

# CLASSIFICAÇÃO DE IMAGENS DE MAMOGRAFIA COM MACHINE LEARNING NO AUXÍLIO DE DIAGNÓSTICOS DE CÂNCER DE MAMA<sup>1</sup>

## *CLASSIFICATION OF MAMMOGRAPHY IMAGES WITH MACHINE LEARNING FOR BREAST CANCER DIAGNOSTIC ASSISTANCE*

Pedro Wurzel<sup>2</sup> e Mirkos Ortiz Martins<sup>3</sup>

### RESUMO

O câncer de mama é o mais comum entre mulheres e apresenta uma taxa de sobrevivência de 95% quando detectado precocemente. O exame de mamografia é o exame por imagem mais utilizado para o diagnóstico do câncer de mama, considerado como o ideal para mulheres que apresentam quadro assintomático. Algoritmos de *deep learning* têm apresentado grande potencial para serem usados no auxílio em diagnósticos, e dentre eles destaca-se as CNN. O objetivo do trabalho é desenvolver uma ferramenta capaz de analisar mamografias para classificar o potencial de casos positivos de câncer de mama e assim auxiliar no diagnóstico médico. A construção do classificador se baseia na utilização de um modelo de CNN, na linguagem Python, com treinamento supervisionado e a utilização da base de mamografias CBIS-DDSM. O modelo construído obteve como resultado a acurácia de 91,34%, um escore de 485 imagens positivas acertadas e 428 negativas acertadas. O algoritmo atingiu os índices esperados para uma aplicação de análise de imagens de mamografia e identificação das texturas tumorosas, sendo um resultado compatível com aqueles encontrados na literatura atual.

**Palavras-chave:** Aprendizagem profunda, redes neurais, imagens médicas.

### ABSTRACT

*Breast cancer is the most common among women and has a 95% survival rate when detected early. The mammography exam is the most used imaging exam for the diagnosis of breast cancer, considered ideal for women who present asymptomatic condition. Deep learning algorithms have shown great potential to be used in assistance to diagnoses, and CNN stands out among them. The objective of the project is to develop a tool capable of analyzing mammograms to classify the potential of positive cases of breast cancer and thus assist in medical diagnosis. The construction of the classifier is based on the use of a CNN model, in Python, with supervised training and the use of the CBIS-DDSM mammogram dataset. The model built obtained as a result an accuracy of 91.34%, a score of 485 correct positive images and 428 correct negative images. The algorithm reached the expected rates for an application of mammography image analysis and identification of tumor textures, being compatible result with those found in the current literature.*

**Keywords:** *Deep Learning, neural networks, medical images.*

1 Trabalho Final de Graduação. Curso de Engenharia Biomédica. Universidade Franciscana - UFN.

2 Orientando. Aluno de Engenharia Biomédica. E-mail: pedro.wurzel@ufn.edu.br

3 Orientador. Professor do curso de Ciência da Computação-UFN. E-mail: mirkos@prof.ufn.edu.br

## INTRODUÇÃO

O câncer de mama é o mais comum em mulheres e representa 18% de todos os cânceres que atingem o público feminino (AKRAM *et al.*, 2017). Devido à sua crescente incidência, morbidade e mortalidade, o câncer de mama é um problema de extrema importância para a saúde pública brasileira e mundial (BARROS *et al.*, 2001). Diversos fatores já foram estabelecidos como desencadeadores da doença, como a vida reprodutiva da mulher e a idade (FERRAZ; MOREIRA-FILHO, 2017).

O exame de mamografia é o exame por imagem mais utilizado no mundo para o diagnóstico do câncer de mama, sendo considerado como o ideal para mulheres que apresentam quadro assintomático (APANTAKU, 2000). A literatura acerca da utilização do exame de mamografia no diagnóstico do câncer de mama demonstra que ele resulta na constatação da doença em seus primeiros estágios, principalmente localizando tumores pequenos (ELKIN *et al.*, 2005). Segundo Wang *et al.* (2013), os índices de sobrevivência dos pacientes continuam aumentando, na medida que se aumenta também o desenvolvimento da detecção precoce e melhora nos tratamentos realizados. A taxa de sobrevivência para casos detectados precocemente chega perto de 95%, enquanto para os detectados tardiamente, apenas 30%.

Contudo, o exame de mamografia não é eficaz em todos os casos, e pode acarretar erros, como falsos negativos e falsos positivos. Resultados falsos positivos podem causar danos psicológicos significativamente grandes para os pacientes, como ansiedade, problemas para dormir, impactos negativos na vida sexual e mudanças na relação com familiares, amigos e colegas (GÖTZSCHE; JØRGENSEN, 2013). Já os resultados falsos negativos podem ocasionar uma demora maior para início do tratamento, e consequentemente haverá menor chance de cura. Nesse sentido, busca-se o desenvolvimento de novas tecnologias para o auxílio de profissionais da saúde e dos pacientes na luta contra o câncer de mama, principalmente em regiões com menos condições financeiras e estruturas físicas precárias para o público.

Muitos recursos são investidos para pesquisar sobre a doença, e muitos pesquisadores focam suas carreiras nesse campo de estudo. Grande parte desse esforço deve-se a ideia de que a prevenção, o diagnóstico e o tratamento do câncer dependem de um maior entendimento sobre o assunto (CHODOSH, 2011). As diretrizes para exames de imagem para diagnóstico de câncer de mama sofrem constantes variações. Com a maior divulgação sobre o assunto e o progresso tecnológico na área médica, o câncer tem sido detectado cada vez mais cedo, em seus estágios iniciais, principalmente em países mais desenvolvidos onde há um maior número de casos (APANTAKU, 2000). É recomendado pelo Ministério da Saúde que sejam feitos exames, tanto de imagem quanto o exame clínico, a cada dois anos para mulheres que não apresentam sintomas e tenham entre 50 e 69 anos. Essas recomendações podem ser alteradas para algumas pessoas caso haja maiores fatores de risco, como fatores genéticos.

