

Classificação de lesões mamárias das categorias 4 e 5 do padrão bi-rads[®] utilizando redes neurais

Classification of breast injuries in categories 4 and 5 of the bi-rads[®] standard using neural networks

Clasificación de las lesiones de la mama en las categorías 4 y 5 del estándar bi-rads[®] mediante redes neuronales

Recebido: 02/06/2022 | Revisado: 20/06/2022 | Aceito: 30/06/2022 | Publicado: 09/07/2022

Elmo de Jesus Nery Júnior

ORCID: <https://orcid.org/0000-0003-0225-5384>
Universidade Federal do Piauí, Brasil
E-mail: elmojunior.cx@gmail.com

Otílio Paulo da Silva Neto

ORCID: <https://orcid.org/0000-0003-1940-9773>
Instituto Federal do Piauí, Brasil, Brasil
E-mail: otilio.paulo@ifpi.edu.br

Francisco Adelson Alves Ribeiro

ORCID: <https://orcid.org/0000-0003-2850-8028>
Instituto Federal do Maranhão, Brasil
E-mail: adelton@ifma.edu.br

Francisco das Chagas Alves Lima

ORCID: <https://orcid.org/0000-0002-0447-4911>
Universidade Estadual do Piauí, Brasil
E-mail: fdcalima@gmail.com

Larysse Maira Cardoso Campos Verdes

ORCID: <https://orcid.org/0000-0001-6064-149X>
Universidade Federal do Piauí, Brasil
E-mail: mayra9_3@hotmail.com

Danylo Rafael Costa Silva

ORCID: <https://orcid.org/0000-0001-6782-5312>
Universidade Federal do Piauí, Brasil
E-mail: danylorafael@hotmail.com

Maria da Conceição Barros Oliveira

ORCID: <https://orcid.org/0000-0002-8436-3604>
Universidade Federal do Piauí, Brasil
E-mail: mariah.da.concecao@hotmail.com

Pedro Henrique Bandeira Diniz

ORCID: <https://orcid.org/0000-0002-4178-6738>
Universidade Federal do Maranhão, Brasil
E-mail: pedro_hbd@hotmail.com

Anselmo Cardoso de Paiva

ORCID: <https://orcid.org/0000-0003-4921-0626>
Universidade Federal do Maranhão, Brasil
E-mail: paiva@nca.ufma.br

Aristófanês Corrêa Silva

ORCID: <https://orcid.org/0000-0003-0423-2514>
Universidade Federal do Maranhão, Brasil
E-mail: ari@nca.ufma.br

Resumo

O câncer de mama é a doença com mais incidência entre as mulheres em todo mundo, estimativa para Brasil no biênio de 2020-2021 cerca de 66.280 novos casos de câncer de mama que corresponde a uma taxa 29,7% dos casos na população feminina e cerca de 15.000 mortes pela doença. A mamografia é um dos exames mais utilizado para detecção precoce desde tipo de neoplasia. No entanto, erros acontecem na leitura e interpretação dos laudos, mesmo um profissional bem treinado apresenta uma taxa de acertos entre 65% a 75% com uma quantidade de falso negativo variando entre 15% a 30% e um falso positivo de 7% a 10%, resultando em quantidade desnecessária de biópsia, de 65% a 90% das biópsias de tecido com suspeita de câncer apresentam-se benigna, causando repercussão emocional e física para as pacientes. Sistemas computacionais podem ser desenvolvidos para auxiliar no diagnóstico médico. Este artigo aplicou as técnicas de redes neurais para desenvolver uma ferramenta computacional capaz de classificar lesões

das categorias 4 e 5 do padrão BI-RADS®. Os resultados adquiridos pelo software, observaram que o melhor classificador no que diz respeito à taxa de acerto acurácia, foi o Deep Learning, atingindo um percentual de 82,60%, o Support Vectors Machine - SVM teve um percentual de 73,97%. Isto demonstra que as técnicas de redes neurais utilizadas no projeto do software mostram uma eficácia na tarefa de classificação das lesões.

Palavras-chave: Câncer de mama; Classificação BI-RADS®; Processamento de imagem; Redes neurais.

Abstract

Breast cancer is the disease with the highest incidence among women worldwide, with an estimate for Brazil in the 2020-2021 biennium about 66,280 new cases of breast cancer, which corresponds to a rate of 29.7% of cases in the female population and about 15,000 deaths from the disease. Mammography is one of the most used tests for early detection of this type of neoplasm. However, errors occur in the reading and interpretation of reports, even a well-trained professional has a success rate between 65% and 75% with an amount of false negative varying between 15% to 30% and a false positive of 7% to 10%, resulting in an unnecessary amount of biopsy, 65% to 90% of tissue biopsies with suspected cancer are benign, causing emotional and physical repercussions for patients. Computer systems can be developed to aid in medical diagnosis. This article applied neural network techniques to develop a computational tool capable of classifying injuries from categories 4 and 5 of the BI-RADS® standard. The results acquired by the software, observed that the best classifier with regard to the accuracy rate was Deep Learning, reaching a percentage of 82.60%, the Support Vectors Machine - SVM had a percentage of 73.97%. This demonstrates that the neural network techniques used in the software design show an efficiency in the lesion classification task.

