



UTILIZAÇÃO DE REDES NEURAS ARTIFICIAS APLICADAS NA DETECÇÃO DE MELANOMA CUTÂNEO

*Use of artificial neural network applied in the detection
of cutaneous melanoma*

Vinicius Andrade Gulartt¹
Rodrigo Luiz Antoniazzi²

Resumo: O melanoma cutâneo é considerado por dermatologistas um dos tumores de pele mais agressivo que existe. Para aumentar as chances de sobrevivência do paciente é necessário realizar o diagnóstico precocemente. Realizando o diagnóstico precoce permite determinar o grau de agressividade da doença. Tendo isso em consideração, foi desenvolvido um sistema que detecta o melanoma cutâneo através de uma imagem digital. A imagem digital é processada com o uso do filtro da mediana, e então é removido as cores, trabalhando com uma imagem em escalas de cinza, e modificado as suas dimensões. Após ter sido modificada, a imagem ela é comparada com os dados armazenados na rede neural desenvolvida. Com a utilização da linguagem de programação *python* e das bibliotecas *OpenCV*, que é utilizada para processamento de imagem, *Keras* e *Tensorflow*, utilizadas para o aprendizado de máquina, foi criado uma rede neural convolucional. Essa rede neural convolucional foi treinada com imagens de melanoma cutâneo assim como imagens de nevos comuns, onde a mesma encontra padrões existentes nas imagens.

Palavras-chave: Rede Neural. Inteligência Artificial. Melanoma Cutâneo.

Abstract: Cutaneous Melanoma is considered by dermatologists as one of the most aggressive skin tumors in existence. To increase the patient's survival chance, early diagnosis is required. Performing early diagnosis allows to determine the degree of aggressiveness of the disease. Having that in mind, a system was developed to detect cutaneous melanoma using a digital image. The digital image is processed using the median filter, and then the colors are removed, working with a grayscale image, and the dimensions of the image are modified. After the image has been modified, it is compared with the data stored in the developed neural network. With the use of the python programming language and the OpenCV library, which is used for image processing, and Keras and Tensorflow libraries, used for machine learning, a conventional neural network was created. This convolutional neural network was trained with images of cutaneous melanoma, as well as images of common nevi, making it possible for the convolutional neural network to detect existing patterns in the images.

Keywords: Neural Network. Artificial Intelligence. Cutaneous Melanoma.



¹ Discente do curso de Ciência da Computação, da Universidade de Cruz Alta - Unicruz, Cruz Alta, Brasil. E-mail: gulartt94@gmail.com

² Pesquisador do Grupo de Pesquisa Engenharias e Tecnologias - ENGETEC, Docente da Universidade de Cruz Alta - Unicruz, Cruz Alta, Brasil. E-mail: rantoniazzi@unicruz.edu.br

1 INTRODUÇÃO

Grande parte da população não associa o surgimento de novos nevos no corpo, também conhecidos como manchas ou pintas, com o câncer de pele. Esses novos nevos, inicialmente possuem uma aparência pouco chamativa, de tal forma que a pessoa não nota o novo nevo logo no início, permitindo que ele evolua para algo mais agressivo. Sendo classificado em três tipos: o primeiro tipo, chamado de carcinoma basocelular, possui maior incidência, aparecendo principalmente em áreas do corpo que foram expostas ao sol, como nariz, orelhas, ombros e costas. Com baixa letalidade e pode ser curado com detecção precoce. O segundo tipo é o carcinoma espinocelular, sendo que seu grau de incidência menor que o carcinoma basocelular; este tipo de câncer de pele pode ocorrer em qualquer parte do corpo. Possuindo casos associados com uso de drogas, transplantes de órgãos e exposição à químicos. Assim como o carcinoma basocelular, este tipo de câncer pode ser curado com a detecção precoce. Sendo melanoma cutâneo, o terceiro tipo de câncer de pele. De acordo com Santos (2019), em comparação com os outros dois tipos, este último possui o menor grau de incidência registrado pelo Instituto Nacional de Câncer.

Mesmo o melanoma cutâneo, possuindo o menor grau de incidência entre os três tipos de câncer de pele, ainda é considerado um dos tumores de pele mais agressivos. É uma doença que quando diagnosticada precocemente, possui uma maior probabilidade de cura, caso a doença se alastre e se torne mais agressiva, a cura deixa de ser viável e o paciente deve fazer tratamento para controlá-la durante o resto de sua vida. A detecção do câncer é realizada com a utilização do dermatoscópio. O dermatoscópio é um equipamento que fotografa e amplia a imagem do nevo de 20 a 70 vezes, permitindo a especialistas da área classificar o tipo de câncer de pele e o seu grau de agressividade seguindo a regra do ABCDE (Assimetria – Borda – Cor – Diâmetro - Evolução) do câncer de pele. Esta classificação é feita por um dermatologista, ou seja, necessita do fator humano. Com a utilização de uma rede neural é possível remover o fator humano para classificar o tumor de pele.