Está claro que a detecção acurada de doenças malignas é um importante fator no tratamento e prognóstico de pacientes de câncer. O diagnóstico precoce é a chave para eliminar a patologia e

aumentar as chances de sucesso do tratamento, principalmente em seu início (SHAMSI; ISLAMIAN, 2017). De acordo com Migowski *et al.* (2018), o atraso de mais de três meses entre o início dos sintomas e o tratamento do câncer de mama pode resultar em uma diminuição de 5% no tempo de sobrevivência do indivíduo. Ainda segundo o autor, há três fatores importantes para o diagnóstico precoce da doença: a conscientização da população sobre sintomas e acesso aos exames para eles; a confirmação diagnóstica eficiente; acesso ao tratamento.

O grande avanço tecnológico da inteligência artificial dos últimos anos se apresenta em um momento oportuno, no qual uma enorme quantidade de dados médicos é computadorizada. Algoritmos que utilizam a técnica de aprendizagem de máquina mostram grande potencial para serem usados na medicina, desde para descobertas de novas drogas ao auxílio em decisões médicas, e assim modificar diversas práticas que são feitas hoje (KER *et al.*, 2017). Esse método é utilizado para encontrar padrões presentes em um conjunto de dados, construir modelos e fazer previsões baseadas em modelos pré-existentes (MIN; LEE; YOON, 2017).

O *deep learning*, uma das ramificações da inteligência artificial, recentemente ascendeu como uma alternativa promissora para o manejo de *big data*. Desde o início dos anos 2000, a técnica pôde superar limitações que existiam na área de algoritmos inteligentes, e por isso o interesse nela aumentou rapidamente. Esse avanço se deu principalmente em âmbitos nos quais a tecnologia de inteligência artificial da época estava com dificuldades, como reconhecimento de imagens e de voz (MIN; LEE; YOON, 2017). O processo realizado pelo *deep learning* é isento de manipulações humanas e pode ser comparado a estudos de princípios cognitivos do cérebro, sobretudo a princípios visuais (WONG; FORTINO; ABBOTT, 2020). Pelo fato de a técnica conseguir identificar diversos padrões contidos em um conjunto de dados automaticamente, ela se torna ideal para modelar relações complexas entre imagens médicas e possíveis interpretações das mesmas. Essa propriedade fez com que grandes avanços ocorressem recentemente, incluindo em áreas como classificação de câncer de pele, detecção de retinopatia diabética e detecção de nódulos no pulmão (BIEN *et al.*, 2018).

As Redes Neurais Convolucionais (CNN) são um tipo de modelo de *deep learning* e têm a capacidade de capturar relações não lineares entre o *input* e o *output*. Elas podem ser empregadas em diversas aplicações, como classificação de imagens, segmentação e eliminação de ruídos (LI *et al.*, 2014). De um modo geral, as operações convolucionais examinam a imagem com possíveis padrões, calculando a influência deles em cada posição. As operações de *pooling* determinam se há ou não a presença de padrões na região e agregam às informações um único número. A sucessão de aplicações das operações de convolução e de *pooling* está presente na maioria das estruturas de análise de imagem (ANGERMUELLER *et al.*, 2016).

Nos últimos anos muitos trabalhos foram publicados sobre a aplicação de *deep learning* na detecção e diagnóstico de câncer de mama, sendo grande parte deles com o uso de CNN (HU *et al.*, 2018). O diagnóstico de câncer de mama utilizando-se de inteligência artificial consiste na constatação e

classificação de lesões e microcalcificações, e na predição de câncer por imagem (LITJENS *et al.*, 2017). Sun *et al.* (2017) utiliza CNN para a identificação de câncer de mama, dispondo-se de 100 exames de mamografia classificados, em um total de 1874 imagens. Mesmo com a grande maioria sendo dados não rotulados, o estudo atinge uma acurácia de 82,43%. Tsochatzidis *et al.* (2017) descreve o uso de diagnóstico computadorizado através da técnica de Recuperação de Imagens Baseada em Conteúdo (*Content-Based Image Retrieval*). O trabalho utiliza-se de uma base de dados de mamografias pública, e tem como objetivo fornecer a chances de a lesão encontrada ser benigna ou maligna. O método proposto resulta em uma predição com 81% de acurácia, podendo ser considerado muito bom.

A promoção de inteligência artificial na área médica vem sendo bastante explorada nos últimos anos pela comunidade científica (LOBO, 2017), e se mostra muito promissora no auxílio em diagnósticos de câncer. A verificação de mamogramas é um trabalho exigente para radiologistas. Seu veredito sobre o exame depende de treinamento, experiência e critérios subjetivos. Nesse sentido sistemas computacionais para o auxílio de diagnósticos podem ajudar os especialistas na interpretação e classificação de anormalidades. A presença de microcalcificações e massas são os dois principais indicadores para o reconhecimento precoce do câncer (CHENG *et al.*, 2006). Tendo em vista o grande número de habitantes no Brasil, e conseqüentemente, o grande número de exames que precisam ser feitos e avaliados por especialistas, especialmente pelo sistema único de saúde (SUS), busca-se criar ferramentas para a assistência aos profissionais dessa área. Nesse sentido, o desenvolvimento de um algoritmo capaz de auxiliar a realização do diagnóstico de tumores através da análise de imagens de mamografias pode auxiliar médicos e pacientes a terem uma resposta mais rápida, considerando que o diagnóstico precoce aumenta a probabilidade de sucesso no tratamento de cura.

