplicado a uma imagem, e um contorno tem uma força média igual a T1, então, devido ao ruído, haverá casos em que a contorno vai abaixo do limite. Igualmente, ele também se estenderá acima do limiar que faz um contorno parecer uma linha tracejada. Para evitar isso, a histerese usa 2 limiares, um alto e um baixo.

2.4. Métodos de análise de imagens pulmonares

Como um trabalho inicial neste campo, Kanazawa et al. (1998) propuseram um Diagnóstico Assistido por Computador (CAD) de deteção de nódulos que segmenta as regiões pulmonares por um algoritmo de agrupamento difuso, em seguida, analisa as regiões segmentadas usando técnicas de processamento de imagem e regras base de classificação. Uma técnica de correspondência de modelos que se baseia no algoritmo genético foi proposta em Lee et al. (2001) para detetar nódulos pulmonares em TC de tórax. Este método foi validado em 20 casos clínicos de um conjunto de dados privado e umas regras base de classificação executadas para reduzir o número de falsos positivos (FP). No entanto, a quantidade de FP nesse estudo foi bastante elevada (30 FP/caso) com taxa de deteção igual a 72%. Um método semelhante de correspondência de modelos que os autores chamaram de algoritmo genético é proposto em Dehmeshki et al. (2007) para a deteção de nódulos de forma esférica. Nesse trabalho, um recurso de forma geométrica 3D é calculado em cada voxel e depois combinado numa

distribuição de intensidade de nódulo global. A taxa de deteção foi de cerca de 90%, com 14,6 FP/caso, que é bastante elevado em comparação com métodos mais recentes.

Alguns estudos utilizam filtros especiais para melhorar as estruturas semelhantes aos nódulos. Por exemplo, Li et al. (2008) propuseram três filtros de aperfeiçoamento seletivo para pontos, linhas e planos, que podem simultaneamente aperfeiçoar objetos de uma forma específica e suprimir outros objetos. Nessa abordagem, a imagem de TC estava ofuscada com um núcleo gaussiano que correspondia ao tamanho do nódulo a ser detetado antes de calcular os valores próprios da matriz hessiana que foi usada para aperfeiçoamento seletivo. Noutro trabalho similar, um filtro de forma cilíndrica como um método de aperfeiçoamento rápido para nódulos pulmonares é proposto por Teramoto e Fujita (2013). A taxa de FP nesse trabalho foi reduzida usando uma máquina de vetores de suporte (SVM) juntamente com sete parâmetros característicos da forma.

O interesse crescente na deteção automática de nódulos pulmonares resultou na disponibilidade de bases de dados de imagem pública para a avaliação e validação de algoritmos. Estudos recentes utilizaram principalmente as imagens incluem o banco de dados de imagens do *Lung Image Database Consortium* (LIDC) (Armato et al., 2004). Um esquema de deteção de nódulos que utilizou um método de contorno ativo 3D foi proposto em Way et al. (2006). Uma abordagem de multi-limiar de triangulação de superfície foi proposta em Golosioetal (2009). Um método de limiar de intensidade múltipla combinado com operações morfológicas é proposto em Messay et al. (2010), onde os candidatos a nódulos foram distinguidos por regras base de classificação.

Como um exemplo de métodos que empregaram a base de dados LIDC, autores em Tan et al. (2011) propuseram um método CAD que identifica nódulos baseados em filtros de realce de nódulos e vasos e é usado um novo conjunto de características seletivas baseado em algoritmos genéticos e redes neurais artificiais para a classificação dos nódulos identificados. No entanto, além do desempenho de deteção, métodos de visualização 3D como renderização de volume e projeção para 2D aceleram o processo de deteção pelos radiologistas.

Neste artigo, Alilou M. et al. (2014) propõem uma nova estrutura CAD abrangente para a deteção de nódulos pulmonares em imagens torácicas de TC. O artigo apresenta um sistema CAD computacionalmente eficiente e fornece uma descrição completa de todas as etapas de processamento. A estrutura proposta automatiza todo o processo de segmentação pulmonar e deteção de nódulos candidatos. Além disso, fornece um conjunto de ferramentas de visualização em 2D e 3D que facilitam a tarefa de deteção

e validação para radiologistas. Para avaliar a capacidade do método, a estrutura CAD foi testada em imagens de TC de 60 pacientes do banco de dados LIDC publicamente disponível e o seu desempenho de deteção e processamento foi comparado a 6 métodos de CAD existentes. Neste estudo, que resulta da revisão da maioria dos artigos sobre o problema de deteção de nódulos publicados nos últimos 15 anos, a forma como escolheram o conjunto otimizado de níveis de limiar e um conjunto eficiente de recursos candidatos a nódulos não foi relatada anteriormente. Além disso, apesar dos avanços promissores nos últimos 15 anos, as soluções CAD existentes podem produzir uma quantidade considerável de falsos positivos e sua sensibilidade geralmente está abaixo dos 90% (Chan et al., 2008). Portanto, a visualização dos diferentes passos dos métodos CAD é importante, pois pode ajudar os radiologistas na interpretação das tomografias. Esta metodologia fornece um conjunto de ilustrações em 3D, 2D e ilustrações 3D projetadas a partir de diferentes etapas do processo de deteção que viabilizam a tarefa de deteção e validação de nódulo pulmonares para radiologistas.

O conjunto de dados do estudo de Alilou M. et al. (2014) incluía 222 nódulos anotados entre 3 e 32 milímetros e o método proposto visava detetar nódulos com diâmetro ≥ 4 mm, o número de nódulos a considerar foi 211 (de 222). Estes dados incluíam nódulos isolados, justavasculares (conectados a vasos) e justapleurais (conectados à pleura) de vários tamanhos. Na figura 12, pode-se visualizar a projeção da intensidade máxima dos nódulos pulmonares do conjunto de dados usado em Alilou M. et al. (2014).




Figura 12 – Projeção da intensidade máxima de nódulos pulmonares de diferentes tamanhos (a) justapleural 23,1 mm, (b) justavascular 20,16 mm, (c) isolado 13,4 mm, (d) justavascular 9,2 mm, (e) justapleural 8.3 mm,

(f) justavascular 6.9 mm, (g) 6,2 mm isolado, (h) isolado 5,7 mm (Alilou M. et al., 2014)

O método desenvolvido em Alilou M. et al. (2014), ilustrado na figura 13, incluiu as seguintes etapas de processamento: segmentação do pulmão e regiões adjacentes para a extração de candidatos de nódulos e vasos dentro da região pulmonar, seguidos por processamento morfológico, extração de uma bolha 3D, recursos de computação dos candidatos a nódulos e classificação baseada em SVM das bolhas 3D e, finalmente, visualização 2D/3D dos scans.

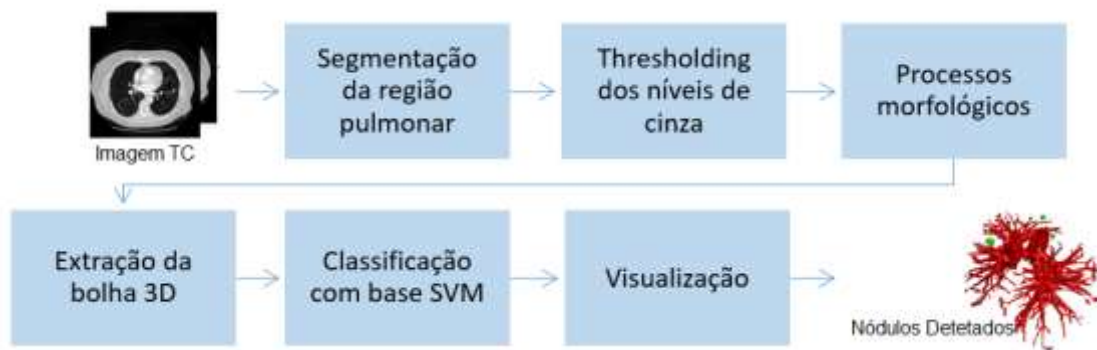


Figura 13 – Exemplo de um diagrama de etapas do método CAD, proposto por Alilou M. et al. (2014).

A segmentação da região pulmonar foi identificada como a primeira fase de processamento deste método e será o principal foco de atenção. O objetivo deste passo é separar os voxels correspondentes aos pulmões dos voxels dos tecidos da região circundante. O princípio do algoritmo de segmentação pulmonar é semelhante ao descrito em Hu et al. (2001) e em Leader et al. (2003). Tendo como imagem de entrada a imagem de TC para realizar a segmentação pulmonar geram e utilizam quatro tipos de máscaras 3D. Estas são a máscara inicial do pulmão (M_i), a máscara corporal (M_c), a máscara pulmonar secundária (M_s) e a máscara pulmonar final (M_f). A figura 14 ilustra exemplos das máscaras geradas durante o processo de segmentação.




Figura 14 – Exemplos das máscaras que são geradas e usadas durante o processo de segmentação pulmonar. (a) máscara pulmonar inicial, (b) máscara corporal, (c) máscara pulmonar secundária, (d) máscara pulmonar final (Alilou M. et al., 2014).

O procedimento de segmentação pulmonar 3D, com visualização 2D, é ilustrado na figura 15. Como se pode verificar na figura 15, em primeiro lugar, o algoritmo de thresholding ótimo é aplicado às imagens de TC de entrada para gerar a máscara pulmonar inicial. O algoritmo de thresholding ótimo é um procedimento iterativo que é usado para separar os voxels (pixels tridimensionais) do corpo (i.e., voxels de alta densidade do corpo e do tórax que possuem valores Hounsfield maiores) dos voxels do não-corpo (i.e. voxels de baixa densidade do pulmão e do ar circundante que têm valores Hounsfield mais baixos). O limite ótimo é determinado através de um procedimento iterativo. Seja T_i o limiar de segmentação no passo i . T_i é aplicado à imagem de entrada para separar voxels de corpo e de não-corpo. Sejam μ_c e μ_n as intensidades médias de cinzento dos voxels de corpo e de não-corpo, respetivamente, segmentados com o limiar T_i . O novo limiar (T_{i+1}) é calculado através de:

$$T_{i+1} = \frac{\mu_c + \mu_n}{2}$$

A atualização iterativa do novo limiar é repetida até $T_{i+1} = T_i$. O valor Hounsfield do ar é escolhido como o valor do limiar inicial ($T_0 = -1000 HU$).

