

A UTILIZAÇÃO DAS REDES NEURAI ARTIFICIAIS NO AUXÍLIO NA IDENTIFICAÇÃO DE MELANOMAS

Adroaldo Antônio Candido Neto¹; Stéfano Schwenck Borges Vale Vita²

^{1,2} Universidade de Uberaba

adroaldoneto94@outlook.com; stefano.vita@uniube.br

Resumo

A pele é o maior órgão do corpo humano. A camada mais externa da pele fica totalmente exposta ao ambiente, é sensível principalmente para peles muito claras, por isso é importante cuidarmos dela. O sol é um dos maiores fatores de risco para ela, quando exposta de maneira excessiva, podendo provocar diversas reações até mesmo o câncer de pele, classificados como melanoma e não melanoma. Melanomas e não melanomas são exemplos de cânceres de pele, sendo o primeiro mais agressivo que o segundo. As Redes Neurais Artificiais (RNAs) é um modelo computacional que lembra a estrutura de um cérebro humano no quesito aprendizado. Dessa forma, a rede neural artificial consegue interpretar de forma autônoma os dados inseridos, desde que os dados sejam referentes ao conteúdo de aprendizagem (HAYKIN, 2001). A utilização de processamento de imagens aliado a técnica das redes neurais artificiais com múltiplas camadas, que são capazes de interpretar dados da imagem de forma autônoma após um período de aprendizagem, vem possibilitar a elaboração de um sistema capaz de classificar imagens do tipo melanoma e não melanoma. Com esse intuito, este artigo tem como objetivo descrever um sistema capaz de classificar melanoma e não melanomas através de imagens digitais.

Palavras-chave: Câncer. Pele. Imagens.

1 Introdução

O câncer é manifestado quando existe um crescimento desordenado das células, havendo uma rápida multiplicação que atinge os órgãos e os tecidos, podendo avançar para outras regiões do nosso corpo, chamado de metástase.

O tumor, também denominado de neoplasias malignas, surge quando há presença dessas características, que é o acúmulo de células cancerosas. (INCA, 2016).

A exposição ao sol de maneira excessiva e o tom de pele são os principais fatores de risco para o câncer de pele. É dividido de maneira geral, em: melanoma, onde será o foco deste artigo, e não melanoma. O não melanoma é de maior incidência, representando 30% de todos os cânceres registrados no Brasil, segundo o INCA, entretanto, o índice de mortalidade é menor. E o melanoma é o mais agressivo entre eles, que é proveniente das células que produzem melanina, denominada de melanócitos, compostas nos nevos melanóticos, também chamados de pinta.

Atualmente, existe um exame, conhecido por dermatoscopia, que consegue avaliar as pintas, utilizando um equipamento denominado de dermatoscópio. Examinar o estado de cada nevo com a dermatoscopia manual pode ser uma tarefa trabalhosa e com uma menor precisão, em relação a dermatoscopia digital. Neste último caso, deve haver um investimento mais elevado para comprar o produto.

A tecnologia evolui muito rápido a cada ano, hoje existem aplicativos e dispositivos para aparelhos celulares que realizam análise dos nevos, porém, a qualidade das análises nos aplicativos ainda não é satisfatória e o valor que é preciso desembolsar para adquirir um dispositivo não é acessível a todos, muito das vezes. Para analisar é necessário identificar alguns padrões que os melanomas possuem, como: assimetria, borda e diâmetro. Para facilitar esse processo é utilizado modelos computacionais, em que podemos destacar a Rede Neural Artificial (RNA), que consegue

11º ENTEC – Encontro de Tecnologia: 16 de outubro a 30 de novembro de 2017

interpretar dados inseridos de modo independente após passar pela etapa de aprendizagem, lembrando a estrutura de um cérebro humano.

O sistema desenvolvido neste trabalho terá como finalidade examinar as pintas. A RNA irá processar as imagens e avaliá-las, informando o estado de cada nevo, se é um possível melanoma ou não. Este trabalho tem como objetivo informar aos usuários um suposto grau de risco das pintas e prevenir de um futuro câncer de pele, não dispensando orientação médica.

