

## Detection of melanoma from dermoscopic images using machine learning

Eduardo Amadeu Dutra Moresi – ORCID 0000-0001-6058-3883 (Universidade Católica de Brasília – moresi@ucb.br)

Julio Cezar Alves dos Santos – ORCID 0000-0002-7384-9553 (Universidade Católica de Brasília – jc.juliocezar.alves@gmail.com)

### Abstract

A skin lesion, in a dermoscopic image, is a single delimited region that is most often distinguishable from the surrounding normal skin because of a different color or texture. Systematic approaches to the assessment of pigmented skin lesions have helped dermatologists improve their ability to clinically recognize early melanoma. The time factor and the physician's experience are extremely important to make the diagnosis with the techniques of dermatoscopy, especially with regard to image analysis. However, experiments were carried out using artificial intelligence paradigms to classify dermoscopic images and assist dermatologists in the diagnosis of melanoma. Therefore, this paper seeks to answer the following research question: how to use machine learning models to assist the dermatologist in the detection of melanoma? The research comprised the following steps: bibliographic research to survey the literature on the topic; choice of the CORE ML framework to obtain the machine learning model; identification of the database of dermoscopic images to train the model; development of an ML model for the detection of melanoma using dermoscopic images; training and testing of the model for the classification of dermoscopic images in melanoma and non-melanoma. The results showed that the model is able to classify the images with accuracy greater than 92%.

**Keywords:** Detection of melanoma, dermoscopic images; artificial intelligence, machine learning.

## Detecção de melanoma a partir de imagens dermatoscópicas utilizando aprendizado de máquina

### Resumo

Uma lesão cutânea, em uma imagem dermatoscópica, é uma região delimitada única que é mais frequentemente distinguível da pele circundante normal em virtude de cor ou textura diferente. As abordagens sistemáticas para a avaliação de lesões cutâneas pigmentadas ajudaram os dermatologistas a melhorar sua capacidade de reconhecer clinicamente o melanoma precoce. O fator tempo e a experiência do médico são de extrema importância para realizar o diagnóstico com as técnicas da dermatoscopia, principalmente no que se refere a análise de imagens. Contudo, experimentos foram realizados utilizando paradigmas de inteligência artificial para classificar imagens dermatoscópicas e auxiliar os dermatologistas no diagnóstico do melanoma. Portanto, o presente artigo busca responder a seguinte questão de pesquisa: como utilizar modelos de aprendizado de máquina para auxiliar o dermatologista na detecção de melanoma? A pesquisa compreendeu os seguintes passos: pesquisa bibliográfica para o levantamento da literatura sobre o tema; escolha do framework CORE ML para obtenção do modelo de aprendizado de máquina; identificação do banco de dados de imagens dermatoscópicas para treinar o modelo; desenvolvimento de um modelo de ML para a detecção de melanoma utilizando imagens dermatoscópicas; treinamento e teste do modelo para a classificação de imagens dermatoscópicas em melanoma e não melanoma. Os resultados mostraram que o modelo consegue classificar as imagens com acurácia superior a 92%.

**Palavras-chave:** Detecção de melanoma, imagens dermatoscópicas; inteligência artificial, aprendizado de máquina.

## 1. Introdução

O câncer da pele registra, a cada ano, cerca de 180 mil novos casos no Brasil. Apesar do número elevado, boa parte consiste no tipo mais comum, conhecido como não melanoma. Sua letalidade é baixa (SBD, 2017), mas pode causar mutilações bem expressivas se não for tratado adequadamente. Os riscos para a saúde ainda se agravam quando a forma mais agressiva se manifesta, podendo ocasionar metástase, que é a disseminação do tumor para outros órgãos.

A doença é mais comum em pessoas com mais de 40 anos de pele clara e que, por algum motivo, teve uma exposição repetida e prolongada aos raios ultravioletas, principalmente durante a infância. Porém, em casos suspeitos para um prognóstico mais eficaz a detecção precoce é fundamental (Brasil, 2020).

O diagnóstico é conduzido por médico dermatologista. Em algumas situações, é realizado o procedimento conhecido como dermatoscopia. É um método não invasivo que consiste em utilizar um aparelho com lente de aumento para visualizar camadas da pele de forma detalhada, mas nem sempre esse recurso é suficiente, sendo necessário a realização de biópsia para confirmar a suspeita (Brasil, 2020).

Ao longo de seus quase 30 anos de história, os critérios ABCDE foram utilizados globalmente nos cursos de Medicina e pela imprensa para fornecer parâmetros simples para análise de lesões pigmentadas que precisam ser avaliadas por um dermatologista (Tsao et al, 2015). A espessura de um melanoma primário é o melhor fator de prognóstico na previsão do curso clínico. Portanto, o diagnóstico precoce seguido de cirurgia curativa é crucial no tratamento do melanoma. A Figura 1 apresenta a descrição do mnemônico ABCDE.










	benigno	maligno	
<b>A</b> ssimetria (formato)	 simétrico	 assimétrico	- Assimetria: uma metade do sinal é diferente da outra.
<b>B</b> ordas	 bordas regulares	 bordas irregulares	- Bordas irregulares: contorno mal definido.
<b>C</b> or	 uma cor só	 mais de uma cor	- Cor variável: presença de várias cores em uma mesma lesão (preta, castanha, branca, avermelhada ou azul).
<b>D</b> iâmetro (tamanho)	 menor que 6mm*	 maior que 6mm	- Diâmetro: maior que 6 milímetros.
			*tamanho da largura de um lápis
<b>E</b> volução	 mudança rápida na aparência (tamanho, forma, cor ou espessura).		- Evolução: mudanças observadas em suas características (tamanho, forma ou cor).

Figura 1 – Descrição do mnemônico ABCDE.

Antes da década de 1980, o diagnóstico de melanoma era frequentemente feito por características macroscópicas graves, como ulceração e sangramento. Como essas características foram predominantemente encontradas em lesões avançadas, eles eram de uso limitado no reconhecimento de melanomas precoces. Estudos durante esse período estavam começando a demonstrar que outras características clínicas, como mudança de cor e tamanho, estavam relacionadas a melanomas anteriores.

Em um esforço para educar os médicos da atenção básica e o público sobre a detecção de melanoma nos estágios clínicos iniciais, Friedman, Rigel e Kopf (1985) publicaram o mnemônico ABCD (assimetria, irregularidade de borda, variação de cor, diâmetro > 6 mm). Em 2004, a letra E (para evolução) foi adicionada ao critério de reconhecimento de que as mudanças / aparências que mudam rapidamente podem significar melanoma (Abbasi et al, 2004). A intenção do mnemônico era ser uma ferramenta simples e direta; portanto, não fornece um modelo abrangente de todas as características do melanoma. As lesões clínicas não precisam ter todos os recursos do ABCDE para sugerir que elas podem representar melanoma. Em vez disso, o índice de suspeita é aditivo e auxiliado pelos recursos do ABCDE; quanto mais critérios a lesão apresentar, maior será a suspeita de melanoma.

Além do mnemônico ABCDE, outros paradigmas de diagnóstico clínico foram desenvolvidos para aprimorar o reconhecimento e o diagnóstico precoces de melanoma. A lista de verificação revisada de sete pontos de Glasgow (Mackie, 1990) inclui três critérios principais (alteração no tamanho / nova lesão, alteração na forma, alteração na cor) e quatro critérios menores (diâmetro > 7 mm, inflamação, crostas ou sangramento e alterações sensoriais). A presença de qualquer um dos principais critérios é uma indicação para uma referência e a presença adicional de qualquer critério menor reforça a necessidade de referência. O checklist de Glasgow foi menos amplamente adotado que o ABCDE, provavelmente devido à sua maior complexidade, com eficácia semelhante na identificação de lesões cutâneas pigmentadas.

Devido à natureza diversa do melanoma precoce, pode estar faltando um ou mais dos ABCDEs, especialmente nas doenças precoces. O diâmetro tem sido o parâmetro mais controverso, porque, à medida que o diagnóstico precoce melhorou, muitos melanomas com menos de 6 mm de largura foram identificados (Abbasi et al, 2008). No entanto, estudos recentes confirmaram que o diâmetro continua sendo um parâmetro diferenciador útil.