Keywords: Breast cancer; BI-RADS® Classification; Image processing; Neural networks.

Resumen

El cáncer de mama es la enfermedad con mayor incidencia entre las mujeres en todo el mundo, con una estimación para Brasil en el bienio 2020-2021 de unos 66.280 nuevos casos de cáncer de mama, lo que corresponde a una tasa del 29,7% de los casos en la población femenina y cerca de 15.000 muertes de la enfermedad La mamografía es una de las pruebas más utilizadas para la detección precoz de este tipo de neoplasias. Sin embargo, se producen errores en la lectura e interpretación de los informes, incluso un profesional bien capacitado tiene una tasa de éxito entre el 65% y el 75% con una cantidad de falsos negativos que varía entre el 15 % y el 30 % y un falso positivo del 7 % al 10 %, lo que da como resultado una cantidad innecesaria de biopsias, del 65 % al 90 % de las biopsias de tejido con sospecha de cáncer son benignas, lo que causa problemas emocionales y físicos. repercusiones para los pacientes. Se pueden desarrollar sistemas informáticos para ayudar en el diagnóstico médico. Este artículo aplicó técnicas de redes neuronales para desarrollar una herramienta computacional capaz de clasificar lesiones de las categorías 4 y 5 del estándar BI-RADS®. Los resultados adquiridos por el software, observaron que el mejor clasificador en cuanto a la tasa de precisión fue Deep Learning, alcanzando un porcentaje de 82,60%, la Máquina de Vectores de Soporte - SVM tuvo un porcentaje de 73,97%. Esto demuestra que las técnicas de redes neuronales utilizadas en el diseño del software muestran una eficiencia en la tarea de clasificación de lesiones.

Palabras clave: Câncer de mama; Clasificación BI-RADS®; Procesamiento de imágenes; Redes neuronales.

1. Introdução

O câncer de mama é a neoplasia maligna mais incidente em mulheres na maior parte do mundo, caracterizado especificamente pela divisão incorreta e desordenada das células na região dos seios, motivo pelo qual leva este nome, podendo ocorrer tanto no corpo masculino quanto no feminino, no entanto, são as mulheres que têm a massacrante maioria dos casos de câncer mamário (Batista *et al.*, 2020; Santos, 2018).

Segundo as estatísticas extraídas pelo Observatório Global do Câncer (Globocan, 2020), em 2020, foram estimados 2,2 milhões de casos novos de câncer e 690 mil óbitos pela doença em 185 países do globo, comprovando que este tipo de câncer é o que mais afeta a população no mundo atual.

A estimativa para o Brasil, de acordo com Instituto Nacional do Câncer (Inca), para biênio de 2020-2021 é o diagnóstico de 66.280 novos casos de câncer de mama que corresponde a uma taxa 29,7% dos casos na população feminina e cerca de 15.000 mortes pela doença, com um risco de aproximadamente 43,74 para cada 100 mil mulheres (Inca, 2019). Todavia há estratégias para se reduzir a mortalidade por câncer de mama. A mamografia é o exame mais utilizado para a detecção precoce deste tipo de neoplasia, o que facilita a identificação de lesões mamárias em sua fase inicial, fator primordial para o sucesso do tratamento (Alves, Ribeiro *et al.*, 2017).

A mamografia, também chamada mamograma ou mamografia digital, é um exame realizado que submete as mamas a raios-X para produzir imagens de alta resolução e permitir que o especialista analise e identifique de forma visual onde se encontra a lesão (Moore *et al.*, 2018). De acordo com estudos observacionais, quando realizado o rastreamento por meio da mamografia visando a detecção precoce, reduz-se o índice de mortalidade em mulheres acometidas pelo câncer de mama em cerca de 15% a 25% (Sala, 2021).

O diagnóstico prévio é a melhor estratégia para prevenção desse tipo de câncer, os exames clínico de imagem da mama são os mais recomendados, com destaque a mamografia se torna um dos métodos mais eficazes (Balas *et al.*, 2020; Giess, 2012; Prado, 2020; Tortora, 2016). Ressalta-se que a leitura e interpretação das imagens são tarefas difíceis que exigem experiência do radiologista visto que mesmo um profissional bem treinado apresenta uma taxa de acertos entre 65% a 75% (Justo *et al.*, 2013).