A máscara inicial do pulmão (M_i) é gerada aplicando o threshold ideal para a imagem de entrada. No passo seguinte, é gerada a máscara corporal (M_c), que é usada para cobrir todos os voxels correspondentes ao corpo, incluindo pulmão e peito. A máscara do corpo que é mostrada na figura 15 é obtida da seguinte forma: em primeiro lugar, o algoritmo morfológico de preenchimento de buracos é aplicado ao complementar da máscara inicial do pulmão ($-M_i$). Então, um algoritmo de rotulação das componentes conectadas em 3D é usado para descobrir as componentes conectadas da máscara do corpo. Ao escolher a componente máximo da imagem resultante que corresponde aos voxels do corpo, obtém-se a máscara do corpo. Note-se que o algoritmo morfológico de preenchimento de buracos é realizado fatia a fatia em 2D para reduzir o tempo computacional do método. Tendo as máscaras iniciais do pulmão e do corpo, como é mostrado na figura 15, a máscara pulmonar secundária é obtida através de:

$$M_s = M_i \wedge M_c$$

onde, M_i é a máscara inicial do pulmão, M_c é a máscara do corpo e " \wedge " é o operador lógico "e". Em seguida, a máscara pulmonar final (M_f) é gerada aplicando o algoritmo de preenchimento de buracos em M_s . Finalmente, a imagem pulmonar segmentada é

obtida pela sobreposição de M_i na imagem de entrada, que servirá como região de interesse (ROI) para detetar os nódulos pulmonares.

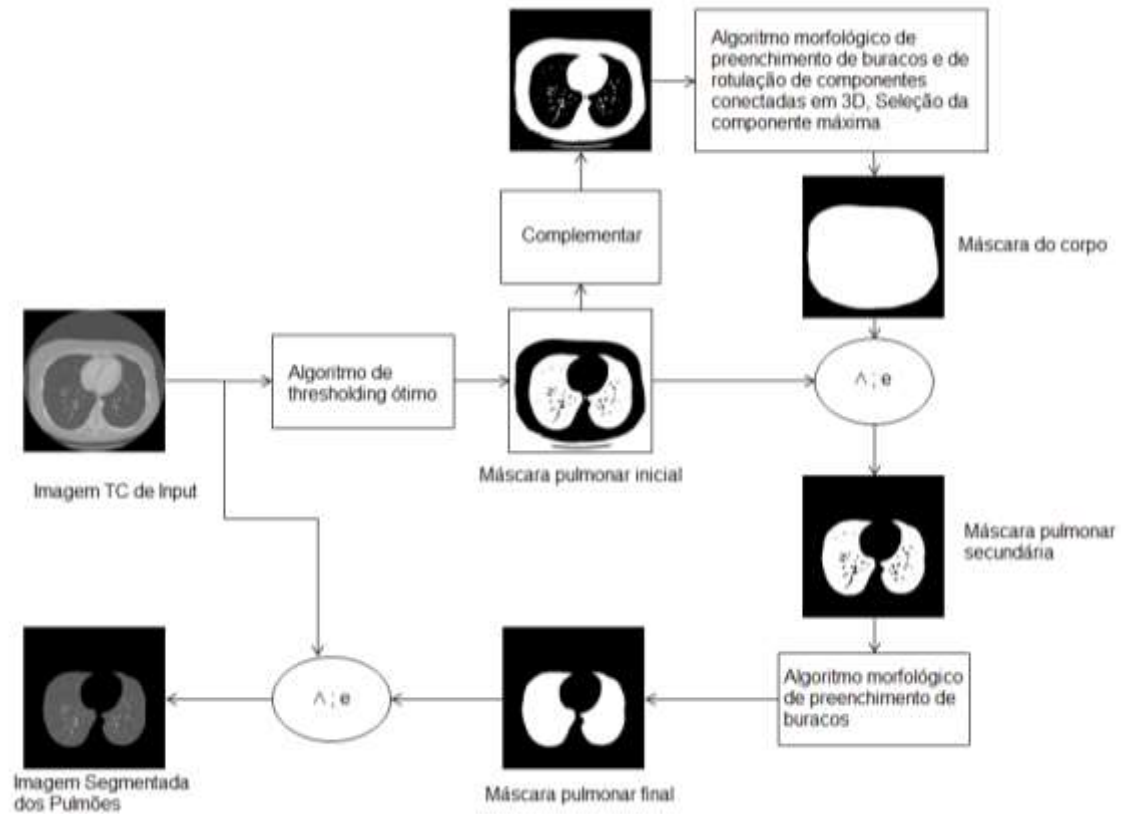


Figura 15 – Exemplo de diagrama do processo de segmentação pulmonar. A operação começa com o processamento da imagem de TC de input 3D e resulta numa imagem de saída segmentada em 3D (Alilou M. et al., 2014).

Tendo a região de interesse (i.e., regiões pulmonares segmentadas), o passo seguinte é identificar as estruturas semelhantes a nódulos dentro da região de interesse (*region of interest*, ROI). Como é mostrado no diagrama do processo de segmentação pulmonar apresentado na figura 15, a identificação dos candidatos de nódulos começa com a segmentação que emprega uma técnica de limiar múltipla (*thresholding*). Uma vez que a densidade do nódulo é maior do que a do tecido pulmonar (Goliosio et al., 2009), os nódulos internos isolados podem ser facilmente isolados por uma separação adequada de um único limiar. Infelizmente, os nódulos internos nem sempre estão isolados, pois podem estabelecer conexões com os vasos. Se o limiar for demasiado baixo, os nódulos justavasculares ou ligados a vasos aparecem ligados aos vasos (Alilou M. et al., 2014). Por outro lado, o limiar não deve ser muito alto. Se for superior à densidade de um nódulo, parte desse nódulo será perdida e seu volume será subestimado. Outro problema em relação ao *threshold* é a segmentação de nódulos justapleurais (isto é, nódulos que estão conectados à parede pulmonar ou à pleura

parietal) (Alilou M. et al., 2014). Acontece muitas vezes que o procedimento de segmentação pulmonar deixa parte da parede do pulmão (pleura) dentro do volume de interesse, especialmente em regiões de alta convexidade. Os nódulos justapleurais nessas regiões permanecerão conectados a parte da parede do pulmão. Se o limite for muito baixo, os nódulos justapleurais estarão conectados a esta camada. Usando um procedimento de múltiplos limiares, podem ser detetados nódulos sólidos conectados aos vasos, bem como nódulos de baixa densidade. A figura 16 ilustra uma amostra de um nódulo justavascular que é segmentado em múltiplos níveis de limiar. Usando um procedimento multi-limiar.




Figura 16 - Visões tridimensionais das isosuperfícies correspondentes a um nódulo justavascular segmentado com limiares de -450, -300 e -150 HU representados em (a), (b) e (c), respetivamente (Alilou M. et al., 2014).

Inspirado pelo método introduzido em Armato et al. (2001), Alilou M. et al. (2014) empregaram uma versão especializada da abordagem de limiar de intensidade múltipla. Os autores de Armato et al. (1999; 2001) aplicaram 36 limiares de intensidades de cinzento ao volume pulmonar segmentado. Para cada limiar, eles identificaram estruturas contíguas com intensidades de cinzento associadas superiores ao limiar e observaram que as únicas estruturas identificadas com intensidades de cinzento inferiores ao valor do limiar podem-se decompor em múltiplas estruturas pequenas com valores de limiar mais altos. Num trabalho semelhante, Golosio et al. (2009), aplicaram uma ampla gama de valores limiar às imagens de TC e armazenaram as conexões entre as ROI em diferentes limiares numa estrutura de dados em árvore. Alilou M. et al. (2014) usaram 10 níveis de limiar na unidade de Hounsfield para examinar os nódulos anotados no conjunto de dados, são eles: -600, -550, -500, -450, -400, -350, -300, -250, -200 e -150. Cada operação de limiar foi seguida por abertura morfológica 2D com um elemento estruturante circular de raio 1 para remover estruturas residuais tais como vasos que podem ser ligados a candidatos a nódulos. A aplicação destes níveis de limiar T_i à ROI (região pulmonar segmentada) conduz a dez máscaras de candidatos a nódulos correspondentes (C_1, \dots, C_{10}). Cada C_i é uma máscara binária 3D correspondente aos

voxels restantes após o limiar. Na etapa seguinte do método CAD proposto por Alilou M. et al. (2014) (ver figura 13), o algoritmo de extração de uma bolha 3D é aplicado para extrair variáveis das componentes conectadas dentro de cada C_i .

Deste modo, Alilou M. et al. (2014) apresentaram uma nova estrutura para segmentação e detecção de nódulos pulmonares solitários em imagens de TC. Além de um bom desempenho na detecção e eficiência de tempo, o método oferece recursos de visualização adicionais (Alilou M. et al., 2014)

Outro método de segmentação é proposto por Lakshmi D. et al. (2013) num artigo em que apresenta um método totalmente automatizado de caracterização de carcinoma e outras anomalias pulmonares, nomeadamente fibrose e suspeita de tuberculose. Um estudo de comparação também é feito com três conjuntos de características que inclui entropia e parâmetros extraídos pela *Gray-Level Co-Occurrence Matrix* (GLCM, Matriz de Co-ocorrência de Intensidades de Cinzento) e pela *Gray Level Run Length Matrix* (GLRLM). Lakshmi D. et al. (2013) propõem um sistema automatizado de análise de textura de fibrose e carcinoma de pulmão. A imagem da fatia da imagem de TC original de cada indivíduo é processada com operações morfológicas para extrair apenas as intensidades de cinzento tecidual dentro do parênquima pulmonar. Isso facilita a identificação da ROI automaticamente. De seguida, os recursos baseados em GLCM, GLRLM e entropia são extraídos e dados como entradas para classificador sistema de inferência adaptativo Neuro-Fuzzy. O desempenho do classificador é avaliado comparando-se com a saída real.

Em Lakshmi D. et al. (2013) é apresentado um método de segmentação de imagens de TC que envolve sete etapas.

Passo 1: a imagem original, como mostra na figura 17a), é processada para determinar o contorno do tórax, mostrado na figura 17b).

Passo 2: a imagem é preenchida com as intensidades de cinzento reais dentro do contorno do tórax, como mostra a figura 17c).

Passo 3: com o osso como referência, os três limites mais altos são analisados. A razão de escolher os três limites mais altos é extrair o parênquima pulmonar de forma clara como mostra na figura 17d).

Passo 4: usando o processamento morfológico é construída uma imagem temporária que é mostrada na figura 17e).

Passo 5: o objetivo deste passo é separar o tecido da região cheia de ar e da gordura. O histograma da imagem de TC do pulmão mostra claramente que o tecido humano e o ar podem ser facilmente separados pelo limiar T_1 , como mostra a figura 18. A imagem

obtida a partir do passo 2 é aplicada um thresholding T_1 e preenchida com a intensidade de cinzento real para obter a área de tecido presentes no tórax, figura 17f).

