

Classificação de anomalias mamárias

Rodrigo Blanke Lambrecht

Resumo—o câncer de mama é o mais comum entre as mulheres no mundo e no Brasil, depois do câncer de pele não melanoma, respondendo por cerca de 28% dos casos novos por ano. Quando a detecção do câncer de mam ocorre precocemente é possível, em grande parte dos casos, aumentar as chances de tratamento e cura. Uma das formas de detecção é através de mamografia. Devido a dificuldade que pode se tornar a análise de uma mamografia surgiram métodos e ferramentas de classificação de lesões mamárias com o intuito de minizar as possíveis falhas de um profissional de medicina. Será apresentado o resumo de artigos voltados a esta área, seus resultados e uma comparação entre eles.

Palavras-Chave—Câncer de mama, classificação, rede neural, processamento de imagem, mamografia.



1 Introdução

Segundo o Instituto Nacional do Câncer (INCA), o câncer de mama é o mais comum entre as mulheres no mundo e no Brasil, depois do câncer de pele não melanoma, respondendo por cerca de 28% dos casos novos por ano, também pode ser desenvolvido em homens, porém é raro e representa apenas 1% dos casos. Quando a detecção do câncer de mam ocorre precocemente é possível, em grande parte dos casos, aumentar as chances de tratamento e cura. Uma das formas de detecção é através de mamografia quando realizada em mulheres sem sinais e sintomas da doença, em uma faixa etária em que haja um balanço favorável entre benefícios e riscos dessa prática. No Brasil o exame de mamografia é recomendado a cada 2 anos para as mulheres que estão entre 50 e 69 anos [1].

Varios fatores podem influenciar na sensibilidade do exame de mamografia, afetando a qualidade do mesmo. Esses fatores resultam em possíveis erros de diagnósticos pelos radiologistas que podem variar de 10% a 30% dos casos. Na medicina o uso de imagens é um recurso muito importante para o diagnóstico de anomalias. O processamento digital de imagens estuda requisitos para extrair informações técnicas a fim de melhorar os parâmetros para um diagnóstico mais

preciso, aumentando a interpretação da mamografia [2].

O restante deste trabalho está organizado da seguinte maneira: Em cada um dos capítulos de 2 a 6 será apresentado o resumo de um artigo relacionado com classificação de lesões mamárias. No capítulo 7 é realizada uma comparação entre os artigos e no capítulo 8 é apresentada a conclusão.

2 Abordagem Deep Learning para Classificação de Lesões Mamárias

Neste trabalho é proposto uma nova metodologia de classificação de regiões extraídas de mamografias em massa e não massa usando técnicas de *deep learning*. Nessas técnicas, as características são extraídas automaticamente de acordo com a base de treinamento [3].

A contribuição consiste em propôr um método eficiente, de alta sensibilidade e baixa taxa de falso positivos através de *deep learning* que permite que características diversas sejam extraídas da própria imagem gerando um número maior de peculiaridades relevantes durante a classificação. A metodologia proposta é demonstrada na Figura 1. A aquisição de imagens para os testes aplicados foi obtida através da *Digital Database for Screening Mammography* (DDSM), em um total de 6181 regiões de interesse (ROI), sendo que 1156 destas classificadas como massas e 5025 em não massa. Foram aplicadas técnicas de processamento de imagens para melhorar o comportamento do resultado, sendo elas a de realce

• **Rodrigo Blanke Lambrecht:** Programa de Pós-Graduação em Eletrônica e Computação, Centro de Ciências Sociais e Tecnológicas. Universidade Católica de Pelotas - UCPEL.
E-mail: rodrigoucpel@hotmail.com

logarítmico e de equalização de histograma, Para realizar a classificação das imagens foram utilizadas arquiteturas de redes neurais de convolução: AlexNet e GooLeNet modificando alguns de seus parâmetros para obter um melhor resultado.



Figura 1. Metodologia de Abordagem Deep Learning para Classificação de Lesões Mamárias

Os resultados obtidos no trabalho foram avaliados de acordo com a Especificidade, Sensibilidade e Acurácia e pode-se comparar os resultados dos dois métodos de *deep learning* nas Tabelas 1 e 2.