No entanto, apesar de todo o avanço tecnológico e científico, era comum que houvesse confusão entre médicos que tratam o câncer de mama perante a análise dos diagnósticos e dos laudos, o que causava problemas aos pacientes relativos às abordagens terapêuticas (Guimarães & Choiniak, 2019).

Com base nestas divergências, no ano de 1993, o Colégio Americano de Radiologia, padronizou os achados mamográficos para que os especialistas “falassem a mesma língua” reduzindo a confusão na interpretação dos laudos, foi criado o sistema de classificação BI-RADS® (Breast Image Reporting and Data System - Sistemas de Dados e Relatório de Imagem da Mama), tem o papel importante na indicação de biópsia em lesões suspeitas (Acr, 2016). A sua classificação é dividida por categoria variando de 0 a 6, em cuja classificação a categoria 0: incompleta; 1 e 2 achado benigno; 3 achado provavelmente benigno; 4 achado suspeito variando de 2% a 95%; 5 achado maligno e 6 malignidade comprovada por biópsia.

A mamografia apresenta falha na sua interpretação com uma quantidade de falso negativo de 15% a 30% e um falso positivo variando de 7% a 10% em mulheres com idade reprodutiva, resultando em quantidade desnecessária de biópsia, de 65% a 90% das biópsias de tecido com suspeita de câncer apresentam-se benigna, causando repercussão emocional e física para as pacientes (ALVES, Ribeiro *et al.*, 2017; Fernandes, 2014).

No entanto, ferramentas computacionais podem auxiliar os profissionais médicos na interpretação e no diagnóstico dessas imagens, como por exemplo, os sistemas Computer Aided Detection – CAde (Detecção auxiliado por computador) e os sistemas Computer Aided Diagnosis – CADx (Diagnóstico orientado por computador) os quais aumentam a sensibilidade, especificidade e acurácia do câncer da mama. Tais ferramentas aplicadas em conjunto com as técnicas de redes neurais para o processamento de imagens mamográficas, podem melhorar e extrair informações úteis ao diagnóstico preciso do câncer de mama melhorando o índice de acertos médicos (EL Atlas *et al.*, 2014; Ganesan *et al.*, 2012).

As redes neurais artificiais, ou simplesmente redes neurais, são estruturas computacionais que tentam emular o comportamento do cérebro humano. Para tal, essas redes são formadas pela interligação de estruturas computacionais chamadas neurônios. Esses neurônios são processadores de dados que tentam se comportar como neurônios naturais, recebendo estímulos nas entradas, processando esses estímulos e através de uma função de ativação exibem uma saída, que para o caso mais simples (o perceptron de camada única) é a simples ativação, ou não, da saída, em valor alto ou baixo dependendo do valor das entradas e de um limiar (Huynh *et al.*, 2016).

O presente artigo visa aplicar as técnicas de redes neurais para desenvolver uma ferramenta computacional capaz de classificar lesões das categorias 4 e 5 do padrão BI-RADS®.

2. Metodologia

O presente trabalho é um estudo experimental sobre classificação BI-RADS® de lesões em imagens mamográficas auxiliadas por computador, a partir do qual foi desenvolvido o software SPIBIRADS – Sistemas de Processamento de Imagem

para classificar lesões mamárias baseado no padrão BI-RADS[®], certificado pelo Instituto Nacional de Propriedade Industrial - INPI registrado com nº BR512019001754-4. O Estudo incluiu 350 imagens divididas em duas categorias: BI-RADS[®] 4 e BI-RADS[®] 5. As imagens utilizadas foram adquiridas na base de dados de domínio público DDSM (Digital Database for Screening Mammography – Banco de dados Digital para Mamografia de Rastreamento), da Universidade do Sul da Flórida, EUA. E em seguida, realizou-se o pré-processamento da imagem para remoção de estrutura indesejada (Pavan, 2017), seguido pela segmentação esse processo é realizado para buscar a melhor limiar da imagem. Utilizamos três procedimentos, o primeiro foi método de OTSU e o segundo foi o método PSO (Particle Swarm Optimization - Otimização por exame de partículas) e o terceiro aplicando o algoritmo Graph Clustering - Agrupamento de grafo, aplicados nas pesquisas de (SILVA, Neto *et al.*, 2016) (ALVES, Ribeiro *et al.*, 2017). Próximo passo fez-se a separação da base, extração das características e classificação das lesões com SVM (Support Vector Machines - Máquina de Vetores de Suporte) e Deep Learning - Aprendizado Profundo.

2.1 Base de Imagens


As imagens mamográficas foram adquiridas na base de dados de domínio público DDSM¹ com uma quantidade aproximadamente de 2.600 imagens. Cada caso mamográfico está disposto pela DDSM em imagens obtidas nas duas mamas de cada paciente, nas posições Médio-Lateral Oblíqua e Crânio-Caudal. Tais imagens são disponibilizadas no padrão LJPEG e representadas em níveis de cinza com resolução de 12 ou 16 bits por pixels. Os laudos gerados por especialistas estão inseridos às imagens contendo informações como o código de cada paciente, a idade da mesma na época do estudo, a classificação na categoria BI-RADS[®] (Breast Imaging Report and Data System) e na composição da densidade mamária segundo o mesmo padrão, além de estarem acompanhados de tipo de anormalidade e a localização da lesão (Heath & Bowyer, 2000).