Portanto, o objetivo do trabalho é desenvolver uma ferramenta de inteligência artificial capaz de realizar análises em imagens de mamografia para classificar o potencial de casos positivos de câncer de mama e assim auxiliar no diagnóstico médico. Também busca-se avaliar se as classificações encontradas pelo modelo estão corretas e condizem com o diagnóstico real da comorbidade, tornando-o apto a auxiliar médicos e pacientes nos diagnósticos.

## **MATERIAL E MÉTODO**

### **CONVOLUÇÕES**

As convoluções, funções matemáticas que dão nome à rede neural em questão, são baseadas em operações entre duas funções, com a geração de uma terceira. Ou seja, um conjunto de pixels ou imagem (*input*) e um filtro (*kernel*) geram uma nova camada, chamada de camada convolucional, que é resultado da multiplicação das duas matrizes de pixels (Figura 1). A nova camada formada pela convolução é uma versão modificada da camada de input, e representa padrões encontrados na

mesma, como linhas horizontais ou verticais nas primeiras convoluções, e padrões mais complexos em convoluções posteriores, como partes do corpo ou texturas específicas. Esse processo acontece repetidas vezes, até que, por fim, a camada de *output* é formada. Essa arquitetura permite à rede neural se concentrar em padrões de baixo nível nas primeiras camadas ocultas, e conforme o número de camadas aumenta, o nível de reconhecimento de padrões também, o que torna esse tipo de rede neural uma ferramenta poderosa no reconhecimento de imagens (SEWAK; KARIM; PUJARI, 2018).

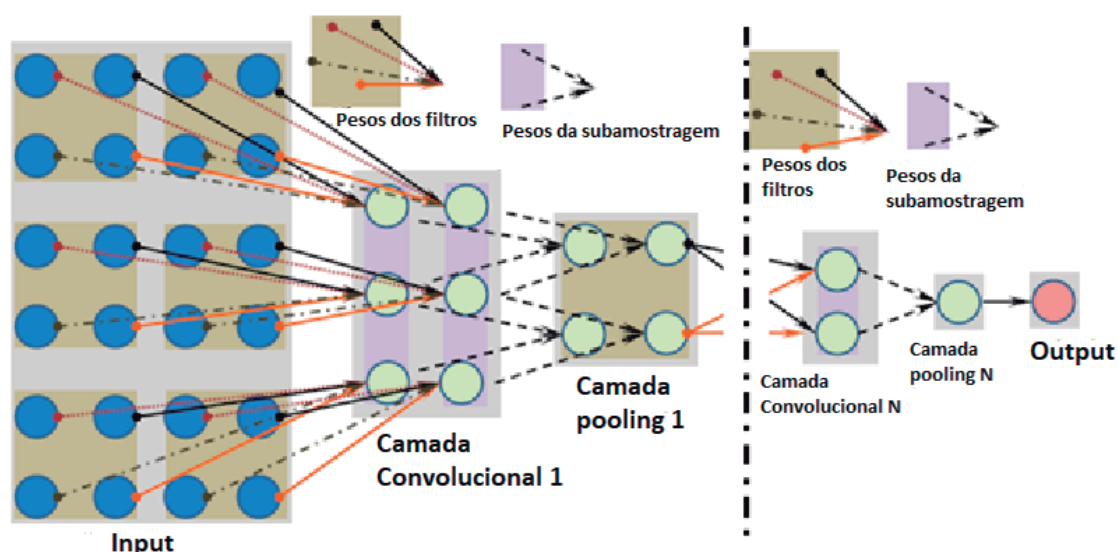
**Figura 1** - Cada camada convolucional possui dados apenas para sua camada receptiva.



Adaptada de: SEWAK; KARIM; PUJARI, 2018

O método para a construção do classificador se baseia na utilização de um modelo de CNN com treinamento supervisionado, demonstrado na Figura 2. O desenvolvimento de algoritmos de CNN requer uma grande capacidade computacional para que seja possível realizar o treinamento do algoritmo utilizando uma larga quantidade de imagens de mamografias.

**Figura 2** - Esquema demonstrativo do funcionamento de uma CNN.



Adaptada de: RAVI *et al.*, 2017

## DADOS PARA A CONSTRUÇÃO DO MODELO

Para que seja possível realizar a extração de características das imagens de mamografias com precisão no treinamento da ferramenta de classificação, é necessário a utilização de uma grande quantidade de amostras. No presente projeto de pesquisa, é utilizada a base de dados *Curated Breast Imaging Subset of DDSM* (CBIS-DDSM), usada para a construção do modelo, realizando-se o treinamento e teste do mesmo.

O *dataset* CBIS-DDSM (2016) apresenta um total de 2620 exames de mamografias escaneadas, abrangendo 1566 participantes. Ele inclui mamografias de mamas normais, mamas com tumores benignos e com malignos, com a patologia verificada por profissionais especializados. Essa é uma nova versão do *dataset Digital Database for Screening Mammography* (DDSM), originalmente disponibilizado em 1997. Quando o banco de mamografias original foi lançado, diversos recursos para processamento de imagens computacionais que se tem hoje não estavam amplamente disponíveis. As imagens do DDSM foram salvas em arquivos de compactação fora do padrão atual, o que requer o uso de códigos de descompactação que não foram mantidos em computadores modernos. Portanto, recomenda-se que pesquisadores implementem algoritmos de segmentação para extração precisa dos recursos fornecidos pelas imagens, e assim impossibilitando a comparação direta do desempenho dos métodos e replicação de resultados anteriores.

