

Detecção de câncer de pele do tipo melanoma utilizando técnicas de processamento digital de imagem e redes neurais artificiais

Thiago A. Carvalho¹, Antônio C.F. Barros¹

¹ Universidade Federal de Viçosa (UFV), Florestal, Brasil

{thiago.a.carvalho, acfava}@ufv.br

Resumo. *O câncer de pele é um dos mais comuns tipos de câncer no Brasil, dentre ele se encontra o melanoma um dos tipos de tumor maligno responsável por muitas mortes. O presente trabalho visa realizar a detecção de melanomas por meio do processamento digital de imagens realizando análise sobre a simetria, cor, irregularidade de bordas e classificando por meio de redes neurais artificiais.*

1. Introdução

O Instituto Nacional de Câncer [INCA s.d] descreve o câncer de pele como o mais frequente no Brasil, correspondendo a cerca de 30% de todos os tumores malignos registrados em todo o país, dessa porcentagem o melanoma representa apenas 3% do diagnóstico. Apesar de pouca ocorrência, o diagnóstico do melanoma requer uma atenção maior, pois ele é classificado como o tipo mais grave, devido à sua alta possibilidade de provocar disseminação do câncer para outros órgãos.

O diagnóstico do melanoma é realizado através da avaliação visual, seguido pela comprovação de biópsia. Na avaliação visual são observadas alterações de cor, tamanho ou forma [Dimatos, 2009]. Por isso, na área da dermatologia existe uma demanda crescente do uso de técnicas de processamento digital de imagens de pele contendo lesões, pois nem mesmo os profissionais mais experientes conseguem identificar com eficácia. Conforme [Friedman, 2008], essas técnicas facilitam a detecção precoce dos melanomas e assim diminuem o número de biópsias realizadas em lesões benignas [apud Thiago Pradi, 2012].

De acordo com [Gonzalez & Woods, 2010] o processamento digital de imagem define-se por “o conjunto de métodos e técnicas capazes de transformar imagens de forma que estas tornem-se mais adequadas à visão humana ou à análise computacional”. A área de processamento digital de imagens vem evoluindo continuamente ao longo dos anos, com um aumento significativo de estudos envolvendo modelagem matemática, redes neurais, processamento de imagens coloridas, compressão de imagens, reconhecimento de imagens e sistemas de análise de imagens. Esse avanço representa atualmente um ponto de apoio importante em diversas áreas da medicina.

Diante deste cenário, desenvolveu-se no presente trabalho um algoritmo para identificação e detecção de melanomas a partir da obtenção, segmentação e classificação das imagens utilizando redes neurais artificiais.

2. Fundamentação teórica

2.1. Melanoma

O melanoma cutâneo maligno é um tipo de câncer de pele que tem origem nos melanócitos (células produtoras de melanina, substância que determina a cor da pele), e constitui cerca de 3% dos tumores cutâneos malignos, apresentando crescente incidência e alta letalidade. Em 2018, no Brasil, a estimativa foi de 6.260 novos casos, sendo 2.920 homens e 3.340 mulheres [INCA, 2018].

O melanoma pode surgir a partir da pele normal ou de uma lesão pigmentada. A manifestação da doença na pele normal inicia após o aparecimento de uma pinta escura com bordas irregulares acompanhada de coceira e descamação. Em casos de uma lesão pigmentada pré-existente, ocorre aumento no tamanho, alteração na coloração e na forma da lesão, que passa a apresentar bordas irregulares [INCA s.d].

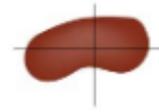
A presença de assimetria da lesão, bordas irregulares e mal definidas, alterações de cor e diâmetro maior que 6 mm, podem ser identificadas por meio de uma técnica chamada ABCD que auxilia no diagnóstico precoce.

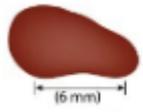
2.1.1 Técnica ABCD

A técnica ABCD é um conjunto de regras visuais proposta em 1994 por Wilhelm Stolz para facilitar o diagnóstico dos três tipos de câncer de pele: carcinoma basocelular, carcinoma espinocelular e melanoma. A metodologia leva em consideração os seguintes critérios para definição de malignidade [Sociedade Brasileira de Dermatologia, S.d].

As características da lesão consideradas pela metodologia fundamentam-se em identificadores como: assimetria (A); irregularidade das bordas (B); variabilidade de cores (C) e estruturas diferenciais (D).

Tabela 1: Diagnóstico de melanoma pela técnica abcd.

 A Assimetria	Assimetria: Lesões malignas possuem grandes probabilidades de serem cancerosas malignas.
 B Borda (bordas irregulares)	Borda irregular: Geralmente lesões malignas possuem contornos irregulares.
 C Cor (tons de preto escuro, várias colorações)	Cor heterogênea: Geralmente os melanomas possuem coloração interna com grande variação das intensidades entre marrom e preta, podendo ter regiões em branco ou azuladas.

