



**UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO  
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**



**FRANCISCO EDUARDO SILVA ALENCAR**

**DESENVOLVIMENTO DE UM SISTEMA PARA  
CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS  
DERMATOSCÓPICAS PARA DISPOSITIVOS MÓVEIS**

**MOSSORÓ – RN  
2015**

**FRANCISCO EDUARDO SILVA ALENCAR**

**DESENVOLVIMENTO DE UM SISTEMA PARA  
CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS  
DERMATOSCÓPICAS PARA DISPOSITIVOS MÓVEIS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação – associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semi-Árido, para a obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Dannel Cavalcante Lopes – UFERSA.

Coorientador: Prof. Dr. Francisco Milton Mendes Neto – UFERSA.

**MOSSORÓ – RN  
2015**

Catálogo na Fonte

Catálogo de Publicação na Fonte. UFERSA - BIBLIOTECA CENTRAL ORLANDO TEIXEIRA - CAMPUS MOSSORÓ

Alencar, Francisco Eduardo Silva.

Desenvolvimento de um sistema para classificação automática de imagens dermatoscópicas para dispositivos móveis / Francisco Eduardo Silva Alencar. - Mossoró, 2015.

76f. il.

1. Desenvolvimento de software. 2. Diagnóstico por imagens - sistema. 3. Visão computacional. 4. Sistemas inteligentes. 5. Dispositivos móveis. I. Título

RN/UFERSA/BCOT/405  
A368d

CDD 005.12

**FRANCISCO EDUARDO SILVA ALENCAR**

**DESENVOLVIMENTO DE UM SISTEMA PARA  
CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS  
DERMATOSCÓPICAS PARA DISPOSITIVOS MÓVEIS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação para a obtenção do título de Mestre em Ciência da Computação.

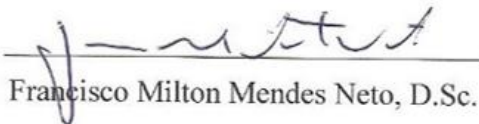
APROVADA EM: \_\_\_ / \_\_\_ / \_\_\_\_\_.

**BANCA EXAMINADORA**



Danniell Cavalcante Lopes, D.Sc.

Orientador



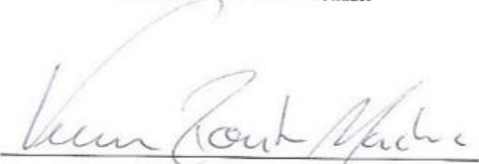
Francisco Milton Mendes Neto, D.Sc.

Coorientador



Círcia Raquel Maia Leite, D.Sc.

Examinadora Interna



Vinícius Ponte Machado, D.Sc.

Examinador Externo- UFPI

Dedico este trabalho aos meus pais Francisco Belo e Maria do Socorro, as minhas irmãs Perpétuo e Patrícia e em especial aos meus avós Maria Bela e José Benevenuto (*in memoriam*), origem da inspiração para enfrentar mais esse desafio.

## AGRADECIMENTOS

Agradeço a Deus pelas oportunidades que ele tem me proporcionado e pela possibilidade de viver esse momento privilegiado. Aos meus pais, Francisco Belo e Maria do Socorro, e as minhas irmãs Patrícia e Perpétuo, por todo os conselhos, incentivo, e pelo enorme esforço para que atingisse essa nova conquista.

Aos meus avós Maria Bela e José Benevenuto (*in memoriam*), pelos conselhos, ensinamentos, preocupação, incentivo aos estudos e por sempre acreditar no meu potencial.

A minha namorada, Ivanalle Sinésio, que esteve sempre presente dando força, incentivando, ajudando e me aturando nos momentos de stress.

A todos os meus amigos que dividiram apartamento comigo, em especial, Diógenes Lopez e João Maurício, pelos momentos de companheirismo, dificuldades, pelas caronas, resenhas e gargalhadas que vivenciamos juntos durante esses dois anos. A todos meus amigos e companheiros de turma que compartilhei alegrias, dúvidas e conhecimento.

Ao meu cunhado e grande amigo Fabio Abrantes, pelos conselhos, revisões de português, motivação e ajuda na implementação do protótipo desse trabalho.

Ao meu orientador Dannel Cavalcante Lopes, por ter me aceitado como orientando, pela sua paciência e auxílio desempenhado durante todo o desenvolvimento desse trabalho. Agradeço muito pela atenção, dicas e conselhos e pela pessoa que se fez sempre presente me compreendendo e ajudando durante esses dois anos.

Ao meu coorientador Francisco Milton Mendes Neto, agradeço pela compreensão, ajuda nas correções e nas dicas e conselhos que fizeram este trabalho melhor.

A todos os professores do programa de pós-graduação em Ciências da Computação UERN/UFERSA que contribuíram de forma direta e indireta para a realização desse trabalho.

A Capes, pelo apoio financeiro concebido no qual viabilizou a realização deste trabalho.

Obrigado a todos.

## RESUMO

O melanoma é o câncer de pele mais letal entre todos os outros tipos, porém quando diagnosticado precocemente obtém altos índices de cura. A análise dessas lesões geralmente é realizada através do exame da dermatoscopia, um exame não invasivo que utiliza um equipamento ótico para auxiliar na análise das estruturas que caracterizam as lesões como nevo benigno ou maligno. Porém, a realização dessa análise geralmente é realizada por um especialista, o que dificulta o acesso ao público a esse exame. Dessa forma, o uso de sistemas computacionais para auxiliar especialistas e profissionais de saúde (médicos e enfermeiros) pode solucionar ou reduzir os vieses decorrentes de diagnósticos incorretos. Além disso, facilita o acesso a esse tipo de exame, tendo em vista que, com a ajuda do sistema, profissionais não especialistas mas com conhecimento sobre o problema poderão executar o exame e analisar as lesões de forma mais precisa. O aumento da disponibilidade dos dispositivos móveis e a facilidade ao acesso a aplicativos através das lojas online resultou na utilização cada vez maior desses dispositivos. A conveniência do uso de um sistema móvel para a classificação de lesões de pele pode melhorar o acesso ao exame de dermatoscopia, assim como aumentar a probabilidade de detecção precoce do melanoma. Deste modo, este trabalho apresenta o desenvolvimento de um sistema de classificação de imagens dermatoscópicas para dispositivos móveis.

Palavras-Chave: Visão Computacional, Diagnóstico por Imagens, Dispositivos Móveis, Sistemas Inteligentes.

## **ABSTRACT**

Melanoma is the most lethal skin cancer among all other types, but when diagnosed early gets high cure rates. The analysis of these injuries is usually performed by examination of dermoscopy, a noninvasive test that uses an optical equipment to assist in the analysis of structures that characterize the lesions as benign or malignant nevus. However, the realization of this analysis is usually performed by a specialist impeding the public access to such examination. Thus, the use of computer systems to assist specialists and health professionals (doctors and nurses), can solve or reduce biases due to misdiagnosis and facilitate access to this type of examination, given that, with the help the non-specialist professional system but with knowledge of the problem may run the scan and analyze more precisely lesions. The increasing availability of mobile devices and the ease of access to applications through online stores has resulted in the growing use of these devices. The convenience of using a mobile system for the classification of skin lesions can improve access to the examination of dermoscopy and increase early detection probability of melanoma. Thus, this paper presents the development of a dermoscopic image classification system for mobile devices.

**Keywords:** Computer Vision, Diagnostic Imaging, Mobile Devices, Intelligent Systems.



## LISTA DE TABELAS

<b>Tabela 1</b> – Exemplos de funções de ativação. ....	36
<b>Tabela 2</b> – Resultados da classificação obtidos pelo algoritmo KNN.....	65
<b>Tabela 3</b> – Resultados da classificação obtidos pelo algoritmo AD.....	65
<b>Tabela 4</b> – Resultados da classificação obtidos pelo algoritmo SVM.....	66
<b>Tabela 5</b> – Resultados obtidos pela Rede MLP.....	66
<b>Tabela 6</b> – Níveis de Sensibilidade e Especificidade. ....	67

## LISTA DE FIGURAS

<b>Figura 1</b> – Percentual de Iniciativas de Mobile Health. ....	18
<b>Figura 2</b> – Representação de uma imagem digital.....	25
<b>Figura 3</b> – Superposição de matrizes formando uma imagem colorida (RGB). ....	26
<b>Figura 4</b> – Modelo do Neurônio Artificial. ....	35
<b>Figura 5</b> – Exemplos de funções de ativação: (a) linear, (b) limiar e (c) sigmoide.....	36
<b>Figura 6</b> – Arquitetura de uma RNA Multilayer Perceptron.....	37
<b>Figura 7</b> – Protótipos de telas do sistema: (a) Tela Inicial, (b) Alerta ao usuário e (c) Captura da lesão.....	43
<b>Figura 8</b> – Protótipos de telas: (a) Visualização da lesão e (b) Resultados da Análise .	44
<b>Figura 9</b> – Estrutura Geral do Sistema .....	45
<b>Figura 10</b> – Em (a) dermatoscópio para smartphone, em (b) adaptador para dermatoscópio.....	45
<b>Figura 11</b> – Diagrama de Atividades do Sistema .....	47
<b>Figura 12</b> – Imagens da base PH <sup>2</sup> . A primeira linha apresenta imagens de nevos comuns, na segunda linha nevos atípicos e na terceira linha melanoma. ....	49
<b>Figura 13</b> – Modelo de imagens retiradas que não foram utilizadas no sistema de classificação: (a) lesão fora dos limites da imagem, (b) excesso de pelos e (c) baixo nível de contraste entre a região da lesão e a cor da pele. ....	50
<b>Figura 14</b> – Etapas do pré-processamento.....	51
<b>Figura 15</b> – Aplicação do filtro bilateral: (a) Imagem normal; (b) Imagem após a aplicação do filtro. ....	52
<b>Figura 16</b> – Melhora nas condições da imagem para realizar a segmentação. Em (a) seleção do canal azul e (b) resultado do filtro de mediana. ....	53
<b>Figura 17</b> – Resultado dos métodos de segmentação. Em (a) imagem segmentada manualmente por um dermatologista, (b) limiarização de Otsu, (c) limiarização adaptativa e (d) watershed. ....	54
<b>Figura 18</b> – Resultados obtidos com utilização das três técnicas. a) Segmentação manual, b) Limiarização de Otsu, c) Limiarização Adaptativa e d) Watershed.....	55
<b>Figura 19</b> – Segmentação com o método de Otsu. ....	56
<b>Figura 20</b> – Resultado da junção da região segmentada e imagem original.....	57
<b>Figura 21</b> – Identificação da lesão: (a) Borda identificada pelo método de Suzuki et al. (1985) e (b) Lesão identificada pelo método de Graham e Frances (1983). ....	58
<b>Figura 22</b> – Aplicação do método convexityDefects. ....	59
<b>Figura 23</b> - Resultado dos testes para obtenção do limiar. Em (a) resultado da detecção da lesão e das irregularidades da lesão, (b), (c) e (d) apresentam as irregularidades com diferentes valores para o limiar. ....	60
<b>Figura 24</b> – Cores a serem analisadas e seus respectivos valores. ....	61
<b>Figura 25</b> – Lesões de pele. ....	62

## LISTA DE SIGLAS

AD – Árvore de Decisão;