Existem outros parâmetros de diagnóstico menos conhecidos para identificar clinicamente o melanoma. Os critérios CUBED (do inglês - *Colored lesions different from skin color, Uncertain diagnosis, Bleeding lesions, Enlarging lesions despite therapy, Delay in healing beyond 2 months*) foram desenvolvidos para ajudar a diagnosticar o melanoma do pé e da unha. Se qualquer uma das duas características estiver presente, é uma indicação para encaminhamento para avaliação da lesão suspeita (Bristow et al, 2010). Além disso, muitos autores tentaram modificar os ABCDEs com a adição de outras características na esperança de aumentar a precisão do diagnóstico, mas nenhuma delas provou-se que essas iterações são superiores ou amplamente adotadas (Tsao et al, 2015).

Essas abordagens sistemáticas para a avaliação de lesões cutâneas pigmentadas ajudaram os dermatologistas a melhorar sua capacidade de reconhecer clinicamente o melanoma precoce. Embora nenhum dos métodos mencionados anteriormente seja perfeito, eles fornecem

diretrizes simples que são usadas por dermatologistas e clínicos gerais para reconhecer sinais de alerta de melanoma precoce.

Devido à sua natureza diversa, o reconhecimento clínico do melanoma continua a ser desafiador, mesmo para dermatologistas experientes. Para fazer o diagnóstico clínico de melanoma, é preciso ter um alto índice de suspeita. É necessário um conhecimento aprofundado das seguintes características do melanoma: clínicas, de suas diferentes variantes e de outras lesões cutâneas pigmentadas (Glazer et al, 2017). Além disso, o conhecimento dos fatores associados ao aumento do risco de desenvolver melanoma, incluindo histórico familiar ou pessoal de melanoma, presença de muitos nevos, histórico de queimaduras solares e tipos claros de pele também deve ser levado em consideração.

A acurácia para o diagnóstico clínico do melanoma, feito por dermatologista, sem a utilização do dermatoscópio, foi estimada entre 75 e 80% e mais baixa se estabelecida por residentes de dermatologia ou clínicos gerais. No entanto, com a utilização do exame dermatoscópico, pode-se alcançar acurácia diagnóstica de aproximadamente 90% para o diagnóstico de melanoma cutâneo (Menzies et al, 2001).

A técnica para a realização da dermatoscopia consiste no emprego de aparelhagem ótica que permite um aumento variável de seis a 400x. O mais utilizado é um aparelho portátil com aumento de 10x. O dermatoscópio incide um feixe luminoso sobre a superfície cutânea, previamente preparada para eliminar a reflexão da luz, permitindo a obtenção de imagem para fins de análise e diagnóstico pelo dermatologista (Rezze et al, 2004).

A dermatoscopia (também conhecida como dermatoscopia ou microscopia de epiluminescência) é um método de obter uma imagem ampliada e iluminada de uma região da pele para aumentar a clareza das manchas na pele (Binder et al, 1995). O instrumento de imagem usado para esse fim é chamado de dermatoscópio. Os dermatoscópios são de dois tipos: contato, usando uma camada de gel/óleo aplicada entre a pele e o dermatoscópio, e sem contato, sem contato com a pele e sem fluido. Imagens sem contato e algumas de contato usam luz polarizada cruzada do dermatoscópio para adquirir a imagem (Rezze et al, 2004). As imagens dermatoscópicas, devido à sua iluminação e ampliação, são amplamente utilizadas na análise e exame de lesões de pele.

Uma lesão cutânea, em uma imagem dermatoscópica, é uma região delimitada única que é mais frequentemente distinguível da pele circundante normal em virtude de cor ou textura diferente. Essa área é considerada a região de interesse para processamento adicional. Segmentar a lesão significa separar a região (lesão) da região normal da pele (não lesão). A segmentação da lesão é um passo muito importante na análise das imagens dermatoscópicas, pois permite a identificação de várias características morfológicas globais específicas da lesão e, ao mesmo tempo, fornece uma região confinada para a segmentação de várias características clínicas locais posteriormente. A borda da região segmentada, chamada borda ou fronteira, também fornece recursos para uso na análise da lesão (Friedman, Rigel, Kopf, 1985). A identificação correta da área não lesional, ignorando os artefatos presentes em algumas imagens, também fornece uma região de pele normal para o cálculo de cores relativas e outros recursos úteis (Stanley, Stoecker, Moss, 2007; Cheng et al, 2008).

A pesquisa com foco no uso de imagens dermatoscópicas para detecção de melanoma conta com poucos bancos de dados públicos. Entre eles, os bancos de dados de imagens PH2

(Mendonca et al, 2015) e EDRA (Argenziano et al, 2000) são mais comumente usados pelas comunidades de pesquisa. Recentemente, a *International Skin Imaging Collaboration* (ISIC) também criou o *ISIC Archive* para o projeto Melanoma, que é um grande banco de dados público de imagens dermatoscópicas (ISIC, 2016). As imagens dermatoscópicas desses bancos de dados podem ser usadas para pesquisa, desenvolvimento e comparação de vários algoritmos para identificação de melanoma.

É nesse contexto que este artigo se insere. O fator tempo e a experiência do médico são de extrema importância para realizar o diagnóstico com as técnicas da dermatoscopia, principalmente no que se refere a análise de imagens. Então o presente artigo busca responder a seguinte questão de pesquisa: como utilizar modelos de aprendizado de máquina para auxiliar o dermatologista na detecção de melanoma?

A proposta deste trabalho é utilizar os recursos de aprendizado de máquina (ML – do inglês *machine learning*) para obter um modelo capaz de analisar imagens dermatoscópicas e fornecer em tempo real a probabilidade de determinada lesão ser um melanoma.

## 2. Revisão de Literatura

A seguir serão analisados os artigos mais citados e os mais recentes de acordo com a base de dados da scopus. Para efetuar a pesquisa bibliográfica foi utilizada a seguinte expressão de busca: ("machine learning" AND (((cancer OR melanoma OR carcinoma) AND "image processing") AND "skin cancer"). O resultado recuperou 444 documentos, no período de 2003 a 2020. Como é possível observar na Figura 2, o pico das publicações ocorreu no ano de 2019 com projeção de continuidade de crescimento em 2020.




Figura 2 - Evolução dos artigos publicados na base Scopus.

Com o propósito de tentar identificar as áreas do conhecimento que mais contribuem com o assunto, foi gerado um gráfico na plataforma da Scopus. como pode ser visto na Figura 3 a área de Ciência da Computação lidera o numero de publicações quando levado em consideração os termos de busca.

Dentre os artigos mais citados, Adomaviciu e Tuzhilin (2005) apresentam uma visão geral relacionada aos sistemas de recomendação (SR) e descrevem como são constituídos os métodos atuais. Na visão dos autores os mesmos podem ser classificados em três categorias; Sendo elas: abordagem de recomendação baseadas em conteúdo, colaborativas e híbridas. No entanto os autores também descrevem as varias limitações dos métodos de recomendações mais modernos e discute as possíveis formas para melhorar os recursos de recomendação, possibilitando assim, uma aplicação mais ampla no desenvolvimento de aplicativos. O artigo relata as seguintes técnicas para aprimoramento dos SR: melhorar a compreensão dos usuários e itens, incorporação das informações contextuais no processo de recomendação, suporte a classificação de multicritérios e uma provisão de tipos de recomendação mais maleável.




Figura 3 - Percentuais de documentos por áreas do conhecimento.

A classificação automatizada de textos em categorias pré-definidas tem crescido de forma significativa nos últimos dez anos; isso ocorre devido a grande quantidade de documentos digitalizado e a necessidade de organizá-los. Para os pesquisadores as técnicas para solucionar esse tipo de problemas advém do termo conhecido como aprendizado de máquina, exemplificando de forma superficial funciona a partir de um conjunto de documentos pré-classificados que tem por objetivo treinar um classificador. Para o autor existem algumas vantagens em relação a abordagem que leva em consideração a engenharia do conhecimento, que consiste em definir de forma manual um classificador por domínio, resultando em economias consideráveis em força de trabalho especializada e a possibilidade de portabilidade direta para domínios diferentes. O foco principal do autor é levantar as principais abordagens para categorização de textos, partindo dos princípios de ML, focando nas seguintes problemáticas: representação de documentos, construção de classificadores e avaliação de classificadores (Sebastiani, 2002).

