

12ª Jornada Científica e Tecnológica

CLASSIFICAÇÃO DE IMAGENS DE CÂNCER DE MAMA UTILIZANDO *DEEP LEARNING* PARA DIAGNÓSTICO AUXILIADO POR COMPUTADORES

João P. do N. SILVA¹; Diego SAQUI²; Steve T.M. ATAKY³; Hemily B. A. TRINDADE⁴

RESUMO

A medicina sofreu constante evolução ao decorrer dos anos, porém ainda não alcançou uma estabilidade satisfatória. Um exemplo é o câncer de mama, o qual em 2019, segundo o INCa, foi o tipo de câncer mais incidente na população feminina brasileira. Em seu processo de identificação existe uma etapa conhecida como Mamografia Digital, referente a um processo radiológico onde são obtidas imagens em diferentes tons de cinza. Sistemas computacionais comuns não possuem a capacidade de classificar os tumores existentes, porém ao utilizar algumas técnicas computacionais como o *Deep Learning*, a classificação dos tumores tornou-se viável a partir do treinamento de um algoritmo utilizando imagens manipuladas em Visão Computacional para reconhecimento e agrupamento de padrões.

Palavras-chave: Machine Learning, Identificação, Inteligência Artificial.

1. INTRODUÇÃO

Segundo o Instituto Nacional do Câncer, em 2019 o câncer de mama foi uma das doenças que mais atingiu a população brasileira feminina, tendo 60 mil novos casos confirmados desde o último ano e, segundo o Sistema de Informações sobre Mortalidade, cerca de 17 mil mulheres morreram em 2017, um aumento de cerca de 18% em relação a última década. Apesar de o avanço tecnológico ao decorrer dos anos, ainda não foi obtida uma solução satisfatória. Uma de suas adversidades é a determinação se um indivíduo após ter realizado a mamografia apresenta o tumor e sua classificação entre maligno e benigno, processo que ainda é feito manualmente em diversos locais (GIGER, 2000). Visando melhorar a detecção e evitar procedimentos desnecessários, foram desenvolvidos processos para classificar e identificar esses tumores através da Inteligência Artificial (IA) e Visão Computacional (VC), onde um algoritmo é capaz de identificar o tumor.

1 Bolsista NIPE, IFSULDEMINAS – Campus Muzambinho. E-mail: jpns1118@gmail.com.

2 Orientador, IFSULDEMINAS – Campus Muzambinho. E-mail: diego.saqui@muz.ifsuldeminas.edu.br

3 École de technologie supérieure (ÉTS) - Montréal - Québec - Canadá. E-mail: steve.ataky@nca.ufma.br

4 IFSULDEMINAS – Campus Muzambinho. E-mail: hemilibeatriz@gmail.com

O desafio presente neste método refere-se às exceções, tais como o algoritmo ser capaz de identificar um objeto independente de suas variações como translação, rotação, dentre outros (SEABRA; LOURENÇO, 2013). Uma região suspeita de câncer é frequentemente confundida com uma lesão benigna, incentivando pesquisadores a implementar diversos trabalhos de descritores comparativos a fim de identificar diferenças marcantes entre imagens de radiografia de tumores e lesões benignas. Devido ao alto índice de classificações feitas de maneira errônea, busca-se otimizar um sistema de *Deep Learning* com o intuito de aumentar a acurácia dos testes e diminuir a margem de erro.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Visão Computacional (VC)

A VC é um campo utilizado quando é necessário extrair informações de imagens e vídeos para encontrar um fator através de características base e tomar decisões. Através da reconstrução de formas, iluminação e cores é possível descrever nosso mundo computacionalmente (SZELISKI, 2010). Por meio da análise de dados de imagens, informações são agrupadas, e em conjunto com o processo de aprendizado de máquina, obtemos métodos extremamente eficazes para a automação de aquisição de modelos visuais com a adaptação dos parâmetros. Dessa forma ao construir um sistema de processamento de imagens treináveis, obtemos um foco nas características determinantes.

2.2 Deep Learning

O *Deep Learning* é considerado um tipo de classificador e evolução do *Machine Learning*, onde suas técnicas exploram camadas não lineares de dados para seleção de características relevantes, transformação, análise de padrões e classificações (DENG, 2014). Ele consiste em classificar informações em diversos grupos comparando sua probabilidade de pertencer ao mesmo através dos dados obtidos. Conforme novas imagens são analisadas, novos grupos de informações são gerados, e a probabilidade dessa imagem pertencer ao mesmo é atualizada.

2.3 Data Augmentation

O processo de *Deep Learning* necessita de uma base de informações para que o algoritmo seja treinado corretamente e a mesma precisa possuir uma ampla variedade, contendo imagens de diferentes ângulos e até mesmo as exceções de um determinado grupo. Isso é importante porque caso o número de imagens seja baixo, contendo uma pequena variabilidade de informações, a classificação das imagens pode ser feita erroneamente ensinando ao algoritmo que um indivíduo que apresenta uma exceção pertence a um outro grupo. Para suprir essas necessidades foi aplicado um processo conhecido como *Data Augmentation*, o qual corresponde a manipulação de imagens para que a base de informações seja aumentada. Essas manipulações podem ser feitas de diferentes

formas, como deslocamento e a rotação, além de outras (RUBÉN, 2019).

