

# PROCESSAMENTO E SEGMENTAÇÃO DE NÓDULOS EM IMAGENS DE MAMOGRAFIA<sup>1</sup>

Éllen Grasiéli Vieira<sup>2</sup>

Maikon Cismoski dos Santos<sup>3</sup>

## RESUMO

Atualmente, na mortalidade proporcional por câncer em mulheres no Brasil, o Câncer de Mama é responsável pela maior taxa de mortalidade entre as mulheres, representando 16,1% do total. Diversos estudos ressaltam que um dos principais métodos para a detecção do Câncer de Mama é o diagnóstico por imagem através de exames de mamografia. As imagens geradas neste exame permitem identificar possíveis nódulos, sejam eles malignos ou benignos, além de, quando iniciado um tratamento, exames de imagem auxiliam no acompanhamento deste tratamento. Entretanto, nem sempre os exames geram imagens com alto grau de detalhamento, o que demanda tempo para a identificação de possíveis nódulos. Portanto, este projeto propôs o desenvolvimento de uma metodologia que, utilizando técnicas de processamento digital de imagens, auxilie na segmentação de nódulos em imagens de mamografia. Para isso, foram utilizados algoritmos de geração de *superpixels*, limiarização, detecção de bordas e operações morfológicas. O trabalho foi desenvolvido com o auxílio da biblioteca de visão computacional OpenCV aplicada à linguagem Python, empregando uma base de imagens pública para testes do protótipo. O protótipo desenvolvido se mostrou eficiente na identificação de nódulos, com um percentual 80% de acurácia em relação às 20 imagens utilizadas, das quais 15 possuíam nódulos malignos.

Palavras-chave: Processamento de imagens. Mamografia. Segmentação. OpenCV.

---

<sup>1</sup> Projeto de pesquisa submetido ao Curso de Bacharelado em Ciência da Computação do Instituto Federal Sul-Rio-Grandense, Câmpus Passo Fundo, como requisito parcial para a aprovação na disciplina de Trabalho de Conclusão de Curso II (TCC II).

<sup>2</sup> Aluna do curso de Ciência da Computação, no Instituto Federal de Educação, Ciência e Tecnologia Sul-rio-grandense de Passo Fundo (IFSUL).

<sup>3</sup> Orientador, professor do Instituto Federal de Educação, Ciência e Tecnologia Sul-rio-grandense de Passo Fundo (IFSUL).

## 1 INTRODUÇÃO

O Câncer de Mama é uma das doenças mais incidente em mulheres no mundo, sendo responsável por 15,5% dos óbitos por câncer em mulheres. Na população feminina brasileira, o câncer de mama é, atualmente, a segunda principal causa de morte e a primeira entre as neoplasias malignas (INCA, 2019). Segundo dados da Organização Mundial da Saúde (OMS), a estimativa é de que ocorrem mais de um milhão de novos casos por ano ao redor do mundo.

O principal método de diagnóstico do câncer de mama é o exame de mamografia, onde as imagens são geradas através do equipamento denominado mamógrafo. O aparelho de mamógrafo faz uso de raios X para gerar uma impressão da mama e neste processo as áreas onde existem irregularidades, como as neoplasias mamárias, acabam sendo destacadas.

O uso de imagens na medicina auxilia na elaboração dos diagnósticos clínicos e na tomada de decisões médicas. O processamento de imagens fornece métodos para a extração de atributos de uma imagem digital e pode oferecer melhores parâmetros para a elaboração de um diagnóstico mais exato, indicando áreas suspeitas (NETO, G. H.; RIBEIRO, G. C.; VALERI, F. V. , 2004).

De acordo com Assis J. V (2015), o Câncer de Mama vem se consolidando como o mais comum entre as mulheres, embora a taxa de incidência tenha diminuído a cada ano, decorrente das pesquisas cada vez mais centradas nesta área, das campanhas de conscientização e dos avanços da tecnologia utilizados no diagnóstico e tratamento da doença.

Além disso, um dos principais fatores nas chances de cura de pacientes com Câncer de Mama é o diagnóstico e tratamento precoce da doença (INCA, 2021). Entretanto, nem sempre os exames geram imagens com alto grau de detalhamento, o que demanda tempo para a identificação de possíveis nódulos. Por esse motivo, a aplicação de técnicas de processamento e segmentação focadas em auxiliar no processo de reconhecimento destes nódulos poderá otimizar o tempo de identificação e auxiliar a equipe clínica no diagnóstico da doença. Além de que, pesquisas desenvolvidas com o propósito de aumentar a eficiência do diagnóstico

de Câncer de Mama através de processamento de imagens em mamografias são uma contribuição positiva com a sociedade e o meio acadêmico.

Este trabalho tem como principal objetivo o desenvolvimento de uma metodologia que utilize técnicas de processamento digital de imagens para auxiliar na detecção das neoplasias malignas nas imagens de mamografia.

O trabalho está estruturado da seguinte forma: a Seção 2 mostra o referencial bibliográfico. A Seção 3 descreve os trabalhos relacionados. Na Seção 4 é apresentado o desenvolvimento do trabalho. Na Seção 5 são apresentados os resultados obtidos e, por fim, na Seção 6, as considerações finais e trabalhos futuros.