Passo 6: usando o limiar T_2 , as regiões de tecido dentro do pulmão são extraídas da gordura. A figura 17g) mostra as áreas de tecido humano dentro do pulmão.

Passo 7: operando com as imagens obtidas a partir das duas etapas anteriores obtém-se a imagem apenas com tecidos fora do pulmão como mostrado na figura 17h) (Lakshmi D. et al., 2013).




Figura 17 – Exemplo de um método de segmentação pulmonar, proposto por Lakshmi D. et al. (2013) (a) Imagem original, (b) Limite do tórax, (c) Extração do tórax inteiro, (d) Três maiores limites, (e) Imagem temporária, (f) Extração das intensidades de cinzento do tecido em todo o tórax, (g) Extração das intensidades de cinzento do tecido apenas no parênquima pulmonar, (h) Extração das intensidades de cinzento do tecido fora do parênquima pulmonar

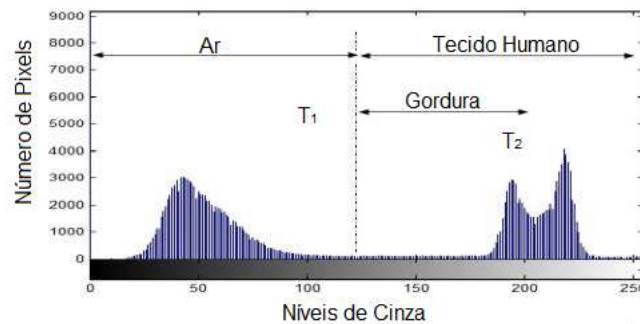


Figura 18 – Histograma de uma imagem de TC do pulmão (Lakshmi D. et al.,2013)

Outro processo de segmentação, descrito por Avazpour I. et al (2013), é baseado em imagens da tomografia por emissão de positrões (*Positron Emission Tomography*, PET) combinada com imagens de tomografia computadorizada (PET/TC). Trabalhos anteriores utilizaram informações em TC apenas para segmentar a imagem sem utilizar a informação que pode ser fornecida pelo PET. Avazpour I. et al. (2013) propõem utilizar os valores de hot spot em PET para orientar a segmentação em imagens de TC, na segmentação automática de imagens usando a técnica de crescimento da região semeada (*Seeded Region Growing*, SRG). Esta rotina de segmentação automática

pode ser usada como parte de ferramentas de diagnóstico automático. Além da seleção inicial de sementes usando valores de hot spot em PET, este artigo também introduz um novo critério de crescimento de SRG, as janelas deslizantes. Catorze imagens de pacientes com tuberculose extrapulmonar foram examinadas usando o método acima mencionado. Para avaliar o desempenho do SRG modificado, são medidos três critérios de fidelidade: percentagem de área de sob segmentação, percentagem de área de sobre segmentação e consumo médio de tempo. Em termos de percentagem de sob segmentação, o SRG com a média do critério crescente da região mostra a menor percentagem de erro (51,85%). Enquanto isso, SRG com média local e variância produziram os melhores resultados (2,67%) para a percentagem de sobre segmentação. Em termos de complexidade do tempo, o SRG modificado com critério de crescimento médio e variância local mostra melhor desempenho. Os resultados indicam que os métodos propostos produzem um desempenho bastante bom em termos de área de sobre e sob segmentação. Os resultados também demonstraram que os valores de hot spot em PET podem ser usados para orientar a segmentação automática na imagem de TC (Avazpour I. et al, 2013).

Em Avazpour I. et al. (2013) o foco da segmentação está no crescimento da região semeada (SRG). O algoritmo funciona ao atribuir as coordenadas de pixels de alta intensidade como pontos de partida do processo de segmentação e expandir a ROI, verificando os pixels vizinhos na imagem de TC. Um critério de crescimento será definido de modo que, em cada etapa, os pixels vizinhos que caem neste critério serão adicionados à ROI. O processo de crescimento continuará até que não haja nenhum outro pixel na vizinhança da ROI que caia dentro deste critério de crescimento. Avazpour I. et al. (2013) testaram o método proposto por Adams e Bischof, média da região, e propõem mais dois outros aspetos do critério de crescimento: média e variância da região e janelas deslizantes.

❖ Média da Região

Aqui em cada passo, os valores médios de intensidade de pixels da região considerada são calculados e cada valor de intensidade de pixel vizinho é comparado com essa média. Considera-se o primeiro ponto de semente como a média inicial. À medida que a região cresce, a média é calculada para controlar o processo de crescimento. O critério de crescimento (CC) é ajustado para o valor médio ROI \pm um valor limiar T .

$$CC = Média(ROI) \pm T$$

O valor limiar T é definido pelo utilizador para satisfazer as condições específicas da imagem. Este é solicitado a atribuir um valor limiar que tenha o resultado mais próximo da segmentação desejada.

❖ Média e Variância da Região

Outro aspeto é aplicar média e variância localmente para controlar o processo de crescimento. Considera-se uma subimagem local S para calcular a média e o desvio padrão dos valores de intensidade na região S em torno de cada ponto de semente. Assim, o CC é definido por:

$$CC = Média(S) \pm DP(S),$$

onde $Média(S)$ é o valor médio da subimagem S e $DP(S)$ é o seu desvio padrão. Em cada etapa, os pixels com o valor dentro desse CC serão adicionados à ROI. O processo cresce para quando não existe um pixel vizinho que satisfaça esse critério.

❖ Janelas deslizantes

As imagens de tomografia computadorizada têm várias propriedades de intensidade e lesões corporais diferentes que aparecem com intensidade diferente, isso exige a necessidade de examinar a especificidade da imagem antes da segmentação. Consideraram-se duas subimagens locais, da imagens de TC, SA e SB centradas na coordenada do ponto de semente foram definidas e o valor médio de pixel de ambos foi calculado. Considerando estas médias, tem-se:

Se $Média(SA) < Média(SB)$ então a área a ser segmentada é mais brilhante do que a área circundante

Se $Média(SA) > Média(SB)$ então a área a ser segmentada é mais escura do que a área circundante

Caso contrário, a área de segmentação e a sua vizinhança têm relativamente a mesma intensidade,

onde $Média()$ é o valor médio de pixel da área de máscara.

Com o espectro de cores em escala de cinzento, assume-se CC como uma janela de intervalo centrada no valor de intensidade do ponto de semente.

A figura 19 mostra os resultados de todos os algoritmos de segmentação.




Figura 19 – Resultados de uma segmentação, proposta por Avazpour I. et al. (2013) – (a) ROI selecionado manualmente, (b) SRG usando a média da região, (c) SRG usando janelas deslizantes e (d) SRG usando média e variância.

A ROI desejada selecionada manualmente é mostrada na figura 19a e os resultados da segmentação são mostrados na figura 19b-d. Como é visível nas imagens, a figura 19c, que é o resultado da segmentação do SRG usando janelas deslizantes, possui a melhor precisão em termos de segmentação da lesão, mas também se trata de uma sobre segmentação. A figura 19d, que é o resultado do SRG usando média e variância da região, sofre de sob segmentação.

O objetivo dos autores em Avazpour I. et al. (2013) foi introduzir métodos automatizados de segmentação que resultam em menos erros e melhor desempenho. Considerando o facto de que as saídas devem ser alimentadas em ferramentas de diagnóstico automático, a área segmentada deve, pelo menos, representar uma estimativa do órgão alvo para que os algoritmos de reconhecimento possam reconhecê-lo (Avazpour I. et al., 2013).

3. Metodologia

Este capítulo tem início com uma breve descrição do conjunto de dados de TC usados neste projeto. Além disso, é descrita toda a metodologia implementada no processo de segmentação pulmonar e no cálculo de volume pulmonar.

3.1. Dados de teste

As imagens do conjunto de dados de TC e as máscaras usadas para testar as metodologias implementadas nesta dissertação foram selecionadas do conjunto de dados, apresentado na secção 2 do capítulo 2, e dividem-se da forma apresentada na tabela 3.

Tarefa	Imagem	Tipo
MDR	MDR_001	DS
	MDR_003	
	MDR_004	
	MDR_005	
	MDR_002	MDR
	MDR_006	
	MDR_007	
	MDR_008	
Tipo TB	TBT_001	Tipo 1
	TBT_002	
	TBT_003	
	TBT_141	Tipo 2
	TBT_142	
	TBT_143	
	TBT_261	Tipo 3
	TBT_262	
	TBT_263	
	TBT_361	Tipo 4
	TBT_362	
	TBT_363	
	TBT_441	Tipo 5
	TBT_442	
TBT_443		

Tabela 3 – Amostra do conjunto de dados de TC. – MDR e Tipo TB são a designação das tarefas propostas. DS: sensível a medicamentos, MDR: multirresistente a medicamentos e os Tipos 1, 2, 3, 4 e 5 são os tipos de tuberculose.

Recorde-se que para subtarefa MDR, o conjunto de dados inclui apenas pacientes HIV-negativos sem reincidências e com uma das duas formas de tuberculose: sensível a medicamentos (*DS*) ou multirresistente a medicamentos (*MDR*). Para a subtarefa Tipo TB, inclui tomografia computadorizada de tórax de pacientes com tuberculose juntamente com o tipo de tuberculose: tipo 1, infiltrativa, tipo 2, focal, tipo 3, tuberculoma, tipo 4, miliar, e tipo 5, fibrocavernosa.

Desta forma, pretende-se abordar uma pequena amostra diversificada beneficiando de todas as particularidades evidenciadas em cada imagem, correspondentes às nuances de cada patologia.

O conjunto de dados trabalhados nesta dissertação, adquiridos na base de dados `imageclefmed/2017/Tuberculosis`, é composto por imagens de TC 3D com tamanho de fatia de 512x512 pixels e o número de fatias a variar entre 50 e 400. Todo o conjunto de dados de TC são armazenadas em formato de arquivo NIFTI com extensão de arquivo `.nii.gz`. Para que seja possível trabalhar computacionalmente estas imagem no software Matlab foi necessário obter as seguintes funções para abrir, ler e converter as imagens para a extensão compatível com o Matlab:

- ❖ `load_nii.m` ❖ `load_nii_ext.m` ❖ `load_nii_hdr.m`
- ❖ `load_nii_img.m` ❖ `save_nii.m` ❖ `xform_nii.m`

Usando estas funções, é possível aceder aos metadados do conjunto de dados de TC como dimensões de imagem, tamanho de voxel em unidades físicas, espessura de fatia, etc.. A figura 20 mostra um exemplo de metadados para um conjunto de dados de TC.

```

hdr: [1x1 struct]
filetype: 2
fileprefix: 'IM_MDR_TRN_001'
machine: 'ieee-le'
ext: []
img: [512x512x128 single]
original: [1x1 struct]

```

Figura 20 – Exemplo de metadados de um conjunto de dados de TC

Antes de iniciar a fase de pré-processamento de imagem, foi necessário criar funções no Matlab que permitissem a visualização de vários cortes do conjunto de dados de TC para avaliar quais os cortes com maior relevância para o projeto, ou seja, aqueles em que é possível extrair um maior número de informações sobre a patologia do pulmão. Na figura 21 é apresentado um exemplo da visualização de vários cortes de um conjunto de dados de TC, fornecido na base de dados `imageclefmed/2017/Tuberculosis`.