Uma rede neural é um modelo computacional que, por meio da entrada de informação, é possível reconhecer padrões existentes. As redes neurais artificiais são baseadas no sistema nervoso dos seres vivos inteligentes. O sistema nervoso é o que permite o ser humano aprender coisas novas, ele capta, interpreta, armazena as informações recebidas, através do tato, olfato e visão. Uma rede neural artificial é como uma criança, ela recebe dados, e esses dados são classificados através de um terceiro. Este terceiro ensina a criança a associar o dado

recebido, colocando um rótulo no dado. A rede neural artificial atua da mesma forma, onde o dado de entrada pode ser como exemplo uma imagem. Esta imagem recebe um rótulo especificando o que ela é. Uma rede neural artificial precisa de muitos dados de entrada para poder ser treinada. Por isso, mesmo que não seja necessário o fator humano na classificação da imagem, ainda é necessário no treinamento da rede. Para a utilização de uma imagem como dado de entrada, existe a necessidade de transformar a imagem para um formato que a rede neural artificial consiga compreendê-la. Então, a imagem é transformada em uma matriz onde cada posição da matriz corresponde a um pixel da imagem, e o valor existente na posição corresponde a cor do pixel. Esta transformação se torna possível com o processamento de imagem digital (SHEN, 2017).

As redes neurais artificiais se mostraram eficazes aplicadas em outros campos, como o trabalho de Cannady (1998) que utiliza redes neurais para detectar e classificar invasões de rede utilizando como critério, fontes de informações incompletas, limitadas ou não lineares. E o trabalho de Dawson e Wilby (2001), que se utilizou de redes neurais artificiais para prever o escoamento da chuva e enchentes.

Uma rede neural é composta de milhares de neurônios intercalados. Esses neurônios enviam e recebem pulsos elétricos, quando um neurônio envia um pulso significa que ele foi ativado, ou seja, a informação recebida pelo neurônio causou uma reação química, fazendo com que ela seja passada adiante. Um único neurônio não possui complexidade, mas uma grande cadeia interligada permite uma grande quantidade de processamento a ser feito. James Cannady em seu trabalho intitulado *Artificial Neural Networks for Misuse Detection*, no ano de 1998, utiliza redes neurais artificiais para detectar invasões de rede, enquanto Christian Dawson e Robert Wilby (2001) utilizaram redes neurais para modelagem de escoamento da chuva e para prever enchentes em seu trabalho intitulado *Hydrological modelling using artificial neural networks* (COPPIN, 2017).

Uma rede neural artificial pode ser utilizada para vários propósitos, como por exemplo, utilizando reconhecimento de padrões, pode reconhecer imagens, rostos, voz, e, também, ser utilizada na indústria para controle de produção, de estoque, qualidade, de falhas. Sendo estas apenas algumas das utilidades das redes neurais (COPPIN, 2017).


Convolução é uma operação linear que, com a utilização de duas funções gera uma terceira representando a primeira modificada. Dessa forma a primeira função a imagem de entrada, e a segunda função o filtro utilizado para modificar a imagem. O filtro também é conhecido como *kernel* (SILVA, 2019).

Uma rede convolucional não necessita que os neurônios estejam ligados com todos os outros neurônios das camadas seguintes, como cita Silva (2019, p. 185):

Para uma rede convolucional, o uso do kernel para calcular todas as entradas de um neurônio garante que, naquele campo receptivo observado pelo kernel a cada iteração, haverá uma contribuição entre pixels próximos, tornando o aprendizado da rede mais conectado às características espaciais da imagem. Portanto, as redes convolucionais fracionam o processamento em grupos menores, não havendo mais a rígida conexão de todos os neurônios de uma camada com os da seguinte. Agora, os pesos são dependentes de cada kernel que busca uma mesma característica em regiões diferentes da imagem, assim, haverá pesos suficientes para cobrir um campo receptivo, sendo replicados para os demais campos (SILVA, 2019, p. 185).