 <p data-bbox="470 324 670 414">D Diâmetro (maior que 5 milímetros)</p>	<p data-bbox="821 268 1356 414">Diâmetro maior que 6mm: Frequentemente os melanomas são maiores do que 6 mm de diâmetro, crescem e mudam de forma rapidamente.</p>
--	--

2.2 Processamento digital de imagem

O processamento de imagens tem como principal função facilitar a visualização e o entendimento da imagem a fim de adequá-la para análises quantitativas através de técnicas de correções de defeitos, realces das regiões de interesse nas imagens, extração e tratamento de dados quantitativos realizado pelo computador. [Gomes, 2001]

As etapas para o processamento digital de imagem são apresentadas na Figura 1. O primeiro passo do processo é a aquisição da imagem e sua digitalização em formatos compatíveis. Após, tem-se o pré-processamento da imagem que tem como o objetivo a melhora da imagem para que as próximas etapas sejam bem-sucedidas.

Após o pré-processamento, vem a etapa de segmentação. O papel básico da segmentação é separar a imagem em partes ou objetos de interesse que por muitas vezes não é adequado sendo necessário realizar o estágio de pós-processamento.

A imagem de saída do pós-processamento está pronta para fornecer as imagens para a etapa de extração de atributos, sendo esta a parte quantitativa da sequência. Nesta etapa, algumas características das imagens são extraídas, resultando em um tipo de valor numérico.

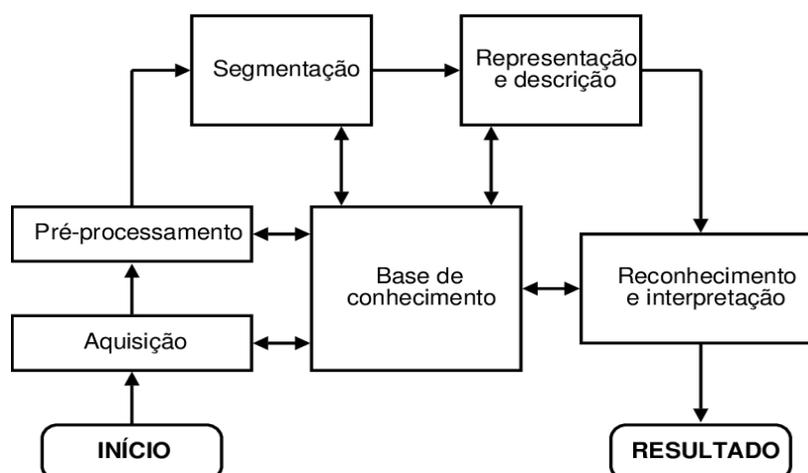


Figura 1: Etapas de um sistema de processamento de imagens digitais [Silva, 2014]

2.2.1 Filtro e segmentação

As imagens obtidas em ambientes não controlados normalmente apresentam ruídos que interferem no seu reconhecimento. Estes ruídos podem ser provocados por sujeira no objeto ou câmera, excesso de brilho ou sombras, e outras interferências na qualidade da imagem. Nesta etapa de filtragem, são aplicados filtros espaciais, baseados em operações de pixels, para remoção destes efeitos indesejados.

Após a filtragem o objeto desejado deve ser separado do fundo. Para tal, é aplicado uma segmentação da imagem, normalmente criando uma máscara binária com valores de 0 e 1, sendo 1 o objeto de destaque e 0 o fundo. Através de uma operação AND desta máscara com a imagem original, o fundo é anulado, ficando em destaque apenas o objeto desejado.

2.2.2 Reconhecimento e interpretação

A execução da etapa do reconhecimento e a interpretação de imagem, pode ser realizada através dos algoritmos de classificação.

[Araújo,2017] define que classificação de imagens é o processo de extração de informações em imagens para reconhecer padrões e objetos homogêneos. Um objeto pode ser definido por padrões como textura, cor, forma, dimensões etc. E o reconhecimento individual destes padrões pode caracterizar um objeto como um todo, ou seja, em uma classe [Gonzalez & Woods, 2010].

De acordo com a literatura os classificadores mais utilizados para o reconhecimento de imagens são: KNN, SVM, Naive Bayes e as Redes Neurais artificiais.

2.2.3 Redes Neurais

As Redes neurais artificiais são técnicas computacionais matemáticas que têm capacidade para solucionar problemas por intermédio de circuitos simples que simulam o funcionamento e o comportamento do cérebro humano [Braga,2007]. Uma das grandes aplicações das redes neurais artificiais é a sua utilização para reconhecimentos de padrões, tendo sido utilizada por [Haffemann, 2014] para a identificação de células cancerígenas.