2 Materiais e Métodos


O objetivo desse projeto é a identificação de um possível câncer de pele por meio da análise de imagens digitais tiradas por um equipamento que exiba nitidamente os atributos de um melanoma. Os padrões de assimetria, borda, cor e diâmetro que estão presentes nas imagens, permitem que a RNA seja implantada no sistema, pois, através dessas características é possível identificar um provável câncer de pele ou não.

A estrutura da rede neural foi montada utilizando o *framework Encog* (HEATON RESEARCH, 2017) para linguagem de programação Java. Através do *Encog* e com um pré-processamento de imagens foi possível a construção de um sistema de identificação dos melanomas de acordo com os padrões de assimetria, borda irregular, cor e diâmetro. Para uma melhor configuração da rede, os parâmetros principais foram alterados, como: taxa de aprendizado, momentum, número de neurônios da camada primária, camada oculta e camada de saída.

A rede neural de múltiplas camadas (BRAGA, 2012) foi implementada para que houvesse um treinamento mais adequado se tratando de imagens, sendo que a camada oculta proporciona a extração de características que possui os dados de entrada. O repositório *International Skin Imaging Collaboration* (ISIC) possibilitou uma quantidade aceitável de imagens de melanomas e nevos necessários para o

treinamento e experimentos da RNA, conforme ilustrado na Figura 1.

Figura 1 – Imagens do repositório ISIC.




Fonte: Repositório digital ISIC Archive
(Disponível em: <<https://isic-archive.com/#>>. Acesso em: junho/2017)

Uma imagem monocromática pode ser considerada a discretização de uma função bidimensional $f(x, y)$, onde x e y são as coordenadas espaciais e o valor de f em algum ponto (x, y) corresponde ao brilho ou níveis de cinza da imagem naquele ponto (GONZALEZ, 2000). Cada ponto na imagem digital é denominado de elemento da imagem ou pixel.


As etapas principais que compõem o sistema são: conversão da imagem para resolução menor, conversão para escala de cinza, segmentação, treinamento da rede neural com repositório de imagens tanto de pintas quanto melanomas e testes da rede com imagens que não foram utilizadas na aprendizagem. As resoluções das imagens foram alteradas para 20% e 6,5% do seu tamanho original. Durante os experimentos, a resolução não trouxe um valor significativo para que pudesse trabalhar com o tamanho real.

Primeiramente, para facilitar a entrada dos dados na rede neural, foi necessário a conversão da imagem para a escala de cinza, variando o valor dos pixels de 0 a 255, correspondendo respectivamente as cores preto e branco, conforme ilustra a Figura 2.

11º ENTEC – Encontro de Tecnologia: 16 de outubro a 30 de novembro de 2017
Figura 2 – (a) Imagem colorida redimensionada. (b) Imagem na escala de cinza.


Fonte: Acervo pelo autor.

Em seguida, a segmentação da imagem foi uma das alternativas para separar o fundo da região de análise, e também para facilitar a entrada de dados na RNA. Para esse processo foi utilizado a segmentação por limiarização (GONZALES, 2000), tanto global quanto local, isto é, existe um ponto de divisão para destacar o fundo e deixar mais visível a área desejada. Na Figuras 3, abaixo, as imagens foram convertidas utilizando esse método onde o fundo foi destacado.

Figura 3 – (a) Imagem com região de interesse na cor preta e fundo branco. (b) Imagem com região de interesse com tons de cinza e fundo preto.


Fonte: Acervo pelo autor.

