

Classificação de Ultrassons de Câncer de Mama pela Utilização de Descritores de Textura

Nikollas G. Assumpção¹, Ricardo Costa P. Santos²

^{1,2}Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais (IFSudesteMG)

Juiz de Fora, MG - Brasil

nikollas18gabriel@gmail.com, ricardo.santos@ifsudestemg.edu.br

Abstract. *Breast cancer is the more common type of cancer among women in Brazil. The speed at which the cancer is identified directly impacts the survival rate and cure chance for the patients. Therefore, this paper sought to compare the characteristics extracted from breast ultrasound images by the texture descriptors LBP, HOG and LOSIB, in a classification task. Thereby, using the LBP descriptor for the extraction of features and an Artificial Neural Network for classification, was obtained an accuracy of 82.4% in the results. Reaching a conclusion that, it is possible to achieve a success rate of 82.4% by using in conjunction a texture descriptor for feature extraction and an Artificial Neural Network for classification.*

Resumo. *O câncer de mama é o tipo mais comum de câncer entre mulheres no Brasil. A velocidade na qual o câncer é diagnosticado impacta diretamente na taxa de sobrevivência e cura das pacientes. Para isso, esse trabalho buscou comparar as características extraídas de imagens de ultrassom de mama pelos descritores LBP, HOG e LOSIB, em uma tarefa de classificação. Foi obtida então, utilizando o descritor LBP na extração de características e uma Rede Neural Artificial para classificação, uma precisão de 82.4% nos resultados. Concluindo-se ao final do trabalho que, é possível alcançar uma taxa de acerto 82.4% aplicando-se em conjunto um descritor de textura para extração de características e uma Rede Neural Artificial na classificação.*

1. Introdução

Câncer é o nome coletivo dado a mais de 100 doenças cujo fator comum entre elas, é o crescimento desordenado (maligno) de células, que posteriormente, invadem tecidos e órgãos, podendo ocorrer metástase para outros órgãos e tecidos (Rodrigues et al, 2015). No Brasil, segundo dados do Instituto Nacional de Câncer (INCA) (INCA, 2020), o câncer de mama feminina é tipo de câncer mais comum entre mulheres e que mais causa mortes entre as mesmas, sendo estimados 66.280 novos casos no ano de 2020, representando 29,7% do número total de diagnósticos de câncer reportados e um total de 18.068 óbitos no ano de 2019, cerca de 16% do total de óbitos causados por câncer no país. A Organização Mundial da Saúde (World Health Organization, WHO) defende que a detecção prévia ainda é uma das melhores defesas contra o câncer de mama (WHO, 2016).

Acesso adequado à métodos de detecção e diagnóstico de câncer de mama é um dos principais passos para se reduzir a mortalidade dessa doença. Contudo, o método padrão para detecção de câncer de mama é a utilização de mamografia digital, é mais caro e requer mais recursos que podem não estar disponíveis em países pobres e/ou em desenvolvimento. Uma alternativa economicamente viável se apresenta na utilização do exame de ultrassom de mama para o diagnóstico, mais barata, com maior portabilidade e a versatilidade de ser aplicado para outras doenças (Sood et al, 2019).

Como dito anteriormente, a velocidade da detecção e diagnóstico de um câncer de mama influencia diretamente no tratamento do mesmo e na taxa de sobrevivência das pacientes, portanto, apresenta-se uma oportunidade para o desenvolvimento de uma ferramenta computacional para auxiliar médicos e especialistas na avaliação das imagens de ultrassom de mama. Este trabalho tem, então, por finalidade, mostrar que descritores de textura podem alcançar uma taxa de precisão considerável na tarefa de classificação de ultrassons de mama.

Este trabalho também busca, como objetivo secundário, criar uma comparação com o trabalho de Oliveira (2019), já que ambos utilizam a mesma base de dados de ultrassons de mama.

2. Revisão Sistemática da Literatura

Foi realizada uma revisão sistemática de artigos científicos nas principais bases acadêmicas como Capes e o Google Acadêmico, principalmente em língua inglesa.

A *string* de busca utilizada foi: ("*texture descriptor*") OR ("*image descriptor*") OR ("*feature descriptor*") AND ("*breast cancer*") AND ("*ultrasound*"). Os termos *texture descriptor* (descritor de textura), *image descriptor* (descritor de imagem) e *feature descriptor* (descritor de características) foram utilizados já que os termos são usados como sinônimos uns dos outros quando o tema dos descritores de textura é abordado nos artigos encontrados.

Foram encontrados 611 artigos científicos. Após leitura de títulos e resumos, 595 desses artigos foram removidos pois tratavam de assuntos ligados estritamente a área médica ou utilizavam outras técnicas de exame/imagem como mamografia digital, termografia, entre outras, que fogem do escopo desse trabalho.