BoF – *Bag-of-Features*

ELM – *Extreme Learning Machine*

GPU - Unidade de Processamento Gráfico

HCFMRP – Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto

HPH – Hospital Pedro Hispano

INCA – Instituto Nacional do Câncer

ITU – *International Telecommunication Union*

KNN – *k-Nearest Neighbors*

MLL – *Machine Learning Library*

MLP – *Multilayer Perceptron*

OpenCv – *Open Source Computer Vision Library*

ONU – Organização das Nações Unidas

OMS – Organização Mundial de Saúde

RBF - *Radial Basis Function*

RNA – Rede Neural Artificial

SE – Sensibilidade

SP – Especificidade

SVM – *Support Vector Machine*

TWP – Transformada *Wavelet Packet*

VC – Visão Computacional

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>13</b>
1.1	MOTIVAÇÃO .....	13
1.2	OBJETIVO GERAL .....	15
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO .....	15
<b>2</b>	<b>MOBILE HEALTH .....</b>	<b>17</b>
2.1	TRABALHOS RELACIONADOS .....	18
<b>3</b>	<b>VISÃO COMPUTACIONAL .....</b>	<b>24</b>
3.1	IMAGENS DIGITAIS .....	24
3.2	RECONHECIMENTO DE PADRÕES .....	26
3.3	BIBLIOTECA <i>OPENCV</i> .....	29
3.4	TRABALHOS RELACIONADOS .....	31
<b>4</b>	<b>REDES NEURAIS .....</b>	<b>34</b>
4.1	REDES NEURAIS ARTIFICIAIS (RNAs) .....	35
4.2	RNA MULTILAYER PERCEPTRON (MLP).....	36
4.3	ALGORITMO BACKPROPAGATION .....	37
4.4	TRABALHOS RELACIONADOS .....	39
<b>5</b>	<b>DESENVOLVIMENTO, EXPERIMENTOS E RESULTADOS .....</b>	<b>42</b>
5.1	CARACTERÍSTICAS E REQUERIMENTOS DO SISTEMA .....	42
5.2	ETAPAS DE PROCESSAMENTO.....	44
5.2.1	<b>Aquisição de Imagens.....</b>	<b>48</b>
5.2.2	<b>Pré-Processamento .....</b>	<b>51</b>
5.2.2.1	Segmentação .....	53
5.2.3	<b>Extração de Características.....</b>	<b>57</b>
5.2.3.1	Análise da Borda .....	57
5.2.3.2	Análise de Cor .....	61
5.2.4	<b>Classificação .....</b>	<b>63</b>
5.2.4.1	Comparação de Trabalhos .....	63
5.2.4.2	Classificador .....	68
5.2.5	<b>Apresentação dos Resultados .....</b>	<b>69</b>
<b>6</b>	<b>CONCLUSÃO E TRABALHOS FUTUROS .....</b>	<b>70</b>
	<b>REFERÊNCIAS .....</b>	<b>71</b>

## 1 INTRODUÇÃO

Este capítulo apresenta, na Seção 1.1, os fatores motivacionais para o desenvolvimento desse trabalho; na Seção 1.2 é apresentado o objetivo geral deste trabalho; e na Seção 1.3 é apresentado a organização desta dissertação.

### 1.1 MOTIVAÇÃO

O câncer é uma das doenças que mais preocupa a medicina. Segundo o Instituto Nacional do Câncer (INCA), para o ano de 2014 foi feita uma estimativa de 580 mil novos casos dessa doença. Dentre os diversos tipos de câncer, os que se apresentam com maior incidência são o câncer de pele não melanoma, próstata, mama, colo de reto, pulmão e estômago (INCA, 2015).

No Brasil, o câncer de pele corresponde a 25% de todos os tumores malignos registrados no país. Essa taxa corresponde a uma estimativa de cerca de 182 mil novos casos para o ano de 2014 (INCA, 2015). O câncer de pele do tipo melanoma é o menos comum, representando cerca de 4% das neoplasias malignas desse órgão. No entanto, esse tipo de câncer é considerado o mais agressivo pelo fato de apresentar um alto índice de metástase.

O melanoma cutâneo tem origem nos melanócitos célula que produz melanina, substância responsável por determinar a cor da pele e pode surgir a partir da pele normal ou pigmentada. A doença se manifesta através do surgimento de uma pinta escura de bordas irregulares, na maioria dos casos não apresenta sintomas, mas o tumor pode vir acompanhado de coceira e descamação. Em caso de lesão pigmentada pré-existente, o tumor irá evoluir apresentando mudanças de cores que podem variar do marrom claro ao preto, aumento da superfície e das bordas da lesão (SOARES, 2008).

O diagnóstico precoce é um fator crucial para o tratamento e cura dessa doença, isso porque nos estágios iniciais o melanoma se desenvolve apenas na camada mais superficial da pele, facilitando a extração da lesão. Nos estágios mais avançados, a lesão é mais profunda, o que aumenta a chance de metástase para outros órgãos e diminui a chance de cura (SBD, 2015).

Uma técnica utilizada pelos dermatologistas para diagnosticar o câncer de pele, e consequentemente o melanoma, é a dermatoscopia. Trata-se de um exame não invasivo, realizado *in vivo*, que analisa superfícies pigmentadas na pele humana. Para a realização dessa análise é necessário a utilização de um aparelho que possa ampliar a lesão. O aparelho mais utilizado pelos médicos é o dermatoscópio. Consiste em um aparelho portátil ótico que permite ampliar a lesão de 10 a 100 vezes. Ele emite um feixe de luz que atinge a superfície da pele em um ângulo de 20°. Para eliminar o reflexo natural da luz, um gel é aplicado previamente sobre a pele, permitindo a identificação de estruturas da pele que antes não eram visíveis a olho nu (FRANGE; ARRUDA; DALDON, 2012). Já a dermatoscopia digital permite capturar imagens da lesão com uma ampliação média de 70 vezes, mantendo a definição da imagem. As imagens capturadas são armazenadas em formato digital e podem ser utilizadas para o acompanhamento das lesões e discussão do diagnóstico. Essa técnica utiliza uma câmera digital (dermafoto digital) ou de vídeo (vídeodermatoscopia digital), tem como desvantagem o alto custo dos aparelhos.

Resultados mostram que a utilização da dermatoscopia, em conjunção com os resultados do exame clínico e o histórico do paciente, melhora a acurácia do diagnóstico da lesão em 50% (PSATY; HALPERN, 2009). Algumas metodologias são utilizadas em conjunto com a dermatoscopia na análise das lesões, dentre elas destaca-se o uso da regra ABCD (DERMOSCOPY, 2015; NACHBAR *et al.*, 1994) e a lista dos sete pontos (ARGENZIANO, 1998). Ambos analisam inicialmente a lesão inspecionando se a mesma é de origem melanocítica ou não melanocítica, ou seja, se tem origem de células de melanócitos. Identificada a origem a lesão, é novamente analisada como benigna ou maligna (melanoma).

Para essa análise a regra ABCD atribui uma pontuação para a lesão. Essa pontuação é obtida através da soma dos pontos atribuídos às características de assimetria (A), borda (B), cor (C), e diâmetro e/ou estruturas diferenciais (rede de pigmento, pontos, estrias, etc.) (D). Caso a soma atinja uma pontuação maior que 5.45, a lesão é diagnosticada como melanoma. A lista dos sete pontos verifica a presença de estruturas diferenciais atípicas, são elas: rede de pigmento, véu azul-esbranquiçado, padrão vascular atípico, estrias, pigmentação irregular, pontos ou glóbulos e estruturas de regressão. Esse método classifica a lesão como melanoma caso sejam identificadas duas ou mais estruturas diferenciais atípicas.

A aquisição de imagens de lesões de pele possibilitou a formação de grandes conjuntos de imagens, gerando a necessidade de utilizar métodos computacionais para o processamento, análise e recuperação de informações contidas nessas imagens.

As tecnologias foram evoluindo possibilitando o desenvolvimento de sistemas computacionais que auxiliassem dermatologistas e profissionais da área da saúde na análise de lesões de pele. Os sistemas de Visão Computacional (VC) estão sendo cada vez mais utilizados como ferramentas de apoio para análise do melanoma. Esses sistemas geralmente utilizam imagens de lesões de pele para extrair as informações das lesões utilizando algoritmos médicos e classificam essas informações utilizando algoritmos de aprendizagem de máquina.

A utilização de sistema de VC no processo de classificação de imagens dermatoscópicas para análise do melanoma tem mostrado resultados promissores. Em (RUIZ *et al.*, 2011), o sistema obteve um índice de especificidade (SP) de 97,87% e uma sensibilidade (SE) de 78,43% e, em (BARATA *et al.*, 2013), os métodos utilizados no sistema obtiveram um índice de 100% em SE e de 75% em SP.

A difícil tarefa de analisar lesões dermatoscópicas para o diagnóstico do melanoma tem influenciado o desenvolvimento de novos métodos que auxiliem o ser humano na realização dessa tarefa. Isso mostra que os sistemas de VC passam a ser de grande interesse e com um potencial enorme a ser explorado como ferramentas de apoio ao diagnóstico do câncer de pele.

## 1.2 OBJETIVO GERAL

O presente trabalho tem como objetivo principal desenvolver uma solução para dispositivos móveis que utilize técnicas de VC para realizar a tarefa de análise das lesões dermatoscópicas, classificar as informações extraídas das imagens utilizando uma Rede Neural e emitir um pré-diagnóstico sobre o diagnóstico do câncer de pele, baseado em imagens dermatoscópicas obtidas a partir do próprio dispositivo móvel, que servirá de ferramenta de apoio para profissionais de saúde não especializados em dermatologia (médicos clínicos gerais, enfermeiros) e dermatologistas.

## 1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada da seguinte forma: Nos capítulos 2, 3 e 4 são apresentados, respectivamente, os aspectos conceituais relacionados a *Mobile Health*, Visão

Computacional, Redes Neurais, e os trabalhos relacionados com cada um desses assuntos. No Capítulo 5 são apresentados os métodos desenvolvidos para cada etapa do sistema. O Capítulo trata dos resultados e discussões dos métodos apresentados no capítulo anterior. E, por fim, o Capítulo 6 apresenta as conclusões e trabalhos futuros.



## 2 MOBILE HEALTH

Os celulares/*smartphones* estão cada vez mais presentes no cotidiano das pessoas em todo mundo. Segundo a *International Telecommunication Union* (ITU, 2014), até o final de 2014, o número de celulares no mundo chegará a quase 7 bilhões de unidades. Isso quer dizer que 96% da população mundial possui um celular, onde os países emergentes representam 78% de todos os celulares em uso no planeta.

Assim como a quantidade de celulares, as redes de telefonia móvel e o acesso à internet vêm aumentando com o passar dos anos. A expansão da tecnologia e o barateamento desses dispositivos impulsionaram o desenvolvimento de aplicações para as mais diferentes áreas, e a saúde vem se beneficiando com essa evolução através das aplicações de *Mobile Health* (Saúde Móvel).

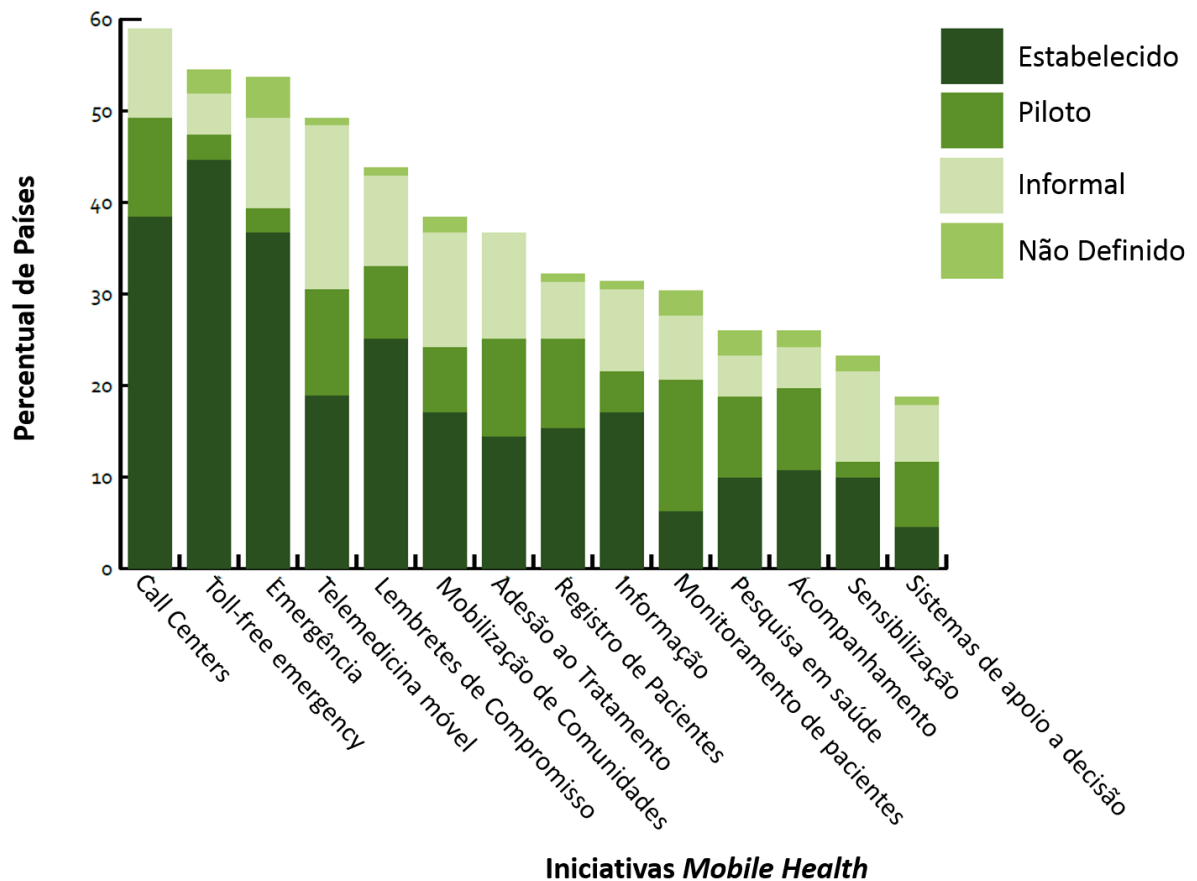
*Mobile Health* é o termo utilizado para prática da medicina e da saúde pública suportados por dispositivos móveis, como telefones celulares, *smartphones*, dispositivos de monitoramento de pacientes, *tablets*, PDAs e outros dispositivos sem fio (KAY, 2011) (CONSULTING, 2009). Aplicações de *Mobile Health* incluem o uso de dispositivos móveis para aumentar o acesso aos cuidados de saúde e à informação relacionada com a saúde (em especial para as populações de difícil acesso), além de prover suporte à melhoria da capacidade de diagnosticar e controlar doenças, ao acompanhamento de pacientes em tempo real, aos sistemas de apoio à decisão, à prestação direta de cuidados de saúde através de *call centers* e linhas diretas de ajuda, entre outros.

