

SEGMENTAÇÃO DE IMAGENS PARA EXTRAÇÃO DE CARACTERÍSTICAS DE LESÕES PULMONARES

Douglas Samuel Gonçalves¹, Geraldo Henrique Neto¹, Rodrigo de Oliveira Plotze¹

¹Faculdade de Tecnologia de Ribeirão Preto (FATEC)

Ribeirão Preto, SP – Brasil

douglas.goncalves13@fatec.sp.gov.br,

geraldo.henrique@fatec.sp.gov.br,

rodrigo.plotze@fatec.sp.gov.br

Resumo. *O objetivo do sistema detalhado nesse artigo é utilizar da segmentação de imagens para extrair características de possíveis lesões pulmonares a partir de tomografias computadorizadas. Características previamente selecionadas que são utilizadas no processo de classificação das possíveis lesões encontradas, tornando mais preciso o diagnóstico médico.*

Abstract. *The objective of the system detailed in this paper is to use image segmentation to extract characteristics of possible pulmonary lesions from computed tomography. Previously selected characteristics that characteristics are used in the classification process of lesions found, make the medical diagnosis more accurate.*

1. Introdução

Segundo dados do INCA (Instituto Nacional de Câncer) (2022b), em 2020 o câncer de pulmão foi responsável pela maior taxa de mortalidade dentre os homens. Sendo estimada uma incidência de 225.980 casos de neoplasias (exceto pele não melanoma) e desses, o câncer de traqueia, brônquio e pulmão foi o que apresentou a quarta maior incidência dentre a população masculina brasileira com 17.760 casos.

De acordo com o INCA (Instituto Nacional de Câncer) (2022a), é de grande importância a detecção da lesão em seu estágio inicial, pois os tratamentos de estágio avançado geram uma série de efeitos colaterais. A confirmação inicial da doença, se dá pela realização de dois exames: Raio-X do tórax e tomografia computadorizada. Tendo confirmada a suspeita, são realizados exames para avaliar os estágios da doença, como: broncoscopia, biópsia, PET-CT, dentre outros.

Para auxiliar na precisão do diagnóstico inicial e permitir um tratamento com menos chance de mortalidade, são utilizados os esquemas CAD (*Computer-Aided Diagnose*). Esquemas que possibilitam realizar a análise das tomografias feitas e retornar um parecer do sistema sobre a lesão em evidência, que será utilizado pelo profissional da área médica como um dos fatores para seu diagnóstico final.

Para diagnósticos realizados com base em imagens, o esquema CAD possui um padrão onde a imagem é obtida, é realizado o pré-processamento, a segmentação, a extração de características (prática denominada, *radiomics*) e essas serão utilizadas por outros sistemas ou pelos próprios profissionais que irão diagnosticar o paciente. Evitando falhas humanas ou características que são de difíceis extração a olho nu ou sem equipamentos que normalmente não estão disponíveis para a rede pública.

2. Referencial Teórico

2.1. CAD

Como demonstrado por Doi (2007), o conceito de diagnóstico automático por computador já era discutido em 1960, porém, com a falta de tecnologia na época, acabou não sendo levado adiante. Por volta de 1980 é retomada essa discussão e os primeiros esquemas para detecção de lesões são criados, suas primeiras aplicações em mamografias e radiografias de tórax resultaram em um alto número de falso-positivos, levantando a questão se realmente o computador poderia substituir os médicos.

Ainda em 1980, foi realizado um estudo para avaliar o desempenho médico em conjunto com os primeiros esquemas de detecção de lesões, agindo apenas como uma “segunda opinião”. O resultado, um aumento significativo no desempenho médico, chegando à conclusão de que a ideia não deveria ser descartada, apenas reformulada e dessa maneira é criado o conceito de CAD (*Computer-Aided Diagnose*).

Conforme descrito por Gonzales e Woods (2010), os olhos humanos são passíveis a ilusões de ótica e outros fenômenos da percepção, esses geram diferença entre o que a imagem está demonstrando e o que é captado pelo interpretador dela.

Esses efeitos e outros como a avaliação interpessoal que é detalhada por Azevedo-Marques (2010), não acontecem com computadores, pois a imagem se torna uma matriz de *pixels* e é isso que o esquema CAD irá utilizar. Uma situação semelhante ocorre com os computadores, uma lesão de fácil detecção para um médico experiente, pode ser indetectável para o computador.

Dessa maneira, é possível visualizar que trabalhando em conjunto, o esquema CAD realiza a avaliação inicial do exame, levantando características e classificando as lesões. Posteriormente o médico responsável irá realizar sua análise, complementando ou editando o que foi proposto pelo sistema.