Em Abdel-Nasser et al (2015), é proposto um descritor fuzzy de padrões locais direcionais para detecção de massas mamárias em raios-X, bem como imagens de ultrassom. Lógica fuzzy foi aplicada nas respostas das bordas dos pixels para produzir um descritor. O descritor proposto pode diferenciar adequadamente entre tecidos normais e massas sob diferentes condições como ruído e variação de compressão. A fim de avaliar a eficácia do descritor proposto, uma máquina de suporte de vetor foi usada para realizar a classificação entre massa ou tecido normal de um conjunto de regiões de interesse. O método proposto foi validado usando o conhecido banco de dados de câncer de mama mini-MIAS (raios-X imagens), bem como um banco de dados de imagens de ultrassom de câncer de mama. Para a tarefa de classificação foram utilizadas uma máquina de suporte de vetores linear (LSVM) e uma máquina de suporte de vetores não-linear (NLSVM), alcançando valores de AUC 86.65% e 91.4%, respectivamente.

Já em Abdel-Nasser et al (2017), para resolver o problema de ruídos e artefatos que aparecem em imagens de ultrassom, que podem degradar o desempenho de sistemas

diagnostico auxiliado por computador (CAD), e ao contrário dos métodos presentes no estado da arte da literatura que utilizam um único ultrassom da mama, é proposto o uso de uma abordagem de super-resolução que explora as informações complementares fornecidas por várias imagens de ultrassom do mesmo alvo. O sistema CAD proposto consiste em quatro estágios: computação de super-resolução, extração da região de interesse (ROI), extração das características de textura e classificação das características extraídas. O número de imagens de ultrassom utilizadas na super-resolução variava entre 3, 5, 7 e 9 imagens. Foram utilizados cinco descritores de textura para avaliar a performance de cada variação no número de imagens da super-resolução, sendo eles: matriz de co-ocorrência de níveis de cinza (GLCM), padrões binários locais (LBP), padrões binários locais baseados em congruência de fase (PCLBP), histograma de gradientes orientados (HOG) e padrão do espectro de lacunaridade. De todos descritores de textura, o melhor resultado foi obtido com 5 imagens de ultrassom com o descritor HOG, alcançando um valor de AUC de 0.989.

Cai (2015) propõe um descritor de textura de padrão binário baseado em congruência de fases (PCBP). Este é um descritor de textura local orientado que combina a abordagem de congruência de fase (PC) com o padrão binário local (LBP). Uma máquina de suporte de vetor (SVM) é posteriormente aplicada para a classificação do tumor. Para verificar a eficiência do descritor de textura PCBP proposto, ele foi comparado com outros três descritores de textura de última geração e experimentos foram realizados em um banco de dados de imagens de ultrassom de mama, incluindo 138 casos. O descritor de textura proposto atingiu o valor de AUC de 0,894.

Shia, Lin e Chen (2021) introduz um método de aprendizado de máquina e demonstra um projeto de um procedimento de análise para a classificação de câncer de mama entre benigno e maligno em imagens de ultrassom, sem a necessidade de pré-processamento da região suspeita de ser um tumor. O conjunto de dados era constituído por 677 imagens de ultrassom, sendo elas 312 benignas e 365 malignas. Em relação às imagens bidimensionais dos ultrassons, um descritor de pirâmide de histograma de gradientes orientados foi extraído e utilizado para obter vetores de características das imagens de ultrassom. A otimização sequencial mínima (SMO) combinada ao aprendizado com peso localizado (LWL), foi utilizada para a tarefa de classificação. O desempenho de classificação do conjunto de dados de imagem mostrou sensibilidade de 81,64% e especificidade de 87,76% para imagens malignas, com uma AUC = 0,847. Os valores preditivos positivo e negativo foram 84,1 e 85,8%, respectivamente.

Em Oliveira (2019), a aplicação de descritores de textura de Haralick para a extração de características em imagens de ultrassom de mama, identificadas previamente como saudáveis ou como contendo nódulos cancerígenos, e a utilização de uma RNA (Rede Neural Artificial) na tarefa de classificação, obteve uma precisão de 76% nos resultados.

3. Fundamentação Teórica

3.1. Local Binary Pattern – LBP

O LBP foi proposto inicialmente para a descrição de uma textura, que poderia ser caracterizada por uma distribuição não uniforme de intensidades ou de cores. Devido a

sua boa performance e simplicidade computacional, ganhou rapidamente popularidade no ramo da visão computacional (Fan, Wang, Wu, 2015).

Aplicando LBP em uma imagem, cada *pixel* é rotulado com um valor inteiro. Cada um desses rótulos é chamado de padrão LBP. Para a determinação desse padrão, o valor do *pixel* é calculado, comparando a relação desse *pixel* com os *pixels* vizinhos.