De acordo com Pan e Yang (2010), os algoritmos de aprendizado de máquina e de mineração de dados devem estar no mesmo escopo de recursos e possuir a mesma distribuição. Porém em muitas aplicações no mundo real essa colocação pode não ser valida. De acordo com os

autores, em algumas situações temos tarefas de classificação em um domínio de interesse, porém para realizar a ação os dados de treinamento que precisamos estão em outro domínio, no qual os últimos dados podem seguir uma distribuição diferente ou estar em um espaço de recurso diferente. Nesse tipo de contexto, caso a transferência de conhecimento seja realizada com sucesso, haverá uma melhora no desempenho de aprendizagem, pois evitar colocar esforços para marcar dados desnecessário. O estudo que os autores propõem em sua pesquisa é concentrar esforços na categorização e efetuar uma revisão no processo utilizado atualmente para aprendizagem de transferência, aplicado em problemas de classificação, regressão e *clustering*. A pesquisa realizada leva em consideração algumas técnicas utilizadas no processo de ML, como adaptação de domínio, aprendizado multitarefa, mudança de covariável e problemas com a seleção de amostra.

Tenenhaus et al (2010) apresentaram um novo sistema para análise de imagens digitais de lesões de pele, que utiliza técnicas de aprendizado estatístico para testar e avaliar a capacidade discriminante de várias características para o reconhecimento do melanoma. Por uma questão de robustez e flexibilidade, o sistema foi projetado especificamente para a análise de imagens digitais de lesões cutâneas pigmentadas adquiridas sob condições não controladas. Variabilidade de lesões, formas, cores, texturas, variabilidade de estruturas (rede pigmentada, glóbulos, etc.), presença de artefatos (cabelos, sombras, etc.) e, finalmente, variabilidade na qualidade das imagens são geralmente considerados fatores que fazem a tarefa de um classificador automático difícil. Contudo, eles usaram técnicas de aprendizado estatístico e conseguiram analisar com sucesso uma enorme variedade de tumores, fornecendo uma estimativa da probabilidade de uma lesão pertencer a cada uma das duas classes (lesões de melanoma vs. não melanoma).

Com o crescente aumento dos dados gerados nos últimos anos, surge a necessidade de analisar e compreender os dados brutos a procura de conhecimento. Embora ao longo do tempo as técnicas de análise tenham se aperfeiçoado, muitas técnicas ainda necessitam evoluir mais. Para He e Garcia (2009) os problemas relacionados com os chamados aprendizado desequilibrado (AD), estão diretamente relacionados com o desempenho nos algoritmos de aprendizado, ao processar dados sub-representados ou distorções graves na distribuição das classes. Para o autor apreender com dados desequilibrados, requer entender alguns princípios e algoritmos, além de fazer uso de algum tipo de ferramenta para efetuar a transformação do dado bruto em dados que possam ser úteis para extração de conhecimento. No seu estudo o autor faz uma revisão abrangente e crítica a respeito do aprendizado com uso de dados desbalanceado, fazendo um levantamento e realizando uma avaliação das técnicas e ferramentas utilizadas nos dias atuais para realizar o tratamento nos dados desbalanceado.

O processo de mineração e extração de conhecimento em grandes bases de dados, tem sido considerado por muitos pesquisadores o ponto chave para efetuar trabalhos com as técnicas de aprendizado de máquina. Por outro lado algumas empresas industriais veem como uma oportunidade de captar grandes receitas. Vários serviços online fazem uso de técnicas de Data Mining (DM), para entender melhor os usuários, possibilitando assim, melhorar os serviços e aumentar as oportunidades de negócios. Levando em consideração a alta demanda relacionada ao assunto, o mesmo fornece uma pesquisa do ponto de vista de banco de dados em relação às técnicas de DM (Chen, Han, Yu, 1996).

De acordo com Fung, Wang e Yu (2010), a captação de dados que são coletadas pelos governos, corporações, criou um cenário de oportunidades para tomada de decisões baseado

na extração do conhecimento. Para o autor esse fenômeno ainda foi impulsionado pela regulamentação que obriga a disponibilização de algumas informações. No entanto alguns dados são confidenciais e não podem ser fornecidos, podendo violar a privacidade individual do indivíduo. O foco principal do estudo proposto é realizar uma avaliação das diferentes técnicas de publicação de dados com preservação de privacidade (PDPP), que visa disponibilizar o dado preservando informações confidenciais.

Com o propósito de cruzar automaticamente documentos com a Wikipedia, o autor explica como o aprendizado de máquina pode ser aplicado para identificar termos significativos dentro do texto não estruturado e melhorá-lo com links para os artigos correlatos da Wikipédia. A acurácia do detector de link chega a uma precisão de quase 75%. No entanto o objetivo do trabalho não é apenas enriquecer trabalhos com links explicativos da Wikipedia, é também fornecer conhecimento de forma estruturada de partes de textos não estruturados, (Milne, Witten, 2008).

Os artigos mais recentes também trazem contribuições para esta pesquisa. Segundo Akran et al. (2020), nos últimos anos vem crescendo a quantidade de diagnósticos de câncer de pele do tipo melanoma. Sua letalidade é alta, porém quando identificado nos estágios iniciais as chances de um bom prognóstico aumentam. Isso resulta em uma probabilidade maior de sobrevivência do paciente. Visando métodos eficientes para detecção precoce da doença, pesquisadores buscam alternativas baseado em computadores. A literatura relata alguns casos de sucesso. No entanto a comunidade que estuda técnicas de aprendizado de máquina, buscam formas cada vez mais precisas para melhorar a acurácia no reconhecimento de melanomas. Algumas abordagens vêm sendo propostas como: Estruturas para classificação de lesões cutâneas, que visa integrar informações profundas sobre as características, originando assim, um vetor de características mais precisas. Essa estrutura possui a vantagem de manter o espaço original. Para realizar esse trabalho foi utilizado modelos profundos para extrair recursos e aproveitar a técnica de aprendizagem por transferência. As etapas do estudo de caso foram divididas em duas etapas, sendo a primeira responsável por segmentar as imagens dermatoscópicas e extração da região da lesão, logo em seguida os recursos são treinados novamente. A proposta de submeter novamente os modelos para treinamento é obter vetores de características fundidas. A segunda fase propõe uma forma para selecionar as características mais discriminantes para reduzir a dimensionalidade. Os resultados dessa simulação comprovam a eficácia para categorizar a lesão de pele com a precisão de 98,8%, 99,2% e 97,1% e 95,9%.

Os algoritmos desempenham um papel fundamental no diagnóstico e planejamento de aplicações terapêuticas. Reshma e Priestly Shan (2020) propõe uma abordagem com aprendizado de máquina para detecção de melanoma. Seu estudo está voltado para um trabalho que consiste em realizar um pré-processamento para segmentação da lesão e a otimização dos recursos. O desempenho do seu classificador foi comparado com outros classificadores e de acordo com seus estudos foi possível obter resultados superiores. Para chegar a essa conclusão foi utilizado métricas como sensibilidade, especificidade e precisão. Sua teoria tem a precisão de 96,4% comparado a outros algoritmos.

A quantidade de dados de imagens médicas e a complexidade para analisá-las vem crescendo exponencialmente. Isso faz com que novos desafios apareçam para os pesquisadores que estudam e desenvolvem melhorias em algoritmos de aprendizado de máquina. No entanto alguns problemas tendem a ser mais desafiadores, como dados não supervisionados, pois a



geração de rótulos nesse contexto tende a ser muito mais trabalhosa e em algumas caso torna-se até mesmo impossível, tornando a interpretação dos dados e resultados um dos grandes problemas para geração de novos conhecimentos quando se trata de um conjunto muito grande de dados. Sendo assim, Peralta e Saeys (2020) enfatizam a importância das técnicas que visam a redução da dimensionalidade não supervisionada, que diminuem o processamento necessário para analisar um grande volume de dados. A proposta dos autores é fornecer uma estrutura que leva em consideração estudos anteriores de agrupamentos de recursos não supervisionados, visando assim a redução de dimensionalidade escalável. Para isso o estudo engloba várias médias de dissimilaridade entre recursos, como, algoritmos de *clustering* e critérios de qualidade para efetuar uma escolha mais assertiva do melhor *clustering* de recursos e dos métodos de redução de dimensionalidade que os *clusters* criam. Para validação dos resultados foram utilizados testes estáticos, e foi possível observar que muitas das combinações diminuíram a complexidade dos conjuntos de dados. Após passar os dados pelo classificador, foi possível observar melhora na precisão dos resultados.