Para o uso do *dataset*, construiu-se um algoritmo para a conversão do formato DICOM original das imagens para o formato JPG. Devido ao grande tamanho das imagens, também se desenvolveu um código para a realização da fragmentação das imagens, para que possam ser analisadas por partes menores, com o tamanho de 255 x 255 pixels. Desta maneira, a aprendizagem se dá pelo reconhecimento da textura característica de tumores, e a classificação ocorre pela presença ou não de tal textura no exame avaliado.

## ESTUDOS PARA A CONSTRUÇÃO DO MODELO

O processo para a definição da estrutura do algoritmo a ser utilizada no treinamento com o banco de dados se deu primeiramente pela construção de um modelo básico, com apenas duas camadas convolucionais. Para a redução do *overfitting*, acrescentou-se ao segundo algoritmo de teste uma camada de *average pooling*, uma camada de *maxpooling*, uma camada de *dropout* e mais uma camada densa. Com isso, o *overfitting* foi diminuído, mas ainda estava presente nos resultados obtidos com os dados de validação.

A Rede Neural Convolutacional desenvolvida e utilizada na fase de testes do algoritmo apresenta em sua estrutura: uma camada de *input* para receber o mamograma, com *average pooling*; duas camadas convolucionais; uma camada de *maxpooling*; uma camada de *dropout*; uma camada *flatten*; e duas camadas densas (totalmente conectadas) para a geração do *output*. Para uma melhor parametrização da rede neural, utilizou-se a API (*Application programming interface* - interface de programação de aplicações) Keras Tuner. Sua função é treinar e testar o modelo desenvolvido utilizando parâmetros diferentes, selecionados pelo usuário, e mostrar qual combinação demonstrou melhores resultados (O'MALLEY *et al.*, 2019). Na camada *average pooling* foram testadas para o *pool size* os valores 2, 4 e 6. Foram testadas de 0 a 4 camadas convolucionais, com o número de camadas de filtros entre os valores de 16, 32 e 64, com os valores 2x2, 3x3 e 4x4. Na camada de *dropout*, foram usados os valores 0,3, 0,4, 0,5, 0,6 e 0,7. Por fim, na penúltima camada densa, foram testados os valores 32, 64, 128 e 256. Os parâmetros do modelo que atingiu melhor acurácia em seu teste são apresentados na Figura 3.

**Figura 3** - Parâmetros definidos pelo Keras Tuner nas fases de testes iniciais.

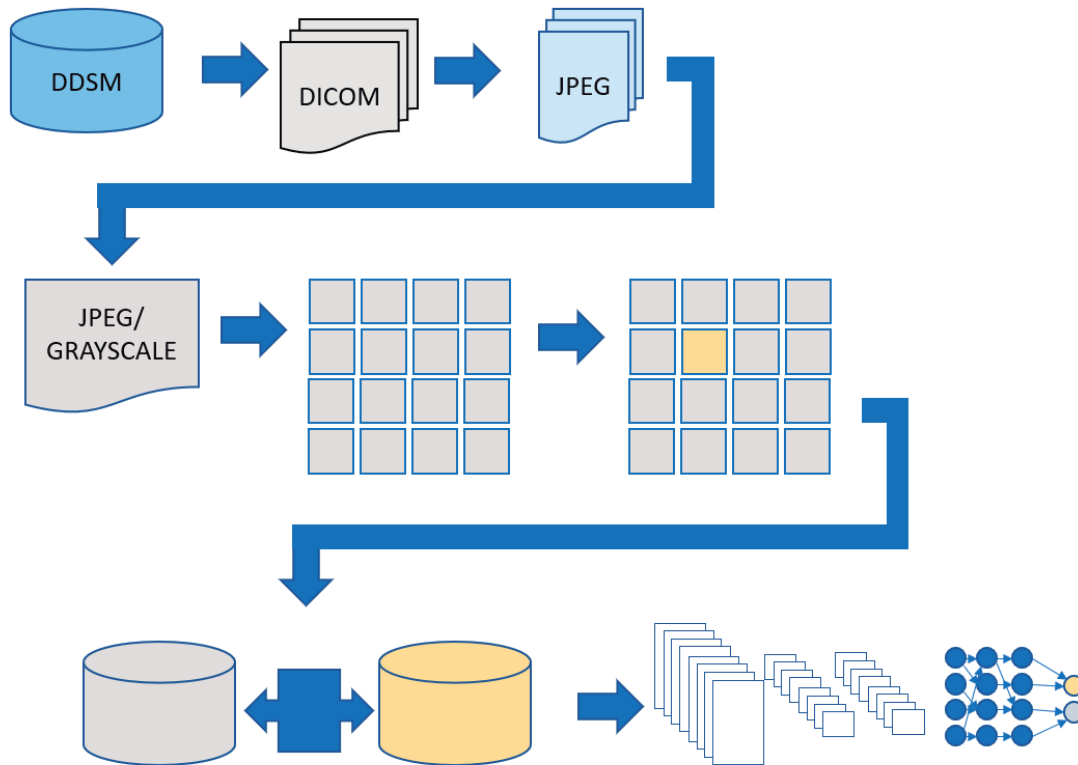
Parâmetro	Valores testados	Melhor valor encontrado
Pool size	2, 4, 6	6
Nº de camadas convolucionais	0, 1, 2, 3, 4	2
Filtros	2x2, 3x3, 4x4	3x3
Dropout	0.3, 0.4, 0.5, 0.6, 0.7	0.4
Camada densa	32, 64, 128, 256	256