2.2. Radiomics

Como descrito por Gillies *et al.* (2015), *radiomics* é a prática conhecida por transformar imagens em dados que estão diretamente relacionados com a fisiopatologia de uma doença ou anomalia de um órgão. Diferente dos esquemas CAD, essa prática apenas extrai uma imensa quantidade de informação de uma imagem que serão utilizadas posteriormente para análise, normalmente junto com características e rotinas do indivíduo.

Radiomics são majoritariamente aplicados na área da oncologia, visto que o resultado gerado por laboratórios é baseado no genoma e proteomas analisados, enquanto a análise por imagens é baseada em volume, tamanho, forma e outras características.

O processo consiste em obter a imagem, determinar as regiões de interesse — onde se localizam as lesões —, delimitar as bordas das lesões, extrair as características e realizar a análise dessas.

Para obtenção das imagens, existem diversos bancos de dados abertos para uso acadêmico, para definir as regiões de interesse, delimitar bordas e extrair características é utilizado o processamento de imagens — que será descrito mais à frente.

As características que serão extraídas, são as elaboradas pelo *American College*

of Radiology Committe (2019) existentes no Lung-RADS.

3. Processamento Digital de Imagens

Segundo Gonzalez e Woods (2010), o emprego de técnicas computacionais para processamento de imagens teve início em 1964. Sendo utilizadas para corrigir distorções das imagens transmitidas pela *Ranger 7*, a sonda espacial que capturou as primeiras imagens da Lua.

Atualmente utilizamos do processamento digital em diversas rotinas, seja para correção de fotos ou em níveis industriais para capturar falhas nos produtos no seu estágio final de confecção, garantindo que o produto atenda a determinado padrão de qualidade.

É possível visualizar na Figura 1 um diagrama do processamento de imagens, nem todas as etapas são obrigatórias pois variam de acordo com o domínio de cada problema. Ao que tange a utilização de tomografias computacionais para extração de características pulmonares, é comum a passagem pelas etapas: Aquisição de Imagens, Filtragem e realce de imagens, Segmentação e Representação e descrição.

Assim, é um recurso de suma importância pois permite realizar exames de alta complexidade como a tomografia computadorizada, que é um dos exames essenciais para diagnosticar as lesões pulmonares.

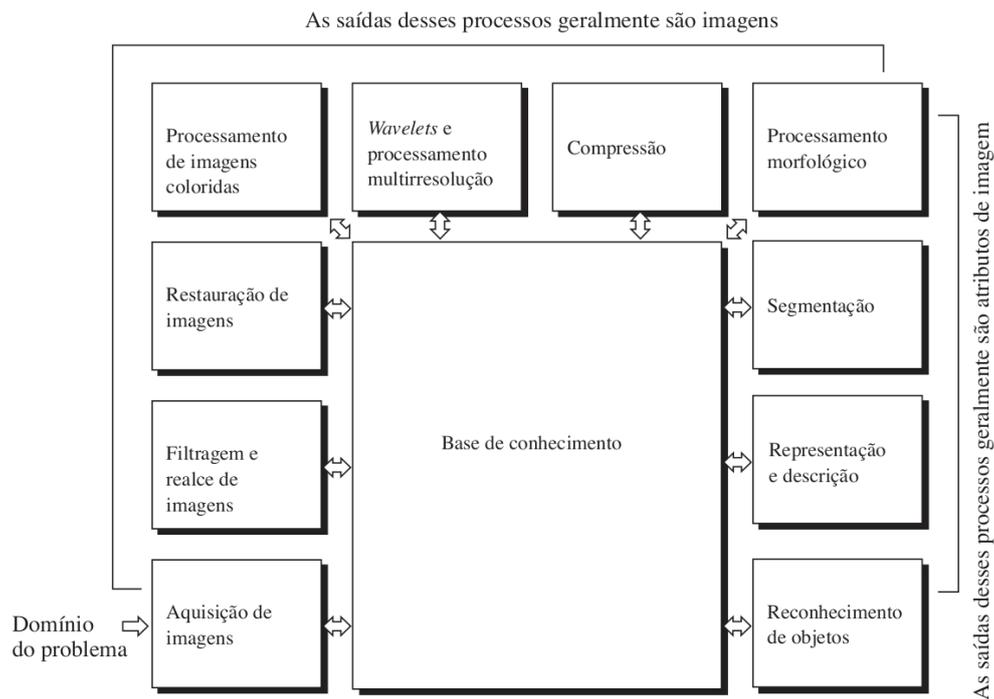


Figura 1. Passos fundamentais em processamento digital de imagens.
 Autor: Gonzales e Woods (2010)

3.1. Aquisição de Imagens

A aquisição de imagens é a base para os esquemas CAD, para o diagnóstico de lesões pulmonares, utilizamos principalmente a tomografia computadorizada.