## **2 EMBASAMENTO TEÓRICO**

### **2.1 CÂNCER DE MAMA E O EXAME DE MAMOGRAFIA**

De acordo com o INCA - Instituto Nacional de Câncer (2022), “o câncer de mama é uma doença causada pela multiplicação desordenada de células anormais da mama, que formam um tumor com potencial de invadir outros órgãos”. Esse tumor é uma estrutura tridimensional que pode ser identificada através da palpação da mama e/ou por exames de imagem. Através dos exames de imagem, é possível delimitar as dimensões do tumor para posteriormente ser classificado como um nódulo (SILVA e COSTA, 2021 apud CALVOSO B.S. 2019).

Dentre os exames de imagem, o principal método de diagnóstico é o exame de mamografia, que é um tipo de radiografia especial das mamas, realizada com uma baixa dose de radiação e por um equipamento conhecido como mamógrafo. Esse exame ajuda a diferenciar o nódulo e identificar se o mesmo é sólido ou cístico; Também permite caracterizar o nódulo quanto a sua forma, margem e densidade.

Segundo Koch e Godinho (2004), nódulos em exames de mamografia podem ser classificados pelas características anteriormente citadas:

- 1. Forma:** redonda, ovalada, macrolobulada ou irregular;

2. **Margens:** circunscrita, microlobulada, obscurecida, mal definidas ou espiculadas;
3. **Densidade:** alta densidade, isodensa ou baixa densidade;

## 2.2 IMAGENS DIGITAIS

De acordo com Gonzalez e Woods (2011) a imagem digital pode ser expressada como uma função bidimensional  $f(x,y)$  onde os pares de  $x$  e  $y$  correspondem às coordenadas espaciais no plano, e a amplitude de  $f$  em qualquer uma destas coordenadas corresponde ao nível de cinza no ponto em questão, no caso de imagens de tons de cinza. Ou corresponde a um conjunto de três valores (*RGB*, sigla para *Red*, *Blue* e *Green*) para representar uma cor. A cada uma das coordenadas deste vetor bidimensional damos o nome de pixel. Quanto maior for a quantidade destes pixels no plano, maior é a resolução da imagem. Em suma, uma imagem digital é uma representação de uma imagem através de um conjunto de elementos discretos e finitos em um vetor bidimensional.

O campo de visão computacional se refere à manipulação de imagens digitais por um computador digital e tem como objetivo desenvolver meios para a melhoria na visualização da imagem, o realce ou a extração de informações de uma imagem de forma adequada para o processamento computacional (Neto et al, 2004; Gonzalez e Woods, 2011).

## 2.3 SEGMENTAÇÃO

“O processo de segmentação é um passo fundamental para analisar e extrair dados das imagens” (Kannan et al, 2015). Essa etapa é responsável por separar uma imagem em regiões ou em objetos constituintes. Conforme Gonzalez e Woods (2011) a definição para a segmentação que será realizada depende do problema a ser resolvido. Segundo Saldanha e Freitas (2010), a segmentação de imagens possui dois objetivos: Decompor a imagem em partes menores para uma análise futura e realizar uma mudança de representação (apud Shapiro e Stockman, 2001).

De acordo com Gonzalez e Woods (2011), os algoritmos de segmentação podem ser categorizados em dois grupos: Algoritmos baseados na busca pelas discontinuidades e algoritmos baseados na busca de similaridades.

Nos algoritmos de descontinuidades, as mesmas são identificadas através de pontos, linhas ou bordas que se sobressaem em uma imagem por possuírem tons distintos a região onde se encontram ou por destacarem uma mudança brusca nos tons entre as regiões, no caso de linhas e bordas. Já nos algoritmos de similaridades, Saldanha e Freitas (2010) definem que “a detecção tem como fundamento a observação do interior dos objetos e não as fronteiras que os delimitam”.

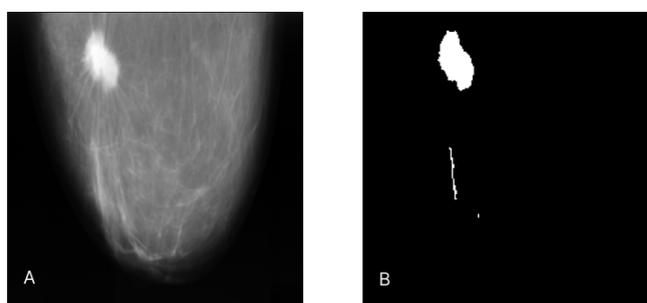
### 2.3.1 Limiarização

O processo de limiarização possui uma implementação simplificada e uma velocidade computacional significativa, e, por estes motivos, possui uma posição central nas aplicações de segmentação de imagem (Gonzalez e Woods, 2011).

Um objeto pode ser definido como uma região da imagem que possui pixels com uma faixa de intensidade em comum. O processo de limiarização faz o uso dessa intensidade comum dos pixels para individualizar as regiões, através da análise do histograma de frequências da imagem, onde as faixas de intensidade correspondem às bandas do histograma (Saldanha e Freitas, 2010).

A Figura 1 ilustra um exemplo de imagem de exame de mamografia, disponibilizada no repositório público “*Dataset of Breast mammography images with Masses*”, onde A) Imagem original e B) Imagem limiarizada considerando um fator de limiarização 170.