A limiarização global adaptativa calcula o valor apropriado do limiar para cada imagem, ou seja, um limiar específico. Primeiro é adotado um valor para o limiar T , com isso é gerado duas regiões G_1 e G_2 , posteriormente é calculado a média dos valores dos pixels de cada região μ_1 e μ_2 , em seguida, para produzir o novo valor de T , faz a somatória das duas médias dividido por 2, representado na Equação 1 (BACKES, 2017). Repita o processo até que

a diferença entre os dois valores consecutivos seja 0.

$$T = \frac{\mu_1 + \mu_2}{2} \quad (1)$$

Para que a RNA consiga interpretar os dados, cada pixel da imagem é inserido em uma posição do vetor, e cada valor passa por um processo de normalização, variando de 0,15 a 0,85. Pois, auxilia no aprendizado e a função de ativação adotada é a sigmoideal, permitindo intervalos de números entre 0 e 1. A normalização é descrita pela Equação 2.


$$y = \frac{(b - a) \cdot (x_i - x_{min})}{x_{max} - x_{min}} + a \quad (2)$$

Onde b é o intervalo máximo da normalização, a é o valor mínimo, x_i é o valor do pixel, x_{min} é o valor mínimo do pixel (0), x_{max} é o valor máximo do pixel (VERAS, 2017).

3 Resultados

Foram realizados diversos experimentos com a finalidade de aumentar a porcentagem de acerto na identificação dos melanomas e dos nevos.

A Figura 4 apresenta um gráfico no qual são exibidos treinamentos da rede neural, um com resolução das imagens de 6,5%, outro com resolução de 20%, ambos com percentual em relação a imagem original, 1024x768 pixels.

Figura 4 – Treinamento da RNA.



Fonte: Elaborado pelo autor.

11º ENTEC – Encontro de Tecnologia: 16 de outubro a 30 de novembro de 2017

Quanto maior a resolução da imagem com um neurônio na saída, maior será a quantidade de épocas para finalizar o treinamento, devido a quantidade de pixels na entrada da rede que aumenta. Isso também implica em um menor período de treinamento.

Na etapa de aprendizagem da RNA, o momentum foi adotado com o valor de 0,8. Ele é fundamental para que a instabilidade nos cálculos dos erros de cada época seja mínima, ou seja, a variação do erro não sofra uma alteração brusca de uma época para outra. Quanto menor o valor do momentum, maior será a oscilação da rede durante o processo de aprendizagem, podendo chegar a um ponto de saturação, onde a rede não consegue convergir. Na Figura 5, o valor do momentum de 0,8 permitiu a que a rede fosse treinada na época 454, diferente dos demais, onde o treinamento não foi concluído.

Figura 5 – Momentum diferentes.



Fonte: Elaborado pelo autor.

A Tabela 1 apresenta as configurações para uma RNA com a resolução da imagem de 20%.

Tabela 1–Configuração com 20% da imagem


Nº neurônio – camada primária	31570
Nº neurônio – camada oculta	20
Nº neurônio – camada de saída	1
Largura da imagem	205
Altura da imagem	154
Taxa de aprendizado	0,03
Momentum	0,8
Parâmetro de erro	0,01

Fonte: Elaborado pelo autor.

Na etapa dos experimentos com os padrões acima, foram alteradas algumas características das imagens para que houvesse um maior percentual de acerto, entre elas: tons de cinza na região que será analisada, normalização, limiar para cada imagem e limiar global. Para esse caso, as escolhas das massas de entrada foram aleatórias, ou seja, não havendo uma seleção visual das imagens, sendo 160 melanomas, 160 nevos e 100 para os testes da rede, dos quais, 50 são melanomas e 50 são nevos.

No Figura 6, apresenta o percentual de acerto para os treinamentos que utilizaram as características de normalização, limiar global e um limiar para cada imagem, deixando a imagem em dois tons, branco e preto.

Figura 6 – Percentual de acerto de duas RNAs com um limiar para cada imagem e um global.




Fonte: Elaborado pelo autor.

Considerando os resultados da Figura 6, 48% de amostras desconhecidas pela rede acertou o diagnóstico de melanoma, 52% errou.

Um experimento semelhante ao anterior também foi realizado, a única alteração foi na área de interesse da análise, deixando-a em níveis de cinza de acordo o limiar definido. A Figura 7 é resultante do experimento utilizando limiar global e a Figura 8 é resultante do experimento utilizando um limiar calculado para cada imagem.