2.2 Pré-processamento

Em seguida, se faz necessária a remoção das estruturas não-desejadas, “limpando” a imagem dos ruídos, bordas, marcações, músculos desinteressantes, e outras informações que divergem do estudo pretendido, mas que estão visíveis na imagem que podem atrapalhar a clareza e assertividade do diagnóstico (Pavan, 2017). Tal procedimento precede a segmentação das imagens. Após a remoção destas estruturas, é aplicada a técnica de realce baseada no histograma e o filtro da média, com finalidade de destacar as estruturas internas das mamografias, ou seja, das regiões que o estudo deve ser focado como mostra a Figura 1 (Alves, Ribeiro *et al.*, 2017) (Silva, Neto *et al.*, 2017).

¹ <http://www.eng.usf.edu/cvprg/Mammography/Database.html>

Figura1. Resultado das etapas do melhoramento: (a) Imagem original; (b) Imagem sem as bordas e marcações; (c) Realce local; (d) Filtro da média.



Fonte: Autores.

2.3 Segmentação

Após o pré-processamento, ocorre a segmentação, que consiste na separação das regiões mais homogêneas e similares na imagem, concluindo nos objetos considerados suspeitos, tais como nódulos, massas estranhas, microcalcificações, assimetrias, ou qualquer outra anomalia que foge da anatomia da região das mamas em questão (ALVES, Ribeiro *et al.*, 2017; Silva Neto, 2016). Neste projeto, é proposta a abordagem de segmentação dividida em três etapas, na primeira utilizamos o método (Otsu, 1979), a segunda o método PSO - Otimização por exame de partículas (Van Den Bergh, 2007) e a terceira é composta pelo Graph Clustering - Agrupamento de grafo.

2.4 Otsu


O algoritmo de (Otsu, 1979) reconhece que a imagem está dividida em duas classes, objeto e fundo, e busca localizar especificamente encontrar a limiar que melhor divide essas anomalias por meio de múltiplas iterações, calculando a diferenciação entre as classes de objeto e fundo para todos e quaisquer possíveis limiares, aplica-se a Equação 1 para encontrar o desvio padrão gerado.

$$\delta^2 = \frac{1}{N} \sum_{j=1}^N (y_i - m_{ij})^2, \quad (1)$$

Então o $\delta^2 > \text{dpmi}$, aplica o centróide g de cada classes/cluster com o novo limiar para se dividir este cluster em dois novos classes/clusters. Aplica-se mais um vez o cálculo do desvio padrão deste cluster, se $(\delta^2 > \text{dpmi})$, conseqüentemente, este passo é executado de forma recursiva até que δ^2 não seja maior que dpmi . N é o número de pixels das imagens.

Quando definido, todos os pixels da imagem que estiverem destacadas, ora, cujos valores de nível acinzentado são menores ao limiar definido, esses serão selecionados para o primeiro cluster e, assim, os valores cujo nível de cinza forem maior ou igual ao estipulado em limiar, são selecionados como pertencentes ao segundo cluster, permitindo melhor diferenciação e identificação da região como mostra a Figura 2. (Silva, Neto *et al.*, 2017).

Figura 2. (a) Imagem de entrada; (b) Processamento Otsu.



Fonte: Autores.

2.5 Otimização por exame de partículas - PSO


Depois de receber a imagem processada aplica-se o algoritmo PSO (Particle Swarm Optimization) para otimizar processo e encontrar a melhor limiar da imagem e consequentemente os melhores clusters/agrupamento, de acordo (Merwe *et al.*, 2003), cada partícula do PSO é formada por um vetor de centróides de tamanho N_c é a quantidade de grupos encontrados, e caracteriza um resultado para o problema. Quando acontece uma iteração, atribui-se os dados ao centróide ao qual estão mais próximos, avalia os resultados atualizados de acordo com a melhor posição de entrada por algumas partículas.

Para cada partícula X_i é tido como um conjunto de clusters, sendo assim, cada partícula representaria uma resposta completa de clusterização, isto é, no enxame do PSO, cada partícula possui um vetor de k centróides que são construídos de acordo com Equação 2 (RIBEIRO, Alves *et al.*, 2017).

$$x_i = (m_{i1} m_{i2}, \dots, m_{ij} m_{iN_c}) \quad (2)$$

Onde N_c é número de clusters, criados, m_{ij} corresponde ao j -ésimo centroide da i -ésima partícula, desse modo, uma única partícula caracteriza uma solução do problema de clusterização como mostra na Figura 3.