Os algoritmos de aprendizado de máquina tiveram uma evolução considerável ao longo do tempo, permitindo o desenvolvimento de soluções que são capazes de realizar o reconhecimento de lesões cutâneas, que até então só eram realizadas por médicos dermatologistas. Sua estrutura de funcionamento baseia-se em fornecer rótulos adequados para as imagens. Pesquisa realizada por Maiti e Chatterjee (2020) apresenta uma técnica única de pré-processamento e modificação de imagens, seguida pela segmentação da imagem. Em seu trabalho os autores afirmam que recursos de texturas e conjunto de dados puderam ser aprimorados aplicando técnicas de engenharia de recursos. Para isso o conjunto de dados aprimorados foram processados dentro de um modelo de *Deep Learning*, utilizando o conceito de entropia cruzada binária. Durante o processo o conjunto de dados é submetido a diversas combinações em várias camadas de ativação. Após a conclusão do estudo os pesquisadores puderam constatar que foi possível desenvolver um modelo mais performático na busca por imagens com melanoma. A validação do modelo foi realizada com 2170 imagens, obtendo uma precisão de 96.8%.

Com o uso da tecnologia, profissionais da área da saúde estão podendo fazer uso de ferramentas que auxiliam no diagnóstico e prognóstico de doenças. Isso se torna possível devido ao grande conjunto de dados disponíveis nos dias atuais, como, registros médicos, banco de dados de imagens. A facilidade de acesso aos recursos aliado ao poder de processamento dos computadores modernos, tem incentivado pesquisadores a desenvolver algoritmos de aprendizado de máquina (ML) com inteligência semelhante à humana em dermatologia. A seguir será apresentado cinco áreas da dermatologia que é possível aplicar ML: Classificação da doenças, através de imagens clínicas; Classificação de doenças através de imagens dermatoscópicas; Avaliação de doenças de pele usando aplicativos móveis e dispositivos de monitoramento pessoal; Possibilitar a pesquisa epidemiológica em larga escala e medicina de precisão (Chan et al., 2020).

A técnica da microscopia confocal de reflexão (RCM), possibilita examinar informações morfológicas e citológicas das lesões que estão na camada epidérmica e dérmica, reduzindo a necessidade de o médico solicitar o exame de biópsia. À medida que os diagnósticos estão sendo realizados utilizando a técnica de (RCM), mais resultados em tempo real estão sendo disponibilizados. No entanto para que o procedimento seja mais assertivo, a qualidade das imagens é de extrema importância. Para isso alguns recursos podem ser utilizados, como a quantificação automática das áreas não informativas lesionada, possibilitando assim, realizar

diagnósticos na região lesionada. Para validar o procedimento foi realizado o treinamento de um modelo segmentado a nível de pixel. O modelo é capaz de mapear as áreas não informativas de diagnóstico, apresentando uma sensibilidade de 82% e 93% de especificidade (Kose et al., 2020).

Em seu trabalho, Shimizu e Nakayama (2020), enfatizam a importância da inteligência artificial na resolução de problemas biomédicos, que inclui o câncer. O aprendizado de máquina que é uma subcampo da IA, tem contribuído muito na última década, pois possui alta flexibilidade na aplicação, com a característica fundamental de suportar extração automática de recursos. Em virtude disso pesquisas básicas e clínica do câncer, estão mostrando cada vez mais interesse nesse segmento que já mostrou ser altamente eficaz em tratamentos oncológicos que até então era considerados insolúveis.

De acordo com Kaladevi et al. (2020), a pele é o maior órgão do corpo humano, sendo responsável pela proteção contra micróbios e outros patógenos. Em seu trabalho os autores descrevem um sistema de diagnóstico automatizado, demonstrando a diferença em relação aos sistemas convencionais que necessitam da arbitragem humana, que tem como base a ideologia do diagnóstico dermatológico. O sistema funciona obedecendo a duas etapas que são dependentes. A primeira é responsável por detectar algum tipo de anormalidade na pele e a segunda por identificar doenças da pele. Para isso o sistema necessita de duas entradas, que são as imagens coloridas e de alta resolução e o histórico do paciente. O funcionamento do sistema baseia-se em um algoritmo genético modificado, um agrupamento de medidas  $k$ , e um classificador que realiza a segmentação de pré-processamento e a extração de recursos nas imagens. Para realizar a detecção de doenças cancerígenas, um algoritmo de rede neural é utilizado, para propagar Feedback artificial. Foi possível observar no sistema analisado uma precisão de 98,99 para detecção de câncer de pele.

Para Arivazhagan e Saranya Devi (2020), o câncer de pele é a forma mais maligna que atinge os humanos, podendo ter várias classificações diferentes, como carcinoma e melanoma, todos eles são causados devido ao crescimento anormal das células. Os três tipos citados são considerados os mais agressivos e o sucesso do tratamento só é possível através de um diagnóstico precoce. No entanto a classificação desses tipos de câncer é realmente desafiadora. Ainda de acordo com os autores é possível realizar a classificação desses três tipos de câncer através de técnicas de aprendizado de máquina. A proposta está dividida em três estágios, que são: pré-processamento, extração de recursos e classificação. Para isso foi utilizado um banco de dados com 150 imagens contendo os três tipos de câncer, sendo 50 imagens para cada tipo. A primeira etapa do estudo de caso consiste em realizar o pré-processamento utilizando dois métodos que realizam as seguintes rotinas: aprimoramento das bordas e equalização do histograma. Na etapa seguinte, foram utilizados dois vetores com características diferentes, como textura e características estatísticas. O último estágio é o de classificação, que funciona baseado em um plano de decisão para separar um conjunto de dados com classes diferentes. Os resultados consistem em analisar as medidas de desempenho dos vetores de textura e características estatísticas, individuais e combinadas. As medidas gerais de desempenho do classificador levadas em consideração foram, precisão, sensibilidade e especificidade. A acurácia obtida foi de 97%.

A seleção de recursos é bastante utilizada no segmento de aprendizado de máquina e também no reconhecimento estatístico de padrões. Quando os recursos desnecessários não são removidos ocasiona uma carga computacional. No entanto quando aplicado diferentes

métodos de seleção de recursos, um subconjunto é selecionado como resposta, podendo assim otimizar o valor de uma função de avaliação. Arshaghi, Ashourian e Ghabeli (2020) propõem um novo algoritmo para classificação de imagens dermatoscópicas que apresentem os tipos malignos e benignos. Para isso é aplicada uma etapa de pré-processamento para melhorar a qualidade das imagens, logo em seguida é realizada uma extração, para separar a área saudável da lesionada. O método para realizar esse procedimento é conhecido como limiar de Otsu. A classificação foi realizada utilizando os métodos SVM, KNN e Decision Tree. A precisão obtida no classificador foi de 94.3%, este resultado é considerado satisfatório e mostra o grande potencial do algoritmo de otimização para extração de recursos.

Os algoritmos de inteligência artificial (IA), em especial o *deep learning* têm mostrado um crescimento notável em rotinas de reconhecimento de imagem. Métodos de redes neurais convolucionais e autocodificadores, atualmente tem possibilitado diversas aplicações no campo de análise de imagens médicas. Porém, a prática da radiologia necessita de médicos capacitados para analisar visualmente imagens clínicas. No entanto, os métodos de IA podem fornecer uma boa solução para reconhecer automaticamente padrões complexos nos dados contido nas imagens. Além de fornecer avaliações quantitativas, e não qualitativas, das características radiográficas.

Por meio de uma estrutura probabilística, Cheng, Caverlee e Lee (2010), estudaram a probabilidade de identificar a cidade de um usuário que utiliza o Twitter, apenas utilizando dados referente aos *tweets* emitidos, o autor leva em consideração três abordagens para alcançar o resultado, que são elas: confiança no conteúdo do tweet, não necessitando de informações do IP do usuário, informações de login ou base de conhecimento externas e por ultimo um fator de classificação, para analisar automaticamente palavras dos tweets.