Figura 1 - Exemplo de imagem limiarizada.



Fonte: do autor

### 2.3.2 Detecção de bordas

“A detecção de bordas é, de longe, a abordagem mais comum para detecção de descontinuidades” (Gonzalez e Woods, 2011). Em uma imagem a borda é definida como sendo o limite entre duas regiões com diferentes propriedades.

Gonzalez e Woods (2011) definem os modelos de borda em três tipos: Bordas em degrau, que ocorrem quando há uma mudança brusca na transição dos níveis de intensidade, geralmente com a distância de um pixel; Bordas em rampa que ocorrem quando há um desfoque na borda; E as bordas em telhado, que são modelos de linhas que cortam uma região da imagem.

Dentro do segmento de detecção de bordas, existem inúmeros algoritmos para o reconhecimento das mesmas, neste trabalho será utilizado o algoritmo de Canny.

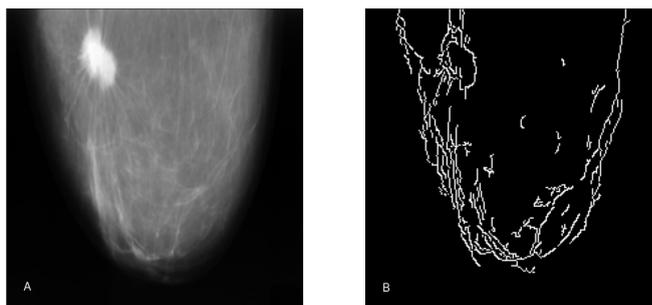
O detector de bordas Canny tem como característica o uso de um filtro gaussiano em conjunto com um operador diferencial a fim de suavizar o ruído e localizar as bordas da imagem (VALE e POZ, 2002). O detector possui alguns critérios para a detecção das bordas: A baixa taxa de erro na detecção das bordas, ou seja, o processo de detecção precisa localizar a maior quantidade possível de bordas existentes na imagem. Outro critério é que o ponto de borda detectado pelo operador deve possuir uma distância extremamente baixa entre ele e a borda verdadeira. Por fim, o detector deve retornar apenas um ponto para cada ponto de borda verdadeiro (Vale e Poz, 2002; Gonzalez e Woods, 2011).

Os quatro principais estágios do algoritmo de Canny, de acordo com Gonzalez e Woods (2011) são:

1. A suavização da imagem de entrada utilizando o filtro gaussiano;
2. O cálculo dos gradientes e dos ângulos das imagens;
3. Aplicar o método de não eliminação da máxima amplitude do gradiente para minimizar a dimensão do pixel;
4. Utilizar da limiarização para analisar e conectar as bordas, onde caso o valor seja maior que o limiar de alta, o valor é aceito, e caso seja menor que o limiar de baixa, é rejeitado.

Na Figura 2 temos um exemplo de aplicação do algoritmo de Canny em uma imagem oriunda de uma exame de mamografia para ilustrar o funcionamento do algoritmo.

**Figura 2 - Exemplo de aplicação do operador de bordas Canny em uma imagem de mamografia.**



**Fonte: do autor.**

Nesta imagem, sem tratamento prévio, foram considerados um limite superior com fator 100 e um limite inferior com fator 50 na aplicação do algoritmo. Ou seja, se o gradiente de intensidade do pixel for maior que o limite superior, ele será adicionado como um pixel de borda na imagem de saída. Se o valor de gradiente de intensidade do pixel for menor que o limite inferior, o mesmo será descartado. Se a intensidade do pixel estiver entre os limites superior e inferior ele será adicionado na imagem de saída conectado a qualquer outro pixel próximo com o valor maior que o limite superior.

## **2.4 ALGORITMO DE SEGMENTAÇÃO SLIC**

O algoritmo de segmentação *Simple Linear Iterative Clustering* (popularmente conhecido como *SLIC*) é uma técnica proposta por Achanta et al. (2010) baseada no algoritmo *K-means*, para a criação de *Superpixels*.

Conforme Redlich (2018) *Superpixels* são o resultado de agrupamentos de pixels que possuem características homogêneas entre si, como a proximidade entre suas intensidades de cores e sua proximidade na disposição do plano.

Resumidamente, o algoritmo SLIC pode ser descrito com os seguintes passos:

1. Primeiramente, a imagem de entrada é dividida em  $k$  regiões retangulares com dimensões  $n \times n$ , sendo o valor de  $k$  um dos parâmetros do algoritmo.
2. A cada iteração do algoritmo, cada pixel da imagem, quando existente uma proximidade em suas características, é associado ao centróide da região mais próxima, considerando a área de  $2n \times 2n$ .
3. Após o final de cada iteração, um novo valor para o centróide de cada região é calculado e novas iterações são realizadas.