Figura 21 – Exemplo de visualização de vários cortes num conjunto de dados de TC

Nestas imagens, os pixels de fundo (não-tecido) geralmente têm intensidade de cinzento semelhante aos pixels do pulmão. Esses pixels do plano de fundo podem afetar o cálculo do valor limiar do pixel ótimo na etapa seguinte. Assim sendo, cria-se um script no Matlab para explorar um corte em maior detalhe, de diferentes conjuntos de dados TC, e extrair os valores da intensidade máxima e mínima dos pixels. O valor mínimo do pixel em todas as imagens de corte é -3024 HU (correspondente ao plano de fundo) e o valor máximo não ultrapassa o 3076 HU. Para assegurar que a intensidade dos pixels varia numa escala entre 0 e 1, e garantir maior eficácia no passo seguinte (segmentação), normaliza-se a imagem pela transformação:

$$Im_N = \frac{Im_I + 3024}{6100}$$

onde Im_I é a imagem inicial e Im_N é a imagem normalizada.

As figuras seguintes mostram essa normalização, em que na figura 22 se visualiza a aplicação da normalização a um corte em particular e na figura 23 se apresenta uma visualização de vários cortes de um conjunto de dados de TC.




Figura 22 – Exemplo da visualização da normalização de uma imagem de um conjunto de dados de TC. (a) Imagem do corte 79 de um conjunto de dados de TC; (b) Imagem do corte 79 de um conjunto de dados de TC normalizada.




Figura 23 – Exemplo da visualização de vários cortes num conjunto de dados de TC normalizada

Neste momento tem-se o conjunto de dados de TC normalizados, dados estes que serão usados na etapa seguinte do processamento de imagem, a segmentação pulmonar.

3.2. Segmentação pulmonar

Nesta dissertação, o método de segmentação pulmonar começa por analisar o histograma da imagem do conjunto de dados de TC normalizada e criar uma função no Matlab para determinar o valores de corte T , obtido através do algoritmo iterativo proposto por Otsu, a usar na partição do histograma em duas ou mais partes – *Thresholding Global*.

A figura 24 mostra uma imagem do conjunto de dados de TC considerado neste projeto e o respetivo histograma, com indicação do valor de $T=0,16275$, em que foi aplicado o *Thresholding Global*.

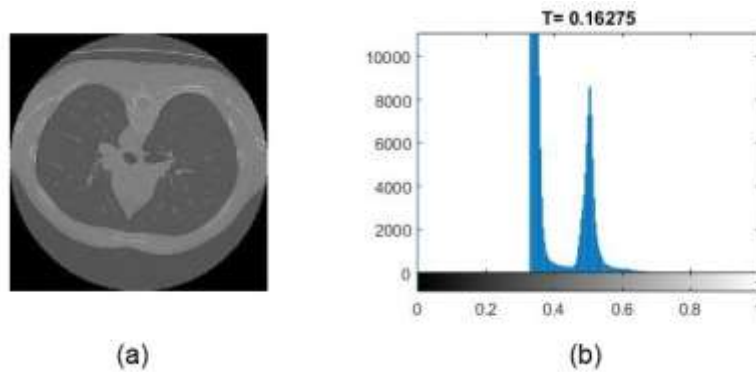


Figura 24 – Exemplo de um *Thresholding Global*. (a) Imagem de um corte do conjunto de dados de TC normalizada; (b) Histograma da imagem de um corte do conjunto de dados de TC normalizada

Como se pode observar, os pixels do fundo da imagem normalizada, representados no histograma com valor 0, influenciam o cálculo do valor T – *threshold*, o que poderia comprometer a eficácia do processo de segmentação. Deste modo, criou-se um script no Matlab para excluir deste procedimento os pixels do fundo, uma vez que estes não pertencem à nossa região de interesse. Daqui, resulta um histograma bimodal, com dois picos na escala de intensidades de cinzento, e um valor $T=0,42353$ para aplicar uma versão modificada do *Thresholding Global*, mais ajustado ao exemplo em questão. Esta alteração é mostrada na figura 25.




Figura 25 – Histograma da imagem de um corte do conjunto de dados de TC normalizada, sem os pixels do fundo

A figura 26 expõe um exemplo deste processo de segmentação/binarização numa imagem de um corte do conjunto de dados de TC normalizada, onde foi aplicada uma versão modificada do *Thresholding* Global de valor $T=0,42353$, resultando numa imagem binária onde os pixels dos pulmões (a branco) aparecem destacados dos restantes pixels da região externa aos pulmões (a preto).




Figura 26 – Exemplo da binarização por aplicação da versão modificada do *Thresholding* Global. (a) Imagem de um corte do conjunto de dados de TC normalizada; (b) Imagem binária de um corte do conjunto de dados de TC

Deste modo, depois de se obter a imagem binária passa-se para a aplicação de processos de simplificação da imagem, com recurso aos operadores morfológicos, já apresentados na subsecção 2.3.3. do capítulo 2.

Para avaliar o contributo de cada operador, dilatação, erosão, abertura e fecho, no aperfeiçoamento da imagem binária resultante do processo de segmentação implementado, foi criada uma função no Matlab para testar o efeito dos vários operadores morfológicos com diferentes elementos estruturantes numa imagem de um corte do conjunto de dados de TC normalizada.

Começando pelo operador dilatação, cujos efeitos são engrossar objetos ou preencher pequenos buracos da imagem, na figura 27 pode-se visualizar a influência de diferentes elementos estruturantes na operação morfológica dilatação de uma imagem de um corte do conjunto de dados de TC.




Figura 27 – Exemplo de aplicação do operador dilatação a uma imagem de um corte do conjunto de dados de TC binária, com diferentes elementos estruturantes: círculo de raio R e quadrado de lado L, com R=3, 5 e 10 pixels e L=3, 5 e 10 pixels.

De seguida, testou-se o operador erosão, cujos efeitos são eliminar componentes menores que o elemento estruturante ou aumentar buracos da imagem, na figura 28 pode-se visualizar a influência de diferentes elementos estruturantes na operação morfológica erosão de uma imagem de um corte do conjunto de dados de TC.

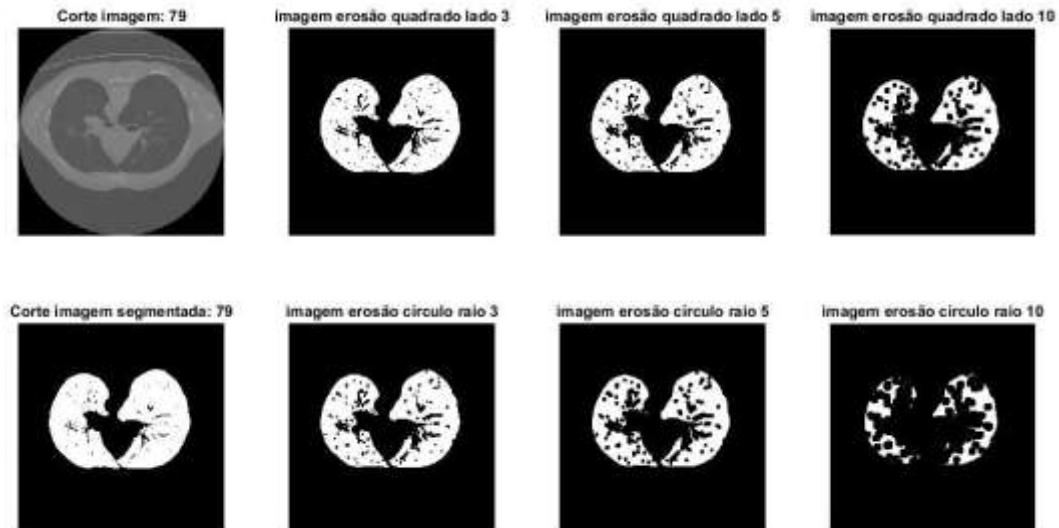


Figura 28 – Exemplo de aplicação do operador erosão a uma imagem de um corte do conjunto de dados de TC binária, com diferentes elementos estruturantes: círculo de raio R e quadrado de lado L, com R=3, 5 e 10 pixels e L=3, 5 e 10 pixels.

Até aqui foram testadas as operações básicas, erosão e dilatação, mas através destas pode-se realizar operações de abertura e fecho.

O teste seguinte foi para o operador abertura, cujos efeitos são suavizar o contorno da imagem ou eliminar saliências finas da imagem, na figura 29 pode-se visualizar a influência de diferentes elementos estruturantes na operação morfológica abertura de uma imagem de um corte do conjunto de dados de TC.

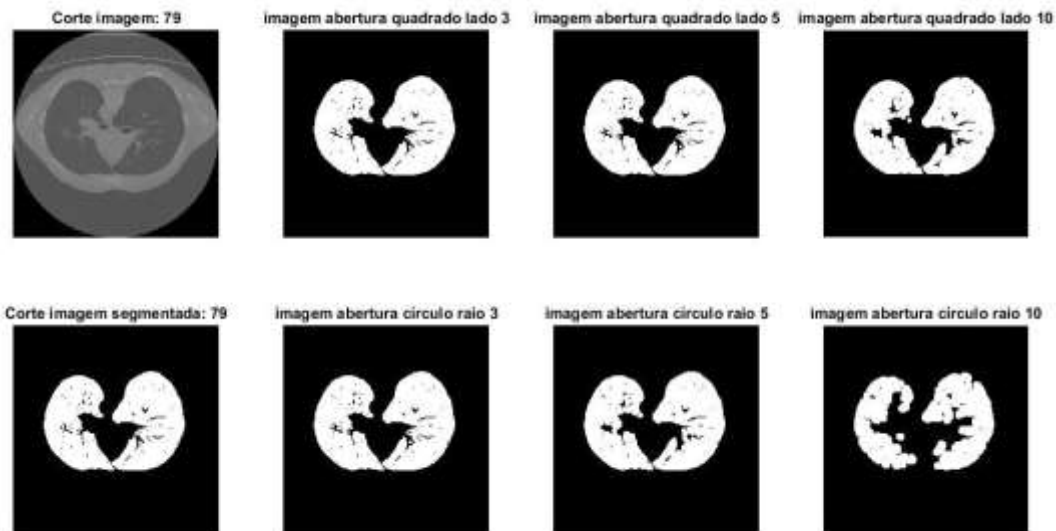


Figura 29 – Exemplo de aplicação do operador abertura a uma imagem de um corte do conjunto de dados de TC binária, com diferentes elementos estruturantes: círculo de raio R e quadrado de lado L, com R=3, 5 e 10 pixels e L=3, 5 e 10 pixels.