Fonte: Autoria própria

## ESTRUTURA DO ALGORITMO

A linguagem de programação que se utiliza no desenvolvimento do algoritmo é Python, versão 3.7.22.0, com as bibliotecas TensorFlow e Keras, ambos versão 2.6, e a API Keras Tuner, versão 1.0.4. Para o download das imagens, foi utilizado um HD com capacidade de 1 Terabyte. A execução foi feita em ambiente Linux (Ubuntu v. 20.04.3 LTS), utilizando como base de imagens a CBIS-DDSM (SAWYER *et al.*, 2017), sendo o DDSM (HEATH *et al.*, 2001) analisado em sua versão completa, com 1566 casos analisados, distribuídos em 10239 imagens no formato DICOM.

**Figura 4** - Esquema da construção do projeto para reconhecimento por *deep learning*.



Fonte: Autoria própria

Posterior ao download com a ferramenta NBIA Data Retriever foi construído um algoritmo que converte imagens DICOM para o formato PNG, percorrendo toda a estrutura de diretórios montados pelo NBIA Data Retriever e salvando as imagens com o nome apropriado, para não se perder o vínculo com o arquivo descritivo das imagens e seus respectivos diagnósticos, conforme visto na Figura 4.

As imagens extraídas do DDSM são formadas por mamografias da mama esquerda e direita, além de anotações do tipo ROI (*Region Of Interest*, Região de Interesse), para descrever a localização de anomalias no tecido da mama, mostrado na Figura 5. A associação da imagem original com a imagem do ROI fornece uma localização espacial dentro da imagem em estudo.

**Figura 5** - Com a união da mamografia original com a imagem ROI obtêm-se a interpretação da localização da anomalia na mama.



Fonte: Autoria própria



Na Figura 6, é mostrada a conversão para formato JPG, na qual o algoritmo percorre todo o diretório informado na variável *root* (linha 4) e se utiliza o comando de *prompt* do Linux. O comando é feito para a execução do *dcmj2pnm*, na linha 18, que é um programa que extrai a imagem do DICOM e faz a conversão para vários outros formatos, inclusive o PNG, utilizado nesse trabalho. Após a conversão para PNG as imagens foram reescritas em JPG sem perda, com um tamanho final de arquivo de ordem de 5% em média (o total consumido de disco para as imagens ultrapassou 1 Terabyte de armazenamento).

Figura 6 - Código para conversão de formato DICOM para JPG nas imagens do DDSM.

```
1 import os
2 import subprocess
3
4 root = 'pastaContendoDICOM'
5
6 contador = 0
7 for path, subdirs, files in os.walk(root):
8     for name in files:
9         origem = path+name
10        destino = root+'/jpg/'+str(contador)+name+'.jpg'
11        #print(os.path.join(path,name))
12        if name!='teste.py':
13            print('Caminho',path, 'Name',name)
14            os.chdir(path)
15            #subprocess.call(["cd",path])
16            command = 'dcmj2pnm --write-png --min-max-window --verbose'
17            #print(command)
18            subprocess.run(['dcmj2pnm', '--write-png', '--min-max-window', '--verbose', name, destino])
19            #print(origem, '\n', destino)
20            contador+=1
21            #if contador==10:
22                # exit(0)
23
24 #dcmj2pnm --write-png --min-max-window --verbose 1-1.dcm saida.png
25
```

Fonte: Autoria própria

Na sequência, as imagens são convertidas para a indexação dos pixels em escala de cinza. Além disso, realizou-se a definição em código das suas propriedades de largura e altura, a fim de fornecer um valor matricial dividindo a imagem em uma matriz cujas células meçam 255x255 pixels.

A Figura 7 representa o código de construção das células a partir das imagens JPG originais. A conversão para escala de cinza é feita na linha 11 e a definição das dimensões da imagem é fornecida na linha 12, reconhecendo a altura e largura da imagem, dividida em células de 255 pixels (altura e largura) na linha 25. Todas as células, ou imagens, são geradas em um mesmo local de destino (linha 26). Para cada célula criada, sua posição é mapeada na imagem original para haver a detecção da área onde ocorreu o ROI anotado nas imagens do CBIS-DDSM, para aferição de localização das anomalias de câncer nas mamografias.

Para cada imagem são geradas entre 215 e 452 sub-imagens, montando uma grade de células que somadas formam um conjunto de 3.418.025 células, distribuídas em 3.393.452 células negativas e 24.573 células de texturas positivas para câncer. As células positivas são aquelas que contém o ROI e as células negativas são todas as restantes.

Nas células negativas é feito um recorte baseado no número de pixels em preto (preto > 30%, a célula é excluída), resultando em 1.459.184 células. Das células positivas e negativas, são escolhidas 24.000 células de textura, aleatoriamente, para montar o *dataset* - balanceado - de treino do algoritmo. Para os dados de teste, foram escolhidas 500 células positivas e 500 células negativas, somando 1000 imagens para validação dos resultados. Após a criação das células, forma-se um *dataset* para servir de entrada para o algoritmo de *deep learning* do tipo CNN-VGG (SIMONYAN; ZISSERMAN, 2015).