Figura 3. Resultado dos clusters gerados: (a) 10 cluster gerado; (b) 20 cluster gerado a partir do anterior; (c) 30 cluster gerado a partir do segundo.



Fonte: Autores.

Depois das imagens mamográficas segmentada através do método OTSU e PSO verifica as regiões suspeitas de lesões, o próximo passo será aplicado o graph clustering para agrupar as regiões de interesse (ROI).

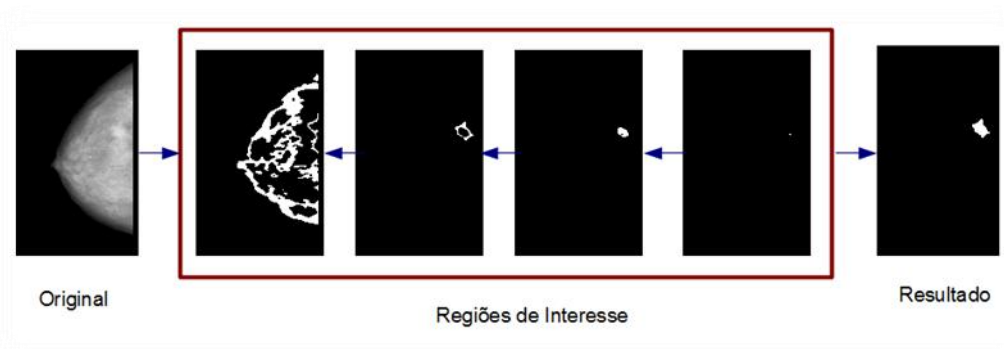
2.6 Graph Clustering - Agrupamento de Grafo

O Graph Clustering é um método de agrupamento dos vértices do gráfico em clusters considerando a estrutura das arestas das imagens. Neste trabalho, definimos alguns parâmetros: a região será definida em 3x3, o gráfico será formado a partir das regiões de interesse (ROI) de uma imagem, verificando sua vizinhança com todas as ROIs encontrados no cluster original, assim, será direcionado o grafo. Ao concluir o processo, os nós do grafo que possuem mais de duas ligações serão excluídos e os nós que tenham nenhuma ou no máximo duas ligações permanecerão. Cada nó do gráfico resposta desse processo, simula uma ROI (Schaeffer, 2007; Silva, Neto *et al.*, 2017).

Em seguida, (Schaeffer, 2007) esclarece os cálculos do graph cluster da seguinte forma: A partir de um nó qualquer do grafo, é calculado seu valor de Fator de Forma Circular (FFC) (Equação FFC), da seguinte forma: a) se FFC for menor que 10%: o nó será descartado e será escolhido outro nó, e o processo se repete; b) se FFC for maior que 10%: verifica-se suas adjacências, realizando as uniões do nós; c) após cada união, o FFC é calculado novamente, caso este, seja maior que 10% a união é válida e será verificado (caso exista) a próxima adjacência; d) se o FFC, após cada união, resultar em um valor menor que 10%, esta união não será válida, e o nó que foi unido será descartado.

Na Equação 3 FFC, que menciona (Alves, Ribeiro *et al.*, 2017), A corresponde à área e P ao perímetro de cada ROI e o cálculo se apresenta da seguinte forma: $FFC = (4 \cdot \pi \cdot A) / P^2$ O percentual da FFC foi adotado em 10%, em decorrência dos testes, sendo este o valor que apresentou melhores resultados como mostra na Figura 4.

Figura 4. Resultado do algoritmo Graph Clustering.




Fonte: Autores.

2.7 Separação da base

Para realizar o treinamento é muito importante organizar corretamente a base de dados de entrada de forma que as redes neurais façam o aprendizado correto, ou seja, o treinamento bem realizado depende da preparação dos dados, isso determina a taxa de aprendizado e predição na execução dos testes. A primeira etapa é organizar o conjunto de imagens que foram adquiridas conforme o trabalho (ALVES, Ribeiro *et al.*, 2017; SILVA, Neto *et al.*, 2017).

Em seguida, as lesões segmentadas passam por um pré-processamento para identificar o maior X (largura) e maior Y (altura) dentre todas as lesões, para se construir uma boundingbox - Caixa delimitadora padrão com fundo preto, inserindo as lesões no centro dessa boundingbox e deixando todas as imagens com as mesmas dimensões de largura e altura. Conforme ilustrado na Figura 5 (a) e (b).


Figura 5. Nódulo em fundo preto



Fonte: Autores.