### **3. Metodologia**

A metodologia para responder a questão de pesquisa compreendeu os seguintes passos:

- pesquisa bibliográfica: foram realizados estudos e levantamentos bibliográficos para o conhecimento do estado da arte do tema proposto, efetuando-se consultas à base Elsevier Scopus;
- escolha do framework do CORE ML para obtenção do modelo de aprendizado de máquina;
- identificação do banco de dados de imagens dermatoscópicas para treinar o modelo de aprendizado de máquina;
- desenvolvimento de um modelo de aprendizado de máquina para a detecção de melanoma utilizando imagens dermatoscópicas;
- treinamento do modelo para classificação de imagens dermatoscópicas em melanoma e não melanoma;
- teste do modelo de aprendizado de máquina para detecção de melanoma.

A seguir, será apresentado o framework Core ML.

#### **3. 1. Framework Core ML**

Core ML é um framework que possibilita desenvolver aplicativos utilizando modelos treinados. Um modelo treinado é o resultado da aplicação de algoritmo de treinamento em um conjunto de dados, sendo assim, é possível inserir novas entradas de dados e obter

previsões (Apple, 2020). A base de funcionalidades e estruturas específicas do Core ML pode ser vista na Figura 4.

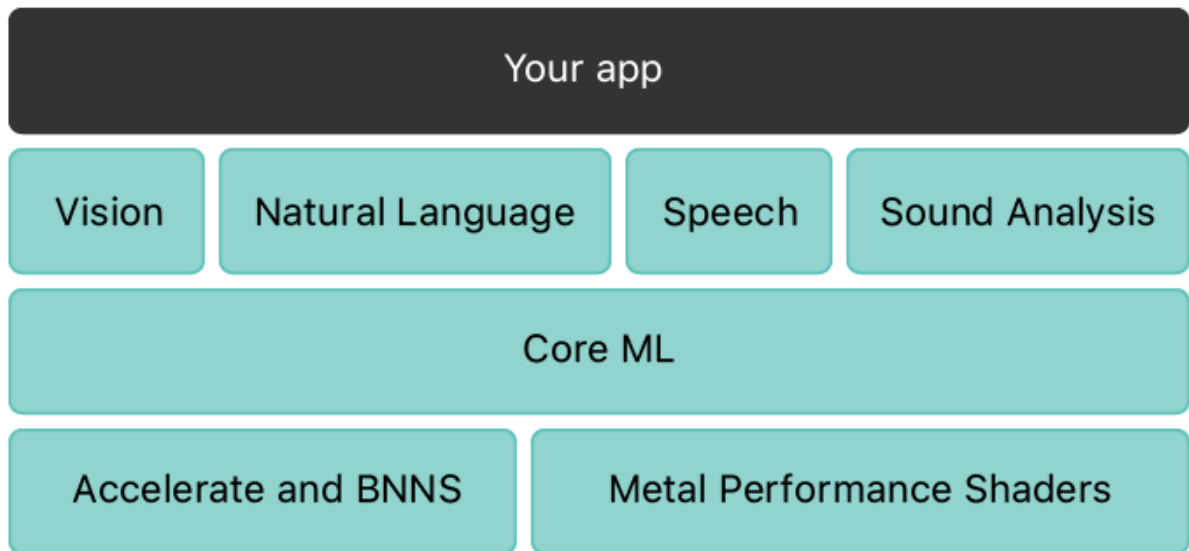


Figura 4 - Base de funcionalidades do Core ML (Apple, 2020)

As camadas superiores do framework Core ML compreendem os seguintes recursos:

- *Vision* - É um framework que possui um conjunto de algoritmos de visão computacional para executar tarefas em vídeos e imagens. Sua estrutura permite realizar detecção de pontos de referência. No entanto, outros recursos podem ser explorados, como detecção de textos e reconhecimento de código de barras;
- *Natural Language* - É um recurso que permite executar tarefas como detecção de idiomas e scripts. A estrutura foi reorganizada para expor APIs de alto desempenho nas plataformas da Apple. A forte integração com o Core ML e Create ML possibilita realizar treinamentos personalizado de modelos de linguagem natural;
- *Speech* - Esse recurso dispõe de algoritmos para reconhecimento de fala e áudio. O reconhecimento de fala está disponível para alguns idiomas. No entanto os servidores da Apple oferecem suporte a framework, devendo ser levado em consideração conexão com a rede;
- *Sound Analysis* - Sua estrutura utiliza um modelo treinado com *Create ML* para analisar e classificar áudio.

Logo abaixo do módulo do Core ML temos as seguintes camadas:

- *Accelerate and BNNS* - É uma rede neural que funciona com base em dados de treinamentos obtidos anteriormente. Sua estrutura é otimizada para todas as CPUs utilizadas na plataforma Apple. O BNNS não foi desenvolvido para realizar treinamentos e sim para fornecer inferência de desempenho em redes treinadas;
- *Metal Performance Shaders* - Tem como objetivo principal otimizar gráficos e ajustar o desempenho do kernel às características de cada GPUs. Os projetos que utilizam esse recurso alcançam bons desempenhos sem a necessidade de codificar e manter shaders para cada tipo de CPUs.

O Core ML é usado para integrar modelos de aprendizado de máquina em um aplicativo iOS. O framework fornece uma representação unificada para todos os modelos. O aplicativo pode utilizar as APIs principais do ML e dados externos para fazer previsões e treinar ou ajustar modelos, tudo no dispositivo do usuário. A Figura 5 apresenta o diagrama do fluxo de dados do Modelo Core ML até o aplicativo. Começando à esquerda está um ícone de arquivo do modelo Core ML. Em seguida, no centro, está o ícone da estrutura Core ML e, à direita, um ícone genérico de aplicativo, rotulado como "seu aplicativo".



Figura 5 – Fluxo do framework Core ML (Apple, 2020).

Um modelo é o resultado da aplicação de um algoritmo de aprendizado de máquina a um conjunto de dados de treinamento. Os modelos podem realizar uma ampla variedade de tarefas, cujo código seria de grande complexidade. Neste artigo, o modelo será treinado para classificar imagens dermatoscópicas como melanoma ou não melanoma.

Um modelo pode ser criado com o aplicativo Create ML incluído no Xcode. Os modelos treinados usando Create ML estão no formato de modelo Core ML e estão prontos para uso no aplicativo. Quando um modelo está no dispositivo de um usuário, pode-se usar o Core ML para treiná-lo novamente ou ajustá-lo no dispositivo, com os dados desse usuário.

O Core ML otimiza o desempenho no dispositivo, aproveitando a CPU, GPU e Neural Engine, minimizando os consumos de memória e de energia. A execução estrita de um modelo no dispositivo do usuário elimina a necessidade de uma conexão de rede, o que ajuda a manter os dados do usuário privados e o aplicativo responsivo.

#### 4. Desenvolvimento do modelo

Neste item, serão abordados alguns conceitos sobre melanoma e aprendizado de máquina. Em seguida, será apresentada uma caracterização da base de imagens do Kaggle e apresentado o modelo desenvolvido.

##### 4.1. Melanoma

O câncer de pele é uma neoplasia muito comum. Sendo que os principais fatores que corroboram para o elevado número de casos é a mudança no estilo de vida com exposição prolongada ao sol e pele branca (Zink, 2014; Bomfim, Giotto, Silva, 2018). O histórico familiar também é levado em consideração Costa (2017). A doença pode ser classificada em dois segmentos (Zink, 2014):

- o primeiro e mais comum é conhecido como não melanoma (NM), que corresponde a 90% dos casos. O NM é um tipo de tumor de crescimento lento e invasivo, seu prognóstico é

considerado bom se identificado precocemente e tratado de forma correta. No entanto, um diagnóstico tardio pode causar mutilações físicas permanentes;

- o segundo e menos comum é conhecido como câncer de pele melanoma (CPM), diagnosticado em cerca de 4% dos pacientes. É considerado a forma mais grave da doença, porém, se tratado no começo tem grandes chances de cura. No entanto, quando há uma demora para iniciar o tratamento, as consequências podem ser irreversíveis, como metástase ocasionando a morte do paciente.

O câncer de pele é classificado em alguns tipos: melanoma, carcinoma basocelular e escamoso. No entanto, o melanoma é muito imprevisível e seu diagnóstico precoce aumenta de forma significativa a qualidade do tratamento, resultando na cura. Porém, se identificado de forma tardia, o mesmo pode crescer profundamente na pele e espalhar por outras partes do corpo. O uso de ferramentas computacionais para análise de imagens médicas pode desempenhar um papel muito importante no auxílio do diagnóstico (Jain, Jagtap, Pise, 2015).