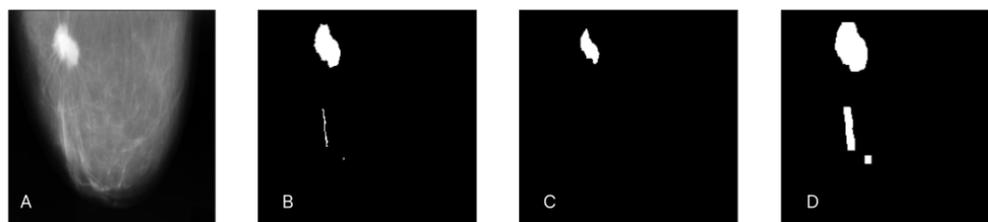
O propósito desta técnica é diminuir a complexidade de processamento da imagem em etapas posteriores, já que o produto desta operação possui regiões homogêneas e não mais pixels distintos, o que torna o processamento mais ágil e menos custoso em termos de processamento computacional.

## 2.5 OPERADORES MORFOLÓGICOS

A área de operações morfológicas, também conhecida como morfologia matemática, tem como objetivo atuar como uma ferramenta para a extração de segmentos da imagem, que são úteis para a descrição e representação (Oliveira, 2016), mas também são comumente utilizadas na remoção de imperfeições originadas no processo de segmentação.

A morfologia matemática conta com duas operações primitivas principais: a erosão e a dilatação. A partir delas, outras operações são originadas. Na erosão, considerando que nossa imagem já está binarizada, podemos separar os pixels da imagem em dois conjuntos,  $A$  e  $B$ , conforme sua intensidade. A erosão de  $A$  por  $B$  é o conjunto de todos os pontos  $x$ , transladados por  $x$ , que estão contidos em  $A$ , com isso, temos a redução da imagem/objeto. Enquanto que a dilatação de  $A$  por  $B$  seria o conjunto de todos os deslocamentos de  $x$  tais que  $B$  refletido e  $A$  se sobreponham em pelo menos um elemento não nulo, a fim de expandir a imagem ou objeto.

**Figura 3 - Exemplos das operações de erosão e dilatação.**



Fonte: do autor.

Na Figura 3 temos um exemplo de implementação das operações de erosão e dilatação em uma imagem limiarizada (a fim de simplificar o entendimento), onde: A) Imagem original; B) Imagem limiarizada; C) Aplicação da operação de erosão sobre a imagem B ; D) Aplicação da operação de dilatação sobre a imagem B. Para ambas as operações foi considerado um fator de operação 4x4.

Nas operações morfológicas, esse fator para operação recebe o nome de Elemento Estruturante. Conforme Gonzalez e Woods (2010), o elemento estruturante é um conjunto de pixels, por convenção convertidos em uma matriz, que percorre a imagem de entrada, realizando as verificações citadas anteriormente.

## 2.6 PYTHON

O Python é uma linguagem de programação multiplataforma, de altíssimo nível (VHLL), desenvolvida por Guido Van Rossum em 1991, com o objetivo de ser uma linguagem simples e de fácil entendimento. De acordo com Paiva et Al (2020), entre as características da linguagem, destacam-se a facilidade em aprender, ler e compreender a mesma; o fato da mesma ser multiparadigma, ou seja, permitir a implementação de uma programação Orientada a Objetos, Funcional ou Procedural; ser uma linguagem com tipagem dinâmica e possuir uma imensa variedade de módulos de extensão, como o OpenCV, que permitem expandir o poder da linguagem.

Python é *open-source*, ou seja, permite que os usuários possam colaborar modificando o código fonte da linguagem e compartilhando essas novas atualizações. A implementação oficial do Python é mantida pela PSF (*Python Software Foundation*).

## 2.7 OPENCV

A biblioteca OpenCV (*Open Source Computer Vision Library*), que foi originalmente desenvolvida pela Intel em 2000, é uma biblioteca multi plataforma, *open-source*, para o desenvolvimento de softwares na área de Visão Computacional e Aprendizado de Máquina (*Machine Learning*). O OpenCV possui suporte a operações de processamento de imagens e vídeo. Além disso, possui em sua biblioteca mais de 2500 algoritmos de visão computacional, facilitando a implementação de operações como: filtros de imagem, reconhecimento e segmentação de objetos, reconhecimento de expressões faciais, classificação de ações humanas, análise estrutural e outros (OpenCV, 2022).

Esta biblioteca foi inicialmente desenvolvida nas linguagens de programação C/C++, porém, atualmente também possui suporte para as linguagem Python, Java e para o MATLAB. A mesma se encontra na versão 4.6.0, que foi lançada em junho de 2022.

## 3 TRABALHOS RELACIONADOS

Neto, G. H. Ribeiro, G. C. Valeri, F. V. (2004) propõem uma metodologia que faz uso da limiarização baseada em estatísticas locais dos níveis de cinza, a fim de binarizar as regiões dos mamogramas digitais. Além disso, invertem os níveis de cinza e utilizam técnicas de alargamento de contraste para corrigir problemas relativos ao baixo contraste da fase de aquisição das imagens.

Silva, F.J.V. e Alves, C.H.F. (2008) empregaram os detectores de bordas Robert, Sobel, Prewitt e Canny, através do software MATLAB para realizar a segmentação de rins humanos em imagens de ultrassonografia, onde o detector de Canny obteve melhor desempenho na segmentação dos órgãos.

Em sua pesquisa, Araújo dos Santos (2018) aplica o operador Canny, através do software MATLAB, para a segmentação de nódulos mamários em imagens de mamografia, onde foi constatado que o operador Canny possui um melhor desempenho quando utilizado em conjunto ao processo de binarização.