Uma rede neural é um sistema paralelo e distribuído, formado por unidades de processamento simples, que tem a capacidade para armazenar conhecimento a partir do processo de aprendizado na qual forças de conexão entre neurônios conhecidas como

pesos sinápticos são utilizados para armazenar o conhecimento adquirido e torná-lo disponível para uso [Ortega, 2009].

Assim como uma rede neural biológica, as unidades básicas da RNA são os neurônios e cada um pode ser representado graficamente como na Figura 2.

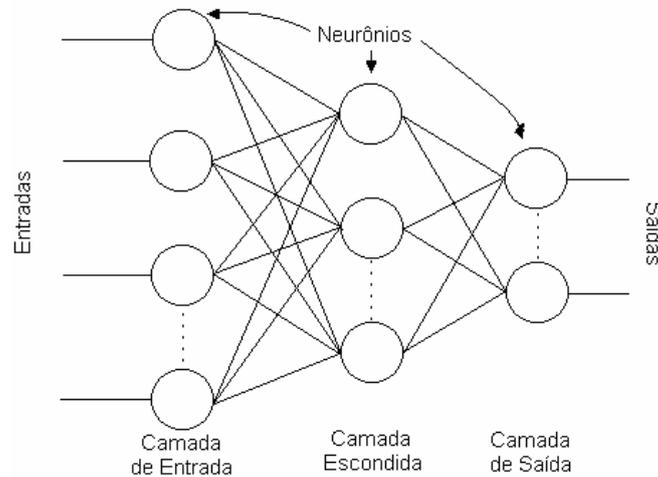


Figura 2: Diagrama de uma rede neural MLP

A utilização de somente um neurônio torna-se limitada a resolução dos problemas, por isso é necessário a combinação em uma estrutura de camadas, sendo cada camada composta por um número diferente de neurônios, formando-se assim uma rede neural denominada *Perceptron* Multicamadas (“*Multi Layer Perceptron — MLP*”). Às MLP são treinadas a partir de um conjunto de entradas e saídas conhecidas, utilizando algoritmo *backpropagation*. Neste treinamento, os pesos (*bias*) intermediários da rede são ajustados para reconhecer um novo padrão de entrada dentro de uma das classes pré-determinadas como saída, sua arquitetura é demonstrada na Figura 3.

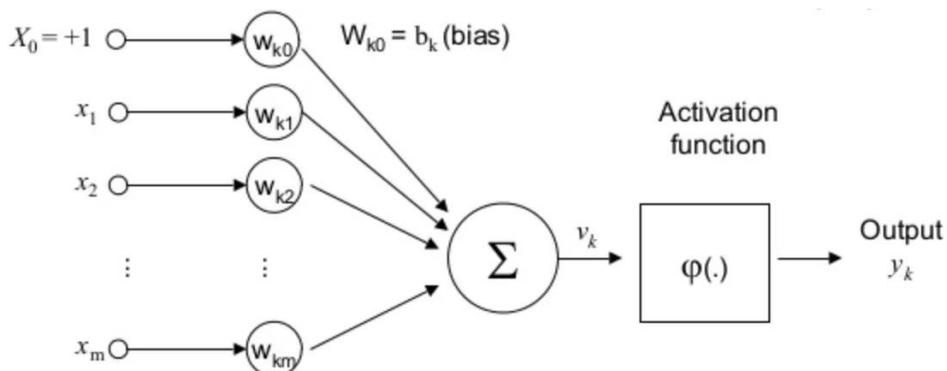


Figura 3: Arquitetura de um MLP [Data Science Academy, 2019]

Nas MLP as funções de ativação exercem um papel importante pois decidem se um neurônio deve ser ativado ou não. Ou seja, se a informação que o neurônio está recebendo é relevante para a informação fornecida ou deve ser ignorada. A função de ativação é a transformação não linear que fazemos ao longo do sinal de entrada. Esta saída transformada é enviada para camada subsequente como entrada. Quando não temos a função de ativação, os pesos e bias simplesmente fazem uma transformação linear [Data Science Academy, 2019].

Na atualidade, com a finalidade de projetar redes neurais existem duas funções de ativação mais utilizadas, a função ReLU e a Sigmóide.