Nos Estados Unidos quase dez mil pessoas morrem anualmente em virtude do câncer de pele quando detectado na forma mais agressiva. A dermatoscopia é utilizada para melhorar a precisão no diagnóstico da doença. As imagens geradas por dermatoscópio podem oferecer oportunidades de aplicar técnicas de aprendizado de máquina no intuito de interpretar os padrões, fazendo com que a dermatoscopia se torne uma ferramenta ainda mais útil. (Ferris et al., 2015).

A inteligência Artificial (IA) tem como objetivo replicar as funções cognitivas humanas, trazendo a cada dia mudanças de paradigma na assistência médica. Isso decorre em virtude da quantidade de dados que são produzidos pela área médica e o rápido crescimento das técnicas de análise. As técnicas de IA possibilitam realizar análises em diferentes tipos de dados, estruturados ou não, fazendo uso de recursos como aprendizado de máquina e *Deep Learning*. Doenças neurológicas, cardiológicas e câncer são as que mais possuem aplicações de IA (Jiang et al., 2019).

De acordo com Jiang et al (2019), a inteligência artificial vem levantando questões que questionam se no futuro a máquina irá substituir os médicos. No entanto, os autores não acreditam nessa possibilidade, mas enfatizam que a IA pode ser um mecanismo para auxiliar os médicos nas tomadas de decisões clínicas, ou em alguns casos substituir o trabalho humano em áreas funcionais que necessitam de julgamento, como é o caso da radiologia.

A Figura 6 aponta as 10 principais doenças que estão recebendo foco da Inteligência Artificial para melhorar os diagnósticos, com os respectivos indicadores de crescimento das aplicações das técnicas de IA, no período de 2013 a 2016.

## **4.2. Aprendizado de máquina**

O aprendizado de máquina tem como propósito, construir um algoritmo de computador capaz de coletar informações importantes dos dados e através dos mesmos realizar ações sem intervenção humana. Tal comportamento é possível graças a modelos de abordagens constituído através de algoritmos estatísticos e algoritmos de busca (Neruda, Figueroa-García, 2015).

No campo da inteligência artificial, o aprendizado de máquina inclui uma abordagem que leva em consideração métodos como programação lógica indutiva, sistemas especialistas, árvores de decisão ou aprendizagem de regras de associação. No entanto eles são normalmente baseados em cálculo formal, representação de conhecimento lógico e muitas técnicas de raciocínio.




Figura 6 - indicadores de crescimento das aplicações das técnicas de IA, no período de 2013 a 2016 (Jiang et al., 2019).

Diversas técnicas de processamento de imagens e algoritmos de aprendizado de máquina (ML) são estudadas na literatura com o objetivo de melhorar as formas de detecção precoce do câncer de pele (Raghuvanshi, Perkowski, 2011). Os autores sugeriram a criação de dois bancos de imagens:

- o primeiro foi compilado com um software que pertence à Universidade de Hosei, localizada em Tóquio. A ferramenta é especializada no treinamento de imagens relacionadas a dermatologia;
- o segundo banco foi criado a partir da extração de recursos de imagens que contêm algum tipo de lesão, para esse procedimento foi utilizado o software *Skinseg*, que tem como característica principal, realizar segmentação de lesões de pele.

Ao final do processo foi desenvolvido um software que retorna a probabilidade, da lesão presente na imagem, ser um melanoma. Porém vale reforçar que a ferramenta não substitui a avaliação do profissional dermatologista, mas fornece informações que permite mais proatividade das pessoas em relação ao diagnóstico precoce do câncer.

Algumas técnicas estão sendo propostas para realizar uma avaliação mais assertiva na classificação das imagens. Através de algoritmos de classificação de imagens já é possível verificar diferentes tipos de parâmetros, como, assimetria, borda, cor, diâmetro (ABCD), possibilitando identificar a presença do melanoma (Elakya et al, 2019).

Contudo, é possível realizar diagnósticos auxiliado por computadores com o uso de imagens dermatoscópicas, para detectar a presença de câncer de pele (Carrera, Ron-Domínguez, 2019). Para isso técnicas de processamento de imagens e algoritmos de aprendizado de máquina são utilizados. Estes autores têm como objetivo disponibilizar um sistema a baixo custo, que seja preciso e de fácil utilização, que possibilite realizar o procedimento inicial

para detectar melanomas. O sistema projetado utilizou uma amostra de 748 imagens dermatoscópicas, alcançando a sensibilidade de 98%. No entanto, esse valor deve ser considerado quando se tem um estágio simples de extração de recursos e um classificador baseado em máquina de vetores é aplicado.

Nyíri e Kiss (2018) analisaram em sua pesquisa novas técnicas para agrupar redes neurais profundas com diferentes hiperparâmetros e dados que são pré-processados de maneira diferente para a classificação de lesões na pele. Para isso foram utilizados dois conjuntos de dados públicos (ISIC 2017 e ISIC 2018). As características das duas fontes de dados se diferem em vários aspectos, tais como: tamanho, qualidade e origem das imagens, número de possíveis categorias de lesões-alvo e métricas usadas para classificação. Os autores mencionaram que o agrupamento pode ser útil para combinar diferentes modelos de aprendizado de máquina e também diferentes opções de hiperparâmetros desses modelos, além de várias estratégias para pré-processar os dados de entrada na tarefa de detecção de lesões de pele.

### 4.3. Base de dados de imagens

Neste trabalho foram utilizadas imagens do Kaggle<sup>1</sup>. Os dados originais compreendem um conjunto de imagens armazenadas na base HAM10k (*Human Against Machine*) com 10.000 imagens de treinamento, com acesso gratuito.

As imagens dermatoscópicas no conjunto de dados HAM10k foram selecionadas e normalizadas em termos de luminosidade, cores, resolução etc. O diagnóstico real foi validado pela histopatologia (também conhecida como fonte da verdade) em mais de 50% dos casos, o que é duas vezes mais do que os conjuntos de dados de lesões de pele disponíveis anteriormente. O restante do diagnóstico das lesões foi baseado em um consenso de dermatologistas.

Em vez de tentar classificar sete lesões de pele com um conjunto de dados muito desequilibrado, o diagnóstico foi simplificado para duas categorias: melanoma e não melanoma. A base possui as categorias acima em dois grupos: 1.113 imagens de melanoma e 8.902 de não melanoma.

A base original foi ampliada, visando equilibrar as imagens nas duas categorias. O aumento de dados permite que o modelo seja exposto a várias modificações de uma imagem de melanoma. Isso, por sua vez, permite que o modelo aprenda e depois generalize. As imagens 10k desequilibradas, anteriormente, tornam-se um conjunto de dados balanceado de 17,8k com 8.903 imagens de melanoma e 8.902 de não melanoma.

Rasul, Dey e Hashem (2020) mostraram experimentos com *Deep Learning* e redes neurais para a análise de lesões na pele. Eles usaram imagens desta base para o treinamento dos modelos. Para a segmentação de lesões, foi utilizado o conjunto de dados ISIC 2018<sup>2</sup>. A base possui 2.594 imagens com máscaras de segmentação, 1815 imagens foram usadas para treinamento, 259 foram mantidas para validação e 520 foram usadas para teste. Para fins de

---

<sup>1</sup> Disponível em: <https://www.kaggle.com/drscarlat/melanoma>.

<sup>2</sup> Disponível em; <https://challenge.kitware.com/#phase/5abcb19a56357d0139260e53>.



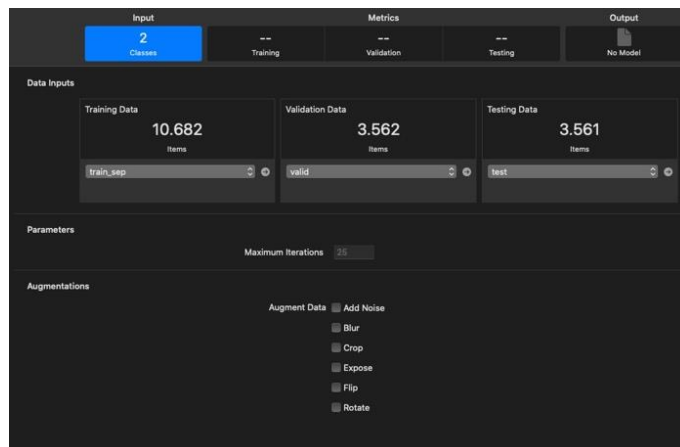
classificação, eles utilizaram o conjunto de dados de melanoma, da base HAM10k. Foram utilizadas 10682 imagens para treinamento, 3562 para validação e 3561 para teste.