O uso da tecnologia para melhorar problemas existentes nos sistemas de saúde, principalmente de países em desenvolvimento, e o crescente aumento de acesso a dispositivos móveis podem ser entendidos como fatores motivacionais para pesquisas no campo de *Mobile Health* (CONSULTING, 2009).

O potencial apresentado pelo uso de *Mobile Health* para solucionar problemas foi reconhecido pela Organização da Nações Unidas (ONU) e pela Organização Mundial de Saúde (OMS), como pode ser visto na pesquisa apresentada por Kay (2011). A pesquisa sobre o uso de *Mobile Health* envolveu 112 países, onde 83% dos 112 participantes relataram a presença de pelo menos uma iniciativa de *Mobile Health* no país. Isso sem contar com os trabalhos desenvolvidos por pequenas empresas ou organizações não governamentais. Os países que

possuem iniciativas também relataram a implantação de quatro ou mais tipos de iniciativas em *Mobile Health*.

O gráfico apresentado na Figura 1 mostra as iniciativas desempenhadas no desenvolvimento de aplicações em *Mobile Health*.



**Figura 1** – Percentual de Iniciativas de *Mobile Health*.

Fonte: Adaptado de (KAY, 2011).

A diversidade de aplicações relacionadas à saúde e a disponibilidade de dispositivos móveis impulsiona cada vez mais o crescimento e popularização do *Mobile Health*. Na próxima seção são apresentados alguns trabalhos relacionados.

## 2.1 TRABALHOS RELACIONADOS

Os dispositivos móveis possuem inúmeras funções. Essas funções permitem o desenvolvimento de aplicações para os mais variados tipos de funcionalidades. A qualidade

dessas aplicações é um fator fundamental, visto que as mesmas são desenvolvidas para auxiliar problemas relacionados com a saúde de seres humanos.

Aplicações para o acompanhamento e controle do diabetes por exemplo, devem atender a algumas características. No trabalho apresentado por Chomutare *et al.* (2011), os autores fizeram uma revisão sobre aplicações de *Mobile Health* para a auto-gestão do diabetes. O artigo faz um estudo sobre as principais características de aplicações móveis para cuidados com diabetes, de acordo com as recomendações das diretrizes clínicas para auto-gestão dessa doença.

A pesquisa foi realizada nas lojas de aplicativos on-line (*Apple Store*<sup>1</sup>, *Google Play*<sup>2</sup>, *BlackBerry*<sup>3</sup>, *Nokia*<sup>4</sup> e *Symbian*<sup>5</sup>) e em trabalhos relacionados ao uso de aplicações móveis para o diabetes, onde essas aplicações deveriam atender uma pelo menos uma das seguintes características: automonitorização; informações sobre glicose no sangue, peso, atividades físicas, dieta, medicamentos e insulina e pressão arterial; suporte à educação, portais e sistemas de transferência de dados e comunicação, alerta e lembretes relacionados à doença; integração com as mídias sociais; e sincronização com sistemas de registro pessoal de saúde (SMITH; SCHATZ, 2010) ou portais com informações do paciente.

Dentre as 973 aplicações encontradas, 137 atenderam aos critérios de seleção. A pesquisa revelou que a educação, um fator crítico fortemente recomendado pelas diretrizes clínicas, não estava inclusa nas aplicações encontradas e, apesar da quantidade de aplicações disponíveis para as pessoas com diabetes, muitos requisitos ainda precisavam ser incluídos para atender às recomendações elaboradas para essas aplicações e assim melhorar suas funcionalidades.

Como foi abordado anteriormente, em um país emergente e com dimensões continentais como o Brasil, *Mobile Health* torna-se uma solução muito útil para inúmeros problemas. Várias aplicações para as mais diferentes finalidades estão sendo desenvolvidas. No trabalho apresentado por Oliveira e Costa (2012) é descrito o desenvolvimento de um aplicativo móvel de referência sobre vacinação no Brasil. O aplicativo multiplataforma foi construído utilizando um *framework* de programação voltado para dispositivos móveis implementado com as tecnologias HTML, CSS e Java Script. Para o desenvolvimento também foi utilizado uma base de dados fornecida pelo Ministério da Saúde do Brasil, do Programa Nacional de Imunização.

---

<sup>1</sup> <http://store.apple.com/br>

<sup>2</sup> <https://play.google.com/store>

<sup>3</sup> <http://appworld.blackberry.com/webstore/?lid=br:bb:apps&lpos=br:bb:apps&countrycode=BR&lang=en>

<sup>4</sup> <http://store.ovi.com/>

<sup>5</sup> [http://symbian.apps.opera.com/pt\\_br/](http://symbian.apps.opera.com/pt_br/)

O sistema disponibiliza um conteúdo sobre vários tipos de vacinas para atender a diferentes profissionais de saúde. O sistema foi avaliado por usuários que verificaram funções como: facilidade de uso, tempo de carregamento, adequação à resolução da tela, frequência de uso e relevância dos dados.

O uso de sistemas para acesso à informação e ao histórico de consultas e doenças contribui para a tomada de decisão e, conseqüentemente, para um melhor diagnóstico e prevenção de doenças. O trabalho apresentado por Paz *et al.* (2012) descreve uma aplicação móvel que utiliza princípios de Computação Ubíqua (WEISER, 1993) para consultar informações de pacientes em ambientes hospitalares utilizando aplicações sensíveis ao contexto (NUNES *et al.*, 2012). O sistema destaca informações relevantes sobre o histórico de doenças do paciente para auxiliar no diagnóstico ou tratamento de doenças. Para isso, o sistema realiza troca de mensagens entre as aplicações e as bases de dados, identificando informações do paciente que são relevantes no momento do atendimento. Essas informações são filtradas e relacionadas com a especialidade do profissional de saúde. A aplicação explora, assim, a atenção do usuário nas informações que sejam cruciais, e ajuda o médico ou outro profissional a obter um diagnóstico rápido. Alguns testes foram feitos e mostraram que o sistema é capaz de fornecer um serviço de atendimento ágil utilizando dados relevantes sobre o estado de saúde do paciente, contextualizando as informações a partir do perfil do usuário.

A utilização de dispositivos móveis para facilitar o acesso à informação e auxiliar o profissional de saúde na realização de exames também é visto no trabalho apresentado por Correia *et al.* (2012). Nesse trabalho, os autores apresentam o Nutrimobile, uma aplicação para dispositivos móveis, na plataforma Android, que auxilia o nutricionista na avaliação nutricional de pacientes/clientes de acordo com as seguintes etapas: Antropometria, Exames Bioquímicos, Avaliação Dietética, Cálculos Energéticos, Anamnese e Dieta.

O sistema foi desenvolvido baseado nas necessidades do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto (HCFMRP) que, segundo os autores, realiza a avaliação nutricional dos pacientes hospitalizados através de um questionário em papel, assim como o cálculo e a formulação da doença. O sistema automatiza a avaliação nutricional reduzindo o tempo gasto em uma avaliação assim como melhora o atendimento e o controle dos dados do paciente. Os resultados apresentados pelo Nutrimobile mostram que o processo de avaliação nutricional ficou mais rápido e confiável, auxiliando o trabalho dos profissionais de nutrição.

Em Almeida, Endler e Haeusler, (2012), os autores apresentam o desenvolvimento de uma ferramenta para a geração de aplicativos móveis, contendo um questionário customizado

para o acompanhamento a distância de pacientes com doenças crônicas. O objetivo desse trabalho é apresentar um protótipo de uma aplicação de monitoramento remoto de pacientes, capaz de gerar de forma automática questionários para dispositivos móveis a partir de uma base de conhecimento contendo descrições formais (tipo de doença, e de tratamento, etc.), a identificação das limitações, vantagens e desvantagens da abordagem.

O protótipo utiliza um conjunto de sintomas que são associados a um questionário, que é produzido por um especialista que escolhe os sintomas que estão relacionados ao paciente. O paciente executa a aplicação em seu dispositivo e responde o questionário. As respostas são enviadas para a aplicação do médico, que analisa as informações e avalia o estado do paciente.

O trabalho apresentado por Navarro *et al.* (2012) apresenta o aplicativo AdaFarma, que interliga as partes envolvidas no processo pós-consulta, são elas: o grupo médico, para a criação de receitas; as redes de farmácia, para obtenção de dados farmacêuticos; e os pacientes. O aplicativo pode recuperar os dados de uma receita via um código e, a partir disso, apresentar a rota de menor custo até a farmácia mais próxima para que o paciente possa obter os medicamentos. Além disso, ele é capaz de avaliar os medicamentos do programa Farmácia Popular, apresentar alertas e instruções prescritas para o uso do medicamento e oferecer o histórico de uso para melhor controle do tratamento. O aplicativo fornece toda a infraestrutura necessária para interligar as partes envolvidas no processo pós-consulta.

Com relação às receitas médicas, percebeu-se que o uso de códigos para entradas de dados evitou erros de digitação, o alarme para lembrar o horário de ingerir determinados medicamentos se mostrou bastante eficiente, e o histórico com os remédios já utilizados facilita o acesso à informação aos profissionais de saúde e evita a ingestão de medicamentos que juntos reflitam em efeitos colaterais graves. Quanto à consulta dos medicamentos existentes nas farmácias, os autores sugerem a definição de um padrão para os dados de todas as farmácias e o armazenamento destes em um repositório comum. O aplicativo apresentou boa funcionalidade e o alcance dos objetivos propostos.

O uso de notificações para dispositivos móveis também é aplicado em *Mobile Health*. Essas aplicações pretendem ser uma maneira de enviar informações importante para os usuários sem que as interrupções lhes causem grande perda de atenção. Costa (2013) apresenta um estudo sobre um modelo de notificações para *Mobile Health* com base em modos de interrupção, conforme os parâmetros de Interrupção, Reação e Compreensão, e na personalização de conteúdo. O estudo realizado tenta reduzir o incômodo de interrupção de uma atividade em andamento, identificar os objetivos de notificação para profissionais de saúde e desenvolver um modelo de notificações especificamente para esta área. O modelo foi aplicado

em um protótipo de sistema de notificação e apresentado a usuários médicos, o que permitiu sua análise e refinamento quanto à adequação das configurações de apresentação, tipos de informações, periodicidade das mensagens e tipos de interrupções propostos.

Outro fator que melhorou nos dispositivos móveis foi a capacidade de armazenamento e o poder de processamento que esses dispositivos vêm apresentando nos últimos tempos, tornando possível o desenvolvimento de jogos e aplicativos de processamento de imagens, por exemplo. O trabalho apresentado por Pradi (2012) apresenta um software para a análise e detecção do câncer de pele do tipo melanoma de forma automatizada utilizando um dispositivo móvel sob a plataforma iOS<sup>6</sup>. O sistema desenvolvido captura a imagem das lesões utilizando a câmera do próprio dispositivo. A imagem capturada é submetida a uma sequência de filtros utilizados para melhorar a imagem e torná-la apta para o processo de segmentação. Com a imagem já segmentada, a próxima etapa é a extração de características. Para essa etapa, o autor utiliza a regra ABCD (NACHBAR *et al.*, 1994) (regra da dermatologia utilizada para análise de lesões de pele). Para o cálculo do resultado que determina se a lesão é maligna ou não, são aplicados pesos aos valores das características. Se o valor obtido for superior a 5.45, a lesão é considerada maligna, enquanto que se os valores estiverem entre 5.45 e 4.75, as lesões são consideradas suspeitas. O sistema apresentou bons resultados na análise do melanoma, onde o mesmo foi capaz de classificar de modo geral 90% das lesões, obtendo um nível de sensibilidade de 93,02% e um nível de especificidade de 86,95%.