A função ReLU (Figura 4), é definida como $f(x) = \max(0, x)$ em relação a outras funções de ativação, ela tem como vantagem a não ativação de todos os neurônios ao mesmo tempo, pois quando as entradas forem negativas, ela será convertida em zero e o neurônio não será ativado, tornando a rede esparsa, e assim sendo mais eficiente. [Data Science Academy, 2019]

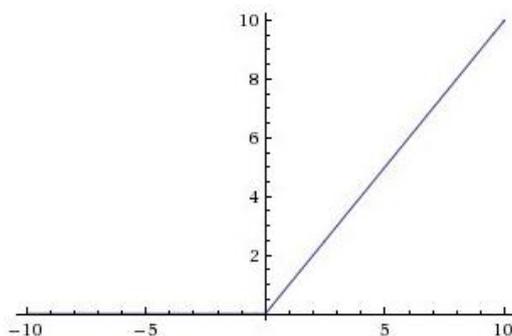


Figura 4: Gráfico da função ReLU

A função Sigmóide, cujo gráfico tem a forma sigmoideal (Figura 5), é definida como uma função estritamente crescente que exibe um balanceamento adequado entre comportamento linear e não linear. Um exemplo de função sigmoide é a função logística definida pela Equação 1.

$$f(x) = \frac{L}{1 + e^{-k(x-x_0)}}$$

Equação 1

Onde:

$x - x_0$ é o parâmetro de inclinação da função Sigmóide, quando o parâmetro de inclinação se aproxima do infinito, a função sigmóide se torna simplesmente uma função

constante. Enquanto a função constante assume o valor de 0 ou 1, uma função Sigmóide assume um intervalo contínuo de valores entre 0 e 1. [Haykin,2001]

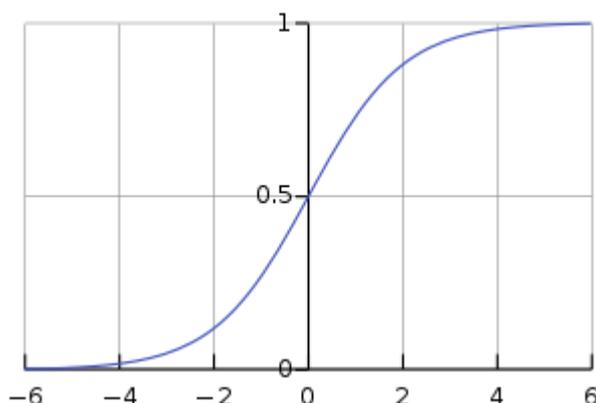


Figura 5: Gráfico da função Sigmóide

Para auxiliar na construção de redes neurais pode ser utilizado bibliotecas que fornecem ferramentas a fim de simplificar o desenvolvimento. Uma das principais bibliotecas utilizadas para a implementação de redes neurais e algoritmos de *deep learning* é o Keras, pois é uma biblioteca totalmente integrada as bibliotecas de *TensorFlow*, facilitando a sua utilização. Ela provê uma estrutura que permite compilar redes neurais combinando camadas de diferentes dimensões e funções de ativação, tornando o ciclo de desenvolvimento de novos modelos de aprendizado de máquina muito mais rápido, simplificada e eficiente. [Chollet,2019]

3. Trabalhos Relacionados

O trabalho desenvolvido por [Botelho, 2007] utiliza redes neurais artificiais para a detecção de câncer de pele. O autor caracteriza as imagens por cor, textura e forma. Como resultado notou-se que, mesmo utilizando uma das técnicas mais simples de caracterização de imagens, ou seja, o histograma em tons de cinza, e um dos primeiros algoritmos de rede neural desenvolvidos, o trabalho teve bons resultados atingindo uma taxa de 69 % de acertos.

O modelo de reconhecimento de câncer de pele do tipo melanoma proposto por [Frutoso, 2016] é executado em duas etapas na qual é realizado a extração de características da imagem, com base na regra ABCD e após isso é executado a classificação das mesmas utilizando três algoritmos diferentes DMC, KNN com taxas de acerto superiores a 70% e Naive Bayes com taxas de acerto superiores 90%.

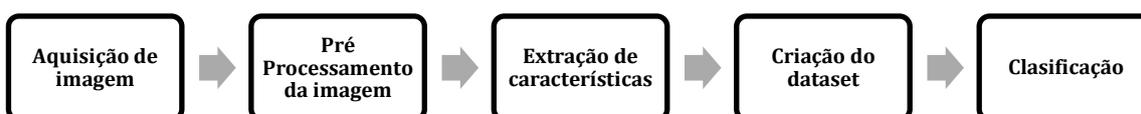
O SKAN – Skin Scanner [Xavier et al. 2017] é uma ferramenta que procura distinguir imagens de câncer de pele de imagens que contenham outros tipos de lesões cutâneas por meio de técnicas adaptativas. Assim como a abordagem anterior a identificação de imagens de melanoma se baseia na regra ABCD. Os resultados foram feitos com uma amostra de 20 imagens e o algoritmo adaptativo se mostrou eficiente,

com precisão de 95% ,em relação ao método não adaptativo nas análises de borda cor e diâmetro tendo como acerto a classificação 18 imagens contra 11 do método não adaptativo.

Nesta seção foi possível acompanhar a evolução cronológica dos métodos, no qual pode-se observar um aumento de eficácia, oriundo de novas metodologias. O diferencial deste trabalho, está sendo a proposta de uma combinação de dados obtidos pelo processamento de imagens (cor, simetria e bordas) e dados históricos clínicos dos pacientes (idade aproximada, tamanho clínico em mm, casos de melanoma na família, espessura do melanoma em mm e sexo).