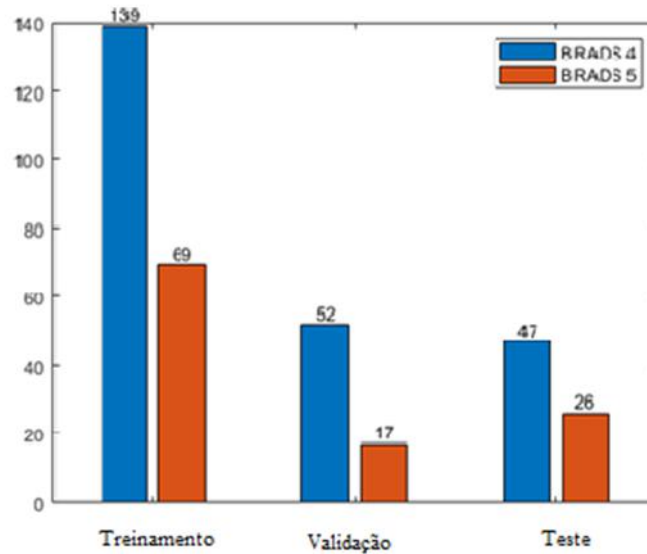
Na Figura 6, ilustra-se o algoritmo de agrupamento k-means (Pacífico, 2020) utilizado para criar os grupos de lesões baseado no desvio padrão, média e tamanho das lesões, gerando seis grupos para subdividir as lesões grandes e pequenas igualmente nas bases de treinamento, validação e teste como mostra na Figura 7. As imagens são rotuladas em duas categorias BI-RADS® 4 e BI-RADS® 5.

Figura 6. Visualização das dimensões das lesões.



Fonte: Autores.

Figura 7. Base treinamento, validação, teste.



Fonte: Autores.

2.8 Extração de características

A extração das características pode ser realizada através da forma e textura dos nódulos. A extração utilizada nesta pesquisa será a partir da textura dos nódulos mamários, aplicando-se os descritores de textura que expõe essas características através do objeto da imagem bem como, suavidade, rugosidade, uniformidade e granulação (Gonzalez; Woods & Eddins, 2010). Para caracterizar a textura ROI – Região de Interesse, utiliza-se as diversidades funcionais de acordo com (Tilman, 2001) que são as variações e valores de uma espécie e suas características influenciadoras no funcionamento de uma determinada comunidade. Foram utilizados os índices de diversidades funcionais para complementar a extração conforme a pesquisa (SILVA, Neto *et al.*, 2017), as ROIs - regiões de interesse dispõem da seguinte características: FADa - índice de diversidade funcional abundante, FADe - índice de diversidade funcional abundante da espécie, FADp - índice de diversidade funcional atributo pixel. Os índices extraídos permitem características mais detalhadas das regiões.

Outra extração de característica utilizada foi baseada nos descritores de Haralick para verificar os padrões de textura das ROIs. Foram aplicados nove descritores de acordo com (Haralick, 1973) contraste, homogeneidade, energia, entropia, momento diferença inverso, momento diferença de ordem, probabilidade máxima, variância inversa e correlação, conforme a pesquisa (Alves, Ribeiro *et al.*, 2017).

3. Resultados e Discussão

3.1 Experimentos

Uma vez que realizado toda metodologia aplicada na pesquisa para as etapas de preparação das imagens mamográficas, aquisição da base de dados DDSM, pré-processamento, segmentação com os métodos OTSU e PSO, graph clustering para encontrar as regiões de interesse (ROI), separação das bases para treinamento, validação, teste e extração das características, os mesmos foram utilizados como entrada para classificação de duas classes BI-RADS® categoria 4 e 5.

Utilizou-se técnicas de redes neurais artificiais para classificação das lesões mamárias baseado no padrão BI-RADS®. A extração e separação dos dados foram realizados em 350 nódulos mamários variando entre as duas categorias BI-RADS® 4 e BI-RADS® 5. Com este grupo de dados, o software foi utilizado para realizar as classificações dos nódulos mamários através

dos algoritmos Support Vectors Machine - Máquina de Vetores de Suporte (SVM) e Deep Learning - Aprendizado Profundo, a métrica utilizada para avaliar os classificadores, foi a acurácia (Gonçalves, 2017).

3.2 Achados

Os teste foram realizados em 350 nódulos escolhidos na base de dados de domínio público Digital Database for Screening Mammography - DDSM da Universidade do Sul da Flórida. Em seguida, se fez necessário realizar o pré-processamento das imagens para remoção das estruturas não-desejadas, após o pré-processamento, ocorre a segmentação da imagem utilizando o algoritmo de OTSU e PSO, o próximo passo será aplicar o graph clustering para agrupar as regiões de interesse (ROI). Depois de encontrar as ROIs é de suma importância realizar a separação da base para preparar as imagens de treinamento, validação e teste. As imagens foram rotuladas em duas categorias BI-RDS[®] 4 e BI-RADS[®] 5. Para a categoria 4 foram utilizadas 139 lesões, enquanto que para a categoria 5 utilizou-se 69 lesões para treino. Ao passo que, na realização da validação foram usadas 52 lesões de categoria 4 e 17 lesões de categoria 5. Para aplicação do teste foram utilizadas 47 lesões de categoria 4 e 26 lesões de categoria 5. O passo seguinte foi aplicar a extração das características utilizando o índice de diversidade e os descritores Haralick. Após realizar todas as etapas descritas acima efetuou-se a classificação dos nódulos mamários através dos algoritmos Support Vectors Machine - Máquina de Vetores de Suporte (SVM) e Deep Learning - Aprendizado Profundo.