Descrito por Posses (2020), o processo para obter uma tomografia

computadorizada avançou conforme os anos, com o intuito de diminuir o tempo para realização do exame. Porém, sempre seguiu o mesmo princípio, o paciente é posicionado deitado em uma mesa e essa se desloca para dentro do *Gantry* (um tubo onde estão os principais componentes do tomógrafo) e então um conjunto de tubos emissores de raio x, emitem radiação que é atenuada pelo paciente e por fim chega aos detectores que recebem o remanescente de radiação.

Esse remanescente é convertido em sinais elétricos que serão enviados aos computadores e nesse momento ocorre o processamento das imagens. Tornando os sinais elétricos em imagens legíveis para o ser humano.

Atualmente existem centenas de *dataset* disponíveis para uso acadêmico, isso pois instituições e comitês como a RSNA (*Radiological Society of North America*), RIC (*Radiology Informatics Committee*), NIH (*National Cancer Institute*) e FDA (*Food and Drug Administration*), apoiam de maneira assídua a criação de esquemas CAD para fornecer diagnósticos precisos para o câncer de pulmão.

Nesse artigo será utilizado o *dataset* LIDC-IDRI elaborado por Armato *et al.* (2011) que é disponibilizado no TCIA idealizado por Clark *et al.* (2013), que possui 1018 casos, sendo cada caso uma tomografia computadorizada e um *XML* com o resultado do diagnóstico que foi cedido por um conjunto de radiologistas. Dessa maneira, é possível realizar o processamento pelo esquema CAD e validar as lesões encontradas pelo sistema com as encontradas pelo especialista.

3.2. Pré-Processamento

Antes de iniciarmos a identificação das regiões de interesse, é necessário realizar o pré-processamento. Essa etapa é importante para remover ruídos da imagem, realizar conversões necessárias e tornar ela mais uniforme e nítida para que se possa enxergar com mais clareza as lesões.

Como descrito por Gonzalez e Woods (2010), não existe um padrão para essa etapa, diferentes domínios de problema possuem respectivas tratativas para filtragem e realce da imagem. Após testes com diferentes conjuntos de filtros, foi escolhido o filtro 2D cuja fórmula é discriminada abaixo

$$\text{dst}(x, y) = \sum_{\substack{0 \leq x' < \text{kernel.cols} \\ 0 \leq y' < \text{kernel.rows}}} \text{kernel}(x', y') * \text{src}(x + x' - \text{anchor.x}, y + y' - \text{anchor.y}) \quad (1)$$

A imagem é subdividida em quadrantes de mesma ordem de *kernel*, que é uma matriz quadrada de ordem ímpar e *anchor* é o ponto central do quadrante da imagem onde o filtro está sendo aplicado.

Para converter a imagem recebida no formato DICOM para o padrão utilizando Hounsfield Unit (HU) — onde cada pixel da imagem possui valores na faixa de -1000 a 4000+ — é utilizada a fórmula descrita na fórmula abaixo

$$\text{HU} = \text{pixel} * \text{slope} + \text{intercept} \quad (2)$$

Onde *pixel* é o ponto da imagem onde a conversão está sendo realizada, *slope* e *intercept* são informações contidas no arquivo DICOM da fatia em estudo.

Com base nesse padrão, é possível distinguir com mais facilidades as estruturas que compõem as tomografias computadorizadas, pois de acordo com Razi, Niknami e Ghazani (2014) os pontos com maior valor são aqueles onde a radiação emitida pelo

aparelho é mais atenuada, como estruturas ósseas e os pontos com menor valor são locais com maior concentração de tecidos finos e ar.

3.3. Segmentação de Imagens

A segmentação de imagens é o processo na qual ocorre a subdivisão da imagem em regiões ou objetos de interesse. Nessa situação, é necessário realizar a segmentação para destacar as lesões encontradas nas tomografias.

Destacado por Gonzalez e Woods (2010), os algoritmos de segmentação são baseados nos níveis de intensidade da imagem que possuem duas propriedades: descontinuidade e similaridade. Onde a descontinuidade busca mudanças abruptas no nível de intensidade para determinar onde se localiza o objeto e a similaridade busca níveis de intensidades próximos para realizar o crescimento de região e determinar a área do objeto.