O sistema desenvolvido por Ramlakhan e Shang (2011) é semelhante ao trabalho anterior. Neste trabalho os autores desenvolveram um sistema que executa sob a plataforma Android, mas a principal diferença está no processo de classificação. Os autores realizam a extração de características utilizando a regra ABCD da dermatologia e aplica os valores extraídos em um classificador KNN (FACELI *et al.*, 2013). O sistema obteve um desempenho geral de 66,7%, um nível de sensibilidade de 60,7% e um nível de especificidade de 80,5% no processo de classificação.

O uso de dispositivos móveis como ferramenta para auxiliar o diagnóstico do câncer também é visto em Massone *et al* (2009). Nesse trabalho, os autores apresentam o uso de um dispositivo móvel como uma ferramenta de triagem do câncer de pele do tipo melanoma. Os autores utilizam um celular e um dermatoscópio de bolso para capturar imagens das lesões de pele, transmitindo as imagens por e-mail ou por uma aplicação web. O estudo aponta que o uso

---

<sup>6</sup> <https://www.apple.com/br/ios/>

dessa prática teve um índice de 93% de aceitação dos profissionais de saúde, e pode auxiliar o diagnóstico do câncer.

Os trabalhos vistos nesta seção são uma pequena amostra da diversidade das aplicações de *Mobile Health*. Os três últimos trabalhos relacionados apresentam soluções relacionadas com a dermatologia e estão diretamente relacionados com o sistema desse trabalho. Comparando com o trabalho de Massone *et al.* (2009), este trabalho apresenta um sistema mais completo pelo fato do próprio sistema apresentar um parecer que possa auxiliar na decisão que será tomada sobre a lesão analisada, sem a necessidade de conexão com a internet. A dependência do uso de internet por parte do sistema pode tornar inviável o uso desse dispositivo, pois o usuário pode se encontrar em regiões onde o sinal da rede não esteja disponível, como na zona rural, por exemplo.

Em Ramlakhan e Shang (2011) e Pradi (2012) foram apresentadas propostas similares à apresentada neste trabalho. No entanto, ambos diferem deste trabalho nas técnicas utilizadas no processamento e, principalmente, na classificação da imagem, onde o primeiro utiliza um classificador KNN e o segundo utiliza a regra ABCD. As aplicações aqui apresentadas mostram que a utilização de *Mobile Health* está cada vez mais presente no nosso dia a dia, fornecendo soluções para os mais diversos problemas existentes na área da saúde.

### 3 VISÃO COMPUTACIONAL

A visão computacional (VC) é a área de estudo responsável pela extração de dados informativos a partir de uma imagem. Geralmente são desenvolvidos algoritmos que buscam automatizar determinadas tarefas que são associadas à visão humana. A extração de dados permite reconhecer, classificar, manipular e pensar sobre os objetos que compõem uma imagem (AZEVEDO; CONCI, 2003).

Um sistema de VC possui uma série de etapas que simulam a visão humana, são elas: aquisição da imagem, pré-processamento, segmentação, seleção de características, reconhecimento e classificação.

A primeira etapa é a aquisição da imagem. Essa etapa consiste em digitalizar uma cena utilizando uma câmera ou aparelho capaz de capturar imagem. Na etapa de pré-processamento, ocorrem processos como redução de ruídos e realce das imagens, geralmente, com o intuito de corrigir possíveis defeitos e/ou melhorar a qualidade da imagem. Após o pré-processamento, as imagens são submetidas à etapa de segmentação, que tem como objetivo extrair regiões de interesse do sistema que estão contidas nas imagens. Após extrair as regiões de interesse (por exemplo, uma lesão de pele), é necessário identificar as características contidas na região segmentada, onde essas características correspondem aos tipos de objetos ou informações de interesse do sistema. Com a obtenção dos objetos de interesse, é possível identificar a qual classe ou grupo essa informação pertence. Esse processo é realizado por algoritmos de classificação de dados (NIXON; AGUADO, 2008; Gonzalez; Woods, 2002).

Embora as etapas apresentadas anteriormente estejam relacionadas e em sequência, elas são independentes, de modo que alguns problemas podem ser resolvidos utilizando uma ou algumas etapas. Nas próximas subseções são apresentados os conceitos sobre imagens digitais, reconhecimento de padrões e a apresentação da biblioteca de VC *OpenCv* (INTEL, 2014).

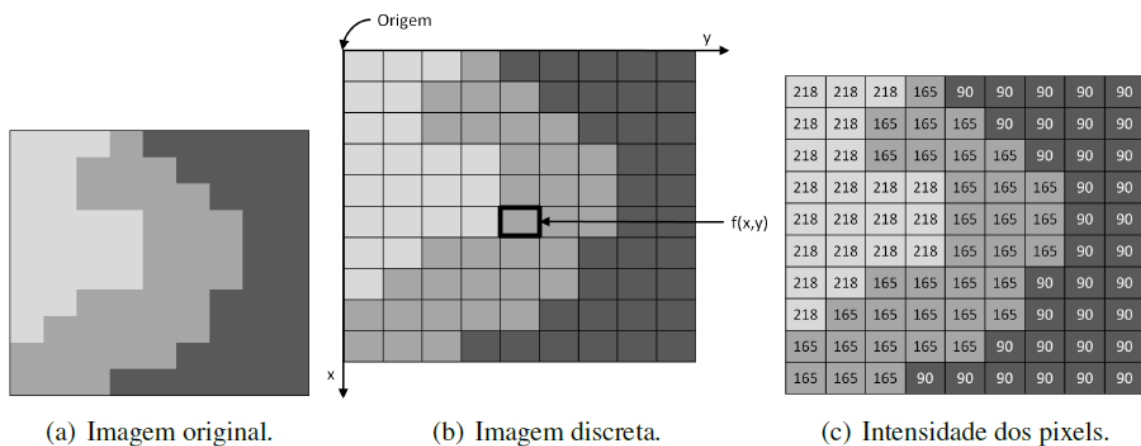
#### 3.1 IMAGENS DIGITAIS

Na área de VC, a imagem digital é o principal objeto de estudo. Uma imagem é uma função de intensidade de luz bidimensional representada por  $f(x,y)$ , onde  $x$  e  $y$  denotam as



coordenadas espaciais e o valor de  $f$  no ponto  $(x,y)$  é proporcional à luminosidade (brilho) da imagem naquele ponto.

Para processar uma imagem no computador, é preciso realizar uma amostragem de  $f(x,y)$  nas coordenadas espaciais, junto com uma quantização da intensidade luminosa. As amostras são igualmente espaçadas e arranjadas na forma de uma matriz  $N \times M$ , com cada elemento sendo uma quantidade discreta (GONZALEZ; WOODS, 2002) citado por (ROLIM, 2009). O elemento que compõe essa matriz é chamado de pixel (“*picture element*”), o qual é o menor elemento de uma imagem digital. A Figura 2 mostra a representação de uma imagem monocromática no domínio discreto e sua subdivisão em pixels.




**Figura 2** – Representação de uma imagem digital.

Fonte: (CAVALCANTE, 2014).

A Figura 2(a) apresenta a imagem em seu formato original. A Figura 2(b) exibe a conversão dos eixos para a representação de uma imagem digital. A Figura 2(c) mostra uma representação numérica dos tons de cinza, onde os valores dos pixels variam de 0 (ausência total de luminosidade) a 254 (maior intensidade de luminosidade) numa escala de 255 tons de cinza.

Para o modelo usado em imagens coloridas, chamado de RGB (abreviação de *Red* = vermelho, *Green* = verde e *Blue* = azul), por exemplo, a imagem pode ser considerada como a associação de três imagens de mesmo tamanho ( $N \times M$ ), uma com pixels na escala de tons de vermelho, uma outra em tons de verde e uma terceira em tonalidades de azul sobrepostas (Figura 3), onde a soma dos valores dos pixels das três imagens forma a cor final. Logo, quanto maior os valores de intensidade, maior será a quantidade de cores, a qualidade e o tamanho da imagem.



**Figura 3** – Superposição de matrizes formando uma imagem colorida (RGB).  
Fonte: (VIANA, 2002).

A seção seguinte apresenta alguns conceitos sobre o processo de reconhecimento de padrões e os tipos de aprendizagem de máquina.

### 3.2 RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões está relacionado com diversas áreas de pesquisa, dentre elas a VC. Em um sistema de VC, o reconhecimento de padrões está incluso na última etapa, sendo ela responsável por analisar e classificar dados utilizando algoritmos de aprendizagem.

"Reconhecimento de padrões é o processo de identificar objetos através da extração de suas características, a partir de dados sobre o objeto" (TOU; GONZALEZ, 1974) citado por (CORDEIRO, 2002). Vale ressaltar que o objeto a ser identificado pode não ser necessariamente concreto.

O processo de reconhecimento de padrões deve analisar as características retiradas de um determinado objeto, identificá-las com padrão conhecido e classificá-lo. Onde a característica é uma informação extraída do objeto observado, que ajuda a identificá-lo. O padrão é o conjunto organizado de características escolhidas para identificar o objeto. Por sua vez, um conjunto de padrões similares forma uma classe (RIBEIRO, 2003).

Para o problema de reconhecimento de padrões de um conjunto de dados, é necessário definir qual abordagem será utilizada. Vale salientar que a escolha dessa abordagem não é uma tarefa simples e, em muitos casos, faz-se necessário contar com a experiência de um especialista. Dentre as várias abordagens, pode-se citar:

- 1) **Casamento de modelos (*template matching*):** é uma das técnicas mais simples para reconhecer padrões. Corresponde a uma operação genérica usada para analisar as similaridades entre duas entidades do mesmo tipo. Essa técnica consiste na utilização de um modelo (*template*) ou protótipo do padrão a ser reconhecido. O padrão reconhecido é casado com modelos armazenados observando as variações em termo de: translação, rotação e mudanças de escalas. A medida de similaridade, normalmente, é relacionada à ideia de correlação e pode ser otimizada com base no conjunto de treinamento (JAIN; DUIN; MAO, 2000).
- 2) **Abordagem estatística:** nessa abordagem, cada padrão é representado em termos de  $d$  características que é visto como um ponto no espaço  $d$ -dimensional. O objetivo dessa técnica é formar vetores de características que possam representar diferentes padrões. O sistema de reconhecimento é treinado com um conjunto de padrões de diferentes classes. O objetivo do treinamento é encontrar os limites de decisão que melhor descrevem os padrões. Os limites de decisão são determinados pelas distribuições de probabilidade dos padrões pertencentes a cada classe (JAIN; DUIN; MAO, 2000).
- 3) **Abordagem sintática:** esta abordagem trata os padrões sob uma perspectiva hierárquica, ou seja, um padrão é composto por sub-padrões mais simples chamados de primitivos, onde o último também pode ser composto por outros mais simples, e os padrões mais complexos são representados pelas inter-relações entre os primitivos. O reconhecimento de padrões sintático faz uma analogia formal entre a estrutura dos padrões e a sintaxe de uma linguagem, onde os padrões são vistos como frases pertencentes a uma língua. Os primitivos são vistos como o alfabeto dessa língua e as sentenças são geradas de acordo com a gramática. A gramática para cada classe de padrões deve ser inferida a partir das amostras de treinamento (JAIN; DUIN; MAO, 2000).
- 4) **Redes Neurais:** As redes neurais podem ser vistas como sistemas computacionais paralelos constituídos por várias interligações e microprocessadores simples. Os modelos de redes neurais tentam usar alguns princípios organizacionais (como aprendizado, generalização, adaptabilidade, tolerância a falhas e representação distribuída, e computação) em uma rede de grafos ponderados dirigidos, em que os nós são os neurônios artificiais e as arestas dirigidas (com pesos) são conexões entre as entradas e as saídas dos neurônios. As principais características das redes neurais são: capacidade de aprendizado a problemas complexos, adaptabilidade aos dados,

e generalização. O processo de aprendizagem ocorre através da atualização da rede e dos pesos das conexões, de forma que a rede possa realizar tarefas específicas de classificação e agrupamento. O uso de redes neurais em problemas de classificação de padrões está relacionado principalmente à sua aparentemente baixa dependência de conhecimento de domínio específico e devido à disponibilidade de algoritmos de aprendizagem eficientes que podem ser utilizados (JAIN; DUIN; MAO, 2000).