	Sensibilidade	Especificidade	Acurácia
Histograma Equalizado	0,7024	0,965	0,9159
Realce Logarítmico	0,6886	0,9586	0,9081
Base de Dados Original	0,7993	0,9745	0,9417

Tabela 1

Resultados encontrados quando os tecidos foram treinados e classificados utilizando-se a AlexNet

	Sensibilidade	Especificidade	Acurácia
Histograma Equalizado	0,5986	0,9705	0,901
Realce Logarítmico	0,2845	0,9299	0,7427
Base de Dados Original	0,6021	0,9315	0,8699

Tabela 2

Resultados encontrados quando os tecidos foram treinados e classificados utilizando-se a GooLeNet

3 Diagnóstico de Câncer de Mama Através de Vetores de Descritores Localmente Agregados

Devido aos padrões complexos de imagens de mamografia é necessário habilidade e experiência por parte do médico examinador, o que pode ocasionar em resultados equivocados. O objetivo principal deste trabalho é diminuir o número destas falhas. Para isso, é proposto uma extração

de características de textura usando Vetores de Descritores Localmente Agregados [4].

A aquisição de imagens deste trabalho foi obtida através da *Digital Database for Screening Mammography (DDSM)*, em um total de 1155 ROI's, sendo 530 benignas e 625 malignas. Foi aplicada técnica de realce logarítmico para melhorar a imagem de forma com que auxiliasse no processo de identificação das massas, Para realizar a classificação foi utilizada a ferramenta AutoWeka que necessita de um dicionário de imagens visuais (BOW+KMeans) constituída de extração de texturas da imagem ROI, foi utilizado o algoritmo SURF. A metodologia está demonstrada na Figura 2. Os resultados obtidos no trabalho foram avaliados de acordo com a Especificidade, Sensibilidade e Acurácia e estão demonstrados na Figura 3.

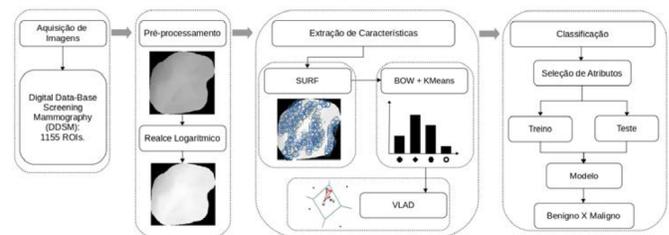


Figura 2. Metodologia de Diagnóstico de Câncer de Mama Através de Vetores de Descritores Localmente Agregados

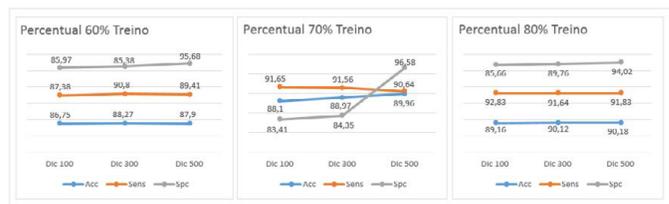


Figura 3. Resultados obtidos para 300 amostras benignas e 300 malignas

4 Diferenciação de padrões de benignidade e malignidade em tecidos da mama baseado na diversidade taxonômica

Este trabalho apresenta um método de classificação de tecidos da mama em maligno e benigno em exames de mamografia. Neste método foram

usados descritores de textura baseado em índices filogenéticos para extração de características, em seguida feita uma classificação usando os classificadores: J48, *RandomForest*, *J48Consolidated* e LMT [5].

As imagens utilizadas neste trabalho são oriundas da *Digital Database for Screening Mammography* (DDSM), em um total de 1155 ROI's, sendo 530 benignas e 625 malignas. Neste trabalho, são utilizados cinco índices de diversidade filogenética para extração dos descritores de textura: *Phylogenetic Diversity* (PD), *Sum of Phylogenetic Distances* (SPD), *Mean Nearest Neighbour Distance* (MNND), *Phylogenetic Species Variability* (PSV) e *Phylogenetic Species Richness* (PSR). A classificação foi realizada utilizando algoritmos (J48, *RandomForest*, *J48Consolidated* e LMT) de Aprendizado de Máquina WEKA, a qual contém ferramentas para pré-processamento de dados, classificação, regressão, agrupamento, regras de associação e visualização.

Os resultados obtidos no trabalho foram avaliados de acordo com a Especificidade, Sensibilidade e Acurácia. A Tabela 3 mostra a comparação de resultado entre cada um dos algoritmos utilizados.