4. Segmentação

Tomando como base as premissas anteriores, para a segmentação das imagens nesse artigo serão realizado os passos: realizar a limiarização da imagem para remover parte das estruturas não desejadas, preencher a região externa do pulmão, utilizar da dilatação seguida da erosão para reduzir o ruído na área externa da região de interesse, preenchimento da área interna dos pulmões, reconhecimento das bordas dos objetos restantes, aplicação da operação “AND” para gerar uma imagem apenas com os objetos de interesse e por fim é realizado a análise de cada objeto contido nessa última imagem.

4.1. Limiarização (*Threshold*)

Como destacado por Neto, Ribeiro e Valeri (2004), a limiarização é o processo de dividir a distribuição de intensidade da imagem, seja por um valor limite definido de maneira fixa ou de forma adaptativa conforme os níveis de intensidade da imagem. A saída desse processo é uma imagem binária (preta e branca). Exemplo desse processo é a Figura 2, onde a imagem já em escala HU é limiarizada em -260, ou seja, valores menores que -260 serão zerados e valores superiores serão definidos como 1.

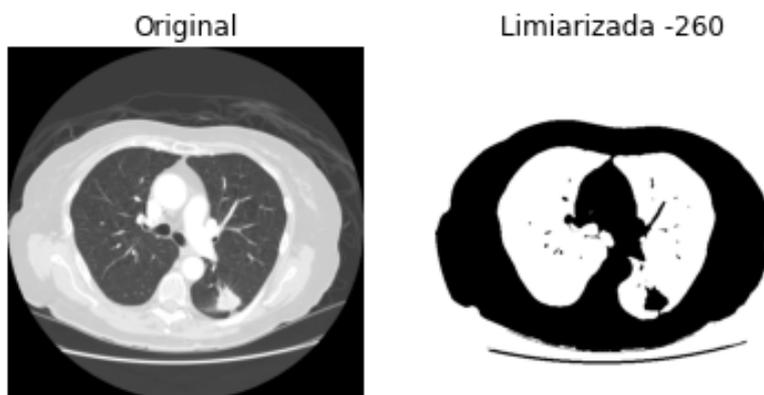


Figura 2. Exemplo de limiarização em -260
Fonte: Autoria Própria (2022)

4.2. Preenchimento por Inundação (*Flood Fill*)

Como descrito e implementado por Walt et al. (2014), o preenchimento por inundação é

um algoritmo que recebe um ponto da imagem, o novo nível de intensidade e a tolerância, o novo nível é aplicado para todos os pontos ao redor do ponto escolhido — normalmente denominado *seed* — enquanto o ponto em estudo estiver dentro da tolerância para mais ou para menos em comparação com a intensidade da *seed*.

É possível encontrar exemplos desse algoritmo em softwares de edição de imagem que possuem a ferramenta “balde de pintura”. A Figura 3 demonstra um exemplo com uma imagem binária, com *seed* em (1, 1), intensidade 0 e tolerância 0.

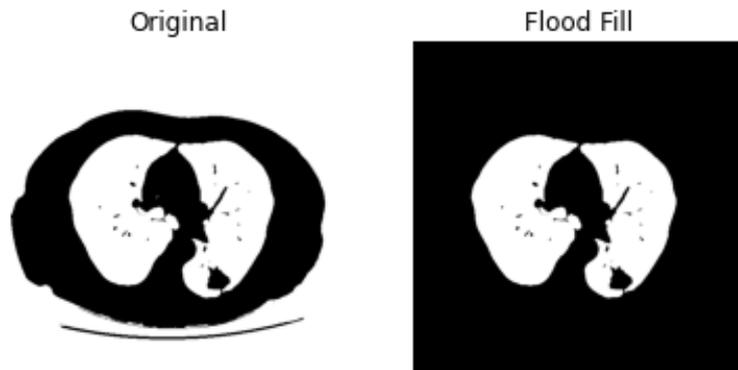


Figura 3. Exemplo de preenchimento por inundação

Fonte: Autoria Própria (2022)

4.3. Detecção de Contornos (*Sobel*)

O filtro de Sobel é utilizado para detecção de contornos, ele utiliza do operador registrado abaixo para encontrar contornos pela imagem. Após passar pelo filtro, o retorno é a imagem com suas bordas definidas e interior tem sua intensidade reduzida.

$$G_x = \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} * ([+1 \quad 0 \quad -1] * A) \text{ e } G_y = \begin{bmatrix} +1 \\ 0 \\ -1 \end{bmatrix} * ([1 \quad 2 \quad 1] * A) \quad (3)$$

No domínio do problema descrito nesse artigo, esse filtro é utilizado conforme o exemplo da Figura 4. Após realizar o preenchimento e deixar os pulmões em evidência, o filtro é utilizado para extrair o contorno dos pulmões, que servirá como máscara nas próximas etapas da segmentação.