Silva *et al.* (2014) propõe uma extensa metodologia onde a imagem inicial passa pelos processos de segmentação, aumento seletivo de contraste, normalização e filtragem para gerar uma imagem realçada. Esta imagem realçada é então segmentada via limiarização global, e com a aplicação de um filtro morfológico são detectados e removidos os possíveis falsos positivos da imagem. Após isso é feita a detecção das bordas do tumor através do operador de Canny e a imagem é então processada novamente para visualização do resultado. A metodologia foi aplicada a 45 imagens, das quais 43 continham a presença de tumores e obteve 85% de eficiência na detecção dos tumores, uma vez que identificou os tumores em 38 das 45 imagens, sem identificar falsos positivos.

Um aspecto importante observado nos trabalhos pesquisados é a etapa de segmentação da imagem, a qual permite a identificação dos nódulos. Nos trabalhos pesquisados, a segmentação foi realizada empregando operadores para detecção de bordas ou binarização. Entretanto, por se tratarem de metodologias mais simples, tais métodos se mostram limitados a diversas outras etapas de tratamento de imagem a fim de se obter a segmentação. Diante do exposto, este trabalho emprega uma metodologia diferente para a detecção dos nódulos, fazendo o uso de Superpixels com o objetivo de segmentar nódulos em imagens de mamografia.

#### **4 DESENVOLVIMENTO**

Para atingir o objetivo proposto neste trabalho, foi criado um algoritmo para destacar nódulos nas imagens de mamografias. As imagens utilizadas para a implementação do protótipo pertencem ao banco de dados *Dataset of Breast mammography images with Masses*, disponibilizado por Lin, Ting; Huang, Mei-Ling (2020). Essa base contém imagens de mamografias e ressonâncias de mama, já classificadas por médicos em imagens com achados malignos, benignos e imagens sem nódulos, além de ser uma base pública disponível para estudantes e pesquisadores.

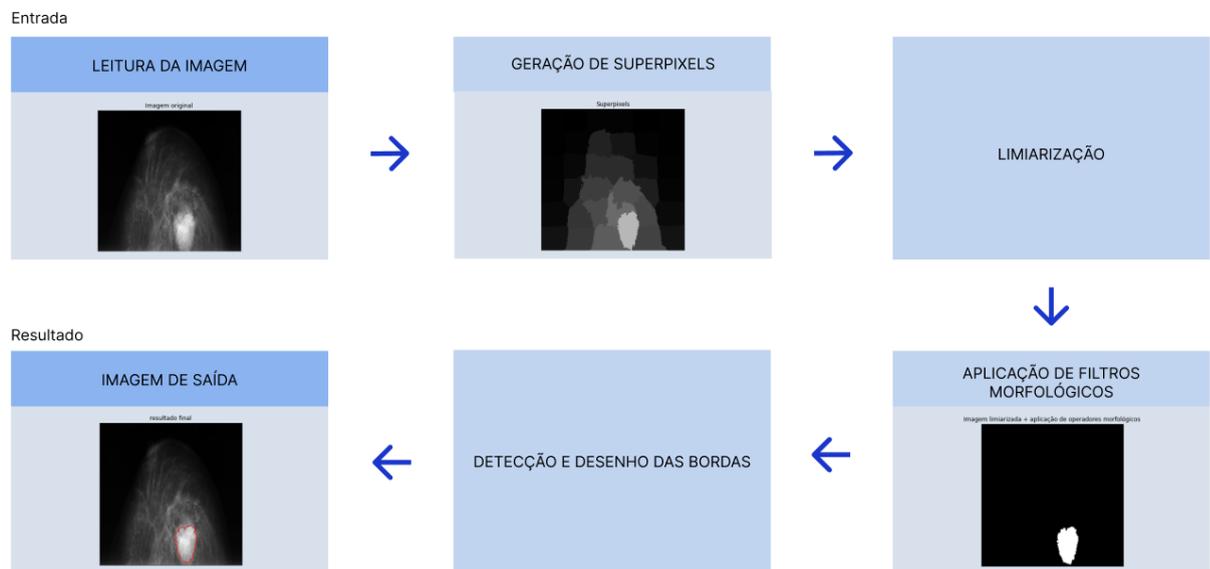
Para o desenvolvimento do protótipo e realização dos testes de validação, foram selecionadas 20 imagens, sendo 15 mamografias contendo um nódulo maligno e 5 imagens sem nódulos identificados, a fim de avaliar se o algoritmo

geraria falsos positivos. As imagens que contêm neoplasias malignas foram escolhidas com o critério de possuírem apenas um nódulo maligno por imagem, a fim de simplificar a execução dos testes.

O protótipo foi desenvolvido na linguagem Python, em conjunto com as bibliotecas OpenCV e Scikit-Image, através da plataforma Colab, mantida pela Google. Essa plataforma permite a escrita e a execução de códigos em Python de forma online, via browser.

O funcionamento geral do algoritmo consiste na leitura da imagem; geração dos superpixels; limiarização; aplicação de operações morfológicas para eliminar possíveis imperfeições originadas no processo de limiarização; subtração da imagem original pela imagem limiarizada (para fins de visualização); detecção e desenho das bordas e por fim a plotagem de resultados 5. No diagrama da Figura 4 é apresentada a organização do protótipo desenvolvido.