Como proposto originalmente em Ojala et al, a intensidade de cada *pixel* vizinho dentro de uma janela de proporção 3 x 3 (que representa a menor unidade de *pixels* vizinhos, possuindo oito direções de *pixels* vizinhos ao redor de um *pixel* central) é comparada a do *pixel* central usando a Equação 1, obtendo-se 0 se o *pixel* vizinho tem intensidade menor que o *pixel* central ou 1 em caso contrário. Essas relações são armazenadas em sentido horário em um *array* binário, esse *array* é então convertido para um valor decimal (Awad, Hassaballah, 2016).

$$S(g_c - g_p) = \begin{cases} 1, & \text{se } g_p \geq g_c \\ 0, & \text{se } g_p < g_c \end{cases}$$

Equação 1. Comparação da intensidade do pixel central com seus vizinhos

Onde g_c é a intensidade do *pixel* central e g_p a intensidade dos *pixels* vizinhos. Numa janela de proporção 3 x 3, onde p representa um dos oito possíveis vizinhos. Então, o padrão LBP de um *pixel* é determinado pelo somatório dos valores de $S(g_c - g_p)$ ponderado por um fator binomial de 2^k . A formula é dada a seguir (Awad, Hassaballah, 2016):

$$LBP = \sum_{k=0}^7 S(g_c - g_p) \cdot 2^k$$

Equação 2. Cálculo do padrão LBP

O *array* binário de um *pixel* com oito vizinhos, assim $2^8 = 256$, significa que para cada *pixel* pode ser obtidas 256 diferentes classificações.

3.2. Histogram of Oriented Gradient - HOG

O HOG como proposto em Dalal e Triggs (2005), tem como objetivo ser um descritor de textura capaz de detectar pessoas e/ou pedestres em imagens mesmo com backgrounds complexos ou com pouca iluminação. Nele, a distribuição das direções dos gradientes de uma imagem é utilizada como características da imagem. Gradientes de uma imagem são uteis, pois, a magnitude de um gradiente é maior em bordas e cantos, ou seja, regiões de mudança abrupta de intensidade. Bordas e cantos apresentam informações muito mais uteis sobre o formato de um objeto do que regiões solidas.

A extração das características é ocorre pelas seguintes etapas:

1. A primeira etapa é o pré-processamento da imagem. Por definição, toda imagem que se deseja analisar utilizando o HOG deve ter uma proporção de 1:2. No artigo que propôs o descritor HOG, as correções de gamma de uma imagem também são um passo para o pré-processamento, mas o ganho de performance é mínimo.

2. Para calcular os valores do gradiente horizontal e vertical, são aplicados dois kernels (Equação 3) na filtragem da imagem:

$$D_x = [-1 \ 0 \ 1]$$

$$D_y = [-1 \ 0 \ 1]^T$$

Equação 3. Kernel para filtragem

3. A magnitude de um gradiente por ser calculada usando a Equação 4 e a orientação pela Equação 5:

$$g = \sqrt{g_x^2 + g_y^2}$$

Equação 4.

$$\theta = \arctan \frac{g_y}{g_x}$$

Equação 5.

4. A imagem é dividida em pequenas regiões conectadas denominadas células, e cada pixel dentro da célula participa de uma votação com pesos para um canal de histograma baseado em orientações, designando um valor de acordo com o bin (número) mais próximo no intervalo entre 0 e 180 graus.

5. O último passo é o cálculo do histograma de gradientes para cada célula. Como gradientes de uma imagem são sensíveis a mudança de iluminação em uma imagem, é necessário que a intensidade do gradiente deva ser normalizada localmente a fim de que essas mudanças não atrapalhem o resultado. Isso requer, porém, que um grupo de células sejam agrupadas em blocos maiores, mas relacionados espacialmente entre si. Esses blocos servem de base para o agrupamento e normalização dos histogramas. A normalização do bloco é dada pela Equação 6.

$$b' = \frac{b}{\sqrt{\|b\|^2 + e^2}}$$

Equação 6.

Onde b é o vetor normalizado contendo todos os histogramas em um dado bloco, e e é uma constante.

3.3. Local Oriented Statistical Information Booster – LOSIB

O principal objetivo do Local Oriented Statistical Information Booster é melhorar a performance dos descritores de textura adicionando informação estatística orientada local, calculada para todos os pixels de uma imagem. Esse tipo de informação é raramente usado quando outros descritores de textura analisam uma imagem (García-Olalla, 2015).

Seja c um pixel de posição (x_c, y_c) na imagem, e p um pixel em sua vizinhança (com $p \in \{0, 1, \dots, (P - 1)\}$, onde P é o número de vizinhos), cujas coordenadas são (x_p, y_p) , e sejam g_c e g_p seus respectivos valores de nível de cinza. A fim de obter o LOSIB de uma imagem, ele é primeiro necessário extrair as diferenças absolutas d_p entre os valores de nível de cinza g_c e g_p , para todos os pixels c da imagem (García-Olalla, 2014) como mostrado na Equação 7.

$$d_p(x_c, y_c) = |g_c - g_p|$$

Equação 7.

Dado um pixel c , as coordenadas (x_p, y_p) de seu p -ésimo vizinho são calculadas pela Equação 8, onde R é o raio da vizinhança ao redor do pixel e P é o número de vizinhos.

$$(x_p, y_p) = \left(x_c + R \cos\left(\frac{2\pi p}{P}\right), y_c + R \sin\left(\frac{2\pi p}{P}\right) \right)$$

Equação 8.

Os valores dos vizinhos que não estão localizados dentro do raio podem ser estimados pela interpolação dos pixels conectados a esse. Então o somatório de todas as diferenças ao longo de uma mesma direção é calculado utilizando a Equação 9, onde M e N são o número de linhas e colunas da imagem, respectivamente (García-Olalla, 2014).

$$\mu_p = \frac{\sum_{x_c=1}^M \sum_{y_c=1}^N d_p(x_c, y_c)}{M \times N}$$

Equação 9.