4. Metodologia

O sistema foi desenvolvido em cinco módulos, conforme demonstrado abaixo.



A linguagem para desenvolvimento utilizada foi a Python, em associação com as bibliotecas OpenCv e PIL.

A OpenCV (Open Source Computer Vision) é uma biblioteca de código aberto inicialmente desenvolvida pela Intel com objetivo de auxiliar a manipulação e análise de imagens e vídeos. Atualmente possui mais de 500 funções com suporte as principais linguagem de programação como C++, Python, Ruby e Java.

O PIL é uma biblioteca para a linguagem de programação Python que adiciona suporte a edição (conversão para tons-de-cinza, rotação, escala, zoom etc.) e gravação de imagens 2D em diferentes formatos (TIFF, GIF, BMP, PICT, JPEG, PNG). [Aclark, 2017]

Na próxima seção será detalhado o funcionamento de cada módulo e suas características.

4.1. Aquisição das imagens

As imagens utilizadas neste trabalho foram obtidas a partir da base de dados da ISIC [ISIC, 2016] que é uma instituição de colaboração internacional acadêmica e industrial com a finalidade de ajudar a reduzir a mortalidade por melanoma. A base de dados contém 23.906 imagens de lesões, sendo essas 19.373 benignas, 2.286 malignas e 2.247 não classificadas. Neste trabalho utilizou-se uma amostragem aleatória de 2000 imagens, sendo 1000 classificadas malignas e 1000 benignas.

Todas as imagens da base de dados são rotuladas tendo atributos como a idade aproximada, sítio anatômico geral, tamanho clínico - diâmetro mais longo (mm) ,tipo de diagnóstico, casos de melanoma na família, classe de melanoma, índice mitótico de

melanoma, espessura do melanoma (mm) tipo de melanoma, tipo de nevo, histórico familiar de melanoma e sexo.

4.2. Pré Processamento

Módulo responsável por carregar as imagens a ser processada e padronizar seu tamanho no formato 300 x 300 e entregar para o módulo de segmentação e filtro de ruídos.

4.2.1 Segmentação e filtro de ruídos

O módulo tem como função a limpeza da imagem a ser processada, retirando assim pelos, pele e ruídos.

4.2.2 Filtro de mediana

O primeiro passo do módulo é a aplicação do filtro de mediana 3x3, sendo este bastante discutido na literatura, pois tem por finalidade suavizar ruído do tipo impulsivo em sinais e imagens digitais.

4.2.3 Binarização da imagem

Esse passo faz com que a imagem colorida seja convertida para tons de cinza e dilatada para que tenha como efeito aumentar partículas, preencher buracos e conectar componentes próximos.

4.2.4 Segmentação da imagem

Neste processo, divide-se a imagem em regiões que correspondem as áreas de interesse da aplicação. Para isso utiliza-se o algoritmo de *thresholding* que tem por objetivo determinar um valor constante de intensidade para cada pixel de imagem. Caso a intensidade do pixel for maior que o valor devido o pixel será convertido na cor branca, caso contrário será convertida na cor preta.

4.3. Extração de características

Esse processo é realizado após a segmentação e é muito importante pois a escolha desses dados é fundamental para se obter bons resultados na etapa de classificação. Esse módulo tem como objetivo a realização de extração de características provenientes das lesões, como análise de cor, textura, simetria e contagem de contornos.

4.3.1 Características de Cor

Nesta parte do módulo através das análises das imagens obtidas pelo histograma de cores RGB, é possível distinguir as lesões malignas das benignas, pois o melanoma tem uma grande variedade de tons de cores e com isso seu histograma apresenta maior distribuição.

O RGB é um sistema de cores em que o Vermelho (Red), o Verde (Green) e o Azul (Blue) são combinados de várias formas com a finalidade de reproduzir um largo espectro cromático. Para isso plotou-se o gráfico Variação de cores *versus* Frequência de

Pixels e calculou-se a média e o desvio padrão de cada cor (vermelho, verde e azul) para a imagem que representa a lesão benigna e a imagem que representa a lesão maligna. A partir destes valores, foram novamente calculados a média das médias e a média dos desvios padrão.

4.3.2 Análise de simetria

Nesta etapa é realizado o cálculo relacionado a assimetria da lesão, para tal foi proposto os seguintes passos:

- A. Converter a imagem colorida para tons de cinza;
- B. Aplicar filtro gaussiano para redução da granulosidade da imagem, com objetivo de não comprometer a etapa de detecção de borda;
- C. Binarizar a imagem para delimitar o limiar da lesão;
- D. A partir da imagem binarizada, são encontrados os contornos da imagem e caso ainda ocorram a existência de pequenos resíduos na imagem, é escolhido o maior contorno encontrado;
- E. Quanto mais a forma do contorno encontrada se parecer com uma elipse, menos deformações existirão nas bordas. Então altos valores desta variável indicam uma deformação da imagem obtida em relação a uma figura geométrica simétrica.