O *Kernel* nas redes neurais convolucionais é utilizado para extrair atributos existentes na imagem, como uma linha, uma curva, cores, mas para isso a imagem deve ser transformada em uma matriz numérica, onde as posições na matriz representam os pixels e os valores representam as cores. As cores são classificadas de 0 a 255. Uma imagem colorida possui três níveis de cores agrupados sendo eles verde, vermelho e azul. Este kernel é uma matriz que se desloca sobre a imagem até atingir a última posição da matriz da imagem. Sendo o número de pixels deslocado chamado de *stride*. Segundo Silva (2019), a velocidade de treinamento da rede neural não é influenciada pelo tamanho do kernel, mas sim pelo tamanho do *stride*. Desta forma o kernel cria os mapas de atributos, os quais sofrem uma transformação em seus valores com a utilização da função de ativação RELU (Unidade Linear Retificada), representado na Figura 1 (SILVA, 2019).

Figura 1- Representação do Kernel



Fonte: Silva (2019).


O presente trabalho tem por objetivo auxiliar os especialistas da área, automatizando a detecção do melanoma cutâneo, de tal forma que possam ser realizados mais diagnósticos em um curto período. Como uma máquina não precisa descansar, e não diminui a produtividade com horas de trabalho, é possível reduzir parte do trabalho executado pelo médico, permitindo que ele foque no tratamento e reabilitação dos pacientes com casos de melanoma cutâneo avançado.

2 MATERIAIS E MÉTODOS

O desenvolvimento foi dividido em três partes, sendo a primeira o processamento das imagens de entrada, depois é feito a criação da rede neural e, por fim, seu treinamento e validação.

Para o processamento de imagens foi utilizada a biblioteca OpenCV, onde a imagem de entrada é de formato “.png” - de tamanhos distintos colorida como exemplo a Figura 2. Logo após, é transformada em escalas de cinza e corrigido a luz. Posteriormente, são modificadas as dimensões da imagem para 100 x 100 pixels padronizando a imagem para ser utilizada na rede.

Figura 21- Processamento de imagem



Fonte: GBM (2020).

Os dados utilizados para treinar uma rede neural convolucional serão separados em grupos. Cada grupo possui seu próprio rótulo de identificação, dessa forma quando forem extraídas informações referentes aos dados de entrada, elas ficarão vinculados aos grupos pré-definidos. Os dados de entrada para a criação de uma rede neural convolucional é dividido em três conjuntos, o conjunto de treinamento, o conjunto de validação e o conjunto de testes. O conjunto de treinamento fica responsável por treinar a rede neural convolucional. Através de

cada iteração ocorrida os dados serão processados para a extração de informações. A rede irá aprender através das informações extraídas do conjunto de treinamento, para que quando inserido novos dados ela possa determinar a qual grupo estes novos dados pertencem. Após cada iteração, os valores da perda de dados serão calculados e os pesos serão modificados para que na próxima iteração os valores da perda de dados sejam reduzidos.


O segundo conjunto é muito parecido com o primeiro, o conjunto de validação vai utilizar dados ainda não processados pela rede neural convolucional e, juntamente com a execução do conjunto de treinamento, o conjunto de validação irá executar de forma parecida. A principal diferença entre o conjunto de treinamento e o conjunto de validação é o de que o conjunto de validação não modifica os valores da perda de dados. A execução do conjunto de validação é utilizada para ver como a rede se comporta com dados fora do grupo de treinamento, ou seja, dados não utilizados previamente. Essa execução simultânea do conjunto de treinamento e do conjunto de validação é utilizado para identificar se a rede está sendo treinada corretamente.

Caso os valores de perda de dados do treinamento sejam muito distantes dos dados da validação e a precisão seja muito diferente também, significa que a rede está com algum problema. Um caso comum que pode ocorrer é o sobre-ajuste dos dados. Isso ocorre quando a rede neural se torna ótima para detectar os padrões do conjunto de treinamento, mas quando apresentado novos dados, ela deixa de ser eficaz. Para isso é utilizado o comando de *dropout*. Esse comando permite, que durante cada iteração, seja desligado de forma aleatória a utilização de certas camadas internas da rede neural, impedindo a rede de seguir um caminho repetitivo, aumentando a precisão dos dados. E, por fim, o terceiro conjunto dos dados de entrada é o conjunto de testes. Este diferente dos anteriores é utilizado apenas após a rede ter sido treinada e, também, não é rotulada. A ideia de existir o conjunto de testes é para que seja testado se a rede é capaz de fazer o que ela foi criada para fazer, que é a classificar os dados sem ajuda externa.