O Quadro 1 apresenta os resultados obtidos por cada algoritmo que foi utilizado na etapa de classificação das lesões, observou que o melhor classificador que teve a melhor acurácia foi o Deep Learning, atingindo um percentual de 82,60%, o Support Vectors Machine - SVM obteve um percentual de 73,97%.

Quadro: 1 Resultado dos Classificadores.

Técnica	Treino		Validação		Teste		Acurácia média(%)
	Birads4	Birads5	Birads4	Birads5	Birads4	Birads5	
SVM	139	69	52	17	47	26	73,97
Deep Learning	139	69	52	17	47	26	82,60

Fonte: Autores.

O resultado encontrado demonstra que o Deep Learning é um algoritmo complexo devido ao empilhamento de diversas camadas ocultas que são similares aos neurônios, alimentam-se de uma grande quantidade de dados são capazes de reconhecer imagens e tem a possibilidade de aprender tarefas extremamente avançadas com poder de tomar decisões intuitivas e inteligentes. O algoritmo Support Vector Machine (SVM) não demonstrou um bom desempenho na extração e classificação das imagens mamográficas por utilizar uma menor quantidade de camadas. O bom desempenho do algoritmo depende da precisão com que os recursos serão identificados e extraídos. Qualquer alteração desses parâmetros de entrada, seu desempenho pode melhorar ou piorar os seus resultados (Reese, 2017).

4. Conclusão

Após a análise e discussão com os resultados da pesquisa verificou-se que a metodologia utilizada para detecção e

classificação das lesões mamárias das categorias 4 e 5 do padrão BI-RADS® somado com pré-processamento, segmentação OTSU e PSO, Graph clustering, separação da base, extração de característica, e classificação com Deep learning resultou em uma taxa de classificação de 82,60% de acurácia. Este estudo permitiu verificar o potencial do algoritmo Deep learning para classificação e detecção das lesões mamárias e as vantagens de aplicar este método independentemente do tipo de mama.

Esta pesquisa limitou-se às imagens mamográficas utilizando a base de dados de domínio público DDSM da Universidade do Sul da Flórida ao qual está disponível desde 1996 e não houve atualizações recentes. Foram também utilizados apenas uma quantidade de 350 imagens limitando assim o resultado e só foram classificados em duas categorias suspeitas de malignidade que são os BI-RADS® 4 e 5. Desta forma recomenda-se otimizar este método utilizando novas bases de dados e aumentando tanto a quantidade de imagens como também a quantidade de classificação por categoria de acordo com o padrão BI-RADS® variando categoria ade 1 a 3.