Logo, LOSIB terá a mesma quantidade de características extraídas que a quantidade de vizinhos considerados dentro da vizinhança e representa o somatório de todas as diferenças para todas as direções respectivas.

3.4. Rede Neural Artificial – RNA

Warren McCulloch e Walter Pitts propuseram um modelo simples para o neurônio biológico, que mais tarde ficou conhecido como um neurônio artificial. Ele tem uma ou mais entradas binárias (on/off) e uma saída binária. O neurônio artificial ativa a sua saída quando um certo número de suas entradas são ativadas. Mesmo com uma arquitetura simples, é possível se construir uma rede a partir desse modelo (Géron, 2017).

Porém, o neurônio artificial é muito simples e pouco versátil. Assim, um novo tipo de neurônio artificial, o perceptron, foi proposto.

O Perceptron é a base da rede neural e consegue receber um sinal como entrada e por algum tipo de função, produz uma saída que é o resultado da função (Bell, 2014). O Perceptron é baseado em um tipo de neurônio chamado de unidade de limite linear (linear threshold unit – LTU). A entrada e saída do perceptron são números ao invés de um sinal binário, e cada valor de entrada tem associado um peso. A LTU calcula uma soma ponderada das entradas (Equação 10) e então aplica uma função de ativação a essa soma e o resultado é a saída do Perceptron (Géron, 2017).

$$z = w_1 \cdot x_1 + w_2 \cdot x_2 \dots + w_n \cdot x_n = w^T \cdot x$$

Equação 10. Soma ponderada das entradas

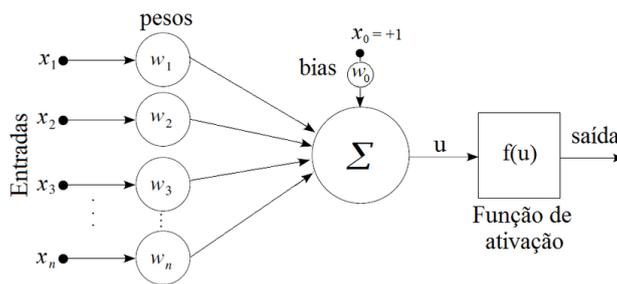


Figura 01. Perceptron LTU.

Fonte: www.researchgate.net/figure/Figura-2-Modelo-artificial-de-neuronio-biologico_fig2_275238647

Quando vários perceptrons são conectados, a rede neural artificial resultante é chamada de perceptron de multi camadas (Multi-Layer Perceptron – MLP).

Uma MLP (Figura 02) é composta por uma camada de entrada, uma ou mais camadas de LTU, chamada de camada oculta, e uma camada final de LTU chamada de camada de saída. Toda camada, exceto a camada de saída, inclui um neurônio *bias* e é conectada completamente com a próxima camada (Géron, 2017).

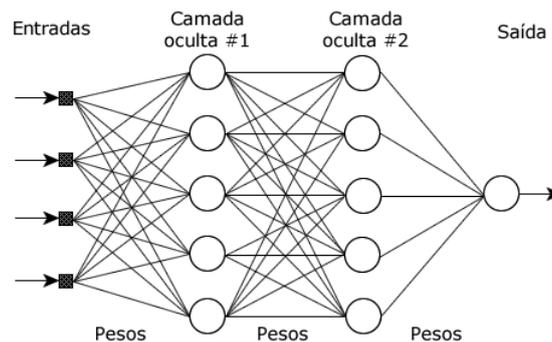


Figura 02. Rede neural MLP com duas camadas ocultas.

Fonte: www.researchgate.net/figure/Figura-29-arquitetura-de-uma-rede-MLP-com-duas-camadas-ocultas_fig3_305641448

3.5. Support Vector Machine - SVM

A máquina de vetores de suporte é uma técnica de classificação condições lineares para a separação em duas classes. Assim, o modo básico de uma SVM é encontrar uma linha, o hiperplano (Figura 03), que separe ao máximo as margens de cada classe (Aggarwal, 2015). A SVM é usada geralmente para a tarefa de classificação binária, mas alguns métodos de classificação multiclasse utilizam uma combinação de classificadores binários para atingir esse objetivo (Bell, 2014).

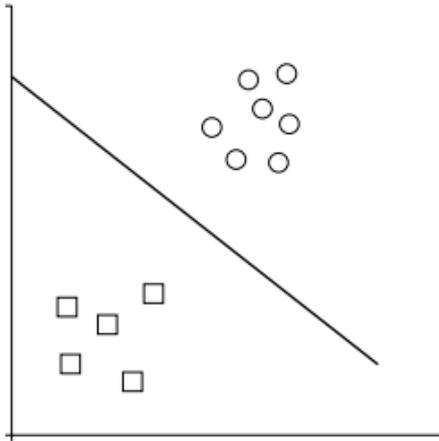


Figura 03. Separação de duas classes por um hiperplano. Crédito: (Bell, 2014)

A eficiência da SVM é totalmente dependente da capacidade de separação das classes pelo hiperplano, é crítico então, que essa separação seja cuidadosa (Aggarwal, 2015). Para cada ponto no gráfico (Figura 03) existe um valor para sua coordenada x e sua coordenada y . O ponto de classificação é então calculado pela Equação 11:

$$\text{sign}(ax + by + c)$$

Equação 11.