4.3.3 Análise de bordas irregulares

Ela tem como principal característica a contagem de contornos presentes em uma lesão de pele e para sua realização foram propostos os seguintes passos:

- A. A imagem é convertida para tons de cinza;
- B. É aplicado a detecção de borda de *canny*;
- C. É realizado uma contagem das bordas encontradas no passo anterior.

4.5. Criação do *dataset*

Para a criação do *dataset*, serão utilizados os resultados obtidos na etapa anterior (cor, simetria e bordas) em formato CSV juntamente com o histórico das lesões fornecidos pelo *dataset* da ISIC como idade aproximada, tamanho clínico em mm, casos de melanoma na família, espessura do melanoma em mm e sexo, totalizando em 9 atributos.

4.6. Classificação

Neste módulo foi desenvolvido uma rede neural artificial com a utilização dos atributos previsores do *dataset* criado e o *dataset* de atributos classes com as respostas.

Para a construção da rede neural, foram selecionados 75% dos dados para o treinamento da rede e 25% para validação.

Desenvolveu se uma rede neural *feedforward* densa ou totalmente conectada. *Feedforward*, pois os dados fluem em uma única direção, isto é, eles não voltam para camadas anteriores nem retornam para as mesmas camadas. Densa, devido a todos os neurônios de uma camada anterior serem conectados com todas as entradas da camada subsequente.

Tem-se na primeira camada da rede neural as 9 entradas com atributos do *dataset*, na camada oculta contendo 5 neurônios com a função de ativação ReLU e na camada de saída apenas 1 neurônio com função de ativação Sigmóide.

5. Resultados

Nesta seção serão apresentados os resultados obtidos com a utilização da metodologia anterior.

5.1 Pré Processamento

5.1.1 Filtro de mediana

Na figura 6 está apresentada a comparação da imagem após a aplicação do filtro de mediana.



Figura 6: (a) Imagem original; (b) imagem após aplicação do filtro de mediana.

5.1.2 Binarização e segmentação da imagem

Na figura 7 apresenta-se os resultados da aplicação da binarização e segmentação da imagem.

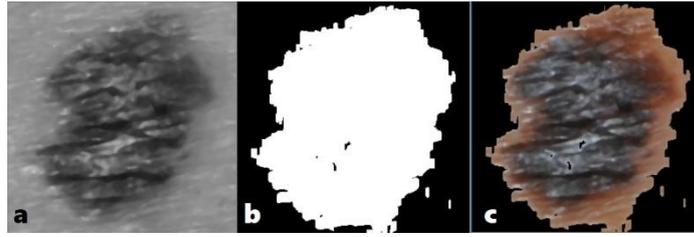


Figura 7: (a) imagem convertida para tons de cinza; (b) binarização da imagem;(c) segmentação da imagem

5.2 Extração de características

5.2.1 Características de Cor

Nesta seção apresenta-se o histograma de uma lesão maligna (Figura 8) e de uma lesão benigna (Figura 9). Os valores da média e do desvio padrão são apresentados no Quadro 1.