Referências

- Alves-Ribeiro, F. A., Costa-Silva, D. R., Escórcio-Dourado, C. S., da Silva-Neto, O. P., de Castro-Gonçalves, M. E., de Ribeiro, V. O., ... & da Silva, B. B. (2017). Masse detection in mammographic images using texture feature extraction and neural networks. *Journal of Computational and Theoretical Nanoscience*, 14(4), 2064-2068.
- AMERICAN COLLEGE OF RADIOLOGY (ACR) (2016). Atlas BI-RADS do ACR: sistema de laudos e registro de dados de imagem da mama / American College of Radiology; [tradução Angela Caracik] Colégio Brasileiro de Radiologia. 2. ed. - São Paulo
- Balas, N., Yun, H., Jaeger, B. C., Aung, M., & Jolly, P. E. (2020). Factors associated with breast cancer screening behaviors in a sample of Jamaican women in 2013. *Women & health*, 60(9), 1032-1039.
- Batista, G. V., Moreira, J. A., Leite, A. L., & Moreira, C. I. H. (2020). Câncer de mama: fatores de risco e métodos de prevenção. *Research, Society and Development*, 9(12), e15191211077-e15191211077.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144-152).
- Costa, F., & Ferreira, D. D. (2020, December). Classificação de nódulos mamários com máquina de vetores de suporte. In *Congresso Brasileiro de Automática-CBA* (Vol. 2, No. 1).
- El Atlas, N., El Aroussi, M., & Wahbi, M. (2014, November). Computer-aided breast cancer detection using mammograms: A review. In *2014 Second World Conference on Complex Systems (WCCS)* (pp. 626-631). IEEE.
- Fernandes, I., & dos Santos, W. (2014). Classificação de mamografias utilizando extração de atributos de textura e redes neurais artificiais. In *Congresso Brasileiro de Engenharia Biomédica* (Vol. 8).
- Ganesan, K., Acharya, U. R., Chua, C. K., Min, L. C., Abraham, K. T., & Ng, K. H. (2012). Computer-aided breast cancer detection using mammograms: a review. *IEEE Reviews in biomedical engineering*, 6, 77-98.
- Giess, C. S., Frost, E. P., & Birdwell, R. L. (2012, August). Difficulties and errors in diagnosis of breast neoplasms. In *Seminars in Ultrasound, CT and MRI* (Vol. 33, No. 4, pp. 288-299). WB Saunders.
- Giger, M. L. (2000). Computer-aided diagnosis of breast lesions in medical images. *Computing in Science & Engineering*, 2(5), 39-45.
- International Agency for Research on Cancer. (2020). *Global cancer observatory: cancer today*. 2020.
- Gonçalves, C. B. (2017). Detecção de câncer de mama utilizando imagens termográficas.
- Gonzalez, R. C., Woods, R. E., & Eddins, S. L. (2010). *Morphological reconstruction. Digital image processing using MATLAB, MathWorks*.
- Guimaraes, M. D., Bitencourt, A. G., Marchiori, E., Chojniak, R., Gross, J. L., & Kundra, V. (2014). Imaging acute complications in cancer patients: what should be evaluated in the emergency setting?. *Cancer Imaging*, 14(1), 1-12.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.
- Heath, M. D., & Bowyer, K. W. (2000, June). Mass detection by relative image intensity. In *Proceedings of the 5th International Workshop on Digital Mammography (IWDM-2000)* (pp. 219-225).
- Huynh, B. Q., Li, H., & Giger, M. L. (2016). Digital mammographic tumor classification using transfer learning from deep convolutional neural networks. *Journal of Medical Imaging*, 3(3), 034501.
- INCA National Cancer Institute. *Controle do Cancer de Mama*, (2019) [Online]. Available: <https://www.inca.gov.br/controle-do-cancer-de-mama/dados-e-numeros/incidencia>. [Accessed: 12/09/2021].

- Justo, N., Wilking, N., Jönsson, B., Luciani, S., & Cazap, E. (2013). A review of breast cancer care and outcomes in Latin America. *The oncologist*, 18(3), 248-256.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Moore, K. L., Dalley, A. F., & ARTHUER, F. (2018). *AgurAMR. Anatomia orientada para a clínica*. Guanabara 2014.
- Neto, O. P. S., Silva, A. C., Paiva, A. C., & Gattass, M. (2017). Automatic mass detection in mammography images using particle swarm optimization and functional diversity indexes. *Multimedia Tools and Applications*, 76(18), 19263-19289.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Pacífico, L. (2020, October). Agrupamento de imagens baseado em uma abordagem híbrida entre a otimização por busca em grupo e k-means para a segmentação automática de doenças em plantas. In *Anais do XVII Encontro Nacional de Inteligência Artificial e Computacional* (pp. 152-163). SBC.
- Pavan, A. L. M., Vacavant, A., Trindade, A. P., & de Pina, D. R. (2017). Fibroglandular tissue quantification in mammography by optimized fuzzy C-means with variable compactness. *Irbm*, 38(4), 228-233.
- Prado, N., Loiola, P., Guimarães, T., Ohara, E. C. C., & Oliveira, L. D. R. (2020). Gestante com diagnóstico de câncer de mama: prevenção, diagnóstico e assistência. *Brazilian Journal of Health Review*, 3(1), 1109-1131.
- Reese, H. (2017). Understanding the differences between AI, machine learning, and deep learning. URL: <https://www.techrepublic.com/article/understandingthedifferencesbetweenaimachinelearninganddeeplearning>.
- Sala, D. C. P. (2021). Rastreamento mamográfico no Brasil: determinantes à implementação no Sistema Único de Saúde e contribuições da Atenção Primária à Saúde (Doctoral dissertation, Universidade de São Paulo).
- Santos, T. A., & Gonzaga, M. F. N. (2018). Fisiopatologia do câncer de mama e os fatores relacionados. *Revista Saúde em Foco*, 10, 359-366.
- Schaeffer, S. E. (2007). Graph clustering. *Computer science review*, 1(1), 27-64.
- Tilman, D. (2001). Functional diversity. *Encyclopedia of biodiversity*, 3(1), 109-120.
- Tortora, G. J., & Derrickson, B. (2016). *Corpo Humano:- Fundamentos de Anatomia e Fisiologia*. Artmed Editora.
- Van Den Bergh, F. (2007). An analysis of particle swarm optimizers (Doctoral dissertation, University of Pretoria).
- Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE transactions on neural networks*, 10(5), 988-999.