#### 4.4. Desenvolvimento do Modelo


Com o objetivo de obter um modelo de aprendizado de máquina, capaz de realizar a classificação de imagens dermatoscópicas, o desenvolvimento seguiu as seguintes etapas:

- primeira: para obtenção do modelo foi utilizada a ferramenta Create ML, com o *template* do Image Classifier (IC), disponível no Integrated Development Environment (IDE) do Xcode. O IC permite reconhecer uma imagem e responder com um rótulo específico;
- segunda: o modelo recebeu a entrada do conjunto de imagens que possuía três subconjuntos: treinamento, validação e testes;
- terceira: treinamento do modelo com imagens pré-classificadas em duas categorias: melanoma e não melanoma.

A Figura 7 apresenta os resultados com o treinamento, a validação e os testes do modelo, sendo utilizadas 17.805 imagens em todo o processo. As imagens foram distribuídas nos seguintes subconjuntos: treinamento - 10.682; validação - 3.562; e testes - 3.561.



(a) Tela com os dados o treinamento, da validação e dos testes.



(b) Tela com os resultados do treinamento, da validação e dos testes.

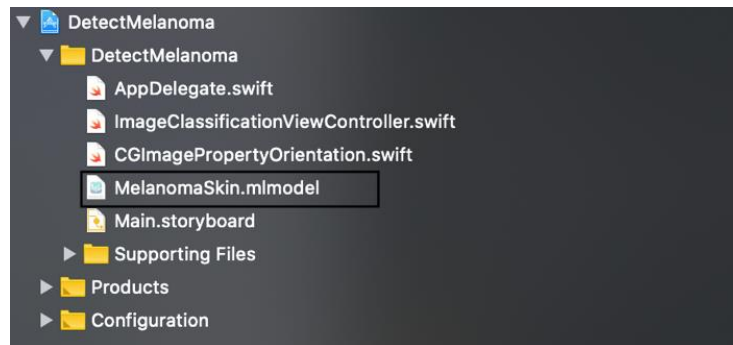
Figura 7 – Treinamento e teste do modelo de ML.

O treinamento efetuado resultou em um classificador com o tamanho de 17KB, como pode ser visto na Figura 7 no campo *output*. Em seguida, o modelo foi exportado no formato "mlmodel" e utilizado em uma aplicação móvel para iPhone.

O treinamento efetuado resultou em um classificador com o tamanho de 17KB, como pode ser visto na figura 7 no campo output. Em seguida, o modelo foi exportado no formato "mlmodel" e utilizado em uma aplicação móvel para iPhone.

A seguir, na Figura 8, é apresentada a estrutura de arquivos de um projeto para iOS, que contempla o modelo treinado - MelanomaSkin - e sua respectiva chamada em uma função desenvolvida na linguagem de programação Swift.

Para facilitar a entrada de imagens dermatoscópicas no classificador, foi desenvolvida uma interface para auxiliar o usuário na leitura dos dados, como pode ser visto na Figura 9. Há uma opção para escolher uma imagem da galeria ou inserir uma nova imagem com o uso da câmera. Após a entrada da imagem, o classificador informa a probabilidade de a lesão ser um melanoma.



(a) Estrutura iOS

```
lazy var classificationRequest: VNCoreMLRequest = {
    do {
        let model = try VNCoreMLModel(for: MelanomaSkin().model)
        let request = VNCoreMLRequest(model: model,
            completionHandler: { [weak self] request, error in
                self?.processClassifications(for: request, error:
                    error)
            })
        request.imageCropAndScaleOption = .centerCrop
        return request
    } catch {
        fatalError("Failed to load Vision ML model: \(error)")
    }
}()
```

(b) Código da aplicação

Figura 8 - Aplicação do modelo em um projeto iOS.


## 5. Considerações Finais

O objetivo deste trabalho foi apresentar o emprego de modelo de aprendizado de máquina para auxiliar o dermatologista na detecção de melanoma. A pesquisa na literatura verificou que o processo de diagnóstico do melanoma utiliza imagens capturadas por meio do

dermatoscópio. Contudo, a interpretação destas imagens depende da experiência do dermatologista.



(a) Tela de seleção da entrada de imagem



(b) Tela de resultado probabilístico

Figura 9 - Aplicação para iPhone.

A solução proposta neste artigo, para auxiliar o dermatologista no diagnóstico do melanoma, utilizou o framework CORE ML para realizar o treinamento do modelo de aprendizado de máquina. Após os testes, o classificador alcançou um nível de acurácia superior a 92%.

Para estudos futuros, pretende-se realizar as seguintes ações: inserir os *argumentations* (Crop, Rotate, Blur, Expose, Noise, Flip) para o treinamento do modelo, afim de melhorar o nível de confiança no reconhecimento de padrões; efetuar novas implementações com o CORE ML 3, possibilitando assim validar a melhora no nível de precisão e processamento das novas atualizações inseridas no framework; exportar o modelo após efetuar mais um ciclo de treinamento com a inserção dos *argumentations*; desenvolver uma aplicação IOS para fazer uso do modelo exportado.

### Referências Bibliográficas

Abbasi, N. R.; Shaw, H. M.; Rigel, D. S. et al. (2004). Early diagnosis of cutaneous melanoma: revisiting the ABCD criteria. *The Journal of the American Medical Association*, v. 292, pp. 2771-2776

Abbasi, N. R.; Yancovitz, M.; Gutkowitz-Krusin, D. et al. (2008). Utility of lesion diameter in the clinical diagnosis of cutaneous melanoma. *Archives of Dermatology*, v. 144, n. 4, pp. 469-474.

Adomaviciu G., Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, v. 17, n. 6, pp. 734-749.

Akram, T., Lodhi, H.M.J., Naqvi, S.R. et al. (2020). A multilevel features selection framework for skin lesion classification. Human-centric *Computing and Information Sciences*, v. 10, Art. 12 (2020).

Apple. (2020). *Framework – Core ML*. Disponível em: <<https://developer.apple.com/documentation/coreml>>. Acesso em: 18 Jul 2020.

Argenziano, G.; Soyer, H. P.; Giorgio, V. D.; Piccolo, D.; Carli, P.; Delfino, M.; Ferrari, A.; Hofmann-Wellenhof, R.; Massi, D.; Mazzocchetti, G.; Scalvenzi, M.; Wolf, I. H. (2000). *Interactive atlas of dermoscopy*. Milan: Edra Medical Publishing & New Media, 2000.

Arivazhagan, S; Saranya Devi, V. (2020). Skin cancer classification using machine learning techniques. *International Journal of Advanced Science and Technology*, v. 29, n. 7, pp. 1085-1095.

Arshaghi, A.; Ashourian; M., Ghabeli, L. (2020). Detection of skin cancer image by feature selection methods using new buzzard optimization (BUZO) algorithm. *Traitement du Signal*, v. 37, n. 2, pp. 181-194.

Binder, M.; Schwarz, M.; Winkler, A.; Steiner, A.; Kaider, A.; Wolff, K.; Pehamberger, H. (1995). Epiluminescence Microscopy - A Useful Tool for the Diagnosis of Pigmented Skin Lesions for Formally Trained Dermatologists. *Archives of Dermatology*, v. 131, n. 3, pp. 286-291.

Bomfim, S. S.; Giotto, A. C.; Silva, A. G. (2018). Câncer de pele: conhecendo e prevenindo a população. *Revista Científica Sena Aires*, v. 7, n. 3, pp. 255-259.

Brasil. Ministério da Saúde. (2020). *Câncer de pele*. Ministério da Saúde. Brasília. Disponível em: <<http://saude.gov.br/saude-de-a-z/cancer-de-pele>>. Acesso em: 18 jul. 2020.

Bristow, I. R.; de Berker, D. A.; Acland, K. M.; Turner, R. J.; Bowling, J. (2010). Clinical guidelines for the recognition of melanoma of the foot and nail unit. *Journal of Foot and Ankle Research*, v. 3, pp. 25.

Carrera, E. V.; Ron-Domínguez, D. (2019). A computer aided diagnosis system for skin cancer detection. In: Botto-Tobar M., Pizarro G., Zúñiga-Prieto M., D'Armas M., Zúñiga Sánchez M. (eds) Technology Trends. CITT 2018. *Communications in Computer and Information Science*, vol 895. Springer, pp. 553-563.