Classificador	Base	Acurácia (%)	Sensibilidade (%)	Especificidade (%)	Curva ROC
J48	DDSM	93,7	91,6	95,5	0,957
J48Consolidated	DDSM	93,8	92,1	95,3	0,955
LMT	DDSM	93,8	92,1	95,3	0,971
RandomForest	DDSM	94,8	92,9	96,5	0,988

Tabela 3

Resultados obtidos para os algoritmos J48, *RandomForest*, *J48Consolidated* e LMT

5 Redução de Falsos Positivos em Imagens de Mamografias Digitais Usando os Índices *Phylogenetic Species Variability*, *Phylogenetic Species Richness* e Múltiplos Classificadores

Neste trabalho utilizam-se índices de diversidade filogenética para extração de características baseada na textura. Tais índices são utilizados como características para os classificadores: *Support Vector Machine*, *Random Forest*, *Random Basis Function* e *MultiLayer Perceptron* identificando

em tecidos de mamografias a presença de massa e não massa, perfazendo assim parte de um *Computer-Aided Diagnosis* (CAD) [6].

As imagens utilizadas são disponibilizadas pelo banco *Digital Database for Screening Mammography* (DDSM), sendo utilizadas 200 imagens de mamografias; sendo 100 imagens com a presença de massa e 100 de não massa. Para a extração de características das imagens foi utilizado o descritor baseado na textura utilizando os índices de diversidade filogenética *Phylogenetic Species Variability* e *Phylogenetic Species Richness*, e para a classificação foi utilizada as Máquinas de Vetores de Suporte *Random Forest*, RBF, MLP. A metodologia completa está demonstrada na Figura 4.

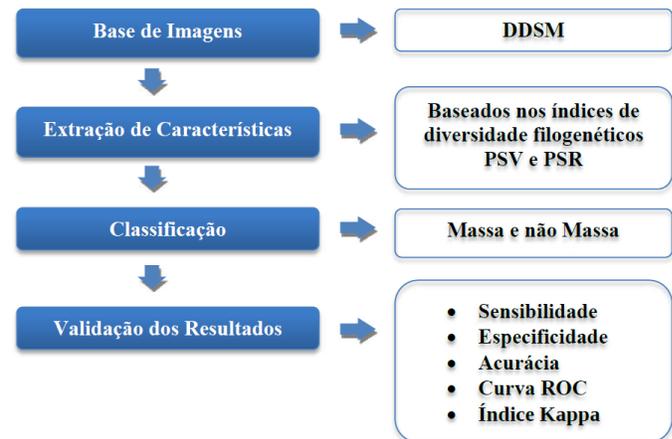


Figura 4. Metodologia para Redução de Falsos Positivos em Imagens de Mamografias Digitais Usando os Índices *Phylogenetic Species Variability*, *Phylogenetic Species Richness* e Múltiplos Classificadores

Os resultados obtidos utilizando PSV e PSR estão demonstrados na Tabela 4

Classificador	SE	EP	FP/i	AUC	AC	K
SVM	82,9%	92%	0,135	0,865	86,5%	0,73
RF	88,3%	91%	0,105	0,934	89,5%	0,79
RBF	88,5%	92%	0,100	0,957	90%	0,80
MLP	89,5%	94%	0,085	0,950	91,5%	0,83

Tabela 4

Resultados da classificação usando PSV e PSR

6 Detecção de Anomalias em Termografia Dinâmica das Mamas

A termografia é um exame que também pode ser utilizada para diagnóstico precoce de câncer de

mama. Regiões com anomalias geralmente apresentam perturbações na temperatura. O trabalho apresentado neste capítulo propõe uma metodologia de análise de séries temporais para encontrar o padrão comportamental deste exame. Uma região onde se encontra tumor geralmente apresenta maior temperatura, pelo processo de angiogênese, se comparada ao restante da mama [7].

As imagens utilizadas neste trabalho são oriundas da *Database for Mastology Research with Infrared Image* (DMR-IR), Utilizando apenas 13 exames considerados não saudáveis para a classificação. Devido ao fato de a aquisição das imagens poderem sofrer com interferências externas, como pequenas movimentações do paciente, faz-se necessário a utilização de técnicas capazes de interpretar esta interferência e poder correções geométrica com base em um sistema de referência. Este técnica é chamada de Registro e a utilizada neste trabalho é a deformável. Um exemplo de série temporal de um paciente saudável é vista na Figura 5 (a), enquanto em (b) é demonstrada a imagem de um paciente com massa, é possível perceber um comportamento homogêneo na série (a) em relação a (b).