Os valores de a, b e c são os valores que definem o plano. Procura-se então uma função que retorne +1 quando o resultado é positivo, significando que o ponto está em uma categoria ou que retorne -1, quando o ponto estiver em outra categoria. Pontos mais distantes do hiperplano demonstram uma maior confiança que eles pertencem a uma classe específica. Cada ponto possui uma equação que indica o quão provável o hiperplano de produzir uma categorização correta. Essa equação é a probabilidade de todos os conjuntos de linhas, dada probabilidade (Equação 12) se baseia na distância dos pontos para o hiperplano (Bell, 2014).

$$\prod_{i=1}^N P[l_i|x_i] = \prod_{i=1}^N \frac{1}{1 + \exp(-l_i(ax_i + by_i + c))}$$

Equação 12.

Uma função de maximização e minimização para os valores da Equação 12 com intuito de encontrar o hiperplano é dada por (BELL, 2014):

$$\sum_{i=1}^N -\log(1 + \exp(-l_i(ax_i + by_i + c)))$$

Equação 13.

A linha principal do hiperplano é obtida pela notação dada a seguir:

$$w \cdot x - b = 0$$

Equação 14.

Onde w é o vetor de d dimensões representando os coeficientes do hiperplano de separação, e x é o ponto do objeto. Como os objetos são separados linearmente, é possível a criação de ainda dois outros hiperplanos de borda, que definem os deslocamentos laterais para ambos os lados do hiperplano principal, como mostrado na Figura 04. Um hiperplano de borda pode ser definido pela equação $w \cdot x - b = 1$ e para o outro $w \cdot x - b = -1$. Os objetos que se encontram nesses hiperplanos de borda são os chamados vetores de suporte (Bell, 2014).

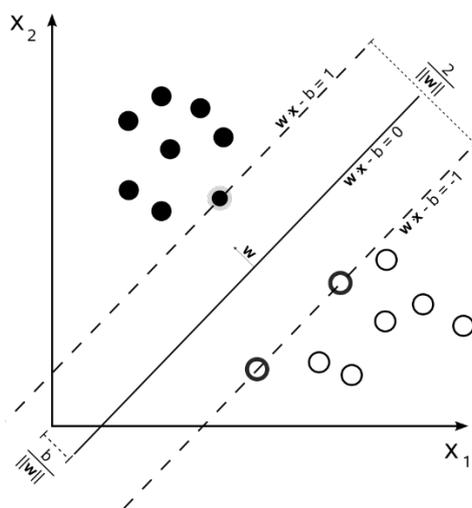


Figura 04. Hiperplanos de borda. Os objetos interceptados por eles são os vetores de suporte.

Fonte: commons.wikimedia.org/wiki/File:Svm_max_sep_hyperplane_with_margin.png

4. Metodologia

As imagens de ultrassom de câncer de mama foram escolhidas e coletadas a partir do banco de dados de imagens médicas, fornecido pelo site Medical Image Database (<http://www.onlinemedicalimages.com>). O site é mantido pela Unidade de Engenharia Biomédica do Instituto Internacional de Tecnologia de Sirindhorn com as imagens de ultrassom de câncer de mama fornecidas pelo Departamento de Radiologia da Universidade Thammasat e o Centro de Câncer de Mama Rainha Sirikit da Tailândia.

Com as imagens adquiridas, as mesmas foram separadas em dois grupos: o primeiro grupo foi montado com as imagens que possuem câncer, e o segundo grupo foi montado com as imagens que não possuem câncer. Em seguida, as imagens foram todas redimensionadas para um mesmo tamanho.

Primeiramente, foi utilizada a ferramenta Matlab para realizar a conversão das imagens de uma escala RGB de cores para uma escala de cinza. Com as mesmas convertidas, então foi criado um script para a extração das características para cada imagem de ultrassom. Nesse script, foi utilizada a implementação nativa oferecida pelo próprio Matlab dos descritores de textura HOG e LBP e para a extração das características do descritor LOSIB foi utilizada uma implementação externa.

As características extraídas por cada descritor de textura geraram três planilhas, respectivamente uma para cada descritor. O descritor HOG extraiu 2.916 características para cada imagem de ultrassom. No caso do descritor LBP, foram extraídas 236

características. Por fim, o descritor LOSIB, extrai 17 características de cada imagem de ultrassom.