Por último, no que diz respeito a operadores morfológicos, testou-se o operador fecho, cujos efeitos são suavizar as fronteiras pelo exterior ou eliminar pequenos buracos da imagem, na figura 30 pode-se visualizar a influência de diferentes elementos estruturantes na operação morfológica fecho de uma imagem de um corte do conjunto de dados de TC.




Figura 30 – Exemplo de aplicação do operador fecho a uma imagem de um corte do conjunto de dados de TC binária, com diferentes elementos estruturantes: círculo de raio R e quadrado de lado L, com $R=3, 5$ e 10 pixels e $L=3, 5$ e 10 pixels.

Depois de analisar as diferentes imagens de output, compiladas nas figuras acima, 27 a 30, o operador adotado para aplicar neste método foi o operador fecho de elemento estruturante círculo de raio 10 pixels.

Efetuada o aperfeiçoamento das imagens de cortes do conjunto de dados de TC binárias, nesta dissertação, segue-se a extração dos dois objetos principais da ROI – o pulmão direito e o pulmão esquerdo. Para o efeito, criou-se uma função no Matlab que extraía os dois maiores objetos da ROI, no entanto, caso os dois pulmões estivessem unidos num único objeto, ou seja, se a razão entre as áreas dos dois maiores objetos fosse inferior a 0,10, então seria extraído apenas o maior objeto. A figura 31 apresenta um exemplo desta técnica para uma imagem de um corte do conjunto de dados de TC constituída pelos pulmões e a zona externa aos pulmões bem delimitadas entre si. O processo de segmentação separa as regiões pertencentes aos pulmões daquelas pertencentes à região externa aos pulmões (fundo), criando um delimitador entre elas. Ao extrair os dois maiores objetos da ROI garante-se a visualização do pulmão direito e do pulmão esquerdo. A etapa de labelização cria um rótulo que identifica cada uma dessas regiões para que os processos seguintes de tratamento da informação sejam concentrados em cada uma das regiões que receberam um rótulo.




Figura 31 – Exemplo da extração dos dois objetos principais da ROI de uma imagem de um corte do conjunto de dados de TC – (a) Imagem original; (b) Imagem binária; (c) Objeto maior – pulmão direito; (d) Segundo maior objeto – pulmão esquerdo; (e) Imagem segmentada com os dois maiores objetos

Continuando a descrição da metodologia implementada chega-se à etapa da aplicação dos operadores de deteção de contornos. Este procedimento tem como objetivo a comparação dos contornos detetados na imagem de um corte do conjunto de dados de TC segmentada e dos contornos detetados máscara disponíveis na base de dados fornecida. Para este efeito, foi criada uma função no Matlab para visualizar os contornos usando os operadores *Roberts*, *Sobel*, *Prewitt* e *Canny*, descritos na subsecção 2.3.5. do capítulo 2. Na figura 32 visualiza-se aplicação dos diferentes operadores de contorno à imagem de um corte do conjunto de dados de TC, da base de dados deste projeto, donde se conclui que não há grandes diferenças entre eles, pois as imagens são isentas de ruído o que beneficia a viabilidade dos diferentes operadores de contornos.

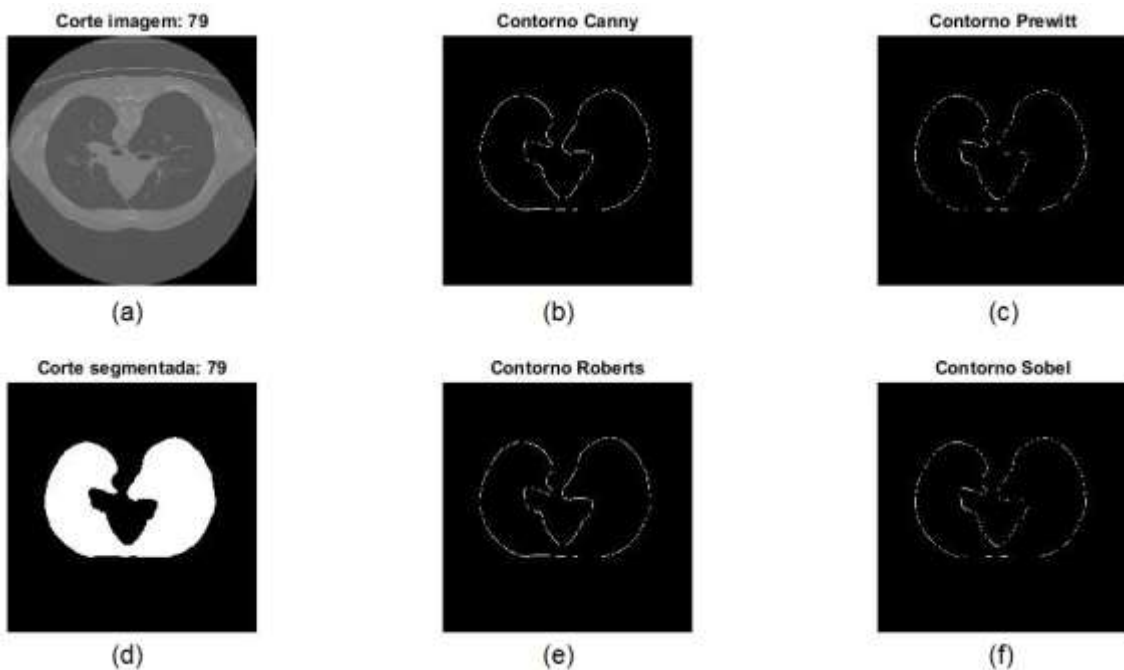


Figura 32 – Exemplo de aplicação de diferentes operadores de deteção de contornos a uma imagem de um corte do conjunto de dados de TC binária (a) Imagem original; (b) Contorno *Canny*; (c) Contorno *Prewitt*; (d) Imagem segmentada (e) Contorno *Roberts*; (f) Contorno *Sobel*

Uma vez que a deteção de contorno *Canny* é conhecido por muitos como o detetor de contornos ideal, é este operador que se usa nesta dissertação. Este contorno será aplicado à segmentação da imagem de um corte do conjunto de dados de TC efetuada neste trabalho e à máscara disponibilizada na base de dados, seguida de uma análise qualitativa das imagens. Esta abordagem surge descrita no capítulo 4 – Resultados.

3.3. Cálculo de volume pulmonar

Quando se visualiza uma imagem de TC observa-se vários elementos de volume (voxels) da fatia de corte reconstruída. Cada voxel é representado na matriz bidimensional (dados brutos da imagem) pelo menor elemento da imagem (pixel), sendo que a altura do voxel é a própria espessura de corte (Hsieh, J.,2003).

Os conjuntos de dados de TC utilizados neste trabalho são constituídos por um conjunto de várias imagens correspondentes a cortes do tórax do paciente, como indicado esquematicamente na figura 33. Estas imagens têm uma resolução espacial de 512x512 pixels e podem ser consideradas como um volume, com a terceira dimensão a variar entre 50 e 400.




Figura 33 – Representação esquemática de uma imagem de TC constituída por várias secções transversais da zona torácica. (Silva, J. S. et al. 2001).

O método desenvolvido para calcular o volume dos pulmões, processa os cortes que compõem a imagem de TC em duas fases: A primeira corresponde a uma análise a duas dimensões, em que cada corte é processado independentemente dos cortes restantes. Através do empilhamento dos cortes pulmonares obtidos em todas imagens tratadas, pelos processos descritos anteriormente, obtém-se uma estimativa para o volume de voxels correspondente aos pulmões.

A figura 34 mostra imagens de 5 cortes de um conjunto de dados de TC, com identificação dos pulmões, esquerdo (2ª linha), direito (3ª linha) e de ambos (4ª linha).




Figura 34 – Exemplo de imagens de cortes do conjunto de dados de TC (primeira linha) usados para estimar os volumes. Pulmão esquerdo (segunda linha), pulmão direito (terceira linha) e ambos (quarta linha)

Desta forma, o volume dos pulmões é obtido através do empilhamento das imagens binárias dos vários cortes, ou seja, é feito o cálculo bidimensional em cada corte do pulmão e o volume é obtido acumulando esse valor ao longo dos cortes. Este procedimento é aplicado aos sucessivos cortes do pulmão esquerdo, obtendo-se o volume do pulmão esquerdo, de forma análoga encontra-se o volume do pulmão direito e, no final, somam-se estes valores e obtém-se o volume pulmonar total. Este método aplica-se à imagem dos cortes do conjunto de dados de TC segmentada neste trabalho e à máscara disponibilizada na base de dados, seguida de uma análise quantitativa dos volumes obtidos. No capítulo 4 apresentam-se os resultados deste processo.

4. Resultados

Neste capítulo são apresentados os resultados da avaliação experimental, baseada na metodologia desenvolvida e descrita no capítulo 3. Desta forma, numa secção é feita uma avaliação da segmentação, com a exposição de casos práticos mais relevantes e, noutra secção, são apresentados os resultados sobre o volume pulmonar e a análise dos erros entre os volumes pulmonares das imagens segmentadas e das máscaras fornecidas.

4.1. Avaliação da segmentação pulmonar

A segmentação pulmonar, como etapa do processo de análise automática de imagens, assumiu um papel preponderante no cálculo dos volumes pulmonares. Pelos resultados que serão expostos na próxima secção e pelos casos práticos que serão apresentados nesta secção pode-se assumir que a segmentação efetuada ao longo do projeto foi ajustada resultando numa boa aproximação entre as imagens obtidas (segmentadas) e as imagens fornecidas (máscara).

A binarização das imagens mostrou-se uma técnica eficiente e a determinação do limiar, T – *threshold*, foi um método útil para a partição dos histogramas em duas partes, uma vez que todos apresentavam dois picos de intensidade. Fazendo um levantamento dos valores T – *threshold* usados neste trabalho, constatou-se que, em todas as imagens tratadas, este limiar oscila entre dois valores, 0,4196 e 0,4235 numa escala de intensidades de cinzento entre 0 e 1.