Após criar os mapas de atributos eles são passados para a camada de subamostragem, onde é reduzido o tamanho dos mapas de atributos e criados grupos. Cada grupo será substituído por um pixel correspondente ao valor máximo do grupo. Reduzindo, dessa forma, os dados e as conexões, sem perder as informações relevantes. Na Figura 3 é ilustrada a camada de convolução onde o kernel atua criando os mapas de atributos, que seguem para a camada de amostragem reduzindo os dados em grupos onde é utilizado o maior valor de cada

grupo chamado de *maxpooling* e, então, segue para a camada final onde utiliza-se da função *softmax*, que associa os atributos coletados a sua respectiva classe de entrada (SILVA, 2019).

Figura 3- Etapas de uma rede neural convolucional



Fonte: Silva (2019).

A rede neural convolucional foi desenvolvida com as bibliotecas *keras* e *tensorflow* que são utilizadas para aprendizado de máquina. Ali é utilizado duas camadas convolucionais uma com matriz de 5 x 5 e outra com matriz de 3 x 3, possuindo 60 mapas de atributos para a primeira e 30 para a segunda, sendo feito o *maxpooling* com caminho 2 x 2 após cada camada convolucional. O comando de *dropout* representa a probabilidade de neurônios aleatórios não fazerem parte da iteração. O comando *flatten* converte a matriz que possui todos os atributos em um vetor de uma dimensão. Após, é inserida uma camada densamente conectada e o número de neurônios que irão fazer parte dessa camada, juntamente com a função de ativação não linear *relu*. Então, utiliza-se da camada densa junto com o número de classes de imagens e a função *softmax* para ajustar a precisão de cada atributo a sua respectiva classe. E, por fim, usa a função de entropia cruzada para minimizar a perda, o otimizador *adam* e como retorno a precisão conforme a Figura 4.

Figura 42- Rede neural convolucional

```

model = Sequential()
model.add(Conv2D(60, (5,5), (32,32,3),activation='relu'))
model.add(MaxPooling2D(pool_size=(2,2)))
model.add(Conv2D(60 // 2, (3,3), função de ativação='relu'))
model.add(MaxPooling2D(pool_size=(2,2)))
model.add(Dropout(0.5))
model.add(Flatten())
model.add(Dense(500, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(2, função de ativação='softmax'))
model.compile(Adam(lr=0.001), loss='categorical_crossentropy', metrics=['accuracy'])

```

Fonte: Elaborado pelos autores (2020).

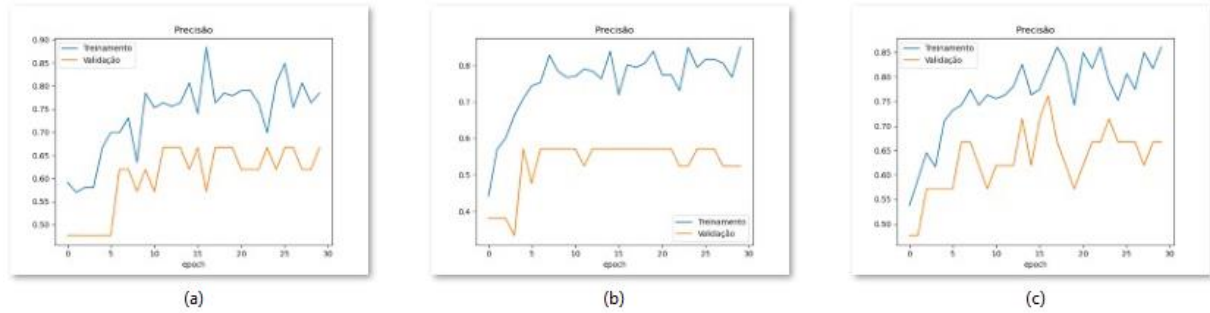
Ao todo foram utilizadas 130 imagens para o treinamento da rede neural, as quais foram divididas em três grupos distintos. O primeiro, o grupo dos nevos melanócitos, sendo popularmente conhecidos como pintas. Os outros dois grupos são compostos por imagens de tumores de pele do tipo carcinoma basocelular e melanoma cutâneo, que são representados por nevos atípicos. Cada grupo possui um número diferente de imagens como dados de entrada, sendo que a coleta de imagens foi feita através de sites de dermatologia encontrados através do google.

O primeiro grupo contém 13 imagens, o segundo grupo contém 43 imagens e o terceiro grupo e o objeto de estudo desta pesquisa é composto por 74 imagens. Sendo que cada grupo foi dividido nos três conjuntos utilizados para a criação e execução correta da rede. Os conjuntos foram divididos da seguinte maneira: o conjunto de validação ficou com 20% dos dados de entrada, o conjunto de treinamento ficou com 20% dos dados restantes após a retirada dos dados do conjunto de validação. E, para o conjunto de treinamento sobrou todo o restante de dados não vinculados a nenhum dos outros dois conjuntos.