Utilizando então a ferramenta Orange Canvas e as planilhas geradas pelos três descritores, foram criados 3 workflows (Figura 05), um para cada planilha referente a cada descritor. Em cada workflow foram colocadas uma Rede Neural Artificial, e uma Máquina de Vetores de Suporte. Para cada rede neural criada foram testadas diferentes combinações de número de neurônios, funções de ativação e solvers a fim de encontrar o melhor resultado. O mesmo foi feito para o caso de cada máquina de vetores de suporte criada, sendo testado diferentes tipos de kernels para obter o melhor resultado. Nos testes realizados com máquina de suporte de vetores, a variação entre eles foi dada pelo uso de diferentes funções para o kernel da SVM, sendo elas: linear, polinomial, RBF e sigmoide. No caso dos testes com rede neural artificial, foram utilizados 50 e 100 neurônios, variando a função de ativação entre: logística, identidade, tanh e relu e variando a função de solver entre: lbfgsb, sgd e adam. Durante os testes com a rede neural artificial, somente os quais foram realizados com 50 e 100 neurônios apresentaram resultados satisfatórios.

Por fim, foi comparado o melhor resultado obtido da rede neural com o da máquina de vetores de suporte respectivo de cada descritor de textura. Então o melhor resultado de cada descritor de textura sendo comparado com o melhor resultado dos demais.

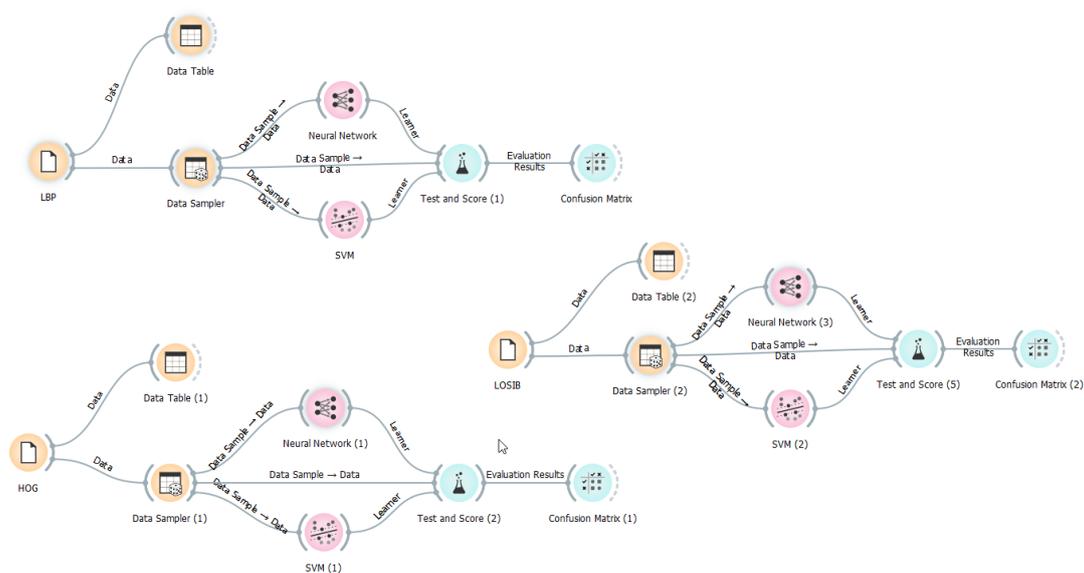


Figura 05. Workflows criados a partir de cada descritor de textura

5. Resultados

Realizando vários testes com cada descritor de textura (HOG, LBP e LOSIB), utilizando redes neurais artificiais e máquinas de suporte de vetores para a tarefa de classificação para cada descritor, a Tabela 01 abaixo apresenta os melhores resultados obtidos para cada descritor de textura em relação aos testes feitos com rede neural artificial utilizando 50 e 100 neurônios e as respectivas funções de ativação e solvers utilizadas. Já na Tabela 02 também abaixo, são apresentados os melhores resultados obtidos para cada descritor nos testes realizados com máquina de suporte de vetor e a respectiva função do kernel

usada. Por fim, a Tabela 03 apresenta os melhores resultados obtidos a partir de cada combinação.

Tabela 01. Melhores resultados obtidos na classificação com RNA

| Descritor | Número de Neurônios | Função de Ativação | Solver | Precisão |
|-----------|---------------------|--------------------|----------|----------|
| LBP | 50 | tanh | L-BFGS-B | 82.4% |
| LBP | 100 | tanh | Adam | 77.8% |
| HOG | 100 | ReLu | Adam | 76.7% |
| HOG | 50 | Logística | L-BFGS-B | 68.8% |
| LOSIB | 100 | ReLu | Adam | 76.7% |
| LOSIB | 50 | Logística | L-BFGS-B | 68.8% |

Tabela 02. Melhores resultados da classificação com SVM

| Descritor | Função do Kernel | Precisão |
|-----------|------------------|----------|
| LBP | RBF | 77.9% |
| HOG | Polinomial | 75.3% |
| LOSIB | Polinomial | 76.5% |

Tabela 03. Melhores resultados obtidos a partir dos resultados dos testes

| | HOG | LBP | LOSIB |
|-----|-------|-------|-------|
| RNA | 76.7% | 82.4% | 68% |
| SVM | 75.3% | 78% | 76.5% |

Analisando-se a Tabela 03, pode-se concluir que o melhor resultado obtido foi utilizando as características extraídas pelo descritor de textura LBP, usadas no treinamento de uma rede neural artificial para classificação. A rede neural foi configurada utilizando 50 neurônios na camada oculta, função de ativação tanh e com o solver L-BFGS-B (Figura 06), alcançando assim uma precisão de 82.4% de acerto (Figura 07). Redes neurais configuradas com mais ou menos que 50 neurônios apresentaram resultados inferiores utilizando as mesmas funções de ativação e solver. Outras funções de ativação e solvers utilizados, também apresentaram resultados com precisão inferior.