Após definir a abordagem a ser utilizada, é necessário definir o tipo de aprendizado que será utilizado para reconhecer/classificar um padrão: aprendizado supervisionado ou aprendizado não supervisionado.

O aprendizado supervisionado é o tipo de aprendizado em que já se conhece previamente as categorias que se deseja classificar. Nesse tipo de aprendizado, sabe-se a quantidade de classes existentes, seus nomes, e os dados são previamente rotulados com os tipos de classes. O objetivo do aprendizado supervisionado está em realizar a classificação de um determinado dado pertencente a um conjunto, utilizando um conjunto de dados como treino para elaborar os critérios de decisão. No aprendizado não supervisionado, o conjunto de dados possui somente padrões de entrada, não há o conhecimento sobre a quantidade de classes, os tipos de classes, nomes e outras informações, ao contrário do aprendizado supervisionado, que o conjunto possui entrada e saída. O método de aprendizado não supervisionado refere-se a situações onde o objetivo principal é formar grupos de dados cujas amostras compartilham informações semelhantes (CERQUEIRA, 2010).

O processo de aprendizado é extremamente importante, pois através dele são definidos quais algoritmos serão utilizados para a tarefa de classificação. Para que ocorra o processo de aprendizado, é necessário treinar o algoritmo. Para isso, um conjunto de dados é dividido, por exemplo, em um conjunto de treino e um de validação. O conjunto de treino possui a maior porcentagem dos dados do conjunto original e exemplos de todas as classes existentes no sistema. Para validar o treinamento realizado, utiliza-se o conjunto de validação, preferencialmente com dados que não estejam no conjunto de treino, onde os dados são aplicados, e ao final observa-se a capacidade de classificação do algoritmo utilizado.

Neste trabalho será abordado um problema de classificação de padrões de imagens dermatoscópicas. Para isso foi escolhida a abordagem de redes neurais (apresentada no Capítulo 4) com aprendizado supervisionado. Na próxima seção será apresentada a biblioteca de visão computacional *OpenCV*. Essa biblioteca implementa várias técnicas de processamento de imagem, além de vários algoritmos de aprendizagem de máquina utilizados no reconhecimento de padrões.

### 3.3 BIBLIOTECA *OPENCV*

*Open Source Computer Vision Library (OpenCv)* é uma biblioteca de código aberto desenvolvida originalmente pela Intel (INTEL, 2014) e voltada para desenvolvimento de aplicações na área de VC. A biblioteca foi escrita em C e C++, possui interface com as linguagens C, C++, Java e Python e pode ser executada nas plataformas Unix, Linux, Windows, Mac OS, Android e Unidade de Processamento Gráfico (GPU) Nvídia (CUDA) (NVIDIA, 2014).

Um dos objetivos do *OpenCv* é fornecer uma infraestrutura para o desenvolvimento de aplicações sofisticadas na área da VC. Esta biblioteca inclui um grande conjunto de algoritmos, alguns tidos como clássicos e outro considerados no estado da arte, tais como: segmentação, reconhecimento de faces, aprendizado de máquina, filtragem de imagens, e rastreamento de movimento. Esses algoritmos podem ser utilizados em aplicações de interface homem-máquina, identificação de objetos, sistema de reconhecimento facial, reconhecimento de movimentos, gravação de vídeos, robôs móveis, reconstrução 3D, realidade virtual, e realidade aumentada (INTEL, 2014; BRADSKI; KAEHLER, 2008).

Os algoritmos de VC e aprendizagem de máquina contidos no *OpenCv* estão divididos em cinco módulos: CV + CVAUX, MLL, HighGUI, CXCORE e CVCam. No módulo CV+CVAUX estão implementadas as funções de processamento de imagens, como filtros, detecção de bordas, histogramas, detecção de cantos, transformações, análise de formas, entre outros (BRADSKI; KAEHLER, 2008).

O MLL (*Machine Learning Library*) possui um conjunto com vários algoritmos que podem ser utilizados para resolver quaisquer problemas de aprendizagem de máquina. Dentre os algoritmos existentes nesse módulo podemos encontrar algoritmos de classificação estatística, agrupamentos e regressão.

O HighGUI foi projetado no intuito de facilitar o acesso à visualização dos resultados. Esse módulo permite criar e manipular janelas que podem exibir imagens, adicionar *trackbars*<sup>7</sup> às janelas, lidar com eventos de *mouse*, funções de leitura e escrita de imagens e vídeos na memória, entre outras funções.

---

<sup>7</sup> Controle deslizante que permite ao usuário mover uma guia com o mouse ou teclado sendo que a posição relativa da guia é exibida como valor do controle.

O CXCORE contém um conjunto de algoritmos implementados que podem ser utilizados em problemas que envolvem o uso de estrutura de dados, álgebra linear, gerenciamento de memória, tratamento de erros, desenhos, texto e matemática básica.

O CVCam fornece funcionalidades para processamento de *stream* de vídeo em câmeras digitais.

O *OpenCv* fornece toda estrutura para que a maioria dos algoritmos e funcionalidades disponíveis para *desktop* possam ser implementadas em outras plataformas, oferecendo suporte para as plataformas: CUDA, Android e iOS. Neste trabalho foi utilizado o *OpenCv* para a plataforma Android. O *OpenCV Manager* é um serviço fornecido para a plataforma Android, que tem como objetivo gerenciar os arquivos binários do *OpenCV* em dispositivos de usuários finais, fornecendo benefícios como: redução no uso de memória, otimização específica de hardware para todas as plataformas, atualizações e correções de erros (OPENCV ANDRIOD, 2014). Os aplicativos desenvolvidos com o *OpenCv* precisam ter o *OpenCv Manager* instalado para que o mesmo possa funcionar. Caso o usuário final não possua o gerenciador instalado, o sistema sugere a instalação do gerenciador encaminhando o usuário ao *Google Play*.

O *OpenCv* pode ser utilizado na plataforma Android para desenvolvimento de aplicações mais simples, assim como para aplicações mais complexas. Para aplicações onde se pretende realizar funções como aplicação de filtros em imagens e vídeos, pode-se utilizar funções simples em Java. Para os casos em que é necessário utilizar funções mais complexas, como segmentação de imagens, estas só podem ser realizadas utilizando código nativo (C e/ou C++). Vale ressaltar que nem todas funcionalidades são implementadas na plataforma Android, como, por exemplo, a criação de janelas para exibição de resultados fornecidos pelo pacote HighGUI, que não são compatíveis com essa plataforma. A escolha da abordagem a ser utilizada depende de uma série de fatores, dentre os quais se pode citar a complexidade de processamento a ser realizada, quais os tipos de operações aplicadas às imagens ou vídeos, a necessidade de operações de baixo nível, entre outros (OPENCV ANDRIOD, 2014).

A biblioteca *OpenCv* apresenta-se como uma boa opção para o desenvolvimento de sistemas de VC, fornecendo uma grande quantidade de algoritmos para os mais diversos tipos de problemas, facilitando o trabalho com vídeos e imagens e possibilitando o desenvolvimento para diferentes plataformas.

A próxima seção apresenta alguns trabalhos relacionados quanto ao uso da VC como solução para os mais diversos tipos de problemas e com foco especial para os sistemas de classificação de imagens dermatoscópicas.

### 3.4 TRABALHOS RELACIONADOS

O crescente número de casos de câncer de pele, principalmente do tipo melanoma, tem preocupado pessoas e organizações de saúde do mundo todo. O diagnóstico precoce do melanoma implica em um alto nível de sobrevivência para os pacientes que possuem essa doença, porém, o diagnóstico do câncer de pele do tipo melanoma não é uma tarefa simples de ser realizada. Tendo em vista as dificuldades apresentadas para o diagnóstico dessa doença, várias aplicações vêm sendo desenvolvidas para auxiliar médicos e profissionais de saúde no diagnóstico do câncer de pele do tipo melanoma.

O trabalho de Ruiz *et al.* (2011) apresenta um sistema de apoio à decisão que classifica imagens com lesões cutâneas suspeitas. O sistema baseia seu diagnóstico em três fases: detecção, descrição e classificação da lesão. Na primeira fase, o autor realiza um pré-processamento na imagem aplicando um filtro de remoção de pelo e, em seguida, a imagem é segmentada por meio de método de *thresholding Otsu* (OTSU, 1979). Na fase de detecção de características, as lesões são analisadas de acordo com a regra ABCD da dermatologia e as características extraídas são selecionadas deixando somente as características que descrevem melhor as lesões malignas. Na última fase, os autores realizam testes utilizando os classificadores: k vizinhos mais próximos (KNN – *K Nearest Neighbours*), um classificador *Bayesian*, uma rede *Multilayer Perceptron* (MLP) (FACELI *et al.*, 2013), e um método colaborativo que aglutina os três anteriores, utilizando um sistema de votos.

Os algoritmos foram avaliados quanto à taxa de classificação, à SP e à SE. Quanto à taxa de classificação, o método colaborativo obteve o melhor resultado (87.76%), seguido pela rede MLP, com 86.73%. Em termos de SP, as diferenças são maiores: a partir de uma SP de 70,21% no classificador KNN para 97,87% no método colaborativo. Neste caso, a alta SP da rede MLP (95,74%), frente à SP das técnicas mais fáceis, justifica a seleção da rede neural artificial. Apesar dos bons resultados apresentados pelos classificadores, o método colaborativo oferece os melhores resultados e os mais equilibrados, atingindo uma SP de 97,87% e uma SE de 78,43%.

Em Barata *et al* (2013), utilizou características de imagens globais e locais, utilizando uma base de dados contendo 176 imagens dermatoscópicas. Na abordagem com imagens globais, que analisa a lesão como um todo, foram abordados os classificadores *AdaBoost* (FREUND; SCHAPIRE, 1997), SVM (BURGES, 1998) e KNN. Utilizando o classificador *AdaBoost*, os autores conseguiram um desempenho de 96% de SE e 80% de SP, enquanto que

utilizando o classificador SVM atingiu um desempenho de 92% de SE e 72% de SP, ao passo que abordando o KNN atingiu um desempenho de 96% de SE e 79% de SP. Utilizando a abordagem com uso de características locais da imagem, Barata *et al.* (2013) utilizaram o método *Bag-of-Features* (BoF) (SITU, 2008), que classifica pontos de interesses detectados nas imagens contendo as lesões. Com essa técnica, os autores obtiveram uma classificação de 100% de SE e de 75% de SP. Ambos os sistemas utilizam atributos de cor e textura para classificar a lesão como sendo do tipo melanoma ou nevo benigno.

Em Soares (2008), o autor apresenta uma metodologia inteligente para análise e classificação de imagens de câncer de pele. Neste trabalho, são utilizadas técnicas de Transformada *Wavelet Packet* (TWP) (KARRAKCHOU; KUNT, 1998) para extrair as características de cor, forma e textura. As características encontradas são classificadas utilizando o algoritmo SVM (VAPNIK, 1995). O sistema apresenta um bom desempenho no processo de classificação, atingindo um nível de SE igual a 92,73% e um nível de SP igual a 86%.

Em Rosado (2009), o autor apresenta o desenvolvimento de um sistema para a classificação do câncer de pele, utilizando a regra ABCD. O sistema de classificação proposto pelo autor é composto por três módulos. O primeiro, chamado de características de baixo nível, verifica a lesão como suspeita ou não suspeita de ser um melanoma. Caso seja verdadeiro, o sistema inicia a extração das características descritas na regra ABCD. O segundo módulo é chamado de características de alto nível. Nessa fase o sistema obtém uma pontuação para cada característica semelhante à regra ABCD, e atribui o valor a cada regra através do uso do algoritmo KNN. No módulo final, chamado de Classificação final, é obtida uma decisão final quanto à malignidade da lesão. Para essa última, são utilizados três classificadores: (i) o KNN, que recebe como entrada as pontuações dos parâmetros obtidos com a regra; (ii) o classificador SVM, que recebe as características semelhantes ao método anterior; e, por último, (iii) o método de limiarização, que recebe como entrada uma combinação linear dos parâmetros obtidos com a regra ABCD.