3. MATERIAL E MÉTODOS

Para o treinamento do algoritmo foi utilizado um *dataset* de imagens de câncer de Mama, disponibilizado no sistema web *PyImageSearch*⁵ o qual foi ampliado através do processo *Data Augmentation*. Conforme a Figura 1, A divisão da base de informações foi feita separando uma porção da base original em imagens e respostas (itens 1 e 1.1) para que o algoritmo fosse capaz de classificá-las, onde cerca de 1000 imagens para treino foram selecionadas e transformadas em 8000 imagens através do processo de *Data Augmentation* e foram separadas cerca de 150 imagens para teste. Em seguida foi gerado o algoritmo treinado (item 2) e este passou por um processo de validação (item 2.1) para garantir que o índice de acerto estava dentro do esperado. As imagens separadas para teste foram testadas pelo algoritmo (item 3) e a resposta obtida foi comparada com as respostas separadas para teste para verificar a porcentagem final de acertos (item 4).




Figura 1: Fluxograma representando os processos do algoritmo classificador

Para configurar o algoritmo, foram utilizados os parâmetros (1) *optimizer* “Adam”: uma alteração do modelo padrão de treino o qual substitui o processo de descida estocástico do gradiente em pesos para treinamento; (2) o *loss* “*sparse categorical cross entropy*”: define que uma entrada possui uma saída; e (3) o *metrics* “*Accuracy*”: compara as respostas obtidas e seu gabarito, comparando a porcentagem de acertos e erros. A estrutura utilizada foi a Multi-Layer Perceptron com 256 neurônios nas camadas ocultas e 2 de saída, possuindo a função de ativação ReLU. Após aplicar as técnicas, foi utilizado o *Data Augmentation* para que uma imagem gere outras 4 imagens de acordo com seu ângulo de rotação, aumentando em quatro vezes o tamanho da amostra original.

Para desenvolver o sistema, foi utilizada a linguagem Python 3.7 devido à sua praticidade e seu alto número de bibliotecas, sendo utilizadas: OpenCv (Manipulação de imagens), Pandas e numpy (operações matemáticas e estatísticas), matplotlib (Gráficos) e *Tensorflow* (*Deep Learning*).

4. RESULTADOS E DISCUSSÕES

⁵ <https://www.pyimagesearch.com/2019/02/18/breast-cancer-classification-with-keras-and-deep-learning/> (acesso em 10/09/2020)

O algoritmo obtido foi capaz de classificar se uma imagem apresenta o câncer do tipo *Carcinoma Ductal Invasivo* (IDC) e alcançou uma marca de cerca de 59% de acurácia nos testes feitos com as imagens separadas para teste. Isso ocorreu pela diferença entre as imagens de treino e teste, como pode ser observado na matriz de confusão abaixo:

	Apresenta Câncer	Não Apresenta Câncer
Apresenta Câncer	55 Imagens Verdadeiro Positivo	29 Imagens Falso Positivo
Não Apresenta Câncer	27 Imagens Falso Negativo	39 Imagens Verdadeiro Negativo

Figura 2: Matriz de Confusão dos resultados

A base de imagens para treino também deve conter uma parcela das imagens que foram classificadas de forma incorreta para que o algoritmo seja capaz de classificá-las corretamente.

5. CONCLUSÕES

O algoritmo gerou resultados satisfatórios dentro do estimado, porém apresenta espaço para aperfeiçoamentos, como uma ampliação da variedade de datasets no treinamento, utilizando métodos como o *cross fold validation* para treinar o algoritmo com diferentes informações aumentando a eficiência. Também é importante implantar a segmentação e delimitação da área referente ao tumor e a subclassificação do mesmo, auxiliando o profissional a classificá-lo.

AGRADECIMENTOS

Gostaria de agradecer principalmente ao NIPE - Muzambinho, o qual financiou esta bolsa de pesquisa e incentivou o desenvolvimento da mesma, pois sem ele nada disso seria possível.

REFERÊNCIAS

- DENG, L.; YU, D. Deep Learning Methods and Applications. Eua: Foundations And Trends, 2014.
- GIGER, M. L. Computer-aided diagnosis of breast lesions in medical images. Comput Sci Eng. 2000 2(5):39–45
- RUBÉN; C; B. Heuristics for Data Augmentation in NLP: Application to scientific paper reviews, 2019
- SCIKIT-IMAGE. Scikit-image image processing in python. Link:<http://scikit-image.org/>. Acesso em Fevereiro de 2020.
- SEABRA Z; LOURENÇO J. Imagiologia no Carcinoma da Mama, 2013
- SZELISKI, R. Computer Vision: Algorithms and Applications, 2010.