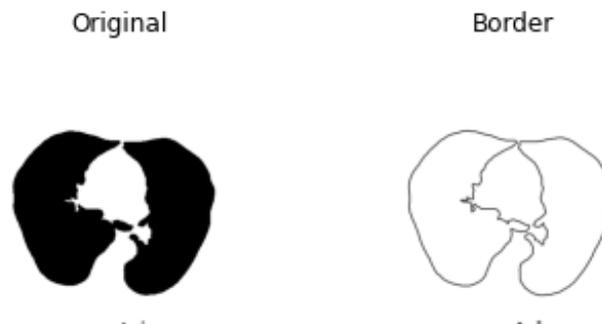


Figura 4. Exemplo de detecção de borda

Fonte: Autoria Própria (2022)

5. Materiais e Métodos

A segmentação e extração de lesões do pulmão é uma tarefa difícil, principalmente de lesões não sólidas ou parcialmente sólidas, pois essas tendem a não assumir um padrão facilmente detectável. Outra complexidade é com questão aos ruídos encontrados na imagem, existem muitas estruturas como, vasos, artérias, bolsões de oxigênio, dentre outros, que podem ser confundidos como lesão.

O algoritmo implementado foi escrito utilizando a linguagem Python em conjunto com as bibliotecas OpenCv e Scikit-Image, todo o código pode ser encontrado nesse repositório do GitHub. Para execução dos testes, foi utilizado uma placa Raspberry Pi 4, sendo sua configuração um processador Quad-core 1.5GHz com 2GB RAM, utilizando uma distribuição baseada em Arch Linux para eliminar qualquer outro processo desnecessário que esteja concorrendo processador com o algoritmo.

Sendo aproximadamente 2 segundos o tempo de execução do processamento de uma fatia na configuração especificada anteriormente e considerando que cada exame tenha em média 180 fatias, seriam necessários 6 minutos para realizar o processamento de um paciente.

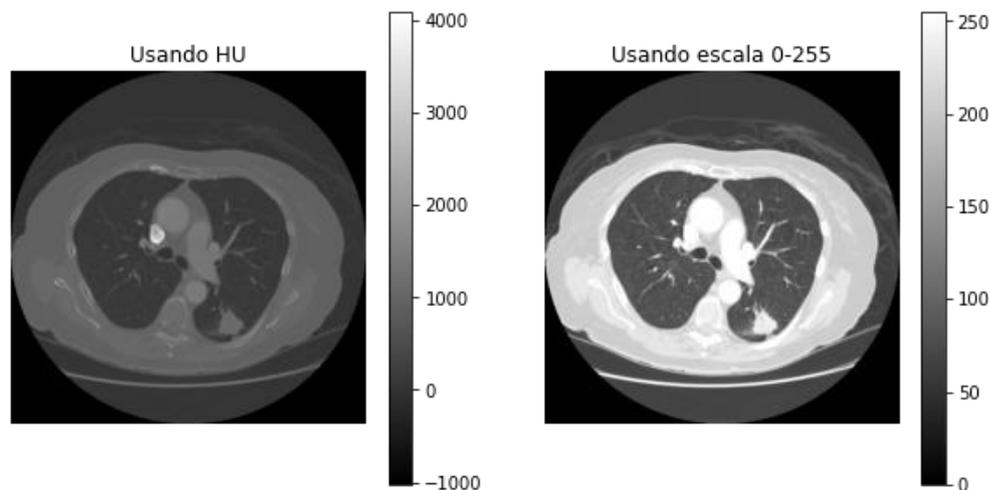


Figura 5. Comparação de imagem original e após a conversão
Fonte: Autoria Própria (2022)

Na sequência, será descrito as etapas utilizadas para o processamento das imagens, a primeira etapa é realizar a conversão para HU, como demonstrado na Figura 5, essa conversão permite mapear diferentes estruturas por possuir uma escala de intensidade maior.