**Figura 4 - Diagrama de funcionamento do protótipo.**



Fonte: do autor.

Cada uma das etapas é detalhada a seguir.

#### 4.1 Geração dos Superpixels

Na etapa de geração de *Superpixels* (aplicação do algoritmo SLIC), foi utilizado a função *slic*, da biblioteca *Scikit-image*. Essa função recebe por parâmetro a imagem de entrada, o número de segmentos em que a imagem será quebrada, utilizado o valor de 40 regiões por convenção e o nível de condensação de cada região (aqui utilizado o valor 20).

Para efetivamente gerar as regiões homogêneas na imagem foi utilizado a função *regionprops*, também da biblioteca *Scikit-image*, onde o objetivo principal é obter informações sobre determinada região da imagem, para isso, são passados como parâmetros os segmentos gerados na função *slic* e os valores de intensidade da imagem. A função *regionprops* devolve um array com as informações para cada região gerada na função *slic*.

Com as informações da função *regionprops*, é utilizada a função *color* para realizar a homogeneização da região em uma imagem de saída, considerando as propriedades *coords* e *mean\_intensity* contidas em cada objeto do array de *regionprops*.

#### 4.2 Limiarização

Para a etapa de limiarização, foi utilizada a função *threshold*, da biblioteca OpenCV, onde são passados como parâmetros a imagem obtida na etapa anterior, os valores de limite inferior e limite superior (aqui sendo 170 e 255, respectivamente) e o tipo de limiarização escolhida, sendo neste projeto utilizado o modelo de *THRESH\_BINARY*, o qual obteve melhores resultados quando comparado aos outros modelos de binarização.

#### 4.3 Aplicação de filtros morfológicos

A aplicação de filtros morfológicos se fez necessária para a remoção de imperfeições originadas no processo de limiarização, através das operações de erosão e dilatação. Entretanto, essa é uma das etapas mais delicadas do processo, uma vez que os processos de erosão e dilatação podem afetar a extração das características de forma e margem, utilizadas para classificar o nódulo.

Para realizar estas operações, foram utilizadas as funções *erode* e *dilate* da biblioteca OpenCV, em sequência. A função *erode* é responsável por gerar a erosão da imagem, assim removendo pequenos agrupamentos de pixels que foram segmentados no processo anterior, mas que não se caracterizam como nódulo, entretanto, essa função acaba modificando a forma do nódulo. Para amenizar isso, é aplicada a função *dilate*, que irá dilatar o nódulo na mesma proporção em que foi corroído, a fim de retornar o objeto segmentado a uma forma muito próxima a obtida anteriormente.

Essas funções recebem por parâmetro a imagem limiarizada anteriormente, o elemento estruturante e o número de iterações que serão feitas, onde neste caso, foram duas iterações.

A criação do elemento estruturante é feita através da função *getStructuringElement(formato, tamanho\_matriz\_estruturante)*, onde o formato utilizado foi o de cruz (*MORPH\_CROSS*). Para esta etapa, foram testados elementos estruturantes de tamanho 3x3, 4x4 e 5x5, onde o elemento de tamanho 3x3 obteve e melhores resultados, enquanto que os outros descaracterizaram as bordas dos nódulos.

#### **4.4 Detecção e desenho das bordas**

Para realizar o desenho do contorno do nódulo, foi utilizado o algoritmo de Canny, através da função *Canny(imagem, limite\_inferior, limite\_superior)*. Como a função foi aplicada sob a imagem limiarizada, foram utilizados os valores de 150 e 255 para limites inferior e superior.

Para localizar as coordenadas da borda do objeto segmentado, foi utilizada a função *findContours* sobre a imagem produto da função de Canny. Essa função retorna um array com todas coordenadas que, em seguida, são utilizadas como parâmetro na função *drawContours*, responsável por efetivamente desenhar as bordas do objeto localizado sobre a imagem original.

## 5 RESULTADOS

Para a análise, foram considerados dois cenários: Imagens com nódulos identificados e número de nódulos identificados por imagem. Conforme a Figura 5, para a exibição do resultado final, são geradas cinco imagens de saída para cada imagem de entrada, sendo A) imagem original, B) Imagem segmentada por SLIC, C) Imagem limiarizada, D) Imagem original mesclada a imagem limiarizada, E) Imagem original com a borda do nódulo destacada.

Figura 5 - Exemplo de imagem gerada como resultado do protótipo.



Fonte: do autor.

Para o cenário de testes em imagens com nódulos identificados, foram consideradas todas as imagens previamente selecionadas, já que o objetivo principal deste teste é validar se o protótipo identificaria falsos positivos nas imagens sem nódulos. Aqui, o retorno esperado era se há ou não um objeto identificado na imagem.

No cenário de testes de quantidade de nódulos identificados por imagem, o objetivo principal é verificar se para cada imagem que continha um nódulo, foi identificado **apenas um** objeto, já que a proporção de nódulos por imagem era 1:1. Os resultados obtidos nos testes podem ser visualizados na Tabela 1.

Tabela 1 - Resultados obtidos.