Depois da extração dos valores T – *threshold*, seguiu-se a metodologia descrita no capítulo 3. Ou seja, pela partição do histograma e aplicação do operador morfológico fecho obtém-se a imagem binária segmentada, explora-se os contornos, pelo operador Canny e faz-se a sobreposição das imagens para avaliar, visualmente, a segmentação efetuada.

Nesta secção explora-se a visualização dos casos mais relevantes, quer pela boa aproximação entre a segmentação efetuada nas imagens dos cortes do conjunto de dados de TC e as máscaras disponibilizadas na base de dados, quer pelas maiores discrepâncias observadas.

❖ Avaliação da segmentação de imagens de TC da tarefa MDR

Nesta tarefa o caso que se destaca pela positiva, ou seja, por uma boa aproximação entre a imagem segmentada e a imagem máscara de referência, é a imagem do conjunto de dados TC MDR_007. A figura 35 ilustra os passos principais do processo de segmentação, que culmina com uma boa sobreposição das duas imagens, segmentada e máscara, na imagem original.

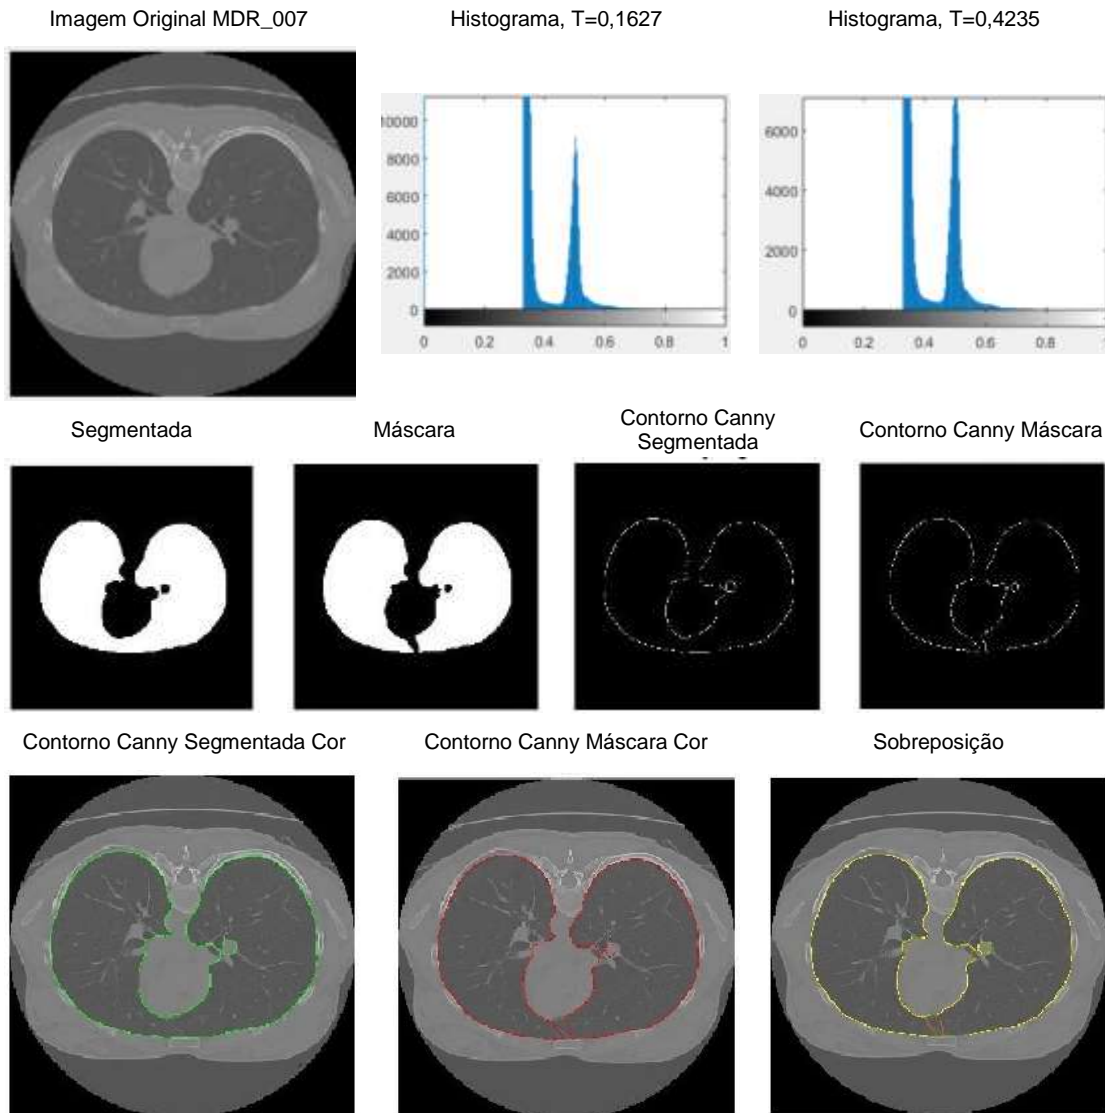


Figura 35 – Esquema de segmentação de uma imagem do conjunto de dados TC, MDR_007

Note-se que na etapa denominada por *Sobreposição* o contorno é, quase na totalidade, amarelo, que resulta da sobreposição do contorno verde, da imagem segmentada, e do contorno vermelho, da imagem máscara. Este é um exemplo de uma boa segmentação que, como vamos constatar na subsecção seguinte, justifica a proximidade dos valores no cálculo do volume pulmonar.

Quanto ao caso de maior disparidade entre a imagem segmentada e a imagem máscara de referência, é a imagem do conjunto de dados TC MDR_004. A figura 36 ilustra as etapas principais do processo de segmentação, que culmina com uma imagem da sobreposição das duas imagens, segmentada e máscara, na imagem original, da qual será extraída uma subimagem para evidenciar as principais diferenças.

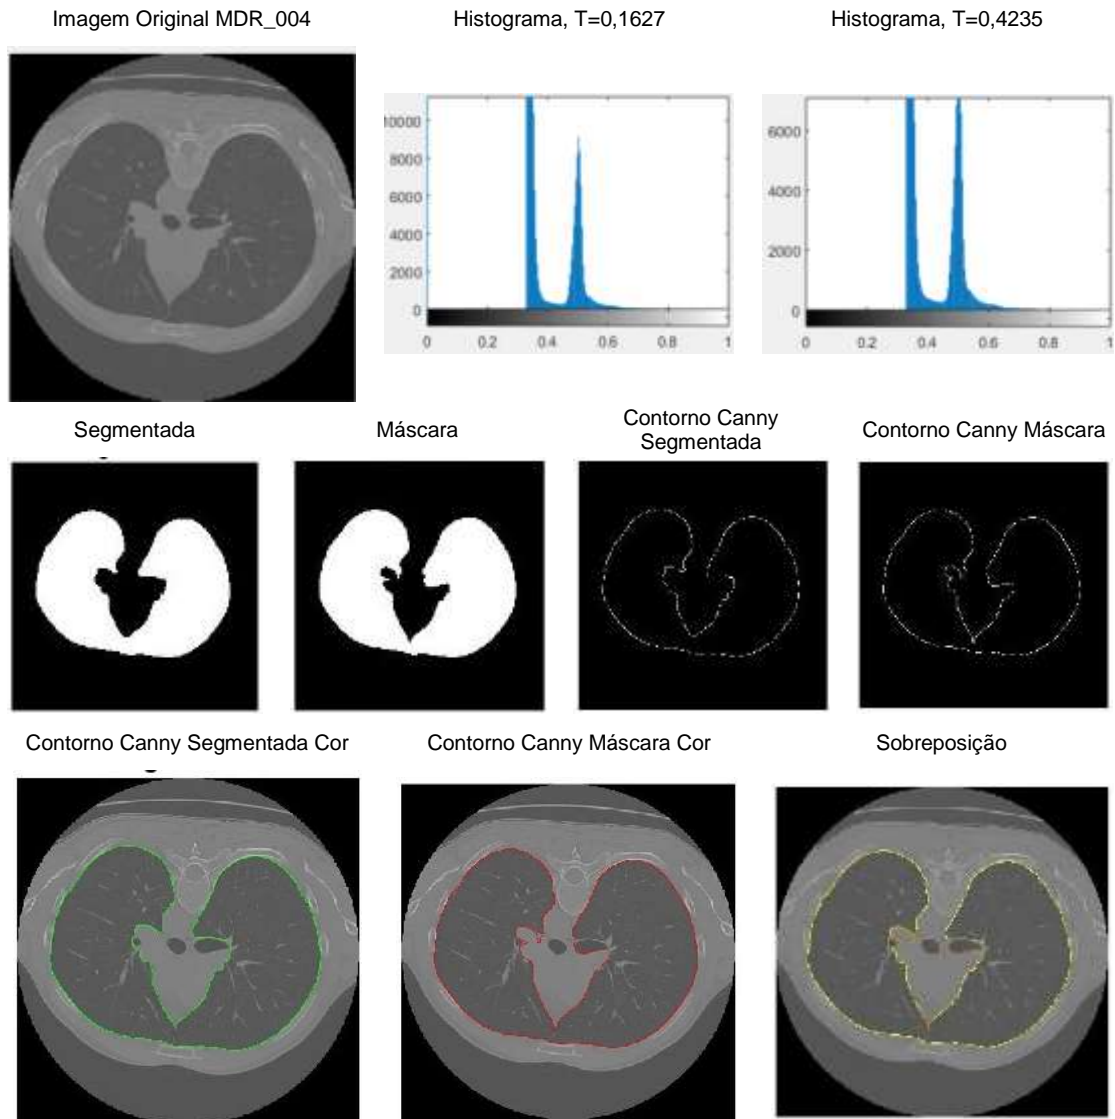


Figura 36 – Esquema de segmentação de uma imagem do conjunto de dados TC, MDR_004




Figura 37 – Contornos peculiares na imagem MDR_004

As principais descoincidência nos contornos são evidenciadas na figura 37, onde se pode visualizar que, nesta zona, há contornos vermelhos e verdes logo, não coincidentes. Numa etapa da segmentação, extração dos dois maiores objetos, o procedimento abordado exclui a pequena mancha à direita, o que fundamenta os erros detetados e explica a melhor aproximação do contorno vermelho, da máscara. Por outro lado, no contorno superior esquerdo, a imagem segmentada aproxima-se mais da imagem original, uma vez que o contorno verde está mais próximo do limite do pulmão.