Ao final do processo, os classificadores obtiveram os seguintes resultados: o KNN obteve 82% de SE e 61% de SP; o SVM obteve o pior desempenho, apresentando apenas 36% de SE e 61% de SP; o método de limiarização foi o que obteve o melhor desempenho entre os três, onde o mesmo conseguiu uma média de 72% de Se e 70% de SP.

No trabalho apresentado por Oliveira (2012), o sistema consegue identificar diferentes tipos de lesões de pele, são elas: nevos melanocíticos, ceratose seborreica e o melanoma. Para isso, são extraídas das imagens características da regra ABCD e da análise de textura. O sistema



utiliza o modelo de difusão anisotrópica (BARCELOS; BOAVENTURA; SILVA, 2003) para efetuar o pré-processamento das imagens e, para a efetuar a segmentação, o autor utilizou o modelo de contorno ativo sem borda de Chan Vese (CHAN; VESE, 2001). Os dados foram classificados utilizando SVM. O método de contorno ativo foi avaliado e o mesmo atingiu um índice de 94,36% para a detecção de contorno, sendo 91,43% deles avaliados como bons e o restante como razoável. O desempenho do classificador foi analisado para cada um dos casos, ou seja, para a diferenciação entre os nevos e a ceratose seborreica, o algoritmo obteve uma média de 79,01% de acerto. Para a diferenciação entre o melanoma e os nevos, o algoritmo obteve uma taxa de 74,36% de acerto, e, para a diferenciação entre o melanoma e a ceratose seborreica, o algoritmo conseguiu classificar corretamente 74,33% dos casos.

Os trabalhos apresentados nesta seção utilizam diferentes técnicas para reconhecer e classificar imagens de lesões de pele, onde os resultados apresentados pelos sistemas mostram que eles podem ser boas opções de ferramentas para auxiliar profissionais da saúde na detecção do câncer de pele do tipo melanoma.

## 4 REDES NEURAIAS

A busca por sistemas capazes de reproduzir ações humanas tidas como simples, como, por exemplo, mover um braço e caminhar, envolvem o uso de diferentes funções, tais como memória, aprendizagem e coordenação motora. Tais ações são simples de serem executadas pelo cérebro humano, porém não são triviais para um computador.

A rapidez e a facilidade em executar tais ações motivou o estudo sobre o cérebro humano, analisando sua estrutura e funcionamento com o objetivo de simular a capacidade de aprendizado e aquisição de conhecimento do mesmo em um computador, surgindo assim as Redes Neurais Artificiais (RNAs).

A procura por modelos capazes de representar o conhecimento surgiu na década de 1940 a partir dos estudos realizados por McCulloch e Pits (1943), onde os mesmos propuseram um modelo matemático de neurônio artificial em que os neurônios executavam funções lógicas simples e cada neurônio tinha a capacidade de executar diferentes tipos de funções. Os estudos apresentados por McCulloch e Pits mostraram que a combinação dos neurônios artificiais era capaz de produzir sistemas com alto poder computacional, mas inicialmente essas redes não possuíam a capacidade de aprendizado (FACELI *et al.*, 2013).

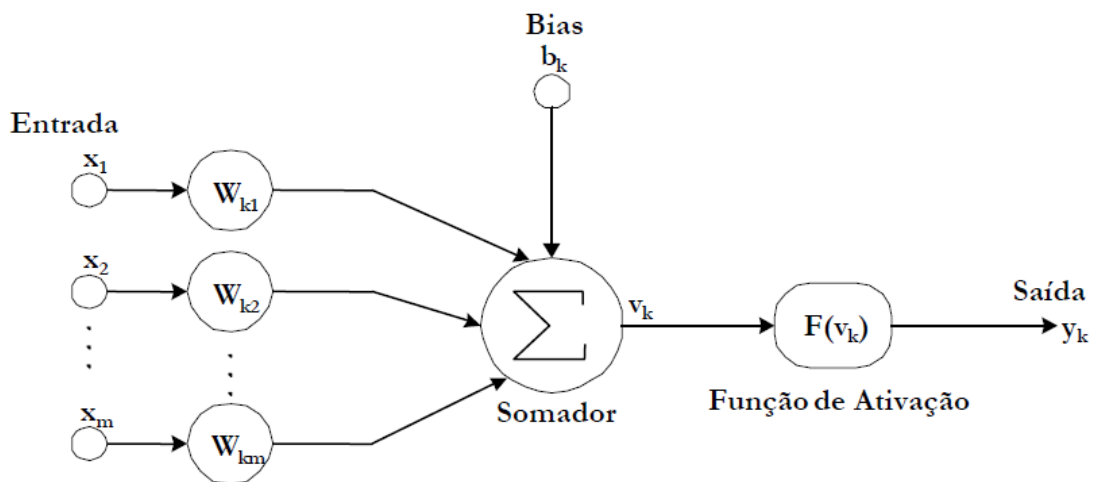
A evolução dos computadores ajudou as pesquisas sobre RNAs, possibilitando o desenvolvimento de novas arquiteturas, com maior capacidade e com algoritmos mais sofisticados. As RNAs vêm sendo cada vez mais utilizadas devido a características como (HAYKIN, 2001):

- Capacidade de trabalhar com problemas não-lineares;
- Capacidade de aprendizado, obtido através do treinamento com um conjunto de amostras contendo exemplos de entrada e saída (aprendizado supervisionado);
- Adaptabilidade;
- Resposta a evidências;
- Informação contextual;
- Generalização; e
- Tolerância a falhas.

A próxima seção apresenta uma breve descrição sobre as Redes Neurais Artificiais (RNAs).

#### 4.1 REDES NEURAIS ARTIFICIAIS (RNAs)

As RNAs são sistemas computacionais distribuídos compostos de unidades de processamento simples, densamente interconectadas, onde essas unidades são conhecidas como neurônios artificiais (FACELI *et al.*, 2013). Assim como no sistema nervoso, o neurônio artificial é a unidade fundamental para o processamento de informação de uma RNA. A Figura 4 apresenta o modelo de um neurônio artificial.



**Figura 4** – Modelo do Neurônio Artificial.


Fonte: (OLIVEIRA, 2005).

No neurônio artificial os valores são recebidos pelas entradas ( $x_1, x_2 \dots x_m$ ) e são ponderados pela ação dos respectivos pesos sinápticos ( $W_{k1}, W_{k2} \dots W_{km}$ ) e combinados por uma função matemática  $V_k$ . Em seguida, a saída gerada pelo somador é aplicada a uma função de ativação  $F(V_k)$ , que restringe a amplitude do sinal de saída ao condicionador de ativação do sinal à ultrapassagem de um determinado limiar pelo valor da soma ponderada das entradas. A saída gerada pela função de ativação  $y_k$  é a resposta do neurônio para as entradas que lhes foram apresentadas. Complementarmente o *bias*  $b_k$  pode ser utilizado para aumentar ou diminuir a entrada da função de ativação (OLIVEIRA, 2005).

Várias funções de ativação podem ser encontradas na literatura. Exemplos de funções de ativação comumente utilizadas são apresentadas na Tabela 1 e na Figura 5.

**Tabela 1** – Exemplos de funções de ativação. (OLIVEIRA, 2005; HAYKIN, 2001)

Função de Ativação	Equação	Comentários
Linear	$F(V_k) = V_k$	Implica como retorno de saída o valor de $V_k$
Limiar	$F(V_k) = \begin{cases} 0, & V_k < 0 \\ 1, & V_k \geq 0 \end{cases}$	Assume o valor 1, se o campo local induzido do neurônio é não negativo, e 0 caso contrário
Sigmoide	$F(V_k) = \frac{1}{1 + e^{(-aV_k)}}$	Variando o parâmetro $a$ obtém-se funções sigmoides com diferentes inclinações.

**Figura 5** – Exemplos de funções de ativação: (a) linear, (b) limiar e (c) sigmoide.

Fonte: Autoria própria

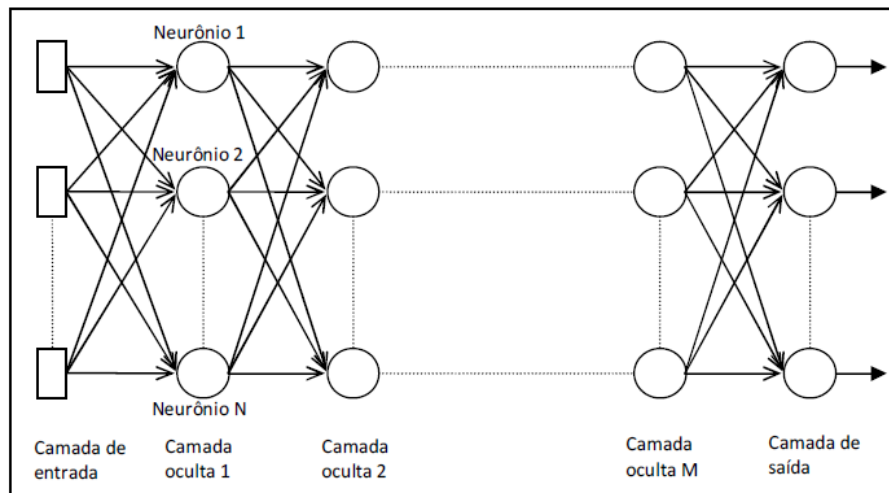
A seguir é apresentada a arquitetura de uma RNA do tipo *Multilayer Perceptron* e o algoritmo de treinamento *backpropagation*.

#### 4.2 RNA MULTILAYER PERCEPTRON (MLP)

Definir a arquitetura de uma RNA é uma tarefa de fundamental importância, pelo fato da sua organização depender do problema a ser tratado pela rede. Outro fator que também está ligado à arquitetura da rede é o tipo de algoritmo utilizado para o treinamento da RNA. Dentre os vários tipos de arquiteturas existentes, a rede *Multilayer Perceptron* é uma das mais utilizadas. Essa arquitetura foi escolhida para ser utilizada neste trabalho.

As redes MLPs são formadas por grupos de neurônios organizados em forma de camadas. A Figura 6 apresenta a estrutura de uma rede MLP. Na primeira camada temos as entradas, unidades sensoriais que não possuem poder de processamento, seguida pela camada oculta (que pode possuir uma ou várias camadas), formada por grupos de nós computacionais

(*perceptrons*), e, por fim, uma camada de saída, também formada por nós computacionais. O sinal recebido pela entrada se propaga por todas as camadas da rede (PRADO, 2014).



**Figura 6** – Arquitetura de uma RNA *Multilayer Perceptron*.  
Fonte: (PRADO, 2014).

A rede apresentada na Figura 6 é considerada como um modelo totalmente conectado, uma vez que todos os neurônios de uma camada estão ligados a todos os neurônios da camada seguinte. Caso esteja faltando alguma conexão na rede, dizemos que a mesma está parcialmente conectada.

Em uma rede MLP, cada neurônio realiza uma função específica. A função implementada por um neurônio de uma dada camada é uma combinação das funções realizadas pelos neurônios da camada anterior que estão conectados a ele. O processamento se torna mais complexo à medida em que o processamento avança nas camadas. A combinação das funções desempenhadas por cada neurônio da rede define a função associada à RNA como um todo (FACELI *et al.*, 2013).

Para que uma rede MLP seja capaz de solucionar um determinado problema, é necessário realizar o treinamento da mesma. Na seção seguinte é apresentado um algoritmo utilizado no treinamento de redes MLP.

#### 4.3 ALGORITMO BACKPROPAGATION

O *Backpropagation* é o principal algoritmo utilizado para o treinamento de redes MLP. Sua técnica consiste em realizar iterações em duas fases, uma fase para frente (propagação) e

outra fase para trás (retropropagação). Na fase de propagação, cada objeto de entrada é apresentado à rede. O objeto é primeiramente recebido por cada um dos neurônios da primeira camada oculta. Os objetos são ponderados pelos pesos associados às conexões de entrada correspondentes ao neurônio  $e$ , em seguida, o valor total recebido é aplicado à função de ativação e a saída produzida pela função é utilizada como entrada para o neurônio da próxima camada. Esse processo é repetido até os neurônios da camada de saída. Os valores gerados pelos neurônios da camada de saída são comparados com a saída desejada. O cálculo da diferença entre esses valores indica o erro cometido pela rede (FACELI *et al.*, 2013). O valor do erro de cada neurônio da camada de saída é então utilizado na fase de retropropagação para ajustar os pesos de entrada, o algoritmo *backpropagation* é descrito como:

---

**Algoritmo 1** – Pseudo-código *Backpropagation*

---

1. Inicializar pesos e bias
  2. Apresentar o padrão de entrada juntamente com sua respectiva saída desejada
  3. Propagar esse padrão de camada em camada de forma que seja calculada a saída para cada nodo da rede
  4. Comparar a saída gerada pela rede com a saída desejada e calcular o erro cometido pela rede para os nodos da camada de saída
  5. Atualizar os pesos dos nodos da camada de saída com base no erro cometido por tais nodos
  6. Até chegar à camada de entrada:
    - a. Calcular o erro dos nodos da camada intermediária baseado no erro cometido pelos nodos imediatamente seguintes ponderados pelos pesos entre os nodos da camada atual e os nodos imediatamente seguintes
  7. Repetir os passos 2, 3, 4, 5 e 6 até obter um erro mínimo ou até atingir um dado número de iterações
- 

O funcionamento do algoritmo *Backpropagation* é apresentado na sequência de passos a seguir (PRADO, 2014). Para o exemplo apresentado a seguir, considera-se uma rede com uma camada oculta e uma camada de saída.