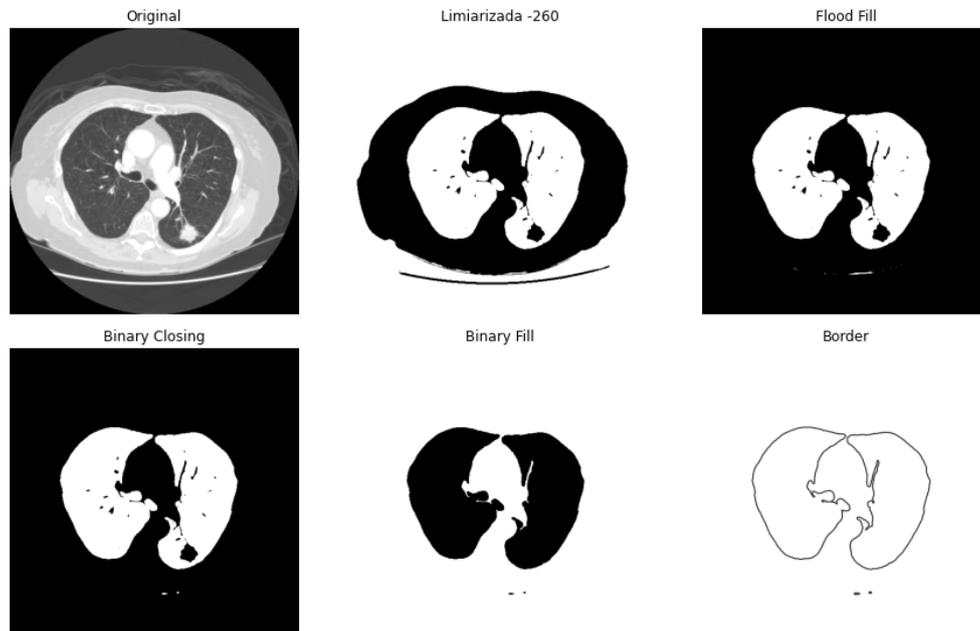


Figura 6. Exemplo de processamento de uma fatia
Fonte: Autoria Própria (2022)

Posteriormente a conversão é realizado o processamento da fatia utilizando dos algoritmos citados anteriormente. A Figura 6 apresenta as saídas de cada etapa do processamento, utilizando o limite fixo -260 para limiarização.

A Figura 7 descreve os objetos que são extraídos utilizando a operação “AND” entre a saída da quarta etapa e a quinta etapa, essa operação consiste em verificar pontos que sejam iguais em ambas as imagens, tanto em local quanto em intensidade. É possível identificar tanto a lesão — nessa situação um tumor cancerígeno, no canto inferior direito — quanto outras estruturas do pulmão.

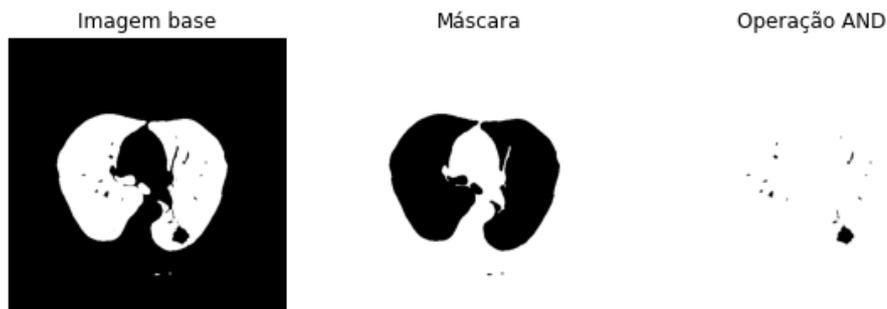


Figura 7. Exemplo de aplicação da operação “E”
Fonte: Autoria Própria (2022)

Com a imagem resultante dessa operação, é realizada a rotulação de cada um dos objetos existentes na mesma. A rotulação consiste em agrupar *pixels* vizinhos que tenham a mesma intensidade, esses têm seus valores trocado por um rótulo. Normalmente o fundo da imagem fica com o rótulo 0 e demais vão de 1, ..., n.

Após a rotulação, é realizada uma iteração por cada objeto rotulado para obter suas coordenadas na imagem e aplicar o preenchimento por inundação na imagem original. O resultado pode ser visualizado na Figura 8, onde os pontos mais claros, são os objetos rotulados anteriormente.

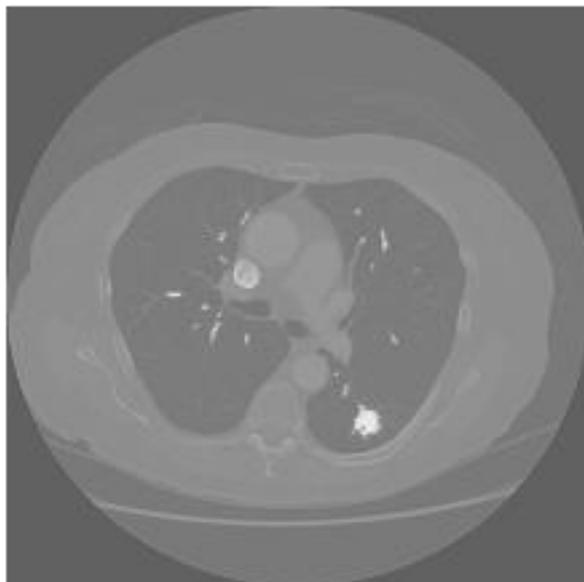


Figura 8. Exemplo após a iteração
Fonte: Autoria Própria (2022)

Por fim, utilizando a biblioteca *Scikit-Image*, é possível extrair características dessas possíveis lesões, a Figura 9 demonstra um exemplo onde a lesão da Figura 8 foi mapeada e recordada da imagem original.