Cenário	Verdadeiros Positivos	Falsos Positivos	Verdadeiros Negativos	Falsos Negativos	Total	% Acurácia
Imagens	11	1	5	3	20	80%
Nódulos identificados	11	4	Não se aplica	3	15	61,11%

Fonte: do autor

A partir das informações contidas na Tabela 1, podemos verificar que das 15 imagens com nódulos utilizadas nos testes, o algoritmo se mostrou eficiente identificando objetos em 11 das imagens (para ambos os testes). Um exemplo de sucesso da identificação é apresentado na Figura 6, onde o nódulo foi corretamente segmentado e teve suas bordas contornadas.

**Figura 6 - Exemplo de imagem em que o protótipo segmentou o nódulo com sucesso.**



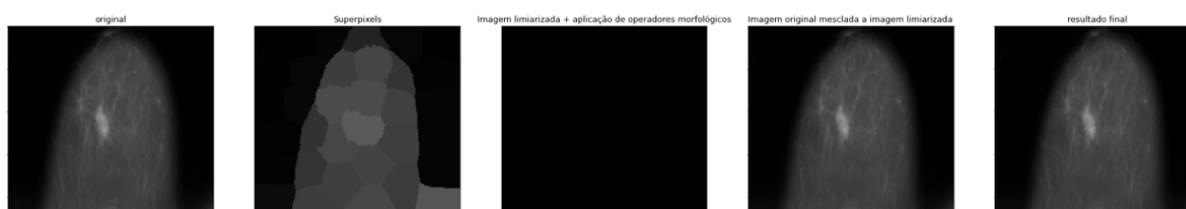
Fonte: do autor.

Nos testes de imagens com nódulos, uma das imagens que continha nódulo foi marcada como verdadeiro positivo, entretanto, a área segmentada se tratava de um reflexo existente na imagem, por esse motivo, ela foi contabilizada como falso positivo. No demais, o protótipo não gerou falsos positivos reais, mas gerou 3 falsos negativos em imagens que continham nódulos, mas que não tinham nenhum objeto segmentado.

## 5.1 Limitações

Analisando as imagens que geram falsos negativos, foi possível identificar que o protótipo apresentou falha na etapa de geração dos superpixels para nódulos em imagens de baixo contraste, conforme a Figura 7, em que o nódulo não foi identificado na fase de limiarização, já que a imagem produto da etapa de geração dos superpixels possui baixo contraste.

**Figura 7 - Exemplo de imagem com baixo contraste, onde o algoritmo não conseguiu localizar nenhum nódulo.**



Fonte: do autor.

**Figura 8 - Exemplo de imagens com mais de um objeto identificado, onde é possível ver reflexos e/ou estruturas que não oriundas da mama.**



Fonte: do autor.

Também foi possível observar que nas imagens que obtiveram falsos positivos, o algoritmo acaba segmentando bordas e reflexos do exame, que por se tratarem de áreas muito grandes, acabam não sendo eliminadas na etapa de limpeza com os operadores morfológicos, como podemos visualizar na Figura 8.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho, foi proposto um protótipo para processamento e segmentação de nódulos em imagens de mamografia que permite auxiliar no diagnóstico do Câncer de Mama. Para tal, foi desenvolvido um algoritmo que, fez o uso de *Superpixels*, limiarização, operadores morfológicos e segmentação com o operador de Canny.

O protótipo desenvolvido obteve sucesso identificando nódulos em 12 das 15 imagens que continham nódulos e não identificando falsos positivos nas imagens sem nódulos, alcançando um percentual de 80% de acurácia.

Nos testes de quantidade de nódulos identificada por imagem, o protótipo atingiu uma acurácia de 61,11% na detecção dos nódulos, entretanto, desconsiderando os valores de falsos positivos, os quais ocorreram devido a reflexos e/ou estruturas que não fazem parte da mama, o valor de acurácia passa para 78,57%. Nos testes de identificação de imagens que possuíam ou não o nódulo, o percentual de sucesso é 80%.

Como foi possível avaliar ao longo deste artigo, o algoritmo se mostra promissor, mas precisa de refinamentos, como o emprego de técnicas de correção de contraste a partir da equalização do histograma da imagem. Uma proposta para

trabalhos futuros seria o uso de inteligência artificial e momentos invariantes para automatizar o processo de reconhecimento e caracterização dos nódulos, a fim de remover os falsos positivos para análises posteriores.

## **ABSTRACT**

Currently, in the proportional mortality rate for cancer in women in Brazil, Breast Cancer is responsible for the highest mortality rate among women, representing 16.1% of the total. Several studies point out that one of the main methods for detecting breast cancer is diagnostic imaging through mammography. The images generated in this exam allow the identification of possible nodules, whether malignant or benign, in addition to, when treatment is started, imaging exams help in the follow-up of this treatment. However, the exams do not always generate images with a high degree of detail, which takes time to identify possible nodules. Therefore, this project proposed the development of a methodology that, using digital image processing techniques, would assist in the segmentation of nodules in mammography images. For this, algorithms for superpixel generation, thresholding, edge detection and morphological operations were used. The work was developed with the help of the OpenCV computer vision library applied to the Python language, using a public image base for prototype testing. The developed prototype proved to be efficient in identifying nodules, with an accuracy of 80% in relation to the 20 images used, of which 15 have malignant nodules.