Chan, S.; Reddy, V.; Myers, B.; et al. (2020). Machine Learning in Dermatology: Current Applications, Opportunities, and Limitations. *Dermatology and Therapy*, v. 10, pp. 365–386.

- Chen, M.-S.; Han, J.; Yu, P. S. (1996). Data mining: An overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*, v. 8, n. 6, pp. 866-883.
- Cheng, Z.; Caverlee, J.; Lee, K. (2010). You are where you tweet: A content-based approach to geo-locating Twitter users. In: *International Conference on Information and Knowledge Management, Proceedings*, pp. 759-768.
- Cheng, Y. I.; Swamisai, R.; Umbaugh, S. E.; Moss, R. H.; Stoecker, W. V.; Teegala, S.; Srinivasan, S. K. (2008). Skin lesion classification using relative color features. *Skin Research and Technology*, v. 14, n. 1, pp. 53-64.
- Costa, G. L. G. (2017). *Estudo Retrospectivo dos casos de câncer de pele diagnosticados no hospital de câncer de Mato Grosso*. Dissertação (Ciências) - Fundação Antônio Prudente.
- Elakya, R.; Singh, P. K.; Bafila, H.; Kumar, A. (2019). Melanoma skin cancer detection. *International Journal of Innovative Technology and Exploring Engineering*, v. 9, n. 1, pp. 4073-4076.
- Ferris L. K.; Harkes, J. A.; Gilbert, B; et al. (2015). Computer-aided classification of melanocytic lesions using dermoscopic images. *Journal of the American Academy of Dermatology*, v. 73, n. 5, pp. 769-776.
- Friedman, R. J.; Rigel, D. S.; Kopf, A. W. (1985). Early detection of malignant melanoma: the role of physician examination and self-examination of the skin. *CA: A Cancer Journal for Clinicians*, v. 35, pp. 130-151.
- Fung, B. C. M.; Wang, K.; Chen, R.; Yu, P. S. (2010). Privacy-preserving data publishing: A survey of recent developments. *ACM Computing Surveys*, v. 42, v.14, pp. 1-53.
- Glazer, A. M.; Rigel, D. S.; Winkelmann, R. R.; Farberg, A. S. (2017). Clinical Diagnosis of Skin Cancer: Enhancing Inspection and Early Recognition. *Dermatologic Clinics*, v. 35, n. 4, pp. 409-416.
- He, H.; Garcia, E.A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, v. 21, n. 9, pp. 1263-1284.
- ISIC. (2016). *ISIC Archive - The International Skin Imaging Collaboration: Melanoma Project*. Disponível em: <https://isic-archive.com>. Acesso em: 20 Jul 2020.
- Jain, S.; Jagtap, V.; Pise, N. (2015). Computer aided Melanoma skin cancer detection using Image Processing. In: *International Conference on Intelligent Computing, Communication & Convergence*.
- Jiang, F.; Jiang, Y.; Zhi, H.; et al. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, v. 2, n. 4, pp. 230-243.

- Kaladevi, A. C.; Ramaya, P.; Elamathi, S.; Atchaya, R.; Dhanalakshmi, M. (2020). An automated diagnosis of skin cancer disease using machine learning techniques. *International Journal of Advanced Science and Technology*, v. 29, n. 6, pp. 4116-4126.
- Kose, K.; Bozkurt, A.; Alessi-Fox, C.; Brooks, D. H.; Dy, J. G.; Rajadhyaksha, M.; Gill, M. (2020). Utilizing Machine Learning for Image Quality Assessment for Reflectance Confocal Microscopy. *Journal of Investigative Dermatology*, v. 146, n. 6, pp. 1214-1222.
- Mackie, R. M. (1990). Clinical recognition of early invasive malignant melanoma. *BMJ*, v. 134, pp. 103-104.
- Maiti, A; Chatterjee, B. (2020). Improving detection of Melanoma and Naevus with deep neural networks. *Multimedia Tools and Applications*, v. 79, pp. 15635-15654.
- Mendonca, T. F.; Ferreira, P. M.; Marcal, A. R. S.; Barata, C.; Marques, J. S.; Rocha, J.; Rozeira, J. (2015). PH2 - A public database for the analysis of dermoscopic images. In: *Dermoscopy Image Analysis*, M. E. Celebi, T. Mendonca and J. S. Marques, Eds., Boca Raton, CRC Press, pp. 419-439.
- Menzies, S. W.; Gutenev, A.; Avramidis, M.; Batrac, A.; McCarthy, W. H. (2001). Short-term digital surface microscopic monitoring of atypical or changing melanocytic lesions. *Archives of Dermatology*, v. 137, pp. 1583-1589.
- Milne, D.; Witten, I. H. (2008). Learning to link with Wikipedia. *International Conference on Information and Knowledge Management, Proceedings*, pp. 509-518.
- Neruda, R.; Figueroa-García, J. C. (2015). Computational intelligence, fuzzy systems, and machine learning: Academic vs industrial learning. In: *2015 Workshop on Engineering Applications - International Congress on Engineering (WEA)*, pp. 1-6,
- Nyíri T., Kiss A. (2018). Novel ensembling methods for dermatological image classification. In: Fagan D., Martín-Vide C., O'Neill M., Vega-Rodríguez M. (eds). Theory and Practice of Natural Computing (TPNC 2018), *Lecture Notes in Computer Science*, v. 11324, pp. 438-448.
- Pan, S. J.; Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, v.22, n. 10, pp. 1345-1359
- Peralta, D; Saeys, Y. (2020). Robust unsupervised dimensionality reduction based on feature clustering for single-cell imaging data. *Applied Soft Computing Journal*, v. 93, Art. N. 106421.
- Raghuvanshi, A.; Perkowski, M. (2011). Image processing and machine learning for the diagnosis of melanoma cancer. In: *Proceedings of the International Conference on Biomedical Electronics and Devices - Volume 1: BIODEVICES, (BIOSTEC 2011)*, pp. 405-410.

Rasul, M. F.; Dey, N. K.; Hashem, M. M. (2020). A Comparative Study of Neural Network Architectures for Lesion Segmentation and Melanoma Detection. *2020 IEEE Region 10 Symposium (TENSymp)*.

Reshma, M; Priestly Shan, B. (2020). A clinical decision support system for micro panoramic melanoma detection and grading using soft computing technique. *Measurement: Journal of the International Measurement Confederation*, v. 163, Art. N. 108024.

Rezze, G. G. ; Soares de Sá, B. C.; Neves, R. I. (2004). *Atlas de Dermatoscopia Aplicada*. São Paulo: Lemar, p.19-109.

SBD. (2017). *Câncer da pele*. Sociedade Brasileira de Dermatologia. Brasília, 2019. Disponível em: <<https://www.sbd.org.br/dermatologia/pele/doencas-e-problemas/cancer-da-pele/64/>>. Acesso em: 29 nov. 2019.

Sebastiani, F. (2002). Machine Learning in Automated Text Categorization. *ACM Computing Surveys*, v. 34, n. 1, pp. 1-47.

Shimizu, H; Nakayama, K.I. Artificial intelligence in oncology. *Cancer Science*, v. 111, n. 9, pp. 1452-1460.

Stanley, R. J.; Stoecker, W. V.; Moss, R. H. (2007). A relative color approach to color discrimination for malignant melanoma detection in dermoscopy images. *Skin Research and Technology*, v. 13, n. 1, pp. 62-72.

Tenenhaus, A.; Nkengne, A.; Horn, J.-F.; Serruys, C.; Giron, A.; Fertil, B. (2010). Detection of melanoma from dermoscopic images of naevi acquired under uncontrolled conditions. *Skin Research and Technology*, v. 16, n. 1, pp. 85-97.

Tsao, H.; Olazagasti, J. M.; Cordero, K. M.; Brewer, J. D.; Taylor, S. C.; Bordeaux, J. S.; ... Begolka, W. S. (2015). Early detection of melanoma: Reviewing the ABCDEs. *Journal of the American Academy of Dermatology*, v. 72, n. 4, pp. 717-723.

Zink, B. S. (2014) *Câncer de Pele: A importância do seu diagnóstico, tratamento e prevenção*. Hupe, Rio de Janeiro.