Figura 9. Exemplo de lesão extraída da imagem original
Fonte: Autoria Própria (2022)

A Tabela 1, demonstra as propriedades que foram extraídas da Figura 8, a biblioteca permite a extração de diversas propriedades do objeto, assim como outras podem ser calculadas utilizando de operações matemáticas com a matriz da imagem.

Tabela 1. Exemplo de propriedades que podem ser extraídas das lesões

Etiqueta	Área (px)	Perímetro (px)
1	8	8.41
2	19	18.00
3	39	35.07
4	9	7.82
5	9	8.03
6	4	3.20
7	5	5.20
8	34	25.07
9	12	10.24
10	5	5.62
11	28	25.65
12	14	14.00
13	13	12.04
14	5	5.20
15	15	15.62
16	363	134.36

Fonte: Autoria Própria (2022)

6. Discussão e Resultado

A ideia do sistema detalhado nesse artigo não é utilizar da segmentação para caracterizar no sentido de dizer se a lesão em evidência é benigna ou maligna, nem esgotar o assunto, mas sim trazer qualquer objeto que exista dentro dos pulmões e então outro algoritmo com o uso de técnicas da inteligência artificial, irá realizar a classificação desses objetos utilizando um modelo radiômico.

Por meio da inteligência artificial, é possível utilizar todos esses objetos e atributos para cruzar propriedades em comum dos mesmos e, por fim, alimentar o algoritmo com essas imagens e informações, permitindo a realização, de maneira automática, da distinção do que realmente é lesão e o que é apenas estrutura do corpo humano e deve ser ignorado para não apresentar um falso positivo.

Outro ponto a ser levado em questão é que a utilização de sistemas CAD são apenas um complemento para os especialistas utilizarem, assim, um falso positivo como, uma bolsa de ar, seria facilmente eliminado por ele. Enquanto uma lesão que é apenas encontrada com a manipulação correta de níveis de contraste e intensidade, pode ser levantada de maneira mais rápida pelo algoritmo.

Uma situação que precisa ser considerada no momento de utilizar esse sistema é com relação as lesões que estão encostadas na parede do pulmão, essas lesões acabam sendo consideradas como parte da estrutura externa do pulmão e por isso são eliminadas erroneamente na operação “AND”. Essa situação será tratada em uma futura melhoria do algoritmo, assim como a implementação da inteligência artificial para classificação das lesões.

7. Conclusão

Com a análise dos resultados obtidos durante os testes, é possível identificar que foram gerados vários cenários que serão utilizados para alimentação de um algoritmo

supervisionado. Tais cenários, ilustram tanto lesões, quanto estruturas que se assemelham a lesões e que poderiam gerar um falso positivo no momento da sua classificação.

Mesmo sendo um algoritmo mais simples, as bibliotecas existentes para o processamento de imagens tornaram esse processo ainda mais fácil de ser implementado. O código fonte do sistema está aberto para uso no repositório do GitHub, uma vez que a ideia é já ter uma base de dados processada para alimentar o algoritmo que irá realizar a classificação, encurtando o processo de pesquisa para criação de modelos radiômicos.

Finalizando, é importante lembrar que o sistema gerado a partir dessa pesquisa não deve ser utilizado para autodiagnóstico e não descarta o laudo do médico especialista. O diagnóstico final deve ser realizado pelo profissional da área médica.

Referências Bibliográficas

American College of Radiology Committee on Lung-RADS®. Lung-RADS Assessment Categories version 1.1. [S. l.], 2019. Disponível em: <https://www.acr.org/-/media/ACR/Files/RADS/Lung-RADS/LungRADSAssessmentCategoriesv1-1.pdf>. Acesso em: 5 jul. 2022.