11º ENTEC – Encontro de Tecnologia: 16 de outubro a 30 de novembro de 2017

Figura 7 – Percentual de acerto da RNA com um global.



Fonte: Elaborado pelo autor.


Figura 8 – Percentual de acerto da RNA com um limar para cada imagem.



Fonte: Elaborado pelo autor.

Um experimento final foi realizado, com alterações na dimensão da imagem para 6,5% (67x50) do tamanho original, totalizando 3350 pixels. As demais configurações são as mesmas da análise anterior. O resultado deste experimento é apresentado no gráfico da Figura 9 abaixo

Figura 9 – Percentual de acerto da RNA com dimensão da imagem em 6,5%.



Fonte: Elaborado pelo autor.

Em relação a Figura 9, dos 70% de acerto, 44% são nevos e 26% melanomas, isto é, 88% de acerto dos nevos e 52% de acerto dos melanomas, apresentando no Gráfico 9.

4 Discussão

O diagnóstico de doenças, como o câncer, através da utilização de imagens e técnicas de inteligência artificial, como as redes neurais artificiais, vem adquirindo grande importância devido a obtenção de resultados significativos, o que auxilia satisfatoriamente profissionais da área da saúde. Por isso, a criação de sistemas capazes de “classificar” doenças vem se destacando na computação.

Com um objetivo futuro de disponibilizar o sistema para um aplicativo celular e tornar acessível à população, é preciso melhorar a confiabilidade, aumentando a porcentagem de acerto dos melanomas e dos nevos. Alguns pontos podem ser destacados:

- Tornar a imagem mais nítida para o aprendizado, como a aplicação de um filtro passa-baixa, que irá diminuir o ruído da imagem, mediana que ajudará a suavização;
- Aumentar a quantidade de imagens da massa de treinamento de ambos os tipos;
- Tirar foto com o mesmo padrão de distância, que possibilitaria adicionar mais uma característica na identificação do melanoma, que é a evolução da regra ABCDE; e

11º ENTEC – Encontro de Tecnologia: 16 de outubro a 30 de novembro de 2017

- Aplicar outras estruturas para melhorar o desempenho da RNA como: máquina de vetor, outros algoritmos de aprendizagem, *deep learning*, etc.

5 Conclusão

Ao realizar experimentos utilizando uma estrutura de rede neural Perceptron de Múltiplas Camadas, o percentual de acerto significativo foi de 68% e 70%, permitindo assim, uma maior extração de características com base na assimétrica, borda irregular, cor e diâmetro. Quanto a detecção do melanoma, o resultado que permaneceu mais estável foi de 68%, que representou 66% de identificação dos nevus e 70% dos melanomas.

Referências

BACKES, André R. **Segmentação de imagens**. Disponível em: <<http://www.facom.ufu.br/~backes/gsi058/Aula09-Segmentacao.pdf>>. Acesso em 16/05/2017.

BRAGA, Antônio de Pádua; CARVALHO, André Ponce de Leon F. de; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais:**

teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2012. 226 p.

GONZALEZ, R. and WOODS, R. (2000). **Processamento de Imagens Digitais**. Editora Edgard Blucher, São Paulo.

HAYKIN, Simon. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HEATON RESEARCH. **Encog Machine Learning Framework**. Disponível em: <<http://www.heatonresearch.com/>>. Acesso em: 16/05/2017.

INCA, Instituto Nacional de Câncer. **O que é o câncer?**. Disponível em: <http://www1.inca.gov.br/conteudo_view.asp?id=322>. Acesso em: 14/09/2016.

VERAS, Carlos Vinicius Aladim. **Estudo comparativo de técnicas de redes neurais artificiais na previsão de velocidade do vento em curto prazo**. Disponível em: <http://tcc.ecomp.poli.br/20132/Carlos_Vinicius_Aladim_Veras%20FINAL.pdf>. Acesso em: 07/06/2017.