Keywords: Image processing. Mammography. Segmentation. OpenCV.

## **REFERÊNCIAS**

ACHANTA, Radhakrishna et al. Slic superpixels. 2010.

ALBUQUERQUE, Márcio Portes de; ALBUQUERQUE, Marcelo Portes de. Processamento de imagens: métodos e análises. Rio de Janeiro, Brasil, v. 12, 2000.

ASSIS, J. B. Estudo do grau de risco de câncer de mama utilizando a dimensão fractal de imagens. Dissertação (Conclusão de Curso). Universidade Tecnológica Federal do Paraná, 2015.

BRASIL. Instituto Nacional de Câncer, Ministério da Saúde. Controle do Câncer de

Mama. Disponível em: <<https://www.inca.gov.br/controle-do-cancer-de-mama>>. Acesso em 19 de abril de 2022.

BRASIL. Instituto Nacional de Câncer, Ministério da Saúde. Parâmetros técnicos para rastreamento do câncer de mama. Rio de Janeiro, RJ 2021. Disponível em: <<http://www.inca.gov.br>>. Acesso em 18 de abril de 2022.

CALVOSO, Beatriz De S. et Al., Diagnóstico e Conduta Acerca De Nódulos Benignos De Mama: Uma Revisão Sistemática. Revista de Medicina da Faculdade Atenas, p. 2236-9252, 2019.

GODINHO, Eduardo R; KOCH, Hilton A., Breast imaging reporting and data system (BI-RADS™): como tem sido utilizado? Radiologia Brasileira, São Paulo, v. 37, ed. 6, p. 413-417, 2004

GODINHO, Eduardo R; KOCH, Hilton A., Rastreamento do câncer de mama: aspectos relacionados ao médico. Radiologia Brasileira, São Paulo, v. 37, ed. 6, v. 37, p. 91-99, 2004.

GONZALEZ, R.C. e WOODS, R.E., Processamento De Imagens Digitais; 3ª ed. São Paulo (SP), Editora Pearson; 2011.

KANNAN, Subbu; GURUSAMY, Vairaprakash; NALINI, G. Review on Image Segmentation Techniques. Pattern recognition 26.9 (1993): 1277-1294.

LIN, T.; HUANG, M, "Dataset of Breast mammography images with Masses", Mendeley Data, 2020.

NETO, G. H. RIBEIRO, G. C. VALERI, F. V. Processamento e Segmentação de Mamogramas Digitais. In Congresso Brasileiro de Informática em Saúde, 2004.

OLIVEIRA, Luiz E. S. Processamento de Imagens: Morfologia Matemática Binária. Anotações de aula, 2004.

OPENCV. Disponível em: <<https://opencv.org/>>. Acesso em: 8 de julho de 2022.

PAIVA, Fábio Augusto Procópio de. et al. Introdução a python com aplicações de sistemas operacionais. Editora IFRN, 2020.

PEDRINI, H; SCHWARTZ, W. R. Análise de Imagens Digitais. Editora Thomson Pioneira, 2008.

PYTHON. Disponível em: <<https://www.python.org/>>. Acesso em: 8 de julho de 2022.

REDLICH, Caroline R., Segmentação de Imagens Baseada em Grafos de Superpixel. Dissertação de Mestrado, PUC-Rio, 2018.

SALDANHA, M. F. S. FREITAS, C. C. Segmentação de Imagens Digitais: Uma Revisão. In: WORKSHOP DOS CURSOS DE COMPUTAÇÃO APLICADA DO INPE, 9. (WORCAP)., 2009, São José dos Campos. Anais... São José dos Campos: INPE, 2009 Disponível em: <<http://urlib.net/ibi/8JMKD3MGP8W/37NC86S>>. Acesso em: 23 de mai. de 2022.

SANTOS, Lyndainês A. dos. Aplicação de Processamento de Imagem Digital para Detecção de Câncer de Mama. In Anais da Mostra Nacional de Robótica - MNR 2018, 2018.

SHAPIRO, Linda; STOCKMAN, George. Computer vision. Vol. 3. New Jersey: Prentice Hall, 2001.

SILVA, Anna K. G. ; COSTA, Letícia F. de J. Importância do diagnóstico por imagem no câncer de mama. 2021. Trabalho de Conclusão de Curso (Bacharelado em Biomedicina) - UNA Câmpus Catalão, [S. I.], 2021. Disponível em: <https://repositorio.animaeducacao.com.br/handle/ANIMA/19213>. Acesso em: 21 jun. 2022.

SILVA, F. J. V.; ALVES, C. H. F. Aplicação de técnicas de processamento de imagens digitais em imagens geradas por ultrassom. 8º Encontro Regional de Matemática Aplicada e Computacional, 2008.

SILVA, T. C. et Al. Detecção automática de tumores em mamografias utilizando técnicas de processamento digital de imagem. In XXIV Congresso Brasileiro de Engenharia Biomédica – CBEB 2014, 2014.

VALE, G. M. D.; POZ, A. P. D. Processo de detecção de bordas de canny. Boletim de Ciências Geodésicas, v. 8, n. 2, 2002.