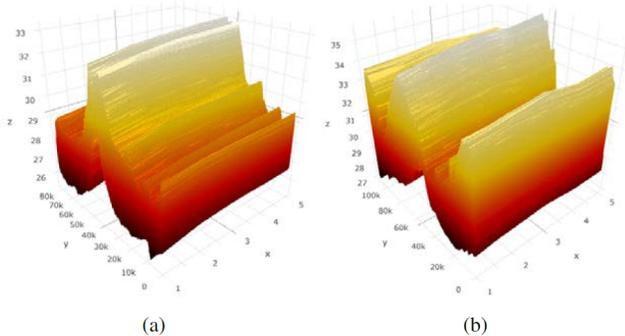


Figura 5. Séries Temporais de paciente saudável (a) e paciente com massa (b)

Para realizar a detecção de anomalias (massas) foi utilizada a metodologia de inteligência artificial *fuzzy c-means*

Este método foi capaz de identificar corretamente 10 dos 13 exames que possuíaam anomalias. Exemplo de identificação na Figura 6.

7 Relação entre os Trabalhos

Existem alguns pontos em comuns entre os trabalhos que faz-se necessário ressaltá-los, dentre eles

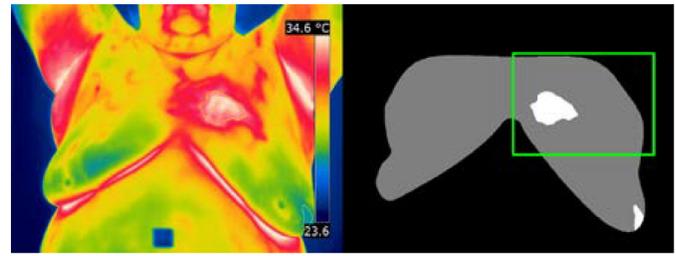


Figura 6. Exemplo de identificação de anomalia

o banco de imagens DDSM e a técnica de realce logarítmico.

7.1 Digital Database for Screening Mammography (DDSM)

DDSM é um banco de dados para rastreamento de mamografias. Ele é um recurso para uso da comunidade de pesquisa de análise mamográfica de imagens. O apoio primário para este projeto foi uma doação do Programa de Pesquisa de Câncer de Mama do Comando de Pesquisa e Material Médico do Exército dos EUA (*Breast Cancer Research Program of the U.S. Army Medical Research and Materiel Command*). O objetivo principal do banco de dados é facilitar a pesquisa no desenvolvimento de algoritmos de computador para auxiliar na triagem. As finalidades secundárias do banco de dados podem incluir o desenvolvimento de algoritmos para auxiliar no diagnóstico e no desenvolvimento de ferramentas auxiliares de ensino ou treinamento. O banco de dados contém aproximadamente 2.500 estudos, cada estudo inclui duas imagens de cada mama, juntamente com algumas informações associadas ao paciente (idade no momento do estudo, classificação de densidade de mama ACR, classificação de sutileza para anormalidades, descrição de anormalidades de palavras-chave ACR) e informações de imagem (scanner, resolução espacial). As imagens que contêm áreas suspeitas têm informações de "ground truth" sobre os locais e tipos de regiões suspeitas. Também são fornecidos softwares para acessar a mamografia e para calcular os números de desempenho para algoritmos automatizados de análise de imagens [8].

7.2 Realce Logarítmico

A técnica de realce de contraste tem por objetivo melhorar a qualidade das imagens sob os crité-

rios subjetivos do olho humano. É normalmente utilizada como uma etapa de pré-processamento para sistemas de reconhecimento de padrões. O contraste entre dois objetos pode ser definido como a razão entre os seus níveis de cinza médios. A manipulação do contraste consiste numa transferência radiométrica em cada "pixel", com o objetivo de aumentar a discriminação visual entre os objetos presentes na imagem. Realiza-se a operação ponto a ponto, independentemente da vizinhança [9].