**Passo 1:** Cálculo da função de transferência, conforme Equação 1.

$$v = \sum x_i * w_i + b_i \quad (1)$$

Onde “ $x$ ” corresponde às entradas, “ $w$ ” são os pesos e “ $b$ ” é o bias do neurônio.

**Passo 2:** Cálculo da função de ativação para o tipo linear, conforme Equações 2.

$$\varphi(v) = v \quad (2)$$

Onde “ $v$ ” corresponde ao resultado da Equação 1.

Cálculo para a função do tipo sigmoide, conforme Equação 3;

$$\varphi(V_k) = \frac{1}{1 + e^{(-V_k/T)}} \quad (3)$$

Início do processo de propagação para trás (retropropagação);

**Passo 3:** Cálculo do erro de saída, conforme a Equação 4.

$$e = d - y \quad (4)$$

onde “ $d$ ” corresponde ao valor da saída desejada e “ $y$ ” é a saída do neurônio.

**Passo 4:** Cálculo dos gradientes de saída e atualização dos pesos da camada de saída, conforme equações 5 e 6.

$$\delta_{10}(n) = e \cdot \varphi' \quad (5)$$

$$w_{10}(n + 1) = w_{10}(n) + \eta \cdot \delta_{10} \cdot x_1 + \alpha \cdot w_{10}(n - 1) \quad (6)$$

onde  $\varphi'$  representa a derivada da função de ativação,  $\eta$  é o coeficiente de aprendizado,  $\delta_{10}$  é o gradiente local do neurônio de saída e  $\alpha$  é o coeficiente de momento.

**Passo 5:** Cálculo dos gradientes da camada oculta e atualização dos pesos da camada oculta, conforme equações 7 e 8.

$$\delta_{1H}(n) = \varphi' \cdot \sum_{k=1}^2 \delta_{k0} \cdot w_{k0} \quad (7)$$

$$w_{1H}(n + 1) = w_{1H}(n) + \eta \cdot \delta_{1H} \cdot x_1 + \alpha \cdot w_{1H}(n - 1) \quad (8)$$

onde  $\delta_{k0}$  são os gradientes locais nos neurônios da camada de saída,  $\delta_{1H}$  é o gradiente local do neurônio da camada oculta em que está sendo corrigido o peso e  $\alpha$  é o coeficiente de momento.

O procedimento apresentado acima é repetido várias vezes até que o valor do erro esteja abaixo de um limiar desejado para o problema ou quando a rede atender algum critério de parada (HAYKIN, 2001; PRADO, 2014).

#### 4.4 TRABALHOS RELACIONADOS

As redes neurais são utilizadas nos mais diferentes processos de classificação. No trabalho apresentado por Oliveira (2005), o autor faz o uso de RNAs em um sistema de detecção, classificação e localização de defeitos em linhas de transmissão. A rede é alimentada por meio da análise de tensões e correntes trifásicas. Após a análise, os dados são aplicados na entrada da rede de detecção, que possui 12 entradas correspondentes aos módulos e ângulos das tensões e correntes trifásicas, e 1 saída, que representa o estado de operação da linha: normal

ou sob defeito. Quando a rede de detecção acusa um curto-circuito, o módulo de classificação composto por 12 entradas e 4 saídas é ativado. O módulo de classificação recebe os sinais da região de defeito e identifica as fases envolvidas no distúrbio. Após identificar o defeito, o módulo de localização é ativado. Esse módulo é composto por redes especialistas para cada tipo de problema. O módulo de localização recebe as entradas apresentadas no módulo de classificação e, como resultado, apresenta o local de ocorrência do distúrbio.

As redes neurais também são utilizadas para classificar lesões de pele através de imagens. No trabalho apresentado por Mhaske e Phalke (2013), os autores utilizam uma técnica de limiarização para segmentar as imagens de câncer de pele. As características são extraídas utilizando a transformada *wavelet* (SARRAFZADE; BAYGI; GHASSEMI, 2010) e para o processo de classificação são utilizadas técnicas de aprendizado supervisionado e não supervisionado. Para o método supervisionado, os autores utilizam uma rede MLP com algoritmo *backpropagation* e uma SVM. Para o modelo não supervisionado, é utilizado o algoritmo de agrupamento *k-means* (JAIN; RICHARD, 1988). Para o aprendizado não supervisionado, o algoritmo *k-means* obteve uma acurácia de 52,63%. Os algoritmos de aprendizado supervisionado conseguiram um desempenho melhor que o método anterior, obtendo uma acurácia entre 60% e 70% para a rede neural e entre 80% e 90% para o SVM.

Em Mahmoud; Al-Jumaily e Takturi (2011) é apresentado um sistema de classificação de imagens de lesões de pele. Neste trabalho os autores utilizam dois métodos de segmentação: segmentação por região de interesse e segmentação por crescimento de regiões. Para a extração de características também são utilizados dois métodos: Transformada *Wavelet* (SIKORSKI, J. 2004) e a Transformada *Curvelet* (CANDES, E. J. et al., 1999; CANDES; DONOHO, 2004). O sistema utiliza uma rede neural com o algoritmo *backpropagation* para classificar as características das imagens. O sistema obteve um índice de acerto de 55,94% para a rede neural utilizando a transformada *Wavelet* e 70,44% utilizando a transformada *Curvelet*.

Em Ruiz *et al* (2008) também foi apresentado um sistema de classificação de imagens de lesões de pele. O sistema realiza um pré-processamento nas imagens para eliminar ruídos e pelos das lesões, e segmenta as imagens utilizando o método de limiarização de Otsu. Para a extração de características, as mesmas foram divididas em três grupos: um relacionado com a forma, outro com a fronteira e outro com a cor. Para a classificação, os autores utilizam um classificador de *Bayesian* e uma rede MLP para classificar as lesões como benignas ou melanoma. A classificação final da lesão é obtida através da análise do resultado dos dois classificadores. Por exemplo, se um classificador  $C_1$  obteve um nível de confiança de 0,97 e um classificador  $C_2$  obteve 0,85, se  $C_1$  classifica a lesão como melanoma e  $C_2$  como benigno, o



resultado final da classificação da lesão será melanoma. Essa decisão é tomada pelo fato do classificador  $C_1$  ter obtido um melhor índice de confiança. Ao final o sistema obteve uma taxa de classificação cooperativa geral de 92,15%, com a SE igual a 79,13% e a SP igual a 93,72%.

Em Surowka e Grzesiak-Kopec (2007), os autores utilizam a decomposição *wavelet-based* (CHANG; KUO, 1993) para gerar a representação multiresolução de imagens dermatoscópicas de lesões de pele potencialmente malignas. Para a classificação são utilizados os algoritmos: rede MLP, SVM e o *Attributional Calculus – AQ21* (MICHALSKI, 2004). Esse último foi utilizado para descrever observações quantitativas e qualitativas sobre as lesões analisadas, além de um acompanhamento estatístico. Como resultado, a rede MLP apresentou um índice de 97% de acerto e a SVM obteve um índice de 97,4% de acerto.

As redes neurais podem ser utilizadas não somente para a classificação. Em Vennila, Suresh e Shunmuganathan (2012), os autores utilizam diferentes tipos de redes neurais para segmentar imagens dermatoscópicas. Os autores utilizaram os seguintes algoritmos: *Backpropagation Network* (BPN), *Radial Basis Function Network* (RBF) e *Extreme Learning Machine* (ELM) (HUANG; ZHU; SIEW, 2004). Todos os algoritmos apresentaram resultados próximos à segmentação manual. Os resultados obtidos também foram comparados quanto à medida de similaridade, à sobreposição espacial, e aos falsos positivos e negativos. Os resultados apresentados nos testes mostram que *Extreme Learning Machine* apresentou o melhor desempenho no processo de segmentação.

As redes neurais podem ser utilizadas para as mais diversas finalidades. Nos trabalhos apresentados nessa seção, pode-se observar o desempenho dessa técnica quanto ao processo de classificação de lesões de pele, a partir de dados extraídos de imagens. Tendo em vista o potencial alcançado por essa técnica, a mesma foi escolhida para o processo de classificação dos dados extraídos de imagens dermatoscópicas. O Capítulo 5 apresenta o desenvolvimento do sistema, assim como os experimentos realizados e a discussão dos resultados obtidos.

## 5 DESENVOLVIMENTO, EXPERIMENTOS E RESULTADOS

Neste capítulo são apresentados o projeto e a descrição de um sistema de classificação de imagens dermatoscópicas para dispositivos móveis. As principais características e funcionalidades desse sistema são descritas assim como as etapas de processamento, algoritmos e métodos utilizados, experimentos realizados e discussão dos resultados obtidos.

### 5.1 CARACTERÍSTICAS E REQUERIMENTOS DO SISTEMA

O uso de sistemas de visão computacional na análise de imagens médicas e em especial imagens de lesões de pele tem aumentado com o passar dos anos. Uma grande variedade de sistemas dessa natureza têm sido utilizados como ferramenta para auxiliar especialistas e profissionais da saúde no pré-diagnóstico do câncer de pele do tipo melanoma. Esses sistemas variam quanto às técnicas de análise das lesões, os algoritmos utilizados para a extração de características e classificação dos dados, porém o uso de outras plataformas ainda é pouco explorado, como os dispositivos móveis por exemplo. Neste contexto, propõe-se neste capítulo descrever o desenvolvimento de um sistema de análise de imagens dermatoscópicas para dispositivos móveis, capaz de capturar imagens de lesões de pele e processá-las no próprio dispositivo utilizando técnicas de visão computacional.

O sistema desenvolvido neste trabalho é baseado no uso de um dispositivo móvel executando sob a plataforma Android, um dermatoscópio acoplado ou pareado ao dispositivo móvel e um *software* capaz de analisar as imagens obtidas pelo dispositivo. O *software* abrange um conjunto de métodos e algoritmos que juntos realizam as etapas necessárias para analisar uma lesão de pele.

Para analisar uma lesão suspeita, inicialmente o usuário (profissional de saúde) deve adquirir uma imagem da lesão. Para isso, o usuário munido de um dispositivo móvel e um dermatoscópio executa o sistema (Figura 7 (a)) e aproxima o aparelho focando a lesão suspeita, sempre certificando-se que a região da lesão esteja centralizada e totalmente dentro da área da imagem. No processo de aquisição, o sistema mostra ao usuário avisos que auxiliam o mesmo durante esse processo assim como mostra a Figura 7(b). O usuário, ao adquirir a imagem da

lesão, observa se a mesma está contida dentro do espaço da imagem, caso contrário uma nova imagem da lesão deve ser adquirida (Figura 7(c) e Figura 8(a)).