❖ Avaliação da segmentação de imagens de TC da tarefa Tipo TB

Nesta tarefa o caso que se destaca pela positiva, ou seja, por uma boa aproximação entre a imagem segmentada e a imagem máscara de referência, é a imagem do conjunto de dados TC TBT_443. A figura 38 ilustra os passos principais do processo de segmentação, que culmina com uma ótima sobreposição das duas imagens, segmentada e máscara, na imagem original.

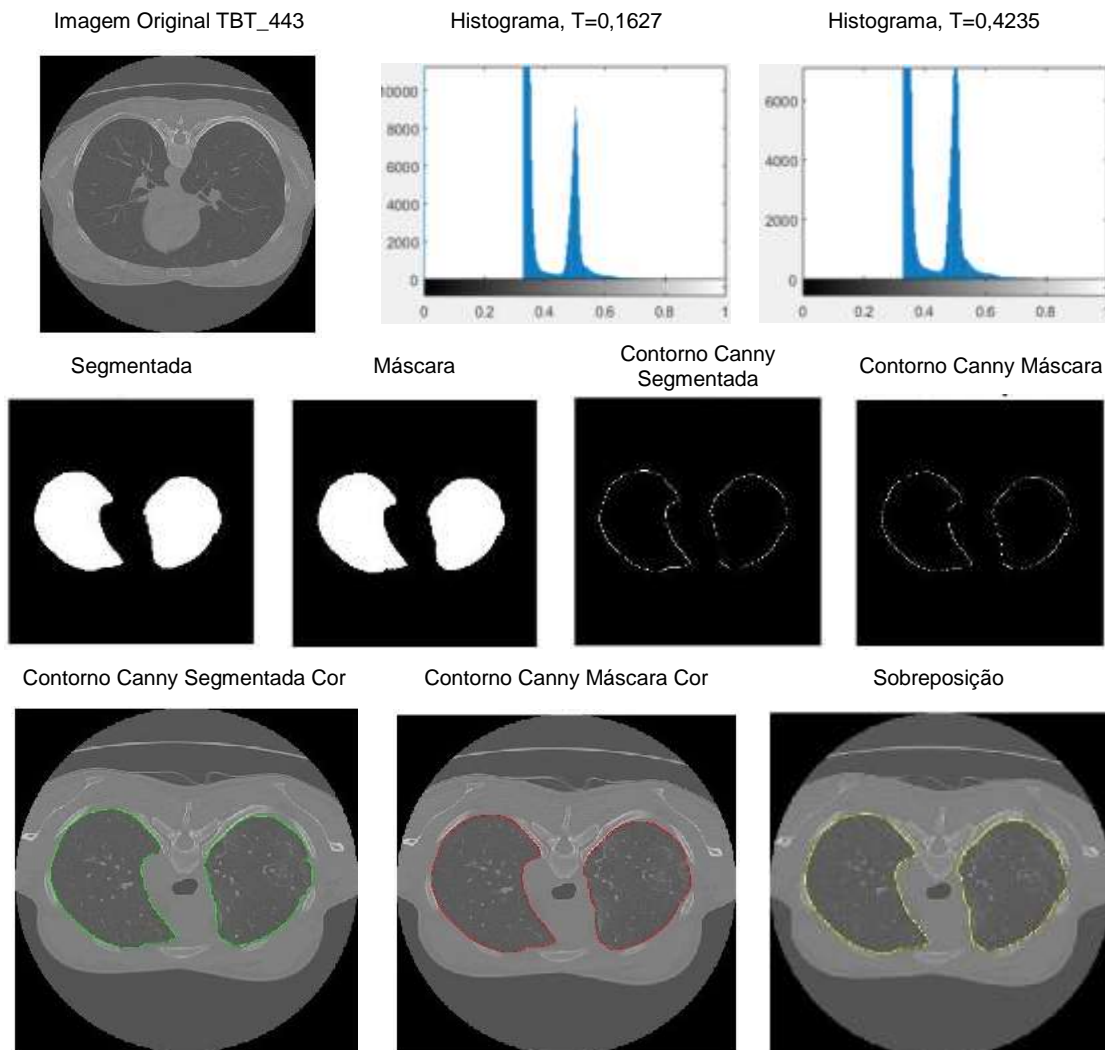


Figura 38 – Esquema de segmentação de uma imagem do conjunto de dados TC, TBT_443

Note-se que na última etapa, *Sobreposição*, o contorno surge a amarelo, que resulta de uma excelente sobreposição do contorno verde, da imagem segmentada, e do contorno vermelho, da imagem máscara.

Quanto ao caso de uma segmentação menos adequada entre a imagem segmentada e a imagem máscara de referência, é a imagem do conjunto de dados TC TBT_441. A figura 39 ilustra as etapas principais do processo de segmentação, que culmina com uma imagem da sobreposição das duas imagens, segmentada e máscara, na imagem original, da qual será extraída uma subimagem para evidenciar as principais diferenças.




Figura 39 – Esquema de segmentação de uma imagem do conjunto de dados TC, TBT_441




Figura 40 – Contornos peculiares na imagem TBT_441

Os principais desajustes nos contornos são evidenciados na figura 40, onde se pode visualizar que, nesta zona, há contornos vermelhos e verdes logo, não coincidentes. Na etapa extração dos dois maiores objetos, o procedimento abordado exclui as pequenas manchas à esquerda (acima do pulmão esquerdo) e à direita (à esquerda do pulmão direito), o que justifica os erros detetados. No entanto, a segmentação do pulmão esquerdo é mais aproximada que a máscara fornecida, pois o contorno verde está mais próximo dos limites do pulmão esquerdo.

Os casos apresentados nesta subsecção também serão relevantes na análise quantitativa dos volumes, como se poderá verificar na próxima subsecção.

4.2. Volume pulmonar

A avaliação quantitativa do volume pulmonar é comprometida por uma segmentação pulmonar desadequada, ou por outras palavras, se forem detetados valores muito desajustados na comparação dos volumes, possivelmente provêm de uma deficiente segmentação. Assim sendo, faz-se uma análise das estimativas do volume pulmonar obtidas neste trabalho, para tecer uma melhor avaliação da segmentação efetuada.

Para calcular o volume dos pulmões, processa-se os cortes que compõem a imagem de TC em duas fases: a primeira corresponde a uma análise a duas dimensões e, através do empilhamento dos cortes pulmonares, obtém-se uma estimativa para o volume de voxels correspondente aos pulmões.

❖ Volumes pulmonares de imagens de TC da tarefa MDR

As imagens do conjunto de dados da tarefa MDR foram submetidas ao método de cálculo de volumes, descrito na secção 2 do capítulo 3. A tabela 4 expõe os resultados obtidos no cálculo dos volumes pulmonares em imagens do conjunto de dados TC da tarefa MDR.

Imagem	Pulmão Esquerdo	Pulmão Direito	Pulmão	Máscara Esquerda	Máscara Direita	Máscara
MDR_001	2712196	3153551	5865747	2738667	3194648	5933315
MDR_002	3010095	3256308	6266403	2964852	3286107	6250959
MDR_003	2102384	2002288	4104672	2086652	2011488	4098140
MDR_004	4053228	4210744	8263972	4084392	4315048	8399440
MDR_005	2500900	2731400	5232300	2504800	2743400	5248200
MDR_006	3620430	3537114	7157544	3611738	3558844	7170582
MDR_007	3821796	4160700	7982496	3794688	4178628	7973316
MDR_008	2748615	2735967	5484582	2738013	2779305	5517318
Valores Médios	3071206	3223509	6294715	3065475	3258434	6323909

Tabela 4 – Volumes pulmonares de imagens do conjunto de dados TC da tarefa MDR

Da tabela 4, resulta que o volume do pulmão direito é maior que o volume do pulmão esquerdo, quer na imagem segmentada quer na imagem da máscara, em média cerca de 152303 voxels e 192959 voxels, respetivamente.

No que concerne a erros de cálculo dos volumes pulmonares, eles foram equacionados da seguinte forma:

$$Erro = \left| \frac{V_{segmentação} - V_{máscara}}{V_{máscara}} \right| \quad (1)$$

onde $V_{segmentação}$ é o volume pulmonar da imagem segmentada e $V_{máscara}$ é o volume pulmonar da máscara fornecida. Na tabela 5, podem-se analisar as percentagens de erro relativo cometidas nos cálculos em questão.

Imagem	Percentagem de erro		
	Esquerdo	Direito	Total
MDR_001	0,97%	1,29%	1,14%
MDR_002	1,53%	0,91%	0,25%
MDR_003	0,75%	0,46%	0,16%
MDR_004	0,76%	2,42%	1,61%
MDR_005	0,16%	0,44%	0,30%
MDR_006	0,24%	0,61%	0,18%
MDR_007	0,71%	0,43%	0,12%
MDR_008	0,39%	1,56%	0,59%
ERRO MÉDIO	0,69%	1,01%	0,54%
DESVIO MÉDIO	0,32%	0,56%	0,43%

Tabela 5 – Percentagens de erro relativo no cálculo dos volumes pulmonares de imagens do conjunto de dados TC da tarefa MDR

Da tabela 5, pode-se constatar que as percentagens de erros são baixas, em média aproximadamente 0,54%, o que transmite uma boa apreciação da segmentação efetuada. Note-se ainda que, a percentagem de erro relativo e de desvio medio são maiores no pulmão direito.

Os resultados coloridos a vermelho e a verde representam a pior e a melhor percentagem de erro, respetivamente. Estes casos particulares foram explorados na secção anterior, avaliação da segmentação, onde se analisaram as imagens que justificam a discrepância, no caso da imagem do conjunto de dados TC MDR_004, e a boa aproximação, no caso da imagem do conjunto de dados TC MDR_007.

❖ Volumes pulmonares de imagens de TC da tarefa Tipo TB

Analogamente ao que foi realizado para as imagens do conjunto de dados da tarefa MDR, as imagens da tarefa Tipo TB, também foram submetidas ao método de cálculo de volumes supracitado e, na tabela 6, mostram-se os resultados obtidos.