Figura 7 - Código para a construção das células, de tamanho 255x255, para cada imagem convertida do DDSM.

```

1  import cv2
2  import numpy as np
3
4  filename=''
5  destino=''
6
7  imagem = cv2.imread(filename)
8  print('tipo',type(imagem))
9  print(imagem.shape)
10
11  gray = cv2.cvtColor(imagem, cv2.COLOR_BGR2GRAY)
12  height, width = gray.shape
13  print(gray.shape)
14  print(height,width)
15  altura = height/255
16  largura = width/255
17  print(int(altura),int(largura))
18
19  c_altura = 0
20  c_largura = 0
21  x=0
22  y=0
23  while c_altura < height:
24      while c_largura < width:
25          thumb_0 = imagem[c_altura:c_altura+255,c_largura:c_largura+255].copy()
26          cv2.imwrite(destino+str(x)+''+str(y)+'.png', thumb_0)
27          x+=1
28          c_largura+=255
29      c_largura=0
30      x=0
31      y+=1
32      c_altura +=255
33
34
35

```

Fonte: Autoria própria

Na Figura 8 é possível se observar a codificação para a construção da rede neural convolucional do tipo VGG, a partir da linha 24 do código. As linhas anteriores são aquelas utilizadas para a criação das bases de treino, teste e validação do modelo a partir dos diretórios onde foram armazenadas as células das imagens. As classificações sobre a célula descrevem uma textura como “com anomalia” ou “sem anomalia” (positivo e negativo), o que torna o modo da classe como binário (0 para negativo, 1 para positivo). Logo, tanto as bases de entrada como o modo de classificação de saída (*binary\_crossentropy*, e uso de somente 1 classe ativa) são resultado da resposta “sim” ou “não” para a pergunta sobre a anomalia na célula da imagem.

Figura 8 - Codificação do modelo de rede neural do tipo VGG.

```

1 import numpy as np
2 import pandas as pd
3 from tensorflow.keras.preprocessing.image import ImageDataGenerator
4 from tensorflow.keras.models import Sequential
5 from tensorflow.keras.layers import Dense, Dropout, Conv2D, Flatten, MaxPooling2D
6 from tensorflow.keras.optimizers import SGD
7 train_datagen = ImageDataGenerator()
8 valid_datagen = ImageDataGenerator()
9 treino_datagen = ImageDataGenerator()
10 print("[INFO] montando a base de treinamento")
11 train_generator = train_datagen.flow_from_directory('train/treino', class_mode='binary',
12 | color_mode="grayscale", target_size=(255, 255), batch_size=10)
13 print("[INFO] montando a base de validação")
14 valid_generator = valid_datagen.flow_from_directory('train/valida', class_mode='binary',
15 | color_mode="grayscale", target_size=(255, 255), batch_size=10)
16 print("[INFO] montando a base de teste")
17 test_generator = treino_datagen.flow_from_directory('train/teste', class_mode='binary',
18 | color_mode="grayscale", target_size=(255, 255), batch_size=10)
19
20 print('[INFO] determinando os tamanhos dos epochs e passos')
21 STEP_SIZE_TRAIN=train_generator.n//train_generator.batch_size
22 STEP_SIZE_VALID=valid_generator.n//valid_generator.batch_size
23 print('Tamanho dos epoch: {} e passos: {}'.format(STEP_SIZE_TRAIN,STEP_SIZE_VALID))
24 print('[INFO] construindo o modelo de CNN-VGG')
25 model = Sequential()
26 model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(255, 255, 1)))
27 model.add(Conv2D(32, (3, 3), activation='relu'))
28 model.add(MaxPooling2D(pool_size=(2, 2)))
29 model.add(Dropout(0.25))
30
31 model.add(Conv2D(64, (3, 3), activation='relu'))
32 model.add(Conv2D(64, (3, 3), activation='relu'))
33 model.add(MaxPooling2D(pool_size=(2, 2)))
34 model.add(Dropout(0.45))
35
36 model.add(Flatten())
37 model.add(Dense(256, activation='relu'))
38 model.add(Dropout(0.5))
39 model.add(Dense(1, activation='sigmoid'))
40
41 sgd = SGD(lr=0.01, momentum=0.9)
42 model.compile(loss='binary_crossentropy', optimizer=sgd)
43 print('[INFO] treinando o modelo')
44 model.fit(train_generator, batch_size=32, epochs=1000)
45 print('[INFO] testando o modelo')
46 score = model.evaluate(test_generator, batch_size=500)

```

Fonte: Autoria própria

## RESULTADOS E DISCUSSÃO

O modelo desenvolvido obteve como resultado do treino e teste a acurácia de 91,34%, um escore de 485 imagens positivas acertadas e 428 negativas acertadas, dentre as 1000 constituintes do *dataset* de teste. Foram identificadas nas imagens com imprecisão no acerto um número de pixels em preto constituindo > 25% da célula, portanto esse padrão precisa ser mais bem explorado no momento da seleção das imagens para a construção dos *datasets*.


Uma solução seria a passagem das imagens anterior ao algoritmo de classificação, em uma máscara que faça a exclusão dos pixels pretos. A questão envolve um potencial computacional bastante custoso em relação ao tempo e não foi possível implementá-lo, testá-lo e validar em tempo hábil da

construção desse trabalho, opção escolhida para um futuro próximo a fim de maximizar o reconhecimento das imagens em detrimento às zonas sem informação para o algoritmo de inteligência artificial.