Armato SG 3rd, McLennan G, Bidaut L, McNitt-Gray MF, Meyer CR, Reeves AP, Zhao B, Aberle DR, Henschke CI, Hoffman EA, Kazerooni EA, MacMahon H, Van Beeke EJ, Yankelevitz D, Biancardi AM, Bland PH, Brown MS, Engelmann RM, Laderach GE, Max D, Pais RC, Qing DP, Roberts RY, Smith AR, Starkey A, Batrah P, Caligiuri P, Farooqi A, Gladish GW, Jude CM, Munden RF, Petkovska I, Quint LE, Schwartz LH, Sundaram B, Dodd LE, Fenimore C, Gur D, Petrick N, Freymann J, Kirby J, Hughes B, Castele AV, Gupte S, Sallamm M, Heath MD, Kuhn MH, Dharaiya E, Burns R, Fryd DS, Salganicoff M, Anand V, Shreter U, Vastagh S, Croft BY. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans. *Medical Physics*, v. 38, p. 915-931, 2011. DOI: <https://doi.org/10.1118/1.3528204>. Acesso em: 13 ago. 2022.

AZEVEDO-MARQUES, Paulo Mazzoncini. Computer-aided diagnosis in radiology. *Radiologia Brasileira*, [s. l.], v. 34, ed. 5, p. 285-293, Set. / Out. 2001. Disponível em: http://www.rb.org.br/detalhe_artigo.asp?id=1904. Acesso em: 20 abr. 2022.

Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Moore, S., Phillips, S., Maffitt, D., Pringle, M., Tarbox, L., & Prior, F. The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository. *Journal of Digital Imaging*, v. 26, ed. 6, p. 1045–1057, 2013. Disponível em: <https://doi.org/10.1007/s10278-013-9622-7>. Acesso em: 13 ago. 2022.

DOCUMENTAÇÃO OpenCv. [S. l.], 2022. Disponível em: <https://docs.opencv.org/4.x/index.html>. Acesso em: 16 out. 2022.

DOI, Kunio. Computer-Aided Diagnosis in Medical Imaging: Historical Review, Current Status and Future Potential. *Computerized Medical Imaging and Graphics*, Houston, v. 31, p. 198-211, 8 mar. 2007. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0895611107000262>. Acesso em: 21 abr. 2022.

NETO, Geraldo Henrique; RIBEIRO, Gilmar Cação; VALERI, Fabio Valiengo.

Processamento e Segmentação de Mamogramas Digitais. Congresso Brasileiro de Informática em Saúde, Ribeirão Preto, ed. IX, p. 822-827, 2004. Disponível em: http://telemedicina.unifesp.br/pub/SBIS/CBIS2004/cliq_aqui.htm. Acesso em: 24 abr. 2022.

GILLIES, Robert J.; KINAHAN, Paul E.; HRICAK, Hedvig. Radiomics: Images Are More than Pictures, They Are Data. *Radiology*, Oak Brook, v. 278, n. 2, p. 563-577, 18 nov. 2015. Disponível em: <https://pubs.rsna.org/doi/10.1148/radiol.2015151169>. Acesso em: 12 mar. 2022.

GONZALEZ, Rafael C.; WOODS, Richard E. *Processamento de Imagens Digitais*. 3. ed. São Paulo: Pearson Education do Brasil, 2010. ISBN 978-85-7605-401-6.

INCA – Instituto Nacional de Câncer: Câncer de pulmão. [S. l.], 04 jun. 2022a. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pulmao>. Acesso em: 12 mar. 2022.

INCA - Instituto Nacional de Câncer: Estatísticas de câncer. [S. l.], 23 jun. 2022b. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/numeros>. Acesso em: 12 mar. 2022.

POSSES, Flávio Pereira. O que é Tomografia Computadorizada. [S. l.], [2020?]. Disponível em: <https://star.med.br/o-que-e-tomografia-computadorizada/>. Acesso em: 21 abr. 2022.

RAZI, Tahmineh; NIKNAMI, Mahdi; GHAZANI, Fakhri Alavi. Relationship between Hounsfield Unit in CT Scan and Gray Scale in CBCT. *J Dent Res Dent Clin Dent Prospects*, [s. l.], v. 8, ed. 4, p. 107-110, 2014. DOI 10.5681/joddd.2014.019. Disponível em: https://joddd.tbzmed.ac.ir/Article/JODDD_181_20140727090056. Acesso em: 5 nov. 2022.

WALT, Stéfan van der; SCHÖNBERGER, Johannes L.; NUNEZ-IGLESIAS, Juan; BOULOGNE, François; WARNER, Joshua D.; YAGER, Neil; GOUILLART, Emmanuelle; YU, Tony; THE SCIKIT-IMAGE CONTRIBUTORS. Scikit-image: image processing in Python. *PeerJ*, [s. l.], v. 2, p. 453, Jun. 2014. DOI 10.7717/peerj.453. Disponível em: <https://doi.org/10.7717/peerj.453>. Acesso em: 23 out. 2022.