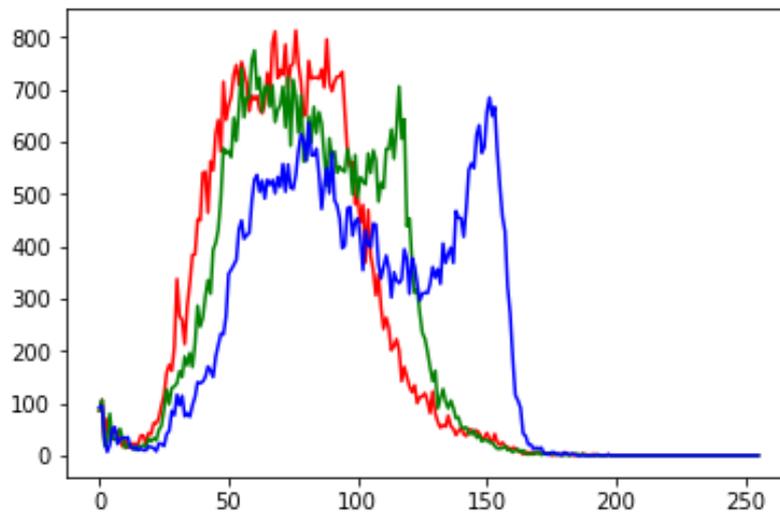


Figura 8: Histograma de uma lesão melanoma média

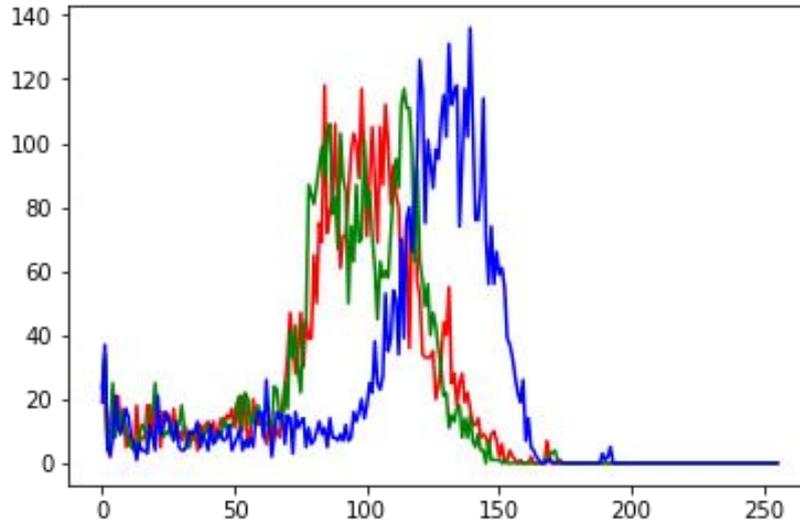


Figura 9:Histograma de uma lesão benigna

Quadro 1

	<i>Média Melanoma</i>	<i>Desvio Melanoma</i>	<i>Média Não Melanoma</i>	<i>Desvio Não Melanoma</i>
<i>RED</i>	214.14	11.05	20.6	16.31
<i>GREEN</i>	214.15	10.90	20.6	15.92
<i>BLUE</i>	214.19	10.41	20.59	14.82
<i>Média Total</i>	214.16	10.78	20.59	15.68

Ao observar o eixo x correspondente a variação de cor, observa-se uma maior distribuição de cores para a lesão maligna, como esperado.

5.2.2 Análise de simetria

Ao se utilizar a relação $simetria = \frac{eixo\ x}{eixo\ y}$ em relação a elipse traçada no exterior como figura 10, obtemos valores de relação entre 0 e 1, onde valores próximos de 0 temos uma lesão simétrica ou seja benigna e valores próximos a 1 uma lesão não simétrica que possivelmente seja um melanoma.

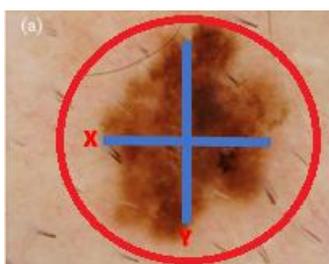


Figura 10: Relação entre o eixo x e y de uma lesão maligna.

5.2.3 Análise de bordas irregulares

Na figura 11 temos o resultado antes e após a aplicação do filtro de detecção de borda de canny de uma lesão maligna e na figura 12 de uma lesão benigna.

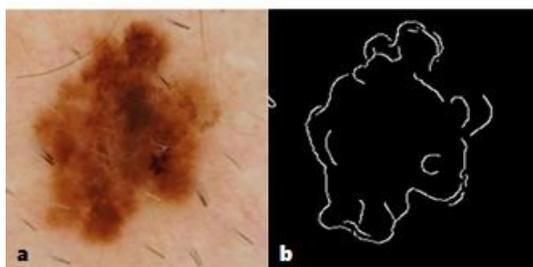


Figura 11: a) Lesão maligna original; b) Lesão maligna utilização do algoritmo de borda de canny.

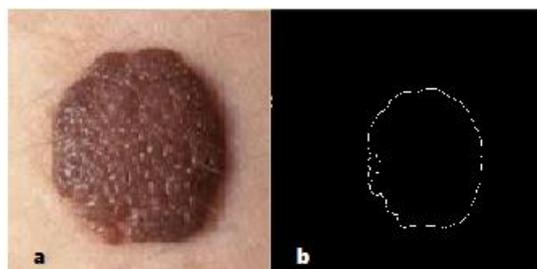


Figura 12: (a) Lesão benigna original; (b) Lesão benigna utilização do algoritmo de borda de canny.

A partir da contagem de bordas das figuras 11 e 12, temos que para lesões benignas a contagem de contornos de uma lesão benigna resulta em valores igual a 1, enquanto em lesões malignas a contagem de contornos é em média superiores a 3.

5.3 Classificação

Na Figura 13 apresenta-se um trecho do código em Python para criação de uma rede neural.

```

classificador = Sequential()
classificador.add(Dense(units = 5, activation = 'relu',
                        kernel_initializer = 'random_uniform', input_dim = 9))
classificador.add(Dense(units = 5, activation = 'relu',
                        kernel_initializer = 'random_uniform'))
classificador.add(Dense(units = 1, activation = 'sigmoid'))

```

Figura 13: Criação da arquitetura da rede neural utilizando Keras.