Ao final da reconstrução da imagem, a partir das texturas classificadas pelo modelo CNN-VGG, obtêm-se a localização (em casos positivos) das texturas treinadas para positivo, em relação a anomalias de câncer, conforme visto na Figura 9. Quando uma textura é marcada como positiva pela rede neural, a célula é contornada por um quadrado verde.

Para a execução do algoritmo foram consumidos 18 dias, entre conversão de DICOM para PNG e JPG, desconstrução das imagens em células de mesma dimensão (em pixels), classificação das imagens para construção dos *datasets*, treinamento do modelo de CNN, testes e validação. Ao final dos testes e validações, o propósito do programa atingiu os índices esperados para uma aplicação de análise de imagens de mamografia e identificação das texturas de um banco de imagens contendo casos de câncer de mama.

**Figura 9** - Imagem reconstruída a partir das células de entrada para uma imagem de textura (a mesma da figura de mamografia original), vista em quadros representativos de 255x255 pixels. Os quadros em verde marcam a área reconhecida para anomalia.



Fonte: Autoria própria

Diversos trabalhos na área de visão computacional com a utilização de CNN têm sido publicados, e trabalhos relacionados ao auxílio de diagnósticos se mostram promissores. De Sá Oliveira e Lins (2020) propõe uma ferramenta para auxiliar profissionais de saúde no diagnóstico de câncer de mama por meio de imagens de mamografias digitalizadas. O trabalho em questão atinge a marca de 93% de acurácia na fase de validação de seu modelo CNN. Um resultado que representa um valor próximo ao encontrado no presente trabalho.

Foram validados modelos com diferentes configurações na rede CNN, conforme a execução de um código de tuning, responsável pela avaliação de métricas (tempo e desempenho) e sugestão de melhorias em número de neurônios na rede, tamanho da rede e critérios de corte (nas classes de treino e teste).

Sendo assim, entende-se que as Redes Neurais Convolucionais apresentam grande eficácia na detecção de objetos em imagens, então no setor de diagnósticos médicos, se torna uma ferramenta poderosa no auxílio à médicos.

## CONSIDERAÇÕES

Algo que deve ser levado em conta para o desenvolvimento de um modelo com CNN é o tamanho das imagens utilizadas para a realização do treinamento do algoritmo (OLIVEIRA e LINS, 2020). Durante a construção do algoritmo, foram realizados testes com *datasets* menores contendo apenas 620 imagens. Quando utilizadas imagens com tamanho de 40 x 40 pixels, o treinamento do modelo durou aproximadamente 6 segundos, enquanto com imagens de 255 x 255 pixels durou em torno de 187 segundos, o que representa um aumento considerável de tempo. Porém a acurácia passou de 0.8320 para 0.9023.

Embora essa situação tenha ocorrido apenas com testes no desenvolvimento do código, ela demonstra a diferença que o tamanho da imagem pode representar, tanto no tempo de treinamento quanto em seu desempenho. Também foram realizados teste com tamanho de 300 x 300 pixels, porém os resultados foram inferiores aos de 255 x 255 pixels (0.8984 de acurácia). Por esse motivo o tamanho elencado para o uso na construção do modelo foi tal.

## CONCLUSÃO

O presente trabalho propõe uma ferramenta para o auxílio de diagnósticos médicos em análises de mamografias, para a detecção do câncer de mama utilizando-se Redes Neurais Convolucionais. Após estudos para a construção de um modelo capaz de realizar a classificação de mamografias com um alto índice de acertos, o algoritmo desenvolvido alcançou a acurácia de 91,34% durante a fase de validação. Os resultados encontrados são compatíveis com a literatura, e mostram que a utilização ferramenta pode trazer benefícios na área de diagnósticos por imagens médicas. Espera-se que esse estudo possa seguir em trabalhos futuros, tanto para que se possa melhorar ainda mais a acurácia do modelo, quanto para utilizar-se de outras bases de imagens para a realização do treinamento, teste e validação do mesmo

## REFERÊNCIAS

AKRAM, M. *et al.* Awareness and current knowledge of breast cancer. **Biological research**, v. 50, n. 1, p. 1-23, 2017.

ANGERMUELLER, C. *et al.* *Deep learning* for computational biology. **Molecular systems biology**, v. 12, n. 7, p. 878, 2016.

APANTAKU, L. M. Breast cancer diagnosis and screening. **American Family Physician**, v. 62, n. 3, p. 596-602, 2000.

ASSIS M., SANTOS, R. O. M.; MIGOWSKI, A. Detecção precoce do câncer de mama na mídia brasileira no Outubro Rosa. **Physis: Revista de Saúde Coletiva**, v. 30, p. e300119, 2020.

BARROS, A. C. S. D. *et al.* Diagnóstico e tratamento do câncer de mama. **AMB/CFM-Projeto Diretrizes**, p. 1-15, 2001.

BIEN, N. *et al.* Deep-learning-assisted diagnosis for knee magnetic resonance imaging: development and retrospective validation of MRNet. **PLoS medicine**, v. 15, n. 11, p. e1002699, 2018.

CHENG, H. *et al.* Approaches for automated detection and classification of masses in mammograms. **Pattern recognition**, v. 39, n. 4, p. 646-668, 2006.

CHODOSH, L. A. Breast cancer: current state and future promise. 2011.

DE FAUW, J. *et al.* Clinically applicable *deep learning* for diagnosis and referral in retinal disease. **Nature medicine**, v. 24, n. 9, p. 1342-1350, 2018.