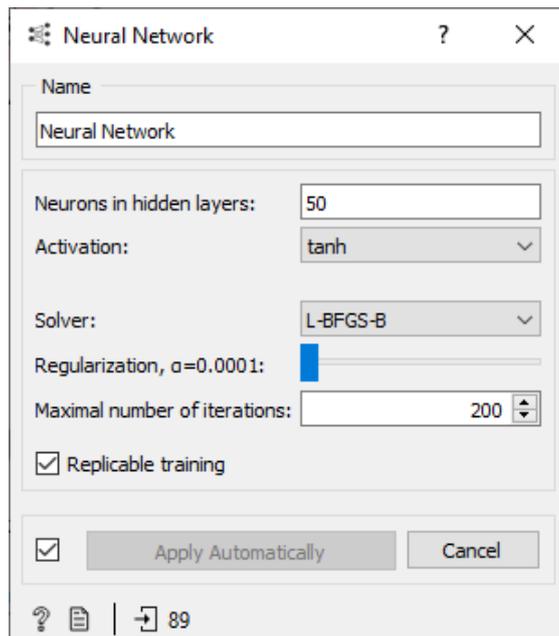


Figura 06. Configuração da Rede Neural

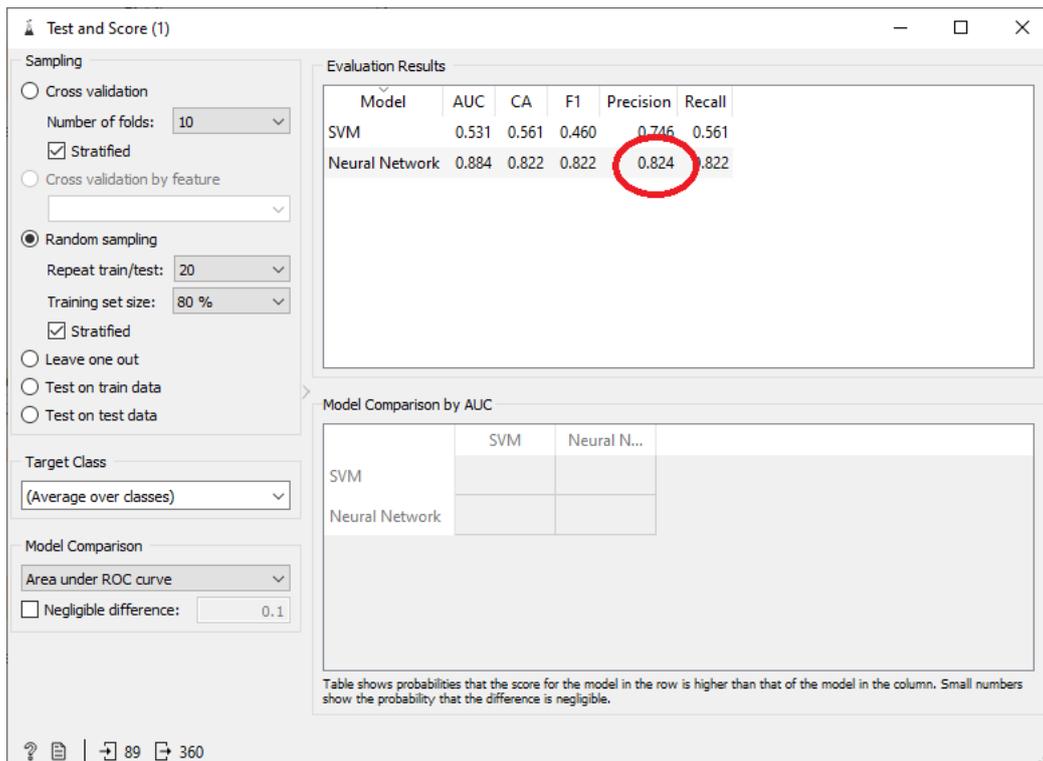


Figura 07. Melhor Resultado Obtido

6. Conclusão

Este estudo teve como objetivo testar a viabilidade da aplicação de descritores de textura para a classificação de imagens de ultrassom de câncer de mama. Utilizando os descritores HOG, LBP e LOSIB na extração de características e rede neurais para classificação, mostrou-se que a aplicando o descritor LBP, foi alcançada uma precisão de 82.4% na tarefa de classificação utilizando as características extraídas pelo mesmo. Comparando com os resultados obtidos por Oliveira (2019), já que esse e o presente trabalho utilizaram a mesma base de dados de imagens de ultrassom de mama, que utilizou as variáveis de Medida de Heterogeneidade e de Correlação descritas por Haralick, em conjunto com uma Rede Neural Artificial, alcançou uma precisão de 76%. Conclui-se então, que o descritor utilizado nesse trabalho apresentou uma performance melhor do que o utilizado no artigo de Oliveira (2019).