Imagem	Pulmão Esquerdo	Pulmão Direito	Pulmão	Máscara Esquerda	Máscara Direita	Máscara
TBT_001	2270700	3503490	5774190	2281314	3522804	5804118
TBT_002	3606174	3548961	7155135	3629223	3579264	7208487
TBT_003	3773718	3820869	7594587	3772431	3846375	7618806
TBT_141	3894134	4419296	8313430	3918441	4427798	8346239
TBT_142	2323152	2688712	5011864	2456168	2695888	5152056
TBT_143	2876432	3309176	6185608	2983864	3333408	6317272
TBT_261	2869344	2837952	5707296	2877216	2820576	5697792
TBT_262	3330059	3446035	6776094	3295179	3454864	6750043
TBT_263	1561056	1806587	3367643	1607112	1823050	3430162
TBT_361	2368800	2896896	5265696	2480064	2932608	5412672
TBT_362	2808416	2941744	5750160	2759120	2958280	5717400
TBT_363	3016894	2972759	5989653	3047546	2924647	5972193
TBT_441	656880	2644448	3301328	890192	2725684	3615876
TBT_442	3272725	11881	3284606	3216263	11990	3228253
TBT_443	2264152	1982024	4246176	2262656	1983608	4246264
Valores Médios	2726176	2855389	5581565	2765119	2869390	5634509

Tabela 6 – Volumes pulmonares de imagens do conjunto de dados TC da tarefa Tipo TB

No que respeita a erros de cálculo dos volumes pulmonares, eles foram igualmente obtidos usando a fórmula (1). Na tabela 7, podem-se analisar as percentagens de erro cometidas nos cálculos em questão.

Imagem	Percentagem de erro		
	Esquerdo	Direito	Total
TBT_001	0,47%	0,55%	0,52%
TBT_002	0,64%	0,85%	0,74%
TBT_003	0,03%	0,66%	0,32%
TBT_141	0,62%	0,19%	0,39%
TBT_142	5,42%	0,27%	2,72%
TBT_143	3,60%	0,73%	2,08%
TBT_261	0,27%	0,62%	0,17%
TBT_262	1,06%	0,26%	0,39%
TBT_263	2,87%	0,90%	1,82%
TBT_361	4,49%	1,22%	2,72%
TBT_362	1,79%	0,56%	0,57%
TBT_363	1,01%	1,65%	0,29%
TBT_441	26,21%	2,98%	8,70%
TBT_442	1,76%	0,91%	1,75%
TBT_443	0,07%	0,08%	0,00%
ERRO MÉDIO	3,35%	0,83%	1,54%
DESVIO MÉDIO	3,51%	0,47%	1,40%

Tabela 7 – Percentagens de erro relativo no cálculo dos volumes pulmonares em imagens do conjunto de dados TC da tarefa Tipo TB

Desta tabela pode-se constatar que as percentagens de erro são superiores, em média, às percentagens obtidas na tarefa MDR, mas ainda assim são baixas, em média aproximadamente 1,54%, o que transporta uma boa apreciação da segmentação efetuada. De referir que, a percentagem de erro relativo é maior no pulmão esquerdo, e é também neste que se verifica um maior desvio médio. Estes resultados são influenciados pela discrepância de valores obtidos na imagem TBT_441, pelo que, se se excluir os dados desta imagem, os erros são menores, como é mostrado na tabela 8.

ERRO MÉDIO	1,72%	0,67%	1,03%
DESVIO MÉDIO	1,37%	0,32%	0,85%

Tabela 8 – Percentagens de erro relativo no cálculo dos volumes pulmonares em imagens do conjunto de dados TC da tarefa Tipo TB, sem o caso particular TBT_441

Os resultados, da tabela 7, coloridos a vermelho e a verde representam a pior e a melhor percentagem de erro, respetivamente. Estes casos particulares também foram explorados na secção anterior, com o objetivo de observar as imagens do conjunto de dados TC que justificam a discrepância, no caso da imagem TBT_441, e a boa aproximação, no caso da imagem TBT_443.

5. Conclusão

O tema desta dissertação, foi a análise automática de imagens pulmonares de tomografia computadorizada. A fase de segmentação da imagem assumiu um papel decisivo na análise automática de imagens pulmonares de TC. Entre os algoritmos de segmentação foi escolhido a binarização, usando uma versão modificada do método de *Thresholding* Global uma vez que as características das imagens conduziam à partição dos histogramas em dois intervalos distintos. Aqui o objetivo foi introduzir um método automatizado de segmentação que resultasse em menos erros e melhor desempenho. Considerando que a área segmentada deve, pelo menos, representar uma estimativa do órgão alvo para que os algoritmos de reconhecimento possam reconhecê-la, surge a aplicabilidade dos operadores morfológicos. Portanto, o mais desejável é minimizar o erro de segmentação, sendo por isso a utilização do operador fecho adequado para suavizar as fronteiras, eliminar pequenos buracos e preencher pequenas falhas ao longo dos contornos. Este estudo enquadrou-se numa perspectiva de contribuição para a detecção precoce de nódulos pulmonares, pois esta continua a ser a maneira mais eficiente de identificar patologias na região dos pulmões (Alilou M. et al.,2014).

O desempenho do método proposto foi avaliado qualitativa e quantitativamente em imagens pulmonares do conjunto de dados TC, para cada uma das tarefas propostas MDR (multirresistente a medicamentos) e Tipo TB (tipo de tuberculose). Os resultados obtidos no cálculo de volumes pulmonares foram consistentes, uma vez que na tarefa MDR o erro relativo foi de aproximadamente 0,54%, com um desvio medio de cerca de 0,43% e na tarefa Tipo TB o erro relativo foi de aproximadamente 1,54%, com um desvio médio de 1,40%.

Em suma, apesar da metodologia descrita ter sido desenvolvida especificamente para avaliar o desempenho dos métodos de segmentação pulmonar e cálculo de volumes pulmonares, a presente dissertação tenciona ser uma mais-valia no sentido de ser suficientemente abrangente para ser usada em outros cenários de segmentação de imagens médicas.

O estudo apresentado não se encontra de modo algum fechado, dado que os conhecimentos adquiridos durante todo o desenvolvimento deste projeto podem ser ampliados. Assim, e de forma a aperfeiçoar o estudo desenvolvido e de forma a continuá-lo, são apresentadas algumas sugestões para trabalhos futuros:

❖ Terminada a etapa da segmentação pulmonar a proposta é dar continuidade ao processo de identificação de nódulos, avançando para a identificação de nódulos candidatos, a classificação e a visualização. Ou seja, dentro das regiões pulmonares segmentadas, os nódulos candidatos são identificados com extração de características de textura e densidade, por exemplo, seguindo-se as etapas de classificação e visualização final.

❖ Outra futura direção de trabalho é o refinamento da segmentação dos nódulos detetados que pode ser levado a cabo através da utilização de agentes reajustáveis baseados em gradiente que é proposto em Alilou e Kovalev (2013). Além disso, uma vez que a estrutura é capaz de detetar nódulos sólidos sem determinar o tipo de nódulos detetados (isto é, se um nódulo detetado é maligno ou benigno), uma futura opção de investigação poderia ser investigar uma solução que permitisse avaliar a opacidade e a consistência da parte sólida dos nódulos e refinar o método para este ser capaz de distinguir entre nódulos benignos e malignos.

6. Bibliografia

- ☞ Abbasi T.A.; Abbasi M.U. (2007). *A novel FPGA-based architecture for Sobel edge detection operator*, *International Journal of Electronics*, 13(9), 2007, 889-896.
- ☞ Alilou M., Kovalev V., Snezhko E., Taimouri V. (2014). *A comprehensive framework for automatic detection of pulmonary nodules in lung ct images*. *Image Anal Stereol* 2014 33:13-27.
- ☞ Avazpour I., Saripan M., Nordin A., Abdullah R. (2013). *Segmentation of Extrapulmonary Tuberculosis Infection Using Modified Automatic Seeded Region Growing*. Shulin Li (ed.), *Biological Procedures Online*, Volume 11, Number 1.
- ☞ Canny J., *A Computational Approach to Edge Detection*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6), 1986, 679-6987
- ☞ CLEF 2016; Conference and Labs of the Evaluation Forum; *Information Access Evaluation meets Multilinguality, Multimodality, and Interaction*; <http://clef2016.clef-initiative.eu/>, consultado em setembro 2017.
- ☞ CLEF 2017; Conference and Labs of the Evaluation Forum; *Information Access Evaluation meets Multilinguality, Multimodality, and Visualization*; <http://clef2017.clef-initiative.eu/>, consultado em setembro 2017.
- ☞ Gonzalez, R. C.; Woods, R. E.; Eddins, S. L. (2004). *Digital image processing using MATLAB*; Pearson Prentice Hall.
- ☞ Gonzalez, R. C.; Woods, R. E. (2008). *Digital image processing*; Pearson Prentice Hall.
- ☞ Hsieh, J. (2003). *Computed Tomography: Principles, Design, Artifacts, and Recent Advances*, 1st ed. SPIE Publications.
- ☞ Herrera, A. G. S.; Schaer, R.; Bromuri, S.; Muller, H.; *Overview of the ImageCLEF 2016 Medical Task*.
- ☞ ImageCLEF a); ImageCLEF/LifeCLEF – Multimedia Retrieval in CLEF; <http://www.imageclef.org/2017/>; consultado em setembro 2017.
- ☞ ImageCLEF b); ImageCLEF/LifeCLEF – Multimedia Retrieval in CLEF; <http://www.imageclef.org/2017/tuberculosis>, consultado em setembro 2017.
- ☞ Lakshmi D., Santhosham R., Ranganathan H. (2013). *Anfis in the characterization of fibrosis and carcinoma using lung ct images*. *Indian Journal of Computer Science and Engineering (IJCSE)* Vol. 4 No.4.

- ☞ Lakshmi D., Santhosham R., Ranganathan H. (2013). *Non-Invasive Method of Characterization of Fibrosis and Carcinoma Using Low-Dose Lung CT Images*. IEEE International Conference on Systems, Man, and Cybernetics.
- ☞ Lim, D.H. *Robust Edge Detection In Noisy Images, Computational Statistics & Data Analysis*, 96(3), 2006, 803-812.
- ☞ Marçal, A.R.S. (2017). *Apontamentos das aulas de Análise e Processamento de Imagem (M4031), Faculdade de Ciências da Universidade do Porto*.
- ☞ Silva, J. S.; Santos, B. S.; Silva, A.; Teixeira, L. (2001). *Identificação, Quantificação e Visualização de Bolhas Pulmonares a partir de Imagens de TAC*.
- ☞ Skoura, E. et al. (2015). *International Journal of Infectious Diseases* 32 87–93.
- ☞ Sonka, M.; Hlavac, V.; Boyle, Roger (2008); *Image processing, analysis, and machine vision; Thomson Learning*.
- ☞ Swanly V., Selvam L., Kumar P., Renjith J., Arunachalam M., Shunmuganathan K. (2013). *Smart Spotting of Pulmonary TB Cavities Using CT Images. Computational and Mathematical Methods in Medicine Volume 2013, Article ID864854, 12pages*.
- ☞ Xu Z., Bagci U., Kubler A., Luna B., Jain S., Bishai W., Mollura D. (2013). *Computer-aided detection and quantification of cavitary tuberculosis from CT scans. Medical Physics, Vol. 40, No. 11, November 2013*.