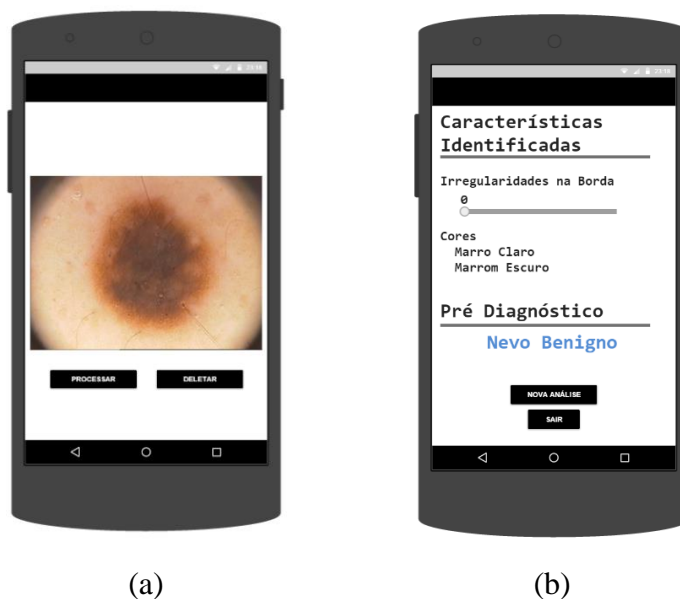


**Figura 7** – Protótipos de telas do sistema: (a) Tela Inicial, (b) Alerta ao usuário e (c) Captura da lesão.

Fonte: Autoria própria

Após adquirir a imagem da lesão, o usuário submete a mesma como entrada para o sistema (Figura 8(a)), que irá analisar a lesão observando as características B (irregularidade de borda) e C (uniformidade nas cores) da regra ABCD. O sistema executa uma sequência de passos necessários para identificar a lesão, extrair as características e classificá-las. Ao final do processamento, o sistema apresenta os valores obtidos na análise da lesão e um pré-diagnóstico que informa se a lesão é benigna ou um melanoma (Figura 8(b)).

O sistema se restringe a análise do câncer de pele do tipo melanoma, pelo fato da técnica de análise ser específica para esse tipo de câncer. Como se trata de um exame de dermatoscopia, o uso do dermatoscópio é obrigatório, pois o mesmo torna possível identificar estruturas presentes nas lesões de pele que dificilmente seriam observadas utilizando apenas a câmera do dispositivo móvel. Outro fator a ser considerado no processo de aquisição da imagem é o valor configurado para o zoom do dermatoscópio, neste caso o dermatoscópio deve ser configurado com um zoom de 20x. Este valor foi fixado devido o mesmo ter sido utilizado na aquisição das imagens que foram utilizadas no desenvolvimento e testes desse sistema.

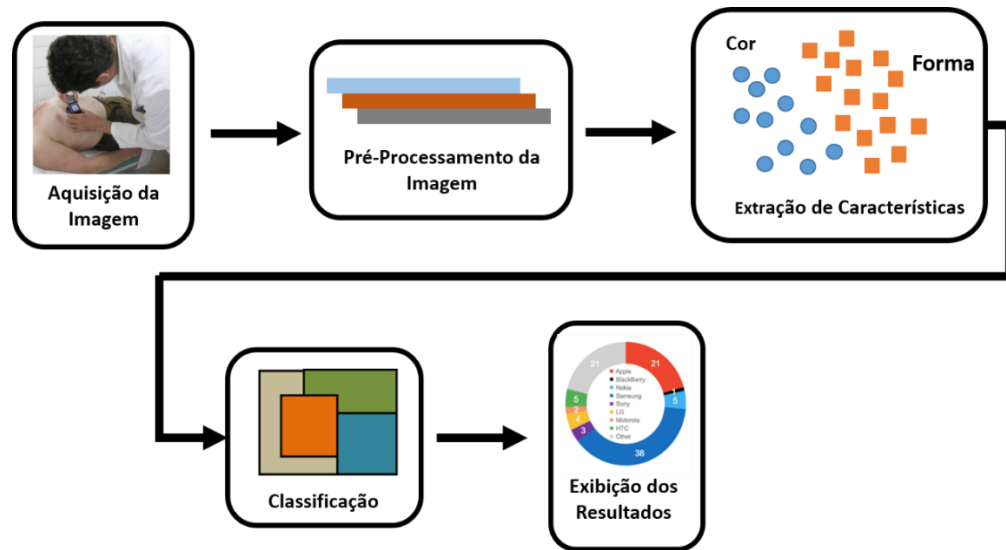


**Figura 8** – Protótipos de telas: (a) Visualização da lesão e (b) Resultados da Análise  
Fonte: Autoria própria

O uso do dermatoscópio contribui para que o sistema possa ser empregado em condições diversificadas de ambiente de modo a torná-lo uma importante ferramenta na prática clínica do exame de dermatoscopia, em regiões que carecem de profissionais especializados para a prática desse exame. Além disso, espera-se que o sistema não se mostre sensível às condições de luz apresentadas nos diferentes ambientes onde o mesmo possa ser aplicado, seja o mais automático possível e, principalmente, que apresente características de precisão e exatidão suficientes para demonstrar sua aplicação clínica e científica.

## 5.2 ETAPAS DE PROCESSAMENTO

O sistema desenvolvido é capaz de emitir um pré-diagnóstico de uma lesão de pele a partir de uma imagem da lesão adquirida com um dispositivo móvel e um dermatoscópio. A imagem adquirida passa por uma série de operações computacionais responsáveis por processar a imagem tornando-a apta para o processo de segmentação, segmentar a região da lesão, extrair informações de borda e cor, classificar essas informações e emitir um pré-diagnóstico sobre a lesão analisada. A Figura 9 apresenta a estrutura geral do sistema e os módulos necessários para a realização do pré-diagnóstico.



**Figura 9** – Estrutura Geral do Sistema  
Fonte: Autoria própria

O sistema proposto é composto dos seguintes módulos:

- Aquisição da Imagem: nesse módulo as imagens são capturadas no ato da consulta. O usuário utiliza a câmera do dispositivo móvel pareado com a lente de um dermatoscópio (Figura 10).

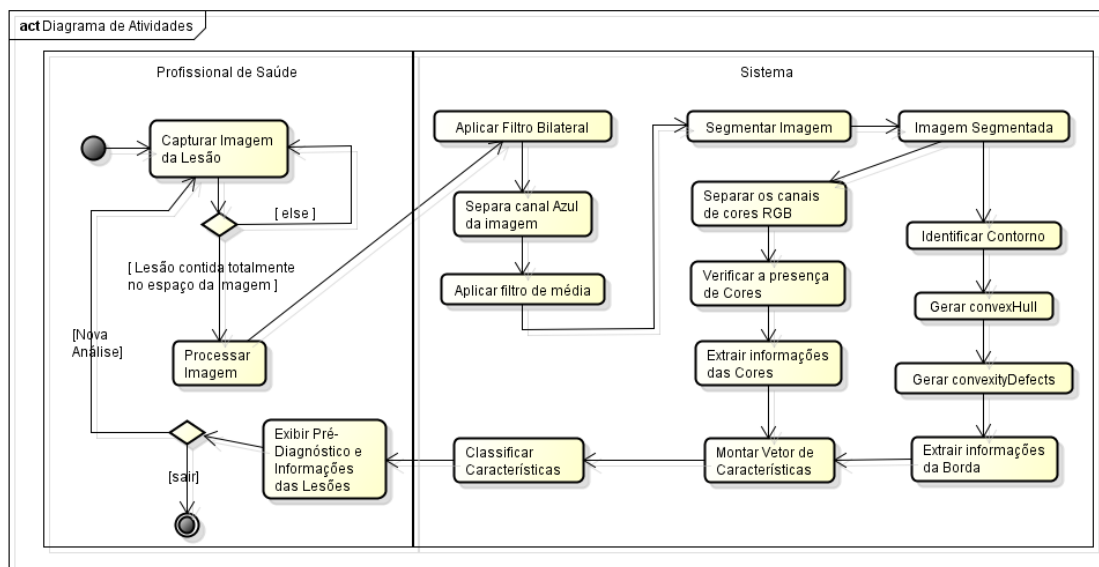


**Figura 10** – Em (a) dermatoscópio para *smartphone*, em (b) adaptador para dermatoscópio.  
Fonte: (BLEYMED, 2015).

Já é possível encontrar no mercado modelos de dermatoscópios desenvolvidos para alguns modelos de *smartphones*, como é visto na Figura 10(a), e adaptadores para *smartphones* que possibilitam acoplar um dermatoscópio ao mesmo, como mostra a Figura 10(b). Feito isso, o usuário deve se certificar que a lesão fique totalmente dentro do espaço da imagem. As imagens capturadas são salvas automaticamente no cartão de memória do dispositivo.

- **Pré-processamento da Imagem:** nesse módulo são realizadas técnicas de pré-processamento para melhorar as condições da imagem e corrigir possíveis ruídos adquiridos no processo de aquisição da imagem. A segmentação da imagem é responsável por identificar a região da lesão de pele. Para isso foi utilizado o método de limiarização de (OTSU, 1979), que analisa a imagem no canal na cor azul do espaço de cor RGB. O método resulta em uma imagem onde a região saudável é apresentada na cor preta e a região colorida representa a lesão de pele detectada.
- **Extração de Características:** esse módulo é responsável por identificar e extrair as características das lesões de pele, como borda e cor. Para análise de borda foi desenvolvido um método utilizando as funções *findContours*, *convexHull* e *convexityDefects*, todas pertencentes a biblioteca *OpenCv* (INTEL, 2014). A característica de cor foi analisada utilizando o método adaptado de (ROSADO, 2009). As características extraídas são utilizadas para montar um vetor de características que é utilizado como dado de entrada para o classificador.
- **Classificação da Lesão:** esse módulo é responsável pela classificação das informações extraídas pelo sistema. O processo de classificação utilizado neste trabalho é realizado por uma rede neural do tipo *Multilayer Perceptron* (MLP) (FACELI *et al.*, 2013) treinada com o algoritmo de aprendizado supervisionado *backpropagation* (FACELI *et al.*, 2013). O algoritmo classifica as lesões em nevo benigno e melanoma.
- **Resultado e Precisão do Diagnóstico:** nessa etapa é apresentado o resultado da classificação e as características identificadas pelo algoritmo.

A Figura 11 apresenta os passos sequenciais utilizados para a realização do pré-diagnóstico. Os primeiros passos são realizados pelos usuários (profissionais de saúde), onde o mesmo é responsável por posicionar o dispositivo de forma que a imagem capturada da lesão atenda a condição de estar contida totalmente dentro do espaço da imagem. Caso a imagem adquirida não atenda a essa condição, o usuário pode repetir essa operação repetidas vezes, até que o mesmo obtenha uma imagem aceitável para a condição imposta pelo sistema. Após a aquisição da imagem, o usuário submete a mesma para o processamento do sistema, a partir desse ponto o sistema se encarrega de efetuar todos os passos necessários para analisar a lesão.



**Figura 11** – Diagrama de Atividades do Sistema

Fonte: Autoria própria

Para isso o sistema inicia pelo módulo de pré-processamento, efetuando a aplicação do filtro bilateral. Esse filtro tem por objetivo suavizar estruturas comuns na pele humana. Em seguida o sistema utiliza a imagem suavizada no formato RGB e separa o canal B (*blue* = azul). Essa escolha justifica-se pelo fato desse canal discriminar melhor a região da lesão, assim como mostra o trabalho apresentado por Rosado (2009). Um filtro de média é aplicado à imagem na cor azul para corrigir alguns ruídos que persistiram na imagem e assim melhorar as condições para que a mesma seja submetida ao processo de segmentação. Após a aplicação dos filtros, a imagem está apta para o processo de segmentação, para isso foi utilizado o método proposto por Otsu (1979) na imagem suavizada e no canal de cor azul. A saída apresentada por esse método é uma imagem binária onde a região da lesão é apresentada na cor branca e a região de pele saudável apresenta-se na cor preta. Para concluir o processo de segmentação, é realizada uma conjunção da imagem original com o resultado da segmentação. O resultado dessa operação é uma imagem onde a região da lesão apresenta-se no formato RGB e a região de pele saudável na cor preta. Essa conjunção é necessária para deixar em evidência a região da lesão que será utilizada nos próximos passos.

Em seguida a imagem segmentada é submetida ao módulo de extração de características. Nesse módulo são verificadas inicialmente as irregularidades de bordas da lesão. Para isso o sistema utiliza as funções do OpenCV (INTEL, 2014) *findContours* para identificar a borda da lesão, *convexHull* para encontrar os pontos convexos da lesão e o *convexityDefects* para verificar as irregularidades apresentadas na lesão. Os pontos irregulares identificados são salvos

em um vetor de características que será utilizado posteriormente no processo de classificação. Para extrair as características de cor, são separados os canais RGB da imagem segmentada. Esse processo é necessário para que possa ser analisada a presença das seguintes cores: preto, branco, azul-cinza, vermelho, castanho-claro e castanho-escuro. Neste trabalho a análise das cores foi realizada utilizando a técnica adaptada do trabalho de Rosado (2009). As cores identificadas são extraídas e salvas em um vetor de características.

Formado o vetor com as informações de borda e cor, as informações são utilizadas como dados de entrada para uma RNA treