



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Nelia Cantanhede Reis

**Comparativo de técnicas de aprendizado
profundo e processamento de imagens para o
diagnóstico de melanoma**

São Luís - MA

2019

Nelia Cantanhede Reis

**Comparativo de técnicas de aprendizado profundo e
processamento de imagens para o diagnóstico de
melanoma**

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharela em Ciência da Computação.

Orientador: Prof. Dr. Geraldo Braz Júnior

São Luís - MA

2019

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Reis, Nelia Cantanhede.

Comparativo de técnicas de aprendizado profundo e processamento de imagens para o diagnóstico de melanoma / Nelia Cantanhede Reis. - 2020.

47 f.

Orientador(a): Geraldo Braz Junior.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, São Luís, 2020.

1. CNN. 2. Diagnóstico. 3. Melanoma. 4. Processamento de imagens. 5. SimpleNet. I. Braz Junior, Geraldo. II. Título.

Nelia Cantanhede Reis

Comparativo de técnicas de aprendizado profundo e processamento de imagens para o diagnóstico de melanoma

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharela em Ciência da Computação.

Trabalho aprovado em 02 de Janeiro de 2020: São Luís - MA

Prof. Dr. Geraldo Braz Júnior

Orientador

Universidade Federal do Maranhão

Prof. Dr. Anselmo Cardoso de Paiva

Membro da Banca Examinadora

Universidade Federal do Maranhão

Prof.^a Dr.^a Simara Viera da Rocha

Membro da Banca Examinadora

Universidade Federal do Maranhão

São Luís - MA

2019

To everyone who believed in me.

Agradecimentos

Em primeiro lugar agradeço a Deus, pelo dom da vida, em segundo aos meus pais Benedito e Benedita Reis, que sempre me apoiaram com amor, motivação, carinho e tudo que foi necessário para eu chegar até aqui.

As minhas irmãs Nádia e Núbia, que cresceram comigo e sempre estão ao meu lado para o que der e vier, me dando conselhos e me incentivando a crescer cada vez mais.

Ao meu orientador Geraldo Braz Júnior, com quem tive o prazer de conviver desde a época do PETComp, foram muitos ensinamentos durante esses anos. Sempre atencioso, paciente e prestativo, e que sem o qual não teria realizado este trabalho.

Ao professor Anselmo de Paiva, pela confiança, ensinamento e oportunidade, ao me convidar para fazer parte do Núcleo de Computação Aplicada (NCA). Lugar esse onde foi muito importante para meu crescimento acadêmico, pessoal e profissional.

Aos professores João Dallyson, Aristófanés e Simara Rocha, por todo o conhecimento repassado. Em especial a Simara por toda ajuda durante o curso, pelas incontáveis dúvidas tiradas, sempre muito paciente. Um ícone de mulher, que admiro muito.

As minhas amigas que conheci durante o curso Mayara, Giselle, Carol e Celielma, com quem sempre pude contar, compartilhar segredos e emoções, onde só elas entendem o que é ser mulher em curso onde a maior parte é formada por homens, e ter que provar que é capaz a todo instante, tê-las ao meu lado nesses momentos foi de suma importância.

Em especial a Carolzinha, por ser uma grande amiga e sempre me ajudar em toda dificuldade que tive pelo caminho, desde sanar minhas dúvidas, até nas implementações de testes, por acreditar em mim, mais do que eu mesma e me incentivar a escrever, sempre com um sorriso no rosto dizendo que tudo ia dar certo.

Aos meus amigos Lucas Abreu, Anderson Silva, Rodrigo Nascimento, Marcos Vinicius, e Victor Henrique, pelas alegrias compartilhadas, conselhos e papos históricos.

Em especial a Anderson, por sempre se dispôr a me ajudar no que eu precisar, por ouvir meus desabafos, reclamações e lamentações em relação a tudo e sempre tentar me animar. Pela companhia e conversas durante horas no percurso até em casa.

A todos os companheiros que fazem parte da família NCA, onde não existe dúvida que alguém não saiba para ajudar a sanar. Galera sempre prestativa e companheira. Em especial a galera do LabMint, que esteve comigo todo santo dia, produzindo ciência.

A todos que direta e indiretamente contribuíram de alguma forma para conclusão deste trabalho.

*"Part of the journey is the end."
(Tony Stark)*

Resumo

O melanoma maligno é um dos tipos de câncer mais mortais que existe, por isso é de suma importância a detecção e diagnóstico de forma precoce com o intuito de aumentar as chances de sobrevivência do paciente. Assim, existem estudos que têm como o objetivo realizar o diagnóstico dessa doença de forma automática utilizando ferramentas de Inteligência Artificial. Este trabalho tem como objetivo fazer um estudo comparativo entre técnicas de aprendizado profundo e técnicas de processamento de imagens convencional, de maneira que possa indicar quais abordagens conseguem capturar e representar melhor os padrões de melanoma. Para isso, foi utilizado o *Meta Learning* e uma CNN, baseada na arquitetura da *Simple Net* para realizar os testes na base de dados pública da ISIC. Os resultados alcançaram uma acurácia de 91.45% e 87.91% para o *Meta Learning* e a CNN, respectivamente. Assim, podemos concluir que os métodos convencionais de processamento de imagens se bem combinados, podem obter resultados promissores, se comparado com a rede *Simple Net*.

Palavras-chaves: Melanoma, Diagnóstico, Processamento de Imagens, CNN, SimpleNet.

Abstract

The malignant melanoma is one of the deadliest cancers, so early detection and diagnosis is of utmost importance in order to increase the patient's chances of survival and is a major challenge in medical imaging. Thus, there are studies that aim to diagnose this disease automatically using Artificial Intelligence tools. This paper aims to make a comparative study between deep learning techniques and conventional image processing techniques, so that it can indicate which approaches can better capture and represent melanoma patterns. For this, we used Meta Learning and a CNN, based on the architecture of Simple Net to perform the tests on ISIC's public database. The results reached an accuracy of 91.45% and 87.91% for Meta Learning and CNN, respectively. Thus, we can conclude that conventional image processing methods, if well combined, can yield better results compared to the Simple Net network.

Keywords: Melanoma, Diagnosis, Image Processing, CNN, SimpleNet.

Lista de ilustrações

Figura 1 – Imagem de um dermatoscópio.	15
Figura 2 – Camadas da pele	19
Figura 3 – Médico utilizando um dermatoscópio	20
Figura 4 – Exemplo de imagens dermatoscópicas saudável e maligna	21
Figura 5 – Etapas de Aplicações de PDI.	22
Figura 6 – Representação de um neurônio artificial.	23
Figura 7 – Funções de ativação.	24
Figura 8 – Rede MLP com duas camadas ocultas.	25
Figura 9 – Ilustração de uma CNN.	26
Figura 10 – Sequência de etapas da metodologia.	29
Figura 11 – Exemplos de imagens da Base ISIC.	30
Figura 12 – Exemplo de escolha de combinação.	32
Figura 13 – Arquitetura base da SimpleNet.	34

Lista de tabelas

Tabela 1 – Espaço de busca utilizado na otimização da <i>SimpleNet</i>	35
Tabela 2 – Cinco melhores combinações de parâmetros de acordo com a acurácia.	37
Tabela 3 – Parâmetros que foram sugeridos pelo otimizador para cada solução.	38
Tabela 4 – Cinco melhores combinações de parâmetros de acordo com a acurácia.	38
Tabela 5 – Parâmetros que foram sugeridos pelo otimizador para cada solução.	39
Tabela 6 – Comparação de resultados	40

Lista de abreviaturas e siglas

CCV	Color Coherence Vector
CLAHE	Contrast Limited Adaptive Histogram Equalization
CLBP	Compound Local Binary Patterns
CNN	Convolutional Neural Network
CSLBP	Center-Symmetric Local Binary Patterns
DenseNet	Densely Connected Convolutional Networks
GLCM	Gray Level Cooccurrence Matrix
GLDM	Gray Level Dependence Matrix
GLRLM	Gray Level Run Length Matrix
GLSZM	Gray Level Size Zone Matrix
HOG	Histogram of Oriented Gradients
ISIC	International Skin Imaging Collaboration
LBP	Local Binary Patterns
LQP	Local Quinary Patterns
MLP	Perceptron de múltiplas camadas
NGTDM	Neighbouring Gray Tone Difference Matrix
ReLu	Rectified Linear Unit
ResNet	Deep Residual Learning for Image Recognition
TPE	Tree-Structured Parzen Estimator

Sumário

1	INTRODUÇÃO	14
1.1	Objetivos	16
1.1.1	Objetivos específicos	16
1.2	Trabalhos relacionados	16
1.3	Organização do Trabalho	17
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Melanoma	19
2.2	Dermatoscopia	20
2.3	Processamento Digital de Imagens	21
2.4	Redes Neurais Artificiais	23
2.4.1	Redes Neurais Convolucionais	25
2.5	Otimização de Hiperparâmetros	27
3	METODOLOGIA	29
3.1	Aquisição da base de imagens dermatoscópicas	30
3.2	Meta Learning	31
3.2.1	Pré-processamento	31
3.2.2	Decomposição	31
3.2.3	Extração de características	31
3.2.4	Otimização	32
3.3	SimpleNet	33
3.3.1	Pré-processamento	33
3.3.2	Treinamento	33
3.3.3	Otimização da CNN	34
3.4	Métricas para avaliação dos resultados	35
4	RESULTADOS E DISCUSSÃO	37
4.1	Apresentação dos resultados para Meta Learning	37
4.2	Apresentação dos resultados para Simple Net	38
4.3	Comparação de resultados entre os métodos propostos	39
4.4	Comparação de resultados com trabalhos relacionados	40
5	CONCLUSÃO	41

REFERÊNCIAS	42
--------------------------	-----------

1 Introdução

Com o avanço da tecnologia, diversas áreas têm sido beneficiadas na simplificação de soluções para seus problemas. Uma dessas áreas é a área da saúde, destacando as pesquisas relacionadas à detecção do tumor e diagnóstico do câncer. O câncer é caracterizado pelo crescimento desordenado das células, que invadem tecidos e células vizinhas, tornando-se, às vezes, agressivas e incontroláveis (BAILEY; KLEIN; LEEF, 2000).

Dentre os tipos de cânceres, o câncer de pele é o mais comum e sua incidência aumenta cada vez mais, por parte, em um reflexo do comportamento humano à exposição excessiva de sol. O melanoma, mesmo sendo considerado o tipo de câncer de pele mais letal, apresenta índices de cura elevados quando diagnosticado em seu estágio inicial. A doença se manifesta em pele normal a partir do surgimento de uma pinta com tonalidade escura e bordas irregulares, ou de uma lesão pigmentada pré-existente, onde o tumor irá evoluir apresentando mudanças de cores e aumento da área da lesão (SOARES, 2008).

Assim, é de suma importância a detecção e diagnóstico do câncer de pele de maneira automatizada, de maneira a prover mecanismos de triagem e segunda opinião para o especialistas. Tais técnicas podem aumentar as chances de sobrevivência do paciente e eficiência do tratamento visto que podem aumentar a precocidade com que tais manifestações são capturadas.

Além da biópsia, existem alguns exames que servem para detectar e prevenir o câncer de pele. A principal técnica para detectar e prevenir o câncer de pele é a dermatoscopia. Esta técnica é não-invasiva, no qual o dermatologista usa um aparelho chamado dermatoscópio, ilustrado na Figura 1, para fotografar a região da lesão, aumentando-a de 10 a 70 vezes. Com uma fonte de luz não-polarizada, uma lente transparente e um líquido que fica entre a luz e a lente, o aparelho permite a avaliação de cores e microestruturas da epiderme, junção dermo-epidérmica e derme papilar que não são visíveis a olho nu. Portanto, esse exame possibilita averiguar regiões que têm chances de ser um tumor maligno, atuando na prevenção do câncer de pele (JR; ODOM; JAMES, 1994).

Por se tratar de uma imagem, o processamento digital de imagens (PDI) pode oferecer soluções com um grande potencial nas diversas modalidades de imagens médicas. A análise e interpretação computadorizada de imagens médicas são fundamentais no auxílio a um diagnóstico por imagem. Com o advento da inteligência artificial e sistemas inteligentes, o diagnóstico pode ser incorporado na análise informatizada da imagem, além da continuidade da existência do parecer médico (SOARES, 2008).

A aplicação de métodos de inteligência computacional, aliada as técnicas de PDI ajudam médicos e dermatologistas em processos de dados mais rápidos a fornecer

Figura 1 – Imagem de um dermatoscópio.



Fonte – Dermed.

diagnósticos melhores e mais confiáveis. Estudos relacionados à classificação automatizada de imagens de lesões cutâneas apareceram na literatura desde 1987 (CASCINELLI et al., 1987). Após algumas experiências bem-sucedidas em sistemas de diagnóstico automático para diagnóstico de melanoma (SOBER; BURSTEIN, 1994), a utilidade da visão de máquina e da análise computadorizada está se tornando mais importante a cada ano. Inúmeras metodologias para diagnóstico de melanoma foram relatados na literatura, onde diferentes algoritmos de detecção de borda, extração de recursos, seleção e classificação são usados, como podemos citar nos trabalhos de (LOPES; SILVA; BONFIM, 2013) e (OLIVEIRA et al., 2012).

Destaca-se ainda uma área de pesquisa relacionada a Machine Learning, denominada aprendizado profundo que permite implementar um sistema de classificação end-to-end (GOODFELLOW; BENGIO; COURVILLE, 2016), ou seja, máquinas de aprendizagem que têm a capacidade de extrair características de importância dos dados e simultaneamente efetuar a tarefa de classificação com alto nível de precisão.

Dentre as diferentes arquiteturas de redes neurais profundas presentes na literatura, as de maior importância em aplicações de processamento de imagens e visão computacional são as *Convolutional Neural Networks* (CNN), sendo aplicadas ao problema de classificação em melanoma em (SANTOS et al.,), obtendo uma taxa de acerto de 96,4%.

Entendendo a importância do diagnóstico de melanoma em seu estágio inicial, métodos de processamento de imagens e aprendizado profundo estão sendo desenvolvidos com o intuito de melhorar as técnicas de diagnósticos já existentes. Assim, a ideia deste trabalho é fornecer um estudo comparativo entre essas técnicas de maneira que possa mensurar qual consegue de maneira mais eficiente realizar o diagnóstico de melanoma.

1.1 Objetivos

Este trabalho tem como objetivo fazer o estudo comparativo entre técnica de aprendizado profundo e técnicas de processamento de imagens convencionais, para identificar quais são as melhores no auxílio ao diagnóstico de melanoma, envolvendo imagens dermatoscópicas.

1.1.1 Objetivos específicos

- Implementar e avaliar as técnicas de processamento de imagens convencionais via *Meta Learning*;
- Adaptar e aplicar a rede neural convolucional *SimpleNet*, para diagnóstico de melanoma;
- Avaliar a efetividade das técnicas testadas em bases públicas de imagens dermatoscópicas.

1.2 Trabalhos relacionados

Esta seção apresenta trabalhos na literatura que tem como objetivo o diagnóstico de melanoma em imagens dermatoscópicas.

Em (MAJTNER; YILDIRIM-YAYILGAN; HARDEBERG, 2016) foi proposta uma abordagem de reconhecimento de lesões de pele com uma combinação de redes neurais convolucionais e recursos convencionais de classificação. Na abordagem usando recursos convencionais foi combinado os descritores RSurf e Local Binary Patterns (LBP). Na abordagem com CNN foi utilizada a AlexNet pré-treinada para extração de características. Para classificação em ambos os casos foi utilizado o Support Vector Machine (SVM). O resultado obtido na combinação dos métodos, alcançou uma acurácia de 82,60%.

Já Santos et al. (2017) propuseram um método que, faz uso de *Data Augmentation* e *BachNormalization*. Nas imagens foram aplicadas mudanças horizontais e verticais, rotações e translações, correções de cor, brilho e contraste, suavização, ruídos e recorte das regiões de interesse. Em seguida foram treinadas utilizando normalização em lotes, as características são extraídas das camadas totalmente conectadas e serviram para a discriminação das lesões. Já a classificação foi realizada pela sugestão de classificadores implementados na ferramenta WEKA. Com o Support Vector Machine (SVM) essa abordagem alcançou uma acurácia de 89,90%.

Codella et al. (2015) propôs uma abordagem para detecção de melanoma através da combinação de Redes Neurais Convolucionais, sparse coding, e SVM. Um dos benefícios dessa abordagem é que a aprendizagem não supervisionada elimina a necessidade de

identificar boas características. O resultado obtidos com essa técnica chegou a 73,90% para acurácia.

Em outro trabalho [Codella et al. \(2017\)](#) usa técnicas de extração de características como redes neurais convolucionais ([KRIZHEVSKY; SUTSKEVER; HINTON, 2012](#)), redes residuais profundas ([HE et al., 2016](#)), rede U-Net ([RONNEBERGER; FISCHER; BROX, 2015](#)), sparse coding e LBP foram utilizadas junto com máquinas de vetor de suporte. O resultado obtido para acurácia foi 81%.

Em ([NASR-ESFAHANI et al., 2016](#)), foi proposto uma abordagem com técnicas de pré-processamento em imagens dermatoscópicas com ruídos de University Medical Center Groningen ([GIOTIS et al., 2015](#)) e utilizou uma Rede Neural Convolucional pré-treinada. Uma máscara de segmentação k-means é aplicada às imagens que, depois de algumas operações morfológicas, são inseridas na CNN. O resultado obteve uma acurácia de 81,00%.

No trabalho de ([BAKHEET, 2017](#)), são usadas características HOG otimizadas em conjunto com SVM para detecção de melanoma. A imagens passam por uma etapa de segmentação, para se obter a região de interesse, usando operações morfológicas. O treino e teste foi realizado usando o esquema leave-one-out que consiste em separar uma imagem para teste, enquanto que as outras são usadas para treinamento. Esse processo se repete para cada imagem, gerando N iterações, sendo N igual ao tamanho da base. O resultado obtido através de testes na base PH², alcançou uma acurácia de 97,32%.

Como principal contribuição deste trabalho para o meio acadêmico, ressalta-se a análise comparativa entre técnicas de processamento de imagens convencionais e técnica de aprendizado profundo. Contribui também para enriquecimento de estudos sobre classificação de melanoma, envolvendo imagens dermatoscópicas, com a finalidade de auxiliar o especialista no diagnóstico precoce dessa lesão.

1.3 Organização do Trabalho

Este trabalho está organizado em mais 4 capítulos, sendo que o Capítulo 2 apresenta a fundamentação teórica utilizada como base para o desenvolvimento deste trabalho. Este capítulo é dividido em 4 seções, onde a primeira apresenta um breve resumo sobre a pele humana, seguido de informações sobre o câncer de pele. A segunda seção desenvolve sobre dermatoscopia, resumindo como é feito o exame e exemplificando como são as imagens geradas por ele, e como normalmente é feito o diagnóstico de melanomas nessas imagens. Por sua vez, a terceira seção apresenta conceitos básicos de processamento digital de imagens. Por fim, a quarta seção aborda redes neurais artificiais, que inicialmente explica os conceitos gerais, e logo após discorre sobre redes neurais convolucionais.

O Capítulo 3 inicialmente apresenta a base utilizada no desenvolvimento deste

trabalho, e logo após discorre sobre os passos dos métodos propostos. Os resultados obtidos por cada um dos métodos individualmente são apresentados e discutidos no capítulo 4, bem como a comparação de ambos os métodos utilizados. Por fim, o Capítulo 5 conclui este trabalho com as considerações finais.

Neste capítulo foi apresentado sobre o câncer de pele, especificamente sobre o melanoma, sobre PDI e aprendizado profundo no contexto dessa patologia, em seguida os objetivos e também alguns trabalhos relacionados. No próximo capítulo será apresentado a fundamentação teórica com as técnicas computacionais utilizadas neste trabalho.

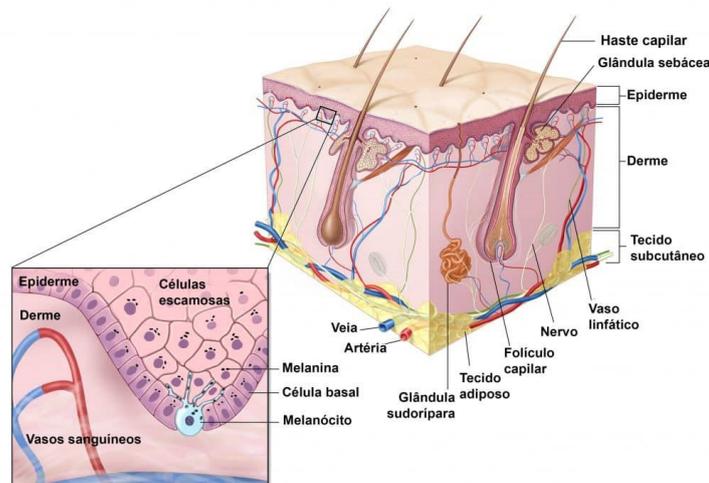
2 Fundamentação teórica

Neste capítulo são discutidos os principais fundamentos do câncer de pele e técnicas computacionais aplicados no trabalho.

2.1 Melanoma

O melanoma é um tipo de câncer de pele e origina-se dos melanócitos, células da pele produtoras de um pigmento denominado melanina, que lhe proporciona proteção contra os danos causados pela radiação ultravioleta (UV). O desenvolvimento do melanoma é consequência da perda dos mecanismos genéticos de controle celular causados principalmente pelas radiações UVA e UVB (REZENDE; CORRÊA; DUARTE, 2009). A estrutura de pele é ilustrada na Figura 2.

Figura 2 – Camadas da pele



Fonte – GBM (2008)

As lesões apresentam aspecto assimétrico, com polimorfismo de estruturas e cores, e formato irregular. As características mais comumente encontradas são: rede pigmentar, pigmentação difusa, despigmentação, glóbulos marrons, pontos pretos, estrias radiadas, pseudópodes e véu azul-acinzentado. Algumas lesões de melanoma cutâneo podem apresentar a rede invertida descrita para os nevos de Spitz, sendo importante no diagnóstico diferencial dessas lesões (REZZE; SÁ; NEVES, 2006).

2.2 Dermatoscopia

A dermatoscopia é um método diagnóstico não invasivo para visualização das estruturas localizadas abaixo do estrato córneo, apresentando como principal indicação o estabelecimento do diagnóstico das lesões pigmentadas da pele, visando ao diagnóstico do melanoma cutâneo nas fases iniciais de evolução e infiltração (REZZE; NEVES, 2018).

A dermatoscopia, quando utilizada como ferramenta de diagnóstico de câncer de pele, tem um ganho significativo na acurácia final. Enquanto os especialistas que utilizam esse exame para realizar o diagnóstico têm uma acurácia de aproximadamente 90%, ao não utilizar, essa porcentagem cai cerca de 10% a 15% (MENZIES et al., 2001). A Figura 3 ilustra a utilização de um dermatoscópio.

Figura 3 – Médico utilizando um dermatoscópio



Fonte – GBM (2008)

No exame, um feixe luminoso é emitido por uma lâmpada halógena que incide, em ângulo de 20 graus, na superfície cutânea, previamente preparada com aplicação de fluido (óleo, água, gel ou glicerina) na interface entre a epiderme e a lâmina de vidro do aparelho. Assim, elimina-se a reflexão da luz, permitindo sua penetração e a visualização das características dermatoscópicas, resultantes principalmente da presença do pigmento melânico nas diferentes camadas da pele (epiderme e derme), hemoglobina dos vasos e fibrose dérmica (REZZE; NEVES, 2018).

A dermatoscopia tem como principal indicação estabelecer o diagnóstico precoce do melanoma e ajudar no diagnóstico diferencial das lesões melanocíticas da pele. Na Figura 4 temos um exemplo de duas imagens geradas por um dermatoscópio, sendo uma benigna e a outra maligna. Através dos critérios definidos por esse método semiológico, é possível classificar as lesões melanocíticas em benignas, malignas ou suspeitas (quando os critérios não são suficientes para malignidade), reduzindo-se o número de biópsias desnecessárias

(FRANGE; ARRUDA; DALDON, 2009).

Figura 4 – Exemplo de imagens dermatoscópicas saudável e maligna

(a) Dermatoscopia de lesão benigna



(b) Dermatoscopia de lesão maligna



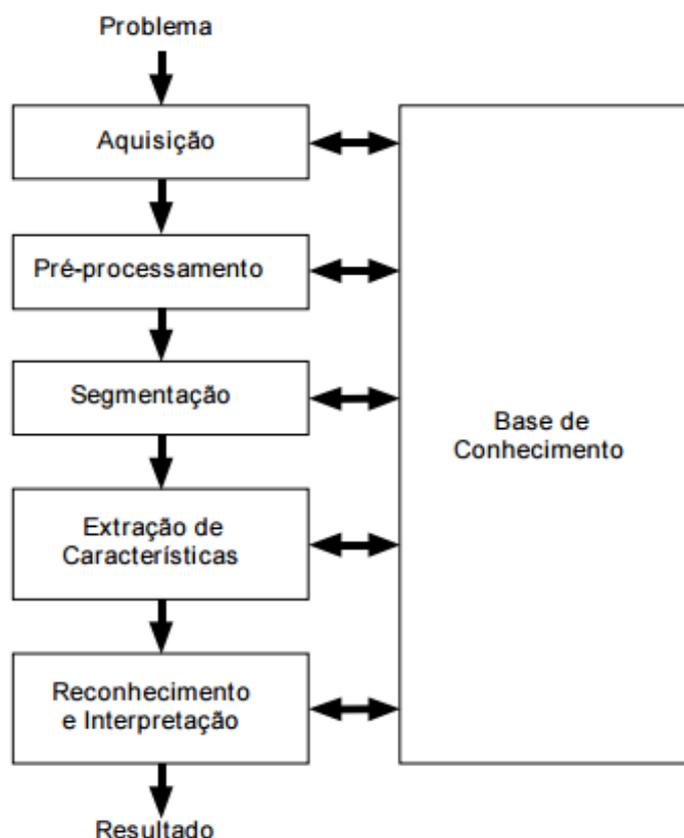
Fonte – Archive (2018)

2.3 Processamento Digital de Imagens

Uma imagem qualquer pode ser compreendida como uma representação visual de um objeto (HOSHIRO; GOLDSCHMIDT, 2008). Ela também pode ser descrita matematicamente como uma função bidimensional $f(x, y)$, onde x e y são coordenadas em R^2 , e a amplitude de f em qualquer par (x, y) de coordenadas representa a intensidade ou nível de cinza da imagem nesse ponto. Se a amplitude de f faz parte de um conjunto de valores finitos e discretos, a imagem é chamada de imagem digital (GONZALEZ; WOODS, 2010). As imagens digitais também são discretizadas espacialmente, onde elas são representadas por uma matriz cujas linhas e colunas identificam pontos da imagem, e seus valores correspondem ao valor de intensidade de *pixel* em cada ponto (FILHO; NETO, 1999).

A área de Processamento Digital de Imagens (PDI) abrange tanto análise de objetos ou características em uma imagem quanto as operações que podem ser realizadas na mesma. Boa parte das aplicações de PDI, como reconhecimento ou segmentação, segue as etapas expostas na Figura 5.

Figura 5 – Etapas de Aplicações de PDI.



Fonte – Filho e Neto (1999)

A primeira etapa trata de aquisição de imagens, onde as imagens que serão processadas pelo método proposto são adquiridas. Para aplicações que visam detectar e diagnosticar melanoma em imagens dermatoscópicas, essas imagens normalmente são adquiridas previamente e armazenadas em uma base de dados.

A segunda etapa é o pré-processamento, onde são aplicadas técnicas de melhoramento de imagens a fim de melhorar os resultados durante a aplicação do método proposto.

Em seguida, normalmente ocorre o processo de segmentação, onde apenas os objetos de interesse para a aplicação são mantidos na imagem, e ela pode ser feita de maneira automática, semi-automática ou manual. Neste trabalho não houve a necessidade de realizar a segmentação das imagens previamente.

Na imagem pré-processada, aplica-se a etapa de extração de características (ou *features*), onde bons descritores dos objetos presentes na imagem são detectados e extraídos, de tal maneira que os mesmos possam ser comparados com outros objetos, podendo discriminá-los em classes. Essas *features* normalmente são modelos matemáticos que descrevem algum comportamento da imagem. Por fim, segue a etapa de reconhecimento e interpretação, onde as características extraídas são interpretadas, e esse resultado é

utilizado pelo resto da aplicação para a tomada de decisões.

2.4 Redes Neurais Artificiais

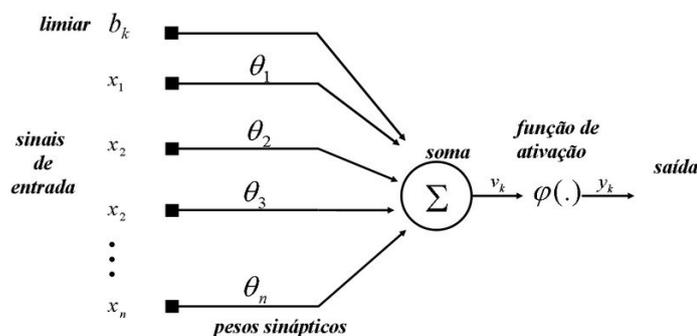
Uma rede neural pode ser definida como um modelo de raciocínio baseado no cérebro humano. O cérebro consiste em um conjunto de células nervosas, ou unidades básicas de processamento de informação, densamente interconectadas chamadas de neurônios. O cérebro humano possui cerca de 10 bilhões de neurônios e 60 trilhões de conexões entre eles, chamadas de sinapses (NEGNEVITSKY, 2005).

Uma rede neural artificial (RNA) consiste em várias unidades de processamento simples e fortemente conectadas chamadas de neurônios, análogos aos neurônios biológicos do cérebro humano. Os neurônios são ligados entre si por conexões ponderadas, e cada um recebe uma quantidade de sinais de entrada através de suas conexões, e produz um único sinal de saída, que pode ser propagado para vários outros neurônios (NEGNEVITSKY, 2005).

Cada conexão entre neurônios possui um peso numérico associado a ela, que são a maneira básica de representar memória de longo prazo em redes neurais artificiais. Esses pesos representam a importância da entrada de cada neurônio, e uma rede é capaz de aprender através de vários ajustes desses pesos (NEGNEVITSKY, 2005).

Um neurônio recebe vários sinais de entrada através de suas conexões, e propaga pelas suas ligações de saída um nível de ativação calculado através do uso de uma função de ativação aplicada em um somatório ponderado dos sinais que ele recebeu de entrada. Os sinais de entrada podem ser dados puros, ou sinais de saída de outros neurônios, e o sinal de saída desse neurônio pode ser ou uma das entradas de outros neurônios ou a própria solução final de um dado problema (NEGNEVITSKY, 2005). Um exemplo de neurônio artificial é ilustrado na Figura 6.

Figura 6 – Representação de um neurônio artificial.



Fonte – Furtado, Velho e Macau (2011)

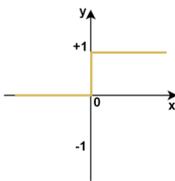
Existem várias possíveis funções de ativação, porém apenas algumas possuem aplicações práticas (NEGNEVITSKY, 2005). As 4 opções mais comuns são apresentadas nas Equações 2.1 e 2.2, e seus respectivos gráficos são ilustrados na Figura 7.

$$Y^{Degrau} = \begin{cases} 1 & \text{se } X \geq 0 \\ 0 & \text{se } X < 0 \end{cases} \quad Y^{Sinal} = \begin{cases} +1 & \text{se } X \geq 0 \\ -1 & \text{se } X < 0 \end{cases} \quad (2.1)$$

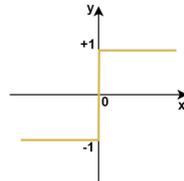
$$Y^{Sigmoide} = \frac{1}{1 + e^{-x}} \quad Y^{Linear} = X \quad (2.2)$$

Figura 7 – Funções de ativação.

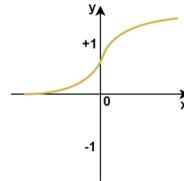
(a) Função Degrau.



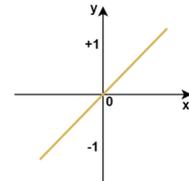
(b) Função Sinal.



(c) Função Sigmoide.



(d) Função Linear.

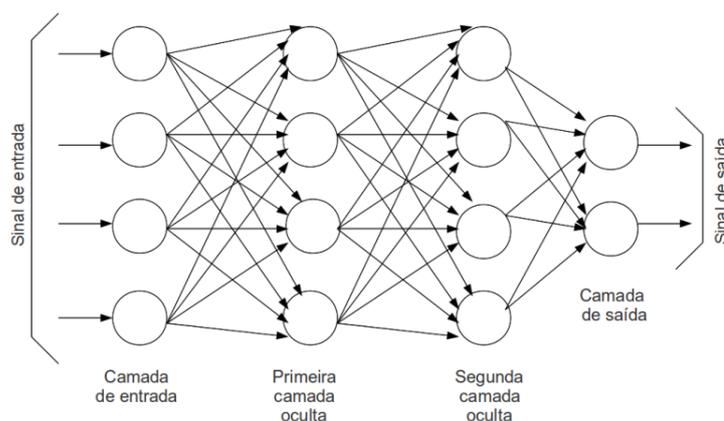


Fonte – Adaptado de Negnevitsky (2005)

A função sigmoide transforma qualquer valor de entrada em um valor no intervalo entre 0 e 1. Neurônios com essa função de ativação são utilizados em redes do tipo *back-propagation*. Uma rede neural artificial com um único neurônio toma decisões da mesma maneira, independente da função de ativação utilizada, de tal maneira que ela só é capaz de classificar apenas padrões linearmente separáveis (SHYNK, 1990).

Para tratar esse tipo de problema, utilizam-se redes neurais multicamadas, como as redes *Multilayer Perceptron* (MLP) treinadas com o algoritmo de *back-propagation*. A MLP é uma rede que possui uma camada de neurônios de entrada, uma ou mais camadas de neurônios intermediárias chamadas de camadas escondidas ou ocultas, e uma camada de neurônios de saída. Os sinais são sempre propagados de uma camada para a sua próxima.

Figura 8 – Rede MLP com duas camadas ocultas.



Fonte – Volpi (2015)

O método mais popular para tornar as redes MLP capazes de aprender é o *back-propagation*, proposto por (BRYSON, 1975). Esse algoritmo de aprendizagem possui duas etapas. Na primeira, um conjunto de padrões de treino é apresentado para a camada de entrada da rede, e os propaga de camada em camada até um padrão de saída ser gerado pela última camada. Se essa saída for diferente da esperada, um erro é calculado e então é propagado na direção contrária, até alcançar a camada de entrada. Os pesos da rede são reajustados a medida que esse erro é propagado. Assim como em qualquer outra RNA, uma que utiliza o algoritmo de *back-propagation* é determinada pela conectividade entre os neurônios (a arquitetura da rede), a função de ativação utilizada e o procedimento para o ajuste dos pesos (NEGNEVITSKY, 2005).

2.4.1 Redes Neurais Convolucionais

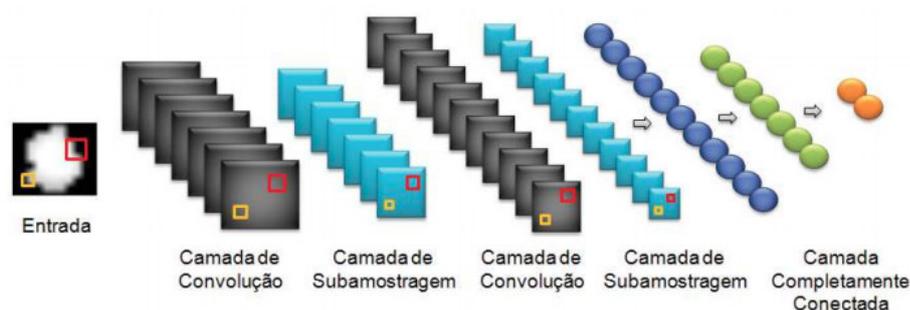
Os humanos e os animais tendem a interpretar e entender conceitos mais simples primeiro, para eventualmente aprenderem abstrações de mais alto nível, baseando-se nos conceitos previamente observados. Esse processo de aprendizagem que sugere uma divisão em camadas hierárquicas com diferentes responsabilidades no cérebro é chamada de aprendizagem profunda (FERNANDES, 2013).

Os métodos de aprendizagem profunda são técnicas de aprendizagem com múltiplos níveis de representação, compostos por modelos não-lineares simples que transformam a representação do nível da própria entrada para um nível de abstração mais alto (LECUN; BENGIO; HINTON, 2015). Esses métodos são capazes de automaticamente descobrir características a partir de um conjunto de imagens sem a necessidade de um *pipeline* complexo de etapas de processamento de imagens e reconhecimento de padrões (HUA et al., 2015).

As redes neurais convolucionais (CNN, do inglês *Convolutional Neural Networks*)

são modelos de aprendizagem profunda biologicamente inspirados que buscam reproduzir os mecanismos de percepção visual com o objetivo de aprender os padrões locais e espaciais de objetos de interesse (HUA et al., 2015). Uma CNN é tipicamente composta de várias camadas de convoluções e subamostragem (que são responsáveis pelo processo implícito de extração de características), seguidas por uma rede MLP completamente conectada (responsável pela classificação dos padrões de entrada).

Figura 9 – Ilustração de uma CNN.



Fonte – Silva et al. (2017)

As características extraídas em cada camada são combinadas através de seus campos receptivos locais, que conectam uma camada com sua anterior. Isso permite que características de mais alto nível sejam extraídas a partir das características combinadas da camada anterior, como bordas ou cantos (FERNANDES, 2013).

Uma camada de convolução é composta por filtros treináveis que são aplicados individualmente em toda a extensão da imagem de entrada, gerando vários mapas de características (LECUN; KAVUKCUOGLU; FARABET, 2010). Cada filtro será responsável pela detecção de uma característica que ocorre em qualquer parte da imagem após a rede ser treinada (SILVA et al., 2017). A Equação 2.3 mostra uma definição do cálculo do mapa de características, onde: k é o índice do neurônio; h_k é o mapa de características com saída k ; w_k é o filtro treinável k ; x é o mapa de características de entrada do neurônio; b_k é o valor de *bias* k ; e o operador $*$ representa o processo de convolução espacial bi-dimensional (LECUN; KAVUKCUOGLU; FARABET, 2010).

$$(h_k)_{ij} = (w_k * x)_{ij} + b_k \quad (2.3)$$

Uma convolução espacial é a aplicação de uma janela $N \times M$ (onde normalmente $N = M$) em uma imagem, de tal maneira que essa janela percorre a imagem inteira, sempre sobrepondo uma região da imagem. Essa aplicação gera uma nova imagem onde

cada valor de *pixel* Z_{ij} é calculado pela Equação 2.4:

$$(Z)_{ij} = \sum_{k=1}^{N \cdot M} Z_k W_k \quad (2.4)$$

onde W_k são os valores da janela de convolução, e Z_k são os valores de *pixel* da imagem original que estão sendo sobrepostos por W_k . A janela percorrerá a imagem original, desde o seu canto superior esquerdo até seu canto inferior direito (FILHO; NETO, 1999).

As camadas de subamostragem são responsáveis por reduzir a resolução espacial dos mapas de características e selecionar as características invariantes a translações e distorções (LECUN et al., 1998). Um dos tipos de subamostragem mais comuns é a ativação máxima (*Max Pooling*), onde apenas o *pixel* de maior intensidade do campo receptivo anterior é mantido.

Por fim, as características extraídas pelas camadas de convolução e subamostragem (os *pixels* de todos os mapas de características da camada anterior) são apresentadas a rede MLP completamente conectada, que é responsável por classificar os padrões de entrada (FERNANDES, 2013).

2.5 Otimização de Hiperparâmetros

Otimização de hiperparâmetros é uma técnica que visa otimizar o resultado de uma função combinando um conjunto de variáveis e valores pré-definidos, o qual é chamado de espaço de configurações (BERGSTRA et al., 2011). Esses espaços de configurações podem ser estruturados de várias formas. Uma das formas é a estrutura em árvore, onde algumas variáveis podem ser definidas como folhas, enquanto outras podem ser definidas como nós. Um algoritmo de otimização de hiperparâmetros deve otimizar, não somente valores de variáveis (sendo discretas, ordinais ou contínuas), mas também deve selecionar quais variáveis irão ser otimizadas. De acordo com Bergstra, Yamins e Cox (2012), muitos algoritmos de visão computacional dependem de hiperparâmetros, como por exemplo, a quantidade de filtros, níveis de quantização e taxa de aprendizagem. Essas escolhas podem influenciar diretamente no desempenho do sistema.

O Tree-Structured Parzen Estimator (TPE) (BERGSTRA; YAMINS; COX, 2013b) é um algoritmo de otimização de hiperparâmetro que atua substituindo nós escolhidos seguindo o modelo de Processos Gaussianos (GP) (WILLIAMS; RASMUSSEN, 2006). A partir de um conjunto de valores e variáveis a serem experimentados, em cada iteração, o TPE aplica uma função do modelo GP ($l(x)$) ao conjunto dos menores valores já obtidos em iterações anteriores, ou seja, os melhores encontrados até o momento. Além disso, outro GP ($g(x)$) é aplicado aos demais valores do conjunto. Por fim, o TPE escolhe o valor x que maximiza o resultado da operação $l(x)/g(x)$. A condição de parada é quando o TPE atingir

o número máximo de iterações ou quando não houver mais variações em seus resultados. Sendo assim, a utilização do TPE para o problema de otimização de hiperparâmetros faz com que se consiga experimentar várias combinações de valores e variáveis de algoritmos.

Neste trabalho o TPE foi utilizado no *Meta Learning* e na *SimpleNet* afim de saber quais as combinações de técnicas e parâmetros iriam fornecer os melhores resultados.

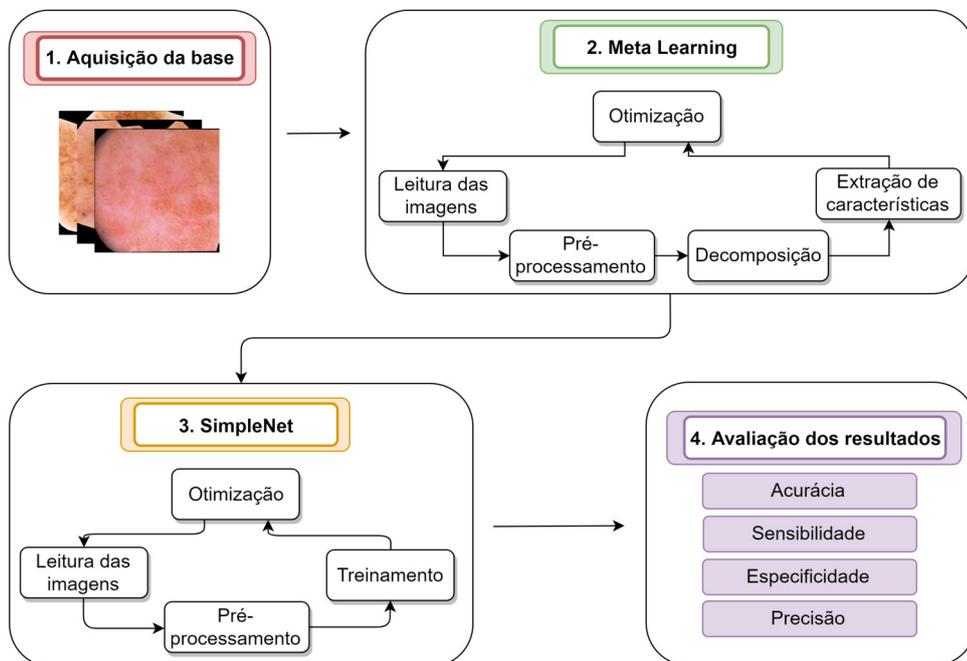
Neste capítulo foi apresentado as principais técnicas computacionais utilizadas neste trabalho como PDI e redes neurais. No próximo capítulo será apresentada a metodologia com as etapas adotadas para efetuar o estudo proposto.

3 Metodologia

Métodos de processamento de imagens e aprendizado profundo estão sendo desenvolvidos com o intuito de melhorar as técnicas de diagnóstico de melanoma já existentes. Assim, a ideia é fornecer um estudo comparativo entre essas técnicas de maneira que possa mensurar qual consegue de maneira mais eficiente realizar o diagnóstico de melanoma.

Neste capítulo é apresentada a sequência de etapas adotadas para efetuar o estudo proposto com o objetivo de diagnóstico de melanoma, como ilustrado na Figura 10. A primeira etapa consiste na aquisição da base de imagens dermatoscópicas. A segunda etapa consiste na apresentação do *Meta Learning*, que irá representar as técnicas de processamento de imagens convencionais, essa etapa é dividida em quatro partes pré-processamento, decomposição, extração de características e otimização. Já terceira etapa apresenta a *SimpleNet*, representando o aprendizado profundo, ela é dividida em três partes pré-processamento, treinamento e otimização. Por fim, na etapa quatro são apresentadas as métricas utilizadas para a avaliação dos resultados.

Figura 10 – Sequência de etapas da metodologia.



Fonte – Acervo da autora

3.1 Aquisição da base de imagens dermatoscópicas

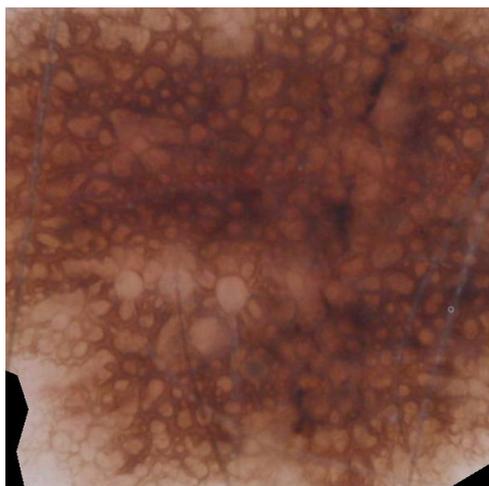
A base utilizada na metodologia é composta por um conjunto de imagens dermatoscópicas retiradas de um repositório público, o ISIC-Archive. Essa base pertence ao *International Skin Imaging Collaboration: Melanoma Project* (ISIC), que é uma parceria da academia e da indústria criada para facilitar a aplicação de imagens digitais de pele para ajudar a reduzir a mortalidade por melanoma.

Atualmente, a falta de padrões para imagens dermatológicas prejudica a qualidade e a utilidade das imagens da lesão da pele. O projeto ISIC está desenvolvendo padrões propostos para abordar as tecnologias, técnicas e terminologia usadas na geração de imagens da pele, com atenção especial às questões de privacidade e interoperabilidade (ou seja, a capacidade de compartilhar imagens entre plataformas tecnológicas e clínicas). Além disso, o ISIC desenvolveu e está expandindo um repositório de acesso público de fonte aberta (*ISIC Archive*) de imagens de pele para testar e validar os padrões propostos. Este arquivo serve como um recurso público de imagens para o ensino e para o desenvolvimento e teste de sistemas de diagnóstico automatizados (PROJECT, 2018).

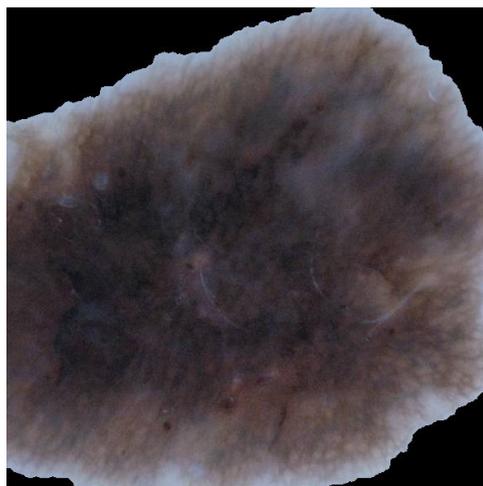
A base de dados utilizada contém 4018 imagens dermatoscópicas, e são separadas em duas classes, *Normal* e *Melanoma*. Sendo 2934 imagens normais e 1084 imagens com melanoma. A Figura 11 apresenta uma imagem de um indivíduo da classe normal (Figura 11a) e de um paciente da classe melanoma (Figura 11b).

Figura 11 – Exemplos de imagens da Base ISIC.

(a) Normal



(b) Melanoma



Fonte – Archive (2018)

3.2 Meta Learning

Este método, propõe a utilização da Otimização Bayesiana para estimar uma combinação ótima de técnicas em cada um dos estágios de processamento que precede o diagnóstico. Foi inicialmente desenvolvida por [Fernandes et al. \(2019\)](#) para diagnóstico de glaucoma. Neste trabalho, a técnica foi aplicada ao diagnóstico de melanoma, utilizando imagens dermatoscópicas. Ele foi escolhido por já conter uma gama de técnicas implementadas de processamento de imagens convencionais o que tornaria o processo de escolha das melhores combinações de técnicas mais abrangentes possível, evitando assim, realizar testes individuais. As técnicas disponíveis no método para cada uma das etapas de processamento são descritas a seguir.

3.2.1 Pré-processamento

As opções disponibilizadas para o pré-processamento eram realce logarítmico, equalização, realce negativo, HOG ([FREEMAN; ROTH, 1994](#)) e CLAHE ([PIZER et al., 1987](#)), dentre essas técnicas três eram possíveis serem aplicadas em conjunto.

3.2.2 Decomposição

As opções de decomposição contidas no método eram: decomposição da imagem em regiões de retângulos, círculos, anéis, grade X, grade W e decomposição Wavelet ([MEYER, 1989](#)). Em todas elas, a quantidade de retângulos ou círculos e ainda o nível de decomposição são parâmetros decididos automaticamente durante a otimização. Também fazem parte LBP ([OJALA; PIETIKÄINEN; HARWOOD, 1996](#)), LQP ([NANNI; LUMINI; BRAHNAM, 2010](#)), CLBP ([AHMED et al., 2011](#)), CSLBP ([HEIKKILÄ; PIETIKÄINEN; SCHMID, 2009](#)).

3.2.3 Extração de características

As técnicas de extração de características disponíveis são: Índices de Diversidade ([MAGURRAN, 2004](#)), que são conceitos utilizados em ecologia como maneira de mensurar a distribuição de diferentes espécies em determinada comunidade; Índices de Diversidade Filogenéticos, que são uma variação dos Índices de Diversidade, GLCM ([HARALICK; SHANMUGAM, 1973](#)), GLRLM ([TUSTISON; GEE, 2008](#)), GLSZM ([THIBAUT et al., 2013](#)), NGTDM ([AMADASUN; KING, 1989](#)) e GLDM ([SUN; WEE, 1983](#)).

Outra forma de extração disponível era *Deep Features*, esse processo consiste na retirada da última camada da rede, onde obtém-se a saída da camada de pooling, logo após a última camada de convolução. As arquiteturas que fizeram parte do método são: VGG-16/VGG-19 ([SIMONYAN; ZISSERMAN, 2014](#)), ResNet 50 ([HE et al., 2016](#)), DenseNet 121, 169 e 201 ([HUANG et al., 2017](#)) que, entre outras, representam as soluções mais modernas

para reconhecimento de imagens (bem como classificação de vídeo, processamento de linguagem natural, descoberta de medicamentos e modelar jogadores artificiais em jogos (AREL et al., 2010)).

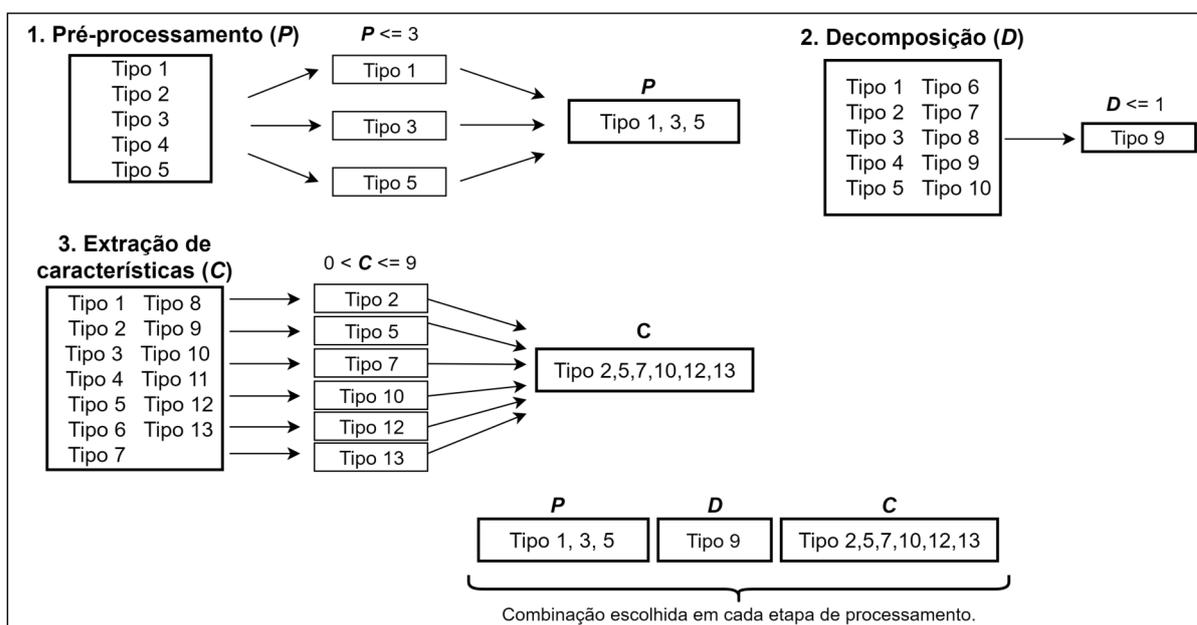
3.2.4 Otimização

A etapa de otimização analisa os resultados de classificações anteriores e sugere novos parâmetros para outro teste.

Os parâmetros dentre os quais o algoritmo de otimização pôde escolher foram definidos em um espaço de busca equivalente ao domínio da função que desejou-se aprimorar.

Esse espaço foi construído em três possibilidades para pré-processamento; uma possibilidade para decomposição; nove possibilidades de extratores de características. Dentre todas as possibilidades citadas anteriormente, existia a chance da escolha nula, exceto para o extrator de característica, onde no mínimo um deveria ser escolhido. A figura 12 ilustra um exemplo de escolha de combinação dentro do espaço de busca.

Figura 12 – Exemplo de escolha de combinação.



Fonte – Acervo da autora

Para avaliar o fitness de cada combinação escolhida durante a otimização, foram utilizados os classificadores Regressão Logística (YU; HUANG; LIN, 2011), Random Forest (BREIMAN, 2001) e XGBoost (CHEN; GUESTIN, 2016). Estes foram escolhidos por se comportarem bem com parâmetros padrão. A escolha é feita automaticamente durante a etapa de otimização.

O algoritmo utilizado para otimização foi TPE (BERGSTRA; YAMINS; COX, 2013a), disponibilizado pela biblioteca HyperOpt. Segundo Fernandes et al. (2019), ele utiliza de decisões bayesianas para escolha de parâmetros, tendo como principal característica, a convergência mais rápida para a solução ótima se comparado com a decisão aleatória ou em grid.

3.3 SimpleNet

A técnica de aprendizado profundo escolhido para realizar a comparação com Meta, foi a rede *SimpleNet* que foi proposta inicialmente por Hasanpour et al. (2016).

A escolha dessa rede foi por ainda não ter sido utilizada em imagens dermatoscópicas, e também por ter uma arquitetura simples, razoavelmente profunda e oferece uma boa troca entre a eficiência da computação, memória e precisão. Mesmo tendo essa arquitetura, a *SimpleNet* superou a maioria das arquiteturas mais profundas e complexas até o momento, como VGGNet, ResNet e GoogleNet em vários *benchmarks* conhecidos, com um número de 2 a 25 vezes menos parâmetros e operações (HASANPOUR et al., 2016).

A seguir será explicado o pré-processamento utilizado nas imagens e o treinamento da rede.

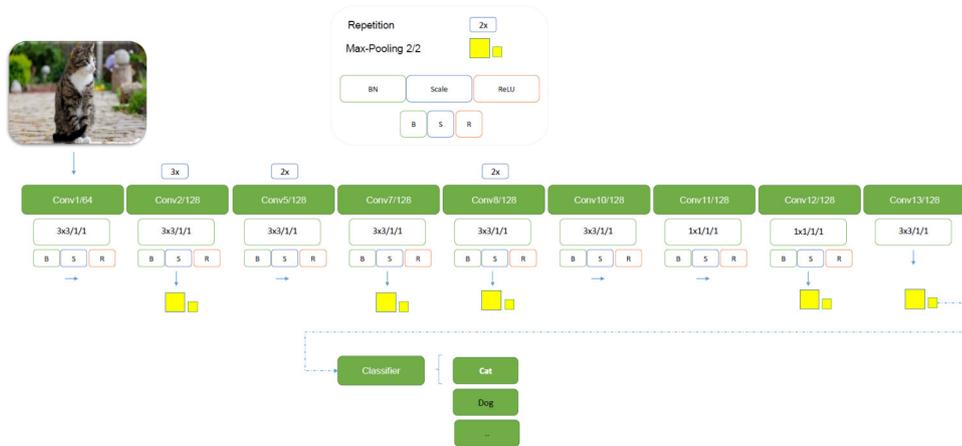
3.3.1 Pré-processamento

Nesta etapa do método proposto, as imagens são tratadas de tal maneira que o desempenho da etapa de treinamento seja melhorado. Duas técnicas de pré-processamento foram avaliadas Realce Logarítmico e negativo, como objetivo evidenciar as características da região de interesse.

3.3.2 Treinamento

Esta rede foi treinada especificamente para realizar o diagnóstico de melanoma em imagens dermatoscópicas. Essa CNN possui 13 camadas, utiliza *kernels* 3x3 para a camada convolucional e *kernels* 2x2 para operações de *pooling*. A Figura 13 ilustra a arquitetura da CNN utilizada.

Figura 13 – Arquitetura base da SimpleNet.



Fonte – Hasanpour et al. (2016)

As únicas camadas que não usam *kernels* 3x3 são as 11^a e 12^a camadas; essas camadas utilizam *kernels* 1x1. A amostragem do mapa de características é realizada usando o *max pooling* 2x2 não sobreposto. Para lidar com o problema do gradiente de fuga e também do ajuste excessivo, ela utiliza normalização de *batch* com fração média de 0,95 antes da função de ativação, e também a redução de peso como regularizador (HASANPOUR et al., 2016). A versão testada utiliza *dropout* para lidar com o excesso de ajuste. Essas características originais da rede foram mantidas durante o processo de otimização.

3.3.3 Otimização da CNN

A otimização da rede foi realizada com o mesmo algoritmo utilizado pelo *Meta learning*, mencionado anteriormente, o TPE, disponibilizado pela biblioteca *HyperOpt*. O espaço de busca foi construído em uma possibilidade para o otimizador e cinco possibilidades para função de ativação a Tabela 1 apresenta os otimizadores e funções de ativação que fizeram parte desse espaço.

As funções de ativações foram aplicadas nas cinco primeiras camadas da rede e em seguida se repetiam nas próximas cinco, seguindo esse fluxo até o total das 13 camadas. Os filtros foram otimizados seguindo a lógica, em que é definido o grau n de saída dos mapas de características advindas das camadas de convoluções. Onde a dimensionalidade do espaço de saída era dois elevado a n mais uma constante. A constante foi utilizada com o intuito de manter o padrão da rede. Essa lógica é descrita pela equação 3.1.

$$F = 2^{n+C} \quad (3.1)$$

onde n é escolhido em um espaço de busca que vai de 2 até 7 e, C varia de 0 até 2 de acordo com a implementação.

Tabela 1 – Espaço de busca utilizado na otimização da *SimpleNet*.

Otimizadores	Funções de ativação
Adam	Relu
Adamax	Selu
Adadelta	Softplus
Nadam	Tanh, Sigmoid

3.4 Métricas para avaliação dos resultados

Para avaliar os resultados propostos pelos métodos utilizados neste trabalho foram usadas métricas de avaliação que são comuns na literatura para classificação de imagens. São elas: Acurácia, Sensibilidade, Especificidade e Precisão.

A acurácia é definida como a razão entre o número de casos na amostra em estudo que foram classificados corretamente (VP e VN) e o número total de casos na amostra em estudo, como mostra a Equação 3.2.

$$Acurácia = \frac{VP + VN}{VN + FP + VP + FN} \quad (3.2)$$

A sensibilidade é a razão de VP, onde fica evidente a capacidade do modelo em prever corretamente as imagens classificadas como melanoma, pelo total de imagens com melanomas presente no estudo, como mostra a Equação 3.3.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (3.3)$$

Especificidade é a proporção de VN, onde o número de imagens foram classificadas corretamente como normal, pelo total de imagens normais, como mostra a Equação 3.4

$$Especificidade = \frac{VN}{VN + FP} \quad (3.4)$$

A precisão indica o quão bom o teste foi para identificar padrões malignos, quanto mais próximo de 100% melhor. Ela pode ser calculada de acordo com a equação 3.5

$$Precisão = \frac{VP}{VP + FP} \quad (3.5)$$

Sendo Verdadeiro Positivo (VP), o número de amostras positivas classificadas corretamente e Verdadeiro Negativo (VN), o número de amostras negativas classificadas

corretamente ambos do total de amostras; Falso Positivo (FP) é quando uma amostra é classificada de forma positiva, mas é negativa. Falso Negativo (FN), ocorre quando a mostra é negativa, mas foi classificada erroneamente.

Neste capítulo foi apresentado a metodologia proposta através do *Meta Learning* e *SimpleNet*, e suas otimizações, em seguida as métricas que foram utilizadas para avaliar os resultados. No próximo capítulo será apresentado os resultados obtidos durante os testes.

4 Resultados e discussão

Neste capítulo, são apresentados e discutidos os resultados obtidos nos testes efetuados dos métodos propostos para o diagnóstico de melanoma, em seguida é realizado um comparativo entre as técnicas utilizadas e também com alguns trabalhos relacionados da literatura.

4.1 Apresentação dos resultados para Meta Learning

A base de dados utilizada da ISIC, conforme descrita na Seção 3, contém 4018 imagens dermatoscópicas, sendo 1084 imagens com melanoma e 2934 imagens normais. Para avaliar este método proposto, a base de dados foi dividida aleatoriamente em dois conjuntos: treino e teste. O conjunto de treino contém 2813 imagens, e o conjunto de teste contém 1205 imagens dermatoscópicas. Foram realizados 70 testes com o HyperOpt, executados por aproximadamente 4 semanas. A Tabela 2 apresenta as cinco melhores soluções geradas, e a Tabela 3 os parâmetros que foram sugeridos pelo otimizador para cada solução.

Tabela 2 – Cinco melhores combinações de parâmetros de acordo com a acurácia.

Soluções	Acurácia	Sensibilidade	Especificidade	Precisão
Solução 1	91,45%	85,66%	93,49%	82,26%
Solução 2	91,21%	85,03%	93,38%	81,90%
Solução 3	91,37%	88,53%	92,37%	80,34%
Solução 4	91,12%	86,62%	92,71%	80,71%
Solução 5	91,04%	88,53%	91,92%	79,42%

A melhor configuração de parâmetros obteve acurácia de 91,45%, que foi na solução 1. Já a melhor sensibilidade de 88,53%, foi nas soluções 3 e 5. Podemos observar que na etapa de pré-processamento dentre as cinco possibilidades de escolha, apenas três fizeram parte das melhores soluções, o Realce negativo encontra-se em três delas, mostrando a necessidade em transformar as imagens claras em escuras e vice-versa. Na etapa de decomposição apenas a solução 2 não foi aplicado nenhum tipo de decomposição, com isso ela obteve a menor sensibilidade se comparada com as outras soluções. Para extração de características as redes DenseNet e VGG estão presente em todas as soluções apresentadas, isso mostra o quão elas representam bem as características das imagens. Na última etapa do método que a parte de classificação todas as melhores soluções foram utilizando o classificador XGBoost, mostrando assim que ele é mais robusto do que os outros classificadores que faziam parte do método.

Tabela 3 – Parâmetros que foram sugeridos pelo otimizador para cada solução.

Soluções	Pré-Processamento	Decomposição	Extração	Classificação
Solução 1	CLAHE + Realce negativo	Wavelet	DenseNet + Div + GLCM + GLRLM + VGG	XGBoost
Solução 2	CLAHE + Realce negativo	–	DenseNet + Div + GLCM + GLRLM + VGG	XGBoost
Solução 3	Realce logaritmo + Realce negativo	LBP	DenseNet + GLSZM + HOG + NGTDM + Phylo + VGG	XGBoost
Solução 4	Realce logaritmo	Círculo	DenseNet + Div + GLCM + GLRLM + Phylo + VGG	XGBoost
Solução 5	Realce logaritmo	Círculo	DenseNet + GLSZM + NGTDM + Phylo + VGG	XGBoost

4.2 Apresentação dos resultados para Simple Net

Para avaliar este método proposto, a base foi dividida aleatoriamente em três conjuntos de dados, treino, validação e teste. O conjunto de treino contém 2813 imagens, a validação 401 imagens e o conjunto de teste contém 804 imagens dermatoscópicas. Foram realizados 125 testes com o HyperOpt, executados por aproximadamente 2 semanas. A Tabela 4 apresenta as cinco melhores soluções geradas, e a Tabela 5 os parâmetros que foram sugeridos pelo otimizador para cada solução.

Tabela 4 – Cinco melhores combinações de parâmetros de acordo com a acurácia.

Soluções	Acurácia	Sensibilidade	Especificidade	Precisão
Solução 1	86,94%	88,01%	86,54%	70,74%
Solução 2	86,91%	86,63%	86,88%	70,94%
Solução 3	87,18%	83,87%	88,41%	72,80%
Solução 4	86,81%	86,63%	86,88%	70,95%
Solução 5	86,56%	87,55%	86,20%	70,11%

Neste método, a melhor configuração de parâmetros obteve acurácia de 87,18% na solução 3, sensibilidade de 88,01% na Solução 1, e a melhor precisão foi na Solução 3, alcançando 72,80%. Podemos observar na Tabela 5, que as cinco melhores soluções foram utilizando o otimizador Adam, assim como o valor que determina o grau n , que é aplicado na Equação 3.1, afim de determinar a quantidade de filtros; foram os mesmos para todas as soluções, isso significa que o número de filtros escolhido pelo algoritmo TPE é menor do que a arquitetura original da rede, que é 7, utilizando a mesma equação para calcular. Dentre as funções de ativações escolhidas a Tanh e Sigmoid aparecem em

todas as soluções, isso pode ter se caracterizado pelo fato delas funcionarem de forma semelhante.

Tabela 5 – Parâmetros que foram sugeridos pelo otimizador para cada solução.

Soluções	Otimizador	Filtros	Função Ativação
Solução 1	Adam	4	Selu, Tanh, Sigmoid, Tanh, Relu
Solução 2	Adam	4	Tanh, Softplus, Sigmoid, Relu, Softplus
Solução 3	Adam	4	Selu, Tanh, Sigmoid, Selu, Softplus
Solução 4	Adam	4	Selu, Tanh, Sigmoid, Tanh, Sigmoid
Solução 5	Adam	4	Relu, Tanh, Sigmoid, Sigmoid, Relu

4.3 Comparação de resultados entre os métodos propostos

Como foi apresentado nas Seções 4.2 e 4.1 os resultados dos métodos propostos, podemos observar que o Meta conseguiu se sair superior com relação a rede *SimpleNet*. Fazendo uma análise individual de cada métrica a acurácia se manteve sempre acima dos 90% no Meta, enquanto na *SimpleNet* a melhor foi 87,18%. A sensibilidade foi uma das métricas em que houve um equilíbrio entre os dois métodos, a melhor dentre as soluções apresentadas, alcançou 88,53% e 88,01% para o Meta e *SimpleNet*, respectivamente. Essa métrica mostra o quanto foi difícil representar os padrões de melanoma para ambas as técnicas. A especificidade, que é a métrica que avalia a taxa de acerto das imagens normais, também foi superior no Meta ficando sempre acima dos 90% enquanto na *SimpleNet* a melhor alcançou 88,41%. Com a precisão não foi diferente, e mais o vez o Meta se saiu melhor em todas as soluções apresentadas.

O Meta utiliza uma variedades de técnicas de processamento de imagens convencionais, mais utilizadas na literatura, assim, vemos que quando bem combinadas podem obter resultados satisfatórios, isso mostra a robustez do método. A *SimpleNet* por sua vez foi treinada do zero, em um curto espaço de tempo, e a quantidade de dados foram insuficientes. Técnicas convencionais de PDI não necessitam de um volume grande de dados para aprender padrões, diferente de técnicas de aprendizado profundo, que necessitam de um tempo considerado para aprender, além de uma grande quantidade de dados, talvez por essa razão não foi suficiente o aprendizado de forma satisfatório.

4.4 Comparação de resultados com trabalhos relacionados

Nesta seção, os resultados obtidos para ambos os métodos propostos são comparados com alguns trabalhos relacionados. Na Tabela 6, são expostos a Acurácia, Sensibilidade, Especificidade e Precisão, utilizados durante os testes de alguns trabalhos.

Tabela 6 – Comparação de resultados

Autor	Acurácia	Sensibilidade	Especificidade	Precisão
(MAJTNER; YILDIRIM-YAYILGAN; HARDEBERG, 2016)	82,60%	53,30%	89,80%	x
(BAKHEET, 2017)	97,32%	98,21%	96,43%	x
(SANTOS et al., 2017)	89,90%	89,90%	x	89,90%
(CODELLA et al., 2015)	73,90 %	73,80%	74,30%	x
(CODELLA et al., 2017)	81,00%	72,00%	83,20%	x
(NASR-ESFAHANI et al., 2016)	81,00%	81,00%	80,00%	75,00%
Método proposto (Meta)	91,37%	88,53%	92,37%	80,34%
Método proposto (<i>SimpleNet</i>)	87,18%	83,87%	88,41%	72,80%

O trabalho que obteve o melhor resultado foi o de Bakheet (2017), contudo a base que ele utiliza é diferente da base utilizada neste trabalho. O método proposto, através do Meta obteve a segunda maior acurácia com 91,37%. O trabalho de Santos et al. (2017), obteve a melhor sensibilidade com 89,90%, não muito distante do resultado do Meta que alcançou 88,53%. Com relação a especificidade o Meta mais uma vez foi melhor entre os outros trabalhos, obtendo 92,37%.

O método proposto através da *SimpleNet*, consegui se sair melhor do que o trabalho de Majtner, Yildirim-Yayilgan e Hardeberg (2016), (CODELLA et al., 2015) (CODELLA et al., 2017), e (NASR-ESFAHANI et al., 2016) em relação a acurácia e a sensibilidade, alcançando 87,18% e 83,87%, respectivamente, contra 82,60% e 53,30%, 73,90% e 73,80% e 81% e 72%, e 81%.

Analisando o desempenho dos trabalhos de diagnóstico de melanoma em imagens dermatoscópicas, é possível afirmar que o método proposto, através do Meta se equipara aos melhores trabalhos encontrados durante o desenvolvimento deste trabalho, sendo as vezes superior em alguns métricas avaliadas. Entretanto, o método usando *SimpleNet* mesmo obtendo bons resultados, mostra que ainda há espaço para melhorias.

5 Conclusão

Este trabalho apresentou um comparativo entre técnicas de aprendizado profundo e processamento de imagens convencionais, levando em consideração a tarefa de diagnóstico de melanoma, através do *Meta Learning* e da rede *SimpleNet*.

Os resultados para o Meta foram satisfatórios, a Solução 1, obteve a melhor combinação de parâmetros, alcançando uma acurácia de 91,45%, sensibilidade de 85,66% especificidade de 93,49% e precisão de 82,26%. Os resultados para a *SimpleNet* que obteve melhor combinação de parâmetros foi na Solução 3, tendo uma acurácia de 87,18%, sensibilidade de 83,87%, especificidade de 88,41% e uma precisão de 72,80%.

Ambas as técnicas utilizaram o algoritmo TPE, através da biblioteca *Hyperopt*, para realizar a otimização dos seus parâmetros. Comparando os resultados, o Meta obteve os melhores alcançando uma acurácia de 91,45% enquanto a *SimpleNet* obteve 87,18%, mostrando assim que abordagens convencionais ainda são uma boa alternativa para serem utilizadas. Mas também se as limitações forem resolvidas com relação a rede, como por exemplo utilizar ela já treinada, o que não foi possível neste trabalho, poderá obter resultados diferentes.

Como trabalho futuro, identificou-se alguns pontos que podem ser aprimorados na metodologia como utilizar mais técnicas de pré-processamento que possam melhorar as imagens antes do treino. São possibilidades a representação da imagem em algum canal de cor que melhor diferencie a lesão da pele, utilizar *Data Augmentation*, sendo que essa técnica cria vários exemplos sintéticos de um mesmo conjunto de dados, permitindo um melhor aprendizado, e por fim utilizar a rede *SimpleNet* pré-treinada com pesos da ImageNet como forma de realizar o aprendizado de maneira mais ágil.

Referências

- AHMED, F.; HOSSAIN, E.; BARI, A.; HOSSSEN, M. S. Compound local binary pattern (clbp) for rotation invariant texture classification. *International Journal of Computer Applications*, International Journal of Computer Applications, 244 5 th Avenue,# 1526, New . . . , v. 33, n. 6, p. 5–10, 2011. Citado na página 31.
- AMADASUN, M.; KING, R. Textural features corresponding to textural properties. *IEEE Transactions on systems, man, and Cybernetics*, IEEE, v. 19, n. 5, p. 1264–1274, 1989. Citado na página 31.
- ARCHIVE, I. <https://isic-archive.com/>. 2018. Citado 2 vezes nas páginas 21 e 30.
- AREL, I.; ROSE, D. C.; KARNOWSKI, T. P. et al. Deep machine learning-a new frontier in artificial intelligence research. *IEEE computational intelligence magazine*, The University of Tennessee, v. 5, n. 4, p. 13–18, 2010. Citado na página 32.
- BAILEY, B.; KLEIN, R.; LEEF, S. Hardware/software co-simulation strategies for the future. *Mentor Graphics Co.*, <http://www.mentor.com>, 2000. Citado na página 14.
- BAKHEET, S. An svm framework for malignant melanoma detection based on optimized hog features. *Computation*, Multidisciplinary Digital Publishing Institute, v. 5, n. 1, p. 4, 2017. Citado 2 vezes nas páginas 17 e 40.
- BERGSTRA, J.; YAMINS, D.; COX, D. D. Making a science of model search. *arXiv preprint arXiv:1209.5111*, 2012. Citado na página 27.
- BERGSTRA, J.; YAMINS, D.; COX, D. D. Hyperopt: A python library for optimizing the hyperparameters of machine learning algorithms. In: CITESEER. *Proceedings of the 12th Python in science conference*. [S.l.], 2013. p. 13–20. Citado na página 33.
- BERGSTRA, J.; YAMINS, D.; COX, D. D. Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures. *Jmlr*, 2013. Citado na página 27.
- BERGSTRA, J. S.; BARDENET, R.; BENGIO, Y.; KÉGL, B. Algorithms for hyper-parameter optimization. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2011. p. 2546–2554. Citado na página 27.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 05–32, Oct 2001. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1023/A:1010933404324>>. Citado na página 32.
- BRYSON, A. E. *Applied optimal control: optimization, estimation and control*. [S.l.]: CRC Press, 1975. Citado na página 25.
- CASCINELLI, N.; FERRARIO, M.; TONELLI, T.; LEO, E. A possible new tool for clinical diagnosis of melanoma: the computer. *Journal of the American Academy of Dermatology*, Elsevier, v. 16, n. 2, p. 361–367, 1987. Citado na página 15.

- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22Nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: ACM, 2016. (KDD '16), p. 785–794. ISBN 978-1-4503-4232-2. Disponível em: <<http://doi.acm.org/10.1145/2939672.2939785>>. Citado na página 32.
- CODELLA, N.; CAI, J.; ABEDINI, M.; GARNAVI, R.; HALPERN, A.; SMITH, J. R. Deep learning, sparse coding, and svm for melanoma recognition in dermoscopy images. In: SPRINGER. *International workshop on machine learning in medical imaging*. [S.l.], 2015. p. 118–126. Citado 2 vezes nas páginas 16 e 40.
- CODELLA, N. C.; NGUYEN, Q.-B.; PANKANTI, S.; GUTMAN, D. A.; HELBA, B.; HALPERN, A. C.; SMITH, J. R. Deep learning ensembles for melanoma recognition in dermoscopy images. *IBM Journal of Research and Development*, IBM, v. 61, n. 4/5, p. 5–1, 2017. Citado 2 vezes nas páginas 17 e 40.
- FERNANDES, A. G. S.; MARTINS, C. M. da S.; LIMA, A. C. de M.; JUNIOR, G. B.; ALMEIDA, J. D. S. de; PAIVA, A. C. de. Meta aprendizagem de extração de características aplicada ao diagnóstico de glaucoma. In: SBC. *Anais do XIX Simpósio Brasileiro de Computação Aplicada à Saúde*. [S.l.], 2019. p. 342–347. Citado 2 vezes nas páginas 31 e 33.
- FERNANDES, B. J. T. *Redes neurais com extração implícita de características para reconhecimento de padrões visuais*. Tese (Doutorado) — Universidade Federal de Pernambuco, 2013. Citado 3 vezes nas páginas 25, 26 e 27.
- FILHO, O. M.; NETO, H. V. *Processamento digital de imagens*. [S.l.]: Brasport, 1999. Citado 3 vezes nas páginas 21, 22 e 27.
- FRANGE, V.; ARRUDA, L.; DALDON, P. Dermatoscopia: importância para a prática clínica. *Rev. Ciênc. Méd.*, p. 209–215, 2009. Citado na página 21.
- FREEMAN, W.; ROTH, M. *Orientation Histograms for Hand Gesture Recognition*, *Mitsubishi Electric Research Laboratories*. [S.l.], 1994. Citado na página 31.
- FURTADO, H.; VELHO, H. de C.; MACAU, E. Assimilação de dados com redes neurais artificiais em equações diferenciais. *Anais do DINCON*, 2011. Citado na página 23.
- GBM. GBM, 2008. Acessado em 02 de Novembro de 2019. Disponível em: <<https://gbm.org.br/o-melanoma/>>. Citado 2 vezes nas páginas 19 e 20.
- GIOTIS, I.; MOLDERS, N.; LAND, S.; BIEHL, M.; JONKMAN, M. F.; PETKOV, N. Med-node: a computer-assisted melanoma diagnosis system using non-dermoscopic images. *Expert systems with applications*, Elsevier, v. 42, n. 19, p. 6578–6585, 2015. Citado na página 17.
- GONZALEZ, R. C.; WOODS, R. E. *Pocessamento digital de imagens*. [S.l.]: Pearson Prentice Hall, 2010. Citado na página 21.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado na página 15.
- HARALICK, R. M.; SHANMUGAM, K. Its' hak dinstein. *Textural features for image classification*, v. 3, n. 6, p. 610–621, 1973. Citado na página 31.

- HASANPOUR, S. H.; ROUHANI, M.; FAYYAZ, M.; SABOKROU, M. Lets keep it simple, using simple architectures to outperform deeper and more complex architectures. *arXiv preprint arXiv:1608.06037*, 2016. Citado 2 vezes nas páginas 33 e 34.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778. Citado 2 vezes nas páginas 17 e 31.
- HEIKKILÄ, M.; PIETIKÄINEN, M.; SCHMID, C. Description of interest regions with local binary patterns. *Pattern recognition*, Elsevier, v. 42, n. 3, p. 425–436, 2009. Citado na página 31.
- HOSHIRO, S.; GOLDSCHMIDT, R. R. Processamento de imagens. *Rio de Janeiro: Seção de Engenharia de Computação*, p. 1, 2008. Citado na página 21.
- HUA, K.-L.; HSU, C.-H.; HIDAYATI, S. C.; CHENG, W.-H.; CHEN, Y.-J. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *OncoTargets and therapy*, Dove Press, v. 8, 2015. Citado 2 vezes nas páginas 25 e 26.
- HUANG, G.; LIU, Z.; WEINBERGER, K. Q.; MAATEN, L. van der. Densely connected convolutional networks. In: *Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2017. Citado na página 31.
- JR, H. A.; ODOM, R.; JAMES, W. A pele: estrutura básica e função. doenças básicas da pele de andrews. *Dermatologia clínica. 8ª. São Paulo (SP): Manole*, p. 1–14, 1994. Citado na página 14.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105. Citado na página 17.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Research, v. 521, n. 7553, p. 436–444, 2015. Citado na página 25.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 27.
- LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. In: IEEE. *Circuits and Systems (ISCAS), Proceedings of 2010 IEEE International Symposium on*. [S.l.], 2010. p. 253–256. Citado na página 26.
- LOPES, D.; SILVA, F. d.; BONFIM, M. F. *Desenvolvimento do algoritmo para processamento de imagens digitais para diagnóstico de melanoma*. Tese (Doutorado) — Tese (Doutorado)—Master’s thesis, Centro Universitário Católico Salesiano ..., 2013. Citado na página 15.
- MAGURRAN, A. Measuring biological diversity. 2004. *Malden: Blackwell*, 2004. Citado na página 31.
- MAJTNER, T.; YILDIRIM-YAYILGAN, S.; HARDEBERG, J. Y. Combining deep learning and hand-crafted features for skin lesion classification. In: IEEE. *2016 Sixth International Conference on Image Processing Theory, Tools and Applications (IPTA)*. [S.l.], 2016. p. 1–6. Citado 2 vezes nas páginas 16 e 40.

- MENZIES, S.; GUTENEV, A.; AVRAMIDIS, M.; BATRAC, A.; MCCARTHY, W. Short-term digital surface microscopic monitoring of atypical or changing melanocytic lesions. *Arch Dermatol*, p. 1583–9, 2001. Citado na página 20.
- MEYER, Y. Wavelets and operators. *Cambridge studies in advanced mathematics*, v. 37, 1989. Citado na página 31.
- NANNI, L.; LUMINI, A.; BRAHNAM, S. Local binary patterns variants as texture descriptors for medical image analysis. *Artificial intelligence in medicine*, Elsevier, v. 49, n. 2, p. 117–125, 2010. Citado na página 31.
- NASR-ESFAHANI, E.; SAMAVI, S.; KARIMI, N.; SOROUSHMEHR, S. M. R.; JAFARI, M. H.; WARD, K.; NAJARIAN, K. Melanoma detection by analysis of clinical images using convolutional neural network. In: IEEE. *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2016. p. 1373–1376. Citado 2 vezes nas páginas 17 e 40.
- NEGNEVITSKY, M. *Artificial intelligence: a guide to intelligent systems*. [S.l.]: Pearson Education, 2005. Citado 3 vezes nas páginas 23, 24 e 25.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, Elsevier, v. 29, n. 1, p. 51–59, 1996. Citado na página 31.
- OLIVEIRA, R. B.; JÚNIOR, C. R. C.; GUIDO, R. C.; MARRANGHELLO, N.; PEREIRA, A. S.; ARAUJO, A. F. de; TAVARES, J. M. R.; ROSSETTI, R. B. Classificação de assimetria em lesões de pele por meio de imagens usando máquina de vetor de suporte. In: *WVC 2012-VIII Workshop de Visão Computacional*. [S.l.: s.n.], 2012. Citado na página 15.
- PIZER, S. M.; AMBURN, E. P.; AUSTIN, J. D.; CROMARTIE, R.; GESELOWITZ, A.; GREER, T.; ROMENY, B. ter H.; ZIMMERMAN, J. B.; ZUIDERVELD, K. Adaptive histogram equalization and its variations. *Computer vision, graphics, and image processing*, Elsevier, v. 39, n. 3, p. 355–368, 1987. Citado na página 31.
- PROJECT, I. <https://isdis.org/isic-project/>. 2018. Citado na página 30.
- REZENDE, M. L.; CORRÊA, M. de P.; DUARTE, E. M. Estimativa do custo do tratamento de câncer de pele tipo melanoma no estado de são paulo–brasil. *An Bras Dermatol*, v. 84, n. 3, p. 237–43, 2009. Citado na página 19.
- REZZE, G.; NEVES, R. Dermatoscopia: o método de análise de padrões* dermoscopy: the pattern analysis. 12 2018. Citado na página 20.
- REZZE, G. G.; SÁ, B. C. S. de; NEVES, R. I. Dermatoscopia: o método de análise de padrões dermoscopy: the pattern analysis. *An Bras Dermatol*, SciELO Brasil, v. 3, p. 261–8, 2006. Citado na página 19.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *International Conference on Medical image computing and computer-assisted intervention*. [S.l.], 2015. p. 234–241. Citado na página 17.

- SANTOS, A.; AIRES, K.; VERAS, R.; UCHÔA, V.; SANTOS, L. Uma abordagem de classificação de imagens dermatoscópicas utilizando aprendizado profundo com redes neurais convolucionais. In: SBC. *Anais do XVII Workshop de Informática Médica*. [S.l.], 2017. Citado 2 vezes nas páginas 16 e 40.
- SANTOS, A. R. F. dos; AIRES, K. R. T.; MELO, R. de; VERAS, S.; PASSARINHO, C. J. P. Classificação de imagens dermatoscópicas utilizando aprendizado profundo para características de borda, cor e textura. Citado na página 15.
- SHYNK, J. J. Performance surfaces of a single-layer perceptron. *IEEE Transactions on Neural Networks*, IEEE, v. 1, n. 3, p. 268–274, 1990. Citado na página 24.
- SILVA, G. L. F. d. et al. *Diagnóstico de nódulos pulmonares em imagens de tomografia computadorizada usando redes neurais convolucionais evolutivas*. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2017. Citado na página 26.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. Citado na página 31.
- SOARES, H. B. Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte. Universidade Federal do Rio Grande do Norte, 2008. Citado na página 14.
- SOBER, A. J.; BURSTEIN, J. M. Computerized digital image analysis: An aid for melanoma diagnosis: —preliminary investigations and brief review—. *the Journal of Dermatology*, Wiley Online Library, v. 21, n. 11, p. 885–890, 1994. Citado na página 15.
- SUN, C.; WEE, W. G. Neighboring gray level dependence matrix for texture classification. *Computer Vision, Graphics, and Image Processing*, Elsevier, v. 23, n. 3, p. 341–352, 1983. Citado na página 31.
- THIBAUT, G.; FERTIL, B.; NAVARRO, C.; PEREIRA, S.; CAU, P.; LEVY, N.; SEQUEIRA, J.; MARI, J.-L. Shape and texture indexes application to cell nuclei classification. *International Journal of Pattern Recognition and Artificial Intelligence*, World Scientific, v. 27, n. 01, p. 1357002, 2013. Citado na página 31.
- TUSTISON, N.; GEE, J. Run-length matrices for texture analysis. *The Insight Journal*, v. 2008, p. 1–6, 2008. Citado na página 31.
- VOLPI, A. *Ferramentas de Python para Aprendizado de Máquina*. Alexandre Volpi, 2015. Acessado em 20 de Dezembro de 2017. Disponível em: <<https://alexandrevolpi.wordpress.com/tag/machine-learning/>>. Citado na página 25.
- WILLIAMS, C. K.; RASMUSSEN, C. E. *Gaussian processes for machine learning*. [S.l.]: MIT press Cambridge, MA, 2006. v. 2. Citado na página 27.
- YU, H.-F.; HUANG, F.-L.; LIN, C.-J. Dual coordinate descent methods for logistic regression and maximum entropy models. *Machine Learning*, v. 85, n. 1, p. 41–75, Oct 2011. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1007/s10994-010-5221-8>>. Citado na página 32.