Os resultados obtidos serão demonstrados na matriz de confusão (Tabela 2) que é uma ferramenta muito utilizada para avaliações de modelos de classificação em aprendizado de máquina.

Tabela 2: Matriz de Confusão

	Melanoma	Não Melanoma	Acurácia
Melanoma	222	28	88,80%
Não Melanoma	40	210	84,00%

A partir do teste foram encontradas as especificações da rede para sua melhor convergência. A rede neural artificial convergiu para um erro médio de 13,6%.

Comparando os resultados dos trabalhos relacionados na Tabela 3, pode-se observar que nossos resultados foram satisfatórios e o valor obtido se manteve dentro da faixa de valores dos resultados relatados na literatura.

Tabela 3: Comparação de resultados

Método Proposto	Precisão
Frutoso 2016 - KNN	Superior a 90%
Xavier 2017 - SKAN – Skin Scanner	95%
Botelho 2007 - Redes neurais artificiais	69%
Método Proposto	86,40%

Apesar das taxas elevadas de acerto obtidas pela rede neural artificial proposta, pode-se sugerir para implementação futura, a inserção de uma camada oculta com a mesma topologia de 5 neurônios utilizando a função de ativação ReLU e a inserção de otimizadores disponível na biblioteca do Keras como ADAM.

6. Conclusão

Neste trabalho foi apresentado um vetor características misto, utilizando dados obtidos da imagem juntamente com dados da anamnese clínica realizado pelo profissional

de saúde. A metodologia apresentada se demonstrou bastante eficaz tendo a taxa de 88,4% de precisão para os dados utilizados.

Este resultado incentiva a analisar outras arquiteturas de redes para classificação, seleção de mais atributos para o padrão ABCD discutido, além de testar classificadores que talvez possam obter melhores resultados.

7. Referências

- ACADEMY, Data Science. Deep Learning Book, 2019. Disponível em: <<http://deeplearningbook.com.br/funcão-de-ativação/>>. Acesso em: 03 maio 2019.
- ACLARK. Pillow 2.2.2. Disponível em: <<https://pypi.org/project/Pillow/2.2.2/>>. Acesso em: 02 dez. 2017.
- ARAÚJO, Agnes Silva de. Classificação de imagens de Sensoriamento Remoto. Londrina: Notas de Aula, 2017. Color.
- BOTELHO, Glenda Michele. Processamento de Imagens no Auxílio à Detecção de Câncer de Pele utilizando Redes Neurais Artificiais. 2007. 66 f. TCC (Graduação) - Curso de Ciência da Computação, Universidade Federal de Goiás, Catalão, 2007. Disponível em: <<https://dcc.catalao.ufg.br/up/498/o/Glenda2007.pdf>>. Acesso em: 29 maio 2019.
- BRAGA, A. P., Carvalho, A. P. L., e Ludermir, T. B. (2007). Redes neurais artificiais: teoria e aplicações. LTC, Livros Técnicos e Científicos.
- CHOLLET, F. Keras. [S.l.]: GitHub, 2015.
- DIMATOS, D. C. MELANOMA CUTÂNEO NO BRASIL, Arquivos Catarinenses de Medicina - Volume 38 - Suplemento 01. 2009.
- FRUTUOSO, Rômulo Lopes et al. Uso de algoritmos de reconhecimento de padrões aplicados ao problema de câncer de pele do tipo melanoma. Anais do 11. Congresso Brasileiro de Inteligência Computacional, [s.l.], v. 1, n. 1, p.1-6, 11 mar. 2016. SBIC. <http://dx.doi.org/10.21528/cbic2013-321>.
- GONZALEZ, Rafael C.; WOODS, Richard E. Processamento de Imagens Digitais. São Paulo: Pearson Education do Brasil, 2010.
- HAYKIN, Simon. Redes Neurais: Princípios e prática. Porto Alegre RS:Bookman, 2001.
- INCA. Câncer de pele melanoma. Disponível em:<<https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-melanoma>>. Acesso em: 16 fev. 2019.
- ISIC Archive, The International Skin Imaging Collaboration: Melanoma Project. 201. Acesso 12 de Maio de 2019. Disponível em: <"<https://isic-archive.com/#>">.
- ORTEGA, Gustavo Victor Chávez; Vellasco, Marley M. B. R. Redes Neurais na Identificação de Perdas Comerciais do Setor Elétrico. Rio de Janeiro, 2008. 184p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.
- SILVA, Bruno Ramon de Almeida e. Sistema de contagem automática de objetos utilizando processamento digital de imagens em dispositivos móveis. 2014. 65 f.

Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Ciência da Computação, Universidade do Estado do Rio Grande do Norte., Mossoró, 2014.