DE SÁ O., VICTOR, F.; LINS, A. LUISA: Uma Proposta de Ferramenta para Auxílio Ao Diagnóstico do Câncer de Mama a Partir de Imagens de Mamografias Digitalizadas. **Revista de Engenharia e Pesquisa Aplicada**, v. 5, n. 2, p. 73-83, 2020.

ELKIN, E. B. *et al.* The effect of changes in tumor size on breast carcinoma survival in the US: 1975-1999. **Cancer: Interdisciplinary International Journal of the American Cancer Society**, v. 104, n. 6, p. 1149-1157, 2005.

FERRAZ, R. O.; MOREIRA-FILHO, Djalma de Carvalho. Análise de sobrevivência de mulheres com câncer de mama: modelos de riscos competitivos. **Ciência & Saúde Coletiva**, v. 22, p. 3743-3754, 2017.

GOODFELLOW, I. *et al.* **Deep learning**. Cambridge: MIT press, 2016.

GÖTZSCHE, P. C.; JØRGENSEN, K. J. Screening for breast cancer with mammography. **Cochrane database of systematic reviews**, n. 6, 2013.

HEATH, M. *et al.* The Digital Database for Screening Mammography. Proceedings of the Fifth International Workshop on Digital Mammography. [S.l.]: **Medical Physics Publishing**, p. 212-218, 2001.

HU, Z. *et al.* *Deep learning* for image-based cancer detection and diagnosis- A survey. **Pattern Recognition**, v. 83, p. 134-149, 2018.

KER, J. *et al.* *Deep learning* applications in medical image analysis. **Ieee Access**, v. 6, p. 9375-9389, 2017.

LEE, R. S. *et al.* Curated breast imaging subset of DDSM. **The cancer imaging archive**, v. 8, p. 2016, 2016.

LI, R. *et al.* *Deep learning* based imaging data completion for improved brain disease diagnosis. In: **International Conference on Medical Image Computing and Computer-Assisted Intervention**. Springer, Cham, 2014. p. 305-312.

LITJENS, G. *et al.* A survey on *deep learning* in medical image analysis. **Medical image analysis**, v. 42, p. 60-88, 2017.

LOBO, L. C. Inteligência artificial e medicina. **Revista Brasileira de Educação Médica**, v. 41, n. 2, p. 185-193, 2017.

MIGOWSKI, A. *et al.* Diretrizes para detecção precoce do câncer de mama no Brasil. I-Métodos de elaboração. **Cadernos de Saúde Pública**, v. 34, p. e00116317, 2018.

MIGOWSKI, A. *et al.* Diretrizes para detecção precoce do câncer de mama no Brasil. II-Novas recomendações nacionais, principais evidências e controvérsias. **Cadernos de Saúde Pública**, v. 34, p. e00074817, 2018.

MIGOWSKI, A. *et al.* Diretrizes para detecção precoce do câncer de mama no Brasil. III-Desafios à implementação. **Cadernos de Saúde Pública**, v. 34, p. e00046317, 2018.

MIN, S.; LEE, B.; YOON, S. *Deep learning* in bioinformatics. **Briefings in bioinformatics**, v. 18, n. 5, p. 851-869, 2017.

O'MALLEY, T.; BURSZTEIN, E.; LONG, J.; CHOLLET, F.; HAIFENG, J.; INVERNIZZI, L. Keras Tuner, 2019. Disponível em: <https://bit.ly/3apnD30>.

ORGANIZAÇÃO MUNDIAL DA SAÚDE. (2021, 26 de março). Breast cancer. Disponível em: <https://bit.ly/3PN6kJd>.

O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. **arXiv preprint arXiv: 1511.08458**, 2015.

RAVI, D. *et al.* Deep learning for health informatics. **IEEE journal of biomedical and health informatics**, v. 21, n. 1, p. 4-21, 2017.

SAWYER, R. L. *et al.* A curated mammography data set for use in computer-aided detection and diagnosis research. **Scientific Data**, v. 4, p. 170177, 2017.

SEWAK, M.; KARIM, M.; PUJARI, P. Practical convolutional neural networks: implement advanced deep learning models using Python. Packt Publishing Ltd, 2018.

SHAMSI, M.; ISLAMIAN, J. P. Breast cancer: Early diagnosis and effective treatment by drug delivery tracing. **Nuclear Medicine Review**, v. 20, n. 1, p. 45-48, 2017

SIMONYAN, K.; ZISSERMAN, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. **arXiv**, ISSN 1409.1556, 2015.

SMITH, R. A. *et al.* Breast cancer in limited-resource countries: early detection and access to care. **The breast journal**, v. 12, p. S16-S26, 2006.

SUN, W. *et al.* Enhancing deep convolutional neural network scheme for breast cancer diagnosis with unlabeled data. **Computerized Medical Imaging and Graphics**, v. 57, p. 4-9, 2017.

TSOCHATZIDIS, L. *et al.* Computer-aided diagnosis of mammographic masses based on a supervised content-based image retrieval approach. **Pattern Recognition**, v. 71, p. 106-117, 2017.

WANG, F. L. *et al.* Effects of age, breast density and volume on breast cancer diagnosis: a retrospective comparison of sensitivity of mammography and ultrasonography in China's rural areas. **Asian Pacific Journal of Cancer Prevention**, v. 14, n. 4, p. 2277-2282, 2013.



WEBB, S. *Deep learning* for biology. **Nature**, v. 554, n. 7693, 2018.

WONG, K. KL; FORTINO, G.; ABBOTT, D. *Deep learning*-based cardiovascular image diagnosis: a promising challenge. **Future Generation Computer Systems**, v. 110, p. 802-811, 2020.