O realce logarítmico de valores de níveis de cinza é útil para aumento de contraste em imagens escuras (valores de cinza baixos),

7.3 Deep Learning

Deep Learning (aprendizagem profunda, em português) é um tema emergente dentro do campo da Inteligência Artificial. Uma subcategoria de aprendizado de máquina que diz respeito a oportunidades de aprendizagem profundas com o uso de redes neurais para melhorar as coisas, tais como reconhecimento de fala, visão computacional e processamento de linguagem natural. Dito de outra forma, é um termo que cobre uma abordagem específica para a construção e formação de redes neurais. As redes neurais têm sido desenvolvidas e aprimoradas desde a década de 1950 e estão se tornando cada vez mais promissoras — aplicáveis para diversos fins, sobretudo no meio corporativo, indústrias de segmentos como saúde, educação e *e-commerce*, entre outras [10].

8 Considerações Finais

Neste trabalho foram abordados resumo de artigos e alguns de seus principais conceitos voltados para área de classificação de lesões mamárias afim de minizar as possíveis falhas humanos na análise de uma mamografia ou termografia.

O uso de sistemas computadorizados para diagnósticos de anomalias em imagens médicas, vem se tornando cada vez mais frequente, visto que, em muitos casos, os dados possuem um grau de dificuldade elevado para avaliação de um especialista. Em suma os métodos apresentados se mostraram satisfatórios mostrando que as tecnologias e os algoritmos estão em uma direção correta para a autonomia na classificação de lesões mamárias.

Referências

- [1] Instituto Nacional de Câncer. Detecção precoce, câncer de mama. <http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/mama/>, 2018.
- [2] Geraldo Braz Junior. Detecção de regiões de massas em mamografias usando índices de diversidade, geostatística e geometria côncava. Tese de doutorado em ciência da computação, Universidade Federal do Maranhão-UFMA, São Luis-MA, 2014.
- [3] João O.B. Diniz Geraldo Braz Junior João D. S. De Almeida Aristófaes Corrêa Silva Anselmo Cardoso de Paiva Roberto M. P. Pereira, Caio E.F. Matos. Abordagem deep learning para classificação de lesões mamárias. *WIM - 16º Workshop de Informática Médica*, 2017.
- [4] Geraldo Braz Junior João Dallyson de Sousa Almeida Ricardo Costa da Silva Marques, Geovane Menezes Ramos Neto1. Diagnóstico de câncer de mama através de vetores de descritores localmente agregados. *WIM - 16º Workshop de Informática Médica*, 2017.
- [5] Alcilene D. de Sousa1 Patricia Vieira da S. Barros1 Patrícia Medyna L. de L. Drumond1 Edson Damasceno Carvalho1, Antônio Oseas de C. Filho1. Diferenciação de padrões de benignidade e malignidade em tecidos da mama baseado na diversidade taxonômica. *WIM - 15º Workshop de Informática Médica*, 2016.
- [6] Alcilene D. de Sousa Patrícia M. L. de L. Drumond Laércio N. Mesquita, Antônio O. de C. Filho. Abordagem redução de falsos positivos em imagens de mamografias digitais usando os Índices phylogenetic species variability, phylogenetic species richness e múltiplos classificadores. *WIM - 16º Workshop de Informática Médica*, 2017.
- [7] Anselmo C. Paiva Stelmo M. B. Netto Aura Conci Jessica P. S. Cardoso1, Aristófaes C. Silva1. Detecção de anomalias em termografia dinâmica das mamas. *WIM - 16º Workshop de Informática Médica*, 2017.
- [8] Instituto Nacional de Câncer University of South Florida Digital Mammography. Ddsm: Digital database for screening mammography. <http://marathon.csee.usf.edu/Mammography/Database.html>, 2018.
- [9] Richard E. Woods Rafael C. Gonzalez. *Processamento Digital de Imagens*. Pearson Education do Brasil, São Paulo, SP, Brasil, 2010.
- [10] Gaea Consulting. Afinal, o que é deep learning. <https://gaea.com.br/afinal-o-que-e-deep-learning/>, 2018.



Rodrigo Blanke Lambrecht Mestrando do Programa de Pós-Graduação em Engenharia Eletrônica e Computação da Universidade Católica de Pelotas, na linha de pesquisa Processamento de imagens. Possui Graduação (2017) em Engenharia Elétrica pela Universidade Católica de Pelotas.