3 RESULTADOS E DISCUSSÕES

Os resultados preliminares após a execução da rede se mostraram desagradáveis, pois ocorreram detecções errôneas e uma grande variação nos valores de precisão ao final do treinamento da rede neural. O principal problema foi o surgimento do sobre-ajuste ocorrido na rede, caracterizado pelo número limitado de dados de entrada utilizados. E, mesmo modificando os parâmetros da rede neural, como o tamanho da imagem, o número de iterações e épocas, assim como o tamanho do filtro utilizado se mostraram ineficazes para a correção do problema encontrado. Assim como demonstrado na figura 5, onde o gráfico a representa a precisão da rede, utilizando imagens com tamanho 30x30, o gráfico b representa a precisão da rede utilizando imagens com tamanho 100x100 e o gráfico c representa a rede precisão utilizando imagens com tamanho 200x200. Sendo que o mesmo problema ocorreu nos três casos, existindo uma grande diferença nos resultados coletados do conjunto de treinamento e do conjunto de validação.

Figura 53- Gráficos de precisão de acerto



Fonte: Elaborado pelos autores (2020).

4 CONSIDERAÇÕES FINAIS

A utilização de uma rede neural convolucional para a detecção de padrões existentes em imagens, prova-se útil, quando o treinamento da rede é realizado a partir da utilização de parâmetros corretamente informados e, também, com uma grande quantidade de dados de entrada. Caso não exista uma certa quantidade de dados de entrada que satisfaça a rede, de tal forma que ela possa distinguir o melanoma cutâneo de qualquer outro nevo existente, impossibilita a sua utilização. Caso os critérios sejam alcançados, a rede neural convolucional se mostra um grande aliado na detecção de padrões em imagens digitais.

REFERÊNCIAS

AZEVEDO, Guinar.; MENDONÇA, Silva. Risco crescente de melanoma de pele no Brasil. **Revista Saúde Pública**, v. 26, n. 4, p. 290-294, 1992.

CANNADY, James. Artificial Neural Networks for Misuse Detection. In: Proceedings of the 21st National Information Systems Security Conference, 1998. **Anais...** New Southeastern: Florida, p. 368-381, 1998.

COPPIN, Ben. **Inteligência Artificial**. 1ª ed., Rio de Janeiro: Editora LTC, 2017.

DAWSON, Christian; WILBY, Robert. Hydrological modelling using artificial neural networks. **Sage Journals**, v. 25, p. 80-108, 2001.

EVARISTO, Alexandre; RODRIGUES Zeni. **Principais Temas Em Dermatologia Provas de Residência Médica**. 1ª ed. São Paulo: Medcel, 2015.

FIGUEIREDO, C. Licia. Câncer de pele: estudo dos principais marcadores moleculares do melanoma cutâneo. **Revista Brasileira de Cancerologia**, v. 49, n. 3, p. 179-183, 2003.

GERHARDT, Tatiana E.; SILVEIRA, Denise. **Métodos de pesquisa**. Porto Alegre: Editora da UFRGS, 2009.

GONZALEZ, Rafael C; WOODS, Richard E. **Digital Image Processing**. 1º ed., Boston: Addison-Wesley, 1992.

INCA. INSTITUTO NACIONAL DE CÂNCER. **Câncer de Pele Melanoma**. Disponível em: <<https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-melanoma>>. Acesso em: 29 ago. 2019.

KOVÁCS, L. Zsolt. **Redes Neurais Artificiais Fundamentos e Aplicações**. 4ª ed, São Paulo: Livraria da Física, 2002.

RUSSEL, Stuart J; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 1ª ed, Nova Jersey: Prentice Hall, 1995.

SANTOS, Camila A dos; SOUZA, Dyego L. B. Melanoma mortality in Brazil: trends and projections (1998-2032). **Ciênc. saúde coletiva**, v. 24, n. 4, p. 1551-1561, 2019.

SHEN, Dinggang; WU, Guorong; SUK, Heung-Il. Deep learning in medical image analysis. **Annual Review of Biomedical Engineering**, v. 19, p. 221-248, 2017.

SILVA, Fabricio M. da; LENZ, Maikon L.; FREITAS, Pedro H. C.; SANTOS, Sidney C. B. dos. **Inteligência Artificial**. Porto Alegre: Editora Grupo A, 2019.