Como dito anteriormente, a velocidade na qual um paciente tem seu câncer diagnosticado impactada diretamente na chance de sobrevivência desse mesmo paciente. Sistemas de auxílio ao diagnóstico tem se tornado cada vez mais comuns na medicina moderna, permitindo que médicos e outros profissionais da área médica identifiquem positivamente cânceres e outras doenças. Oferecer então, tecnologias e técnicas nas quais esses sistemas possam utilizar é de extrema importância. Como mostrado neste trabalho, descritores de textura, principalmente o LBP, associados a um classificador, conseguem alcançar uma taxa de precisão que os torna candidatos viáveis para integrar um sistema de diagnóstico.

Em uma proposta para trabalho futuro, seria a ideia de combinar as características extraídas por diferentes descritores de textura, como por exemplo HOG e LBP, e utilizar esse combinado em uma tarefa de classificação para avaliar se, a combinação de abordagens diferentes de descritores de textura combinadas, podem alcançar resultados melhores que aqueles obtidos pelas mesmas separadamente.

Referências

- Rodtook, A., Kirimasthong, K., Lohitvisate, W., Makhanov, S.S. (2018) “Inicialização automática de contornos ativos e método de definição de nível em imagens de ultrassom de anormalidades mamárias”. *Reconhecimento de Padrões*, Vol. 79, p. 172-182;
- García-Olalla, O., Alegre E., Fernández-Robles, L., González-Castro, V. (2014) “Intensificador de Informações Estatísticas Orientadas Locais (LOSIB) para a Classificação de Texturas”, *Conferência Internacional sobre Reconhecimento de Padrões (ICPR)*, Estocolmo, Suécia;
- Rodrigues, J. D., Cruz, M. S. e P., Nascimento, A. (2015) “Uma análise da prevenção do câncer de mama no Brasil”. *Ciência & Saúde Coletiva*, Vol. 20, Nº. 10, p. 3163-3176;
- Sood, R., Rositch, A. F., Shakoor, D., Ambinder, E., Pool, K., Pollack, E., Mollura, D. J., Mullen, L. A. (2019) “Ultrassom para Detecção de Câncer de Mama no Mundo: Uma Revisão Sistemática e Meta-Análise” *Diário de Oncologia Mundial de Harvey*, Vol. 5, p. 1-17;
- Ojala T, Pietikainen M, Maenpaa T (2002) “Classificação de Textura de Multirresolução em Escala de Cinza e de Rotação Invariante com Padrões Locais Binários” *IEEE Transações em Análise de Padrões e Inteligência de Máquina* 24;
- Fan, B.; Wang, Z.; Wu, F. (2015) “Descritor Local de Imagem: Abordagens Modernas”. *Springer Berlin Heidelberg*, (SpringerBriefs em Ciência da Computação);
- Awad, A., Hassaballah, M. (2016) “Detectores e Descritores de Características de Imagem: Fundamentos e Aplicações”. *Springer Publicação Internacional*, (Estudos em Inteligência Computacional);
- Oliveira, L. S. (2019) “Identificação de Câncer em Exames por Imagens de Ultrassom Utilizando Redes Neurais Artificiais”.
- García-Olalla, O., Alegrea, E., Barreirob, J., Fernández-Robles, L., García-Ordása, M.T. (2015) “Classificação do Desgaste de Ferramenta Usando Descritores Baseados em LBP Combinado com Potenciadores baseados em LOSIB” *Conferência Internacional da Sociedade de Engenharia de Manufatura*;
- Abdel-Nasser, M., et al. (2015) “Caracterização de Tecido Mamário em Imagens de Raio X e Ultrassom Utilizando Padrão Direcional Local Difuso e Máquinas de Suporte de Vetores”. *Procedimentos da 10ª Conferência Internacional sobre Teoria e Aplicações de Visão Computacional*, p. 387-394;
- Abdel-Nasser, M. et al. (2017) “Classificação de Tumores Mamários em Imagens de Ultrassom Utilizando Métodos de Análise de Textura e Super Resolução”. *Aplicação de Inteligência Artificial para Engenharia*, p. 84-92;
- Cai, L., et al. (2015) “Robusto Descritor de Textura Baseado em Fase para a Classificação de Imagens de Ultrassom de Mama”. *Engenharia Biomédica Online*;

Shia, W., Li, L., Chen, D., (2021) “Classificação de Tumores Malignos em Ultrassom de Mama Utilizando Abordagens com Aprendizado de Máquina Não-Supervisionado”. Scientific Reports;

Géron, A. (2017) “Experiência Prática de Aprendizado de Máquina com Scikit-Learn & TensorFlow”. O ‘Reilly Media, 1º Edição;

Bell, J. (2020) “Aprendizado de Máquina na Prática para Desenvolvedores e Profissionais Técnicos”. Willey, 2º Edição;

Aggarwal, C. C. (2014) “Algoritmos e Aplicações para Classificação de Dados”. Chapman e Hall/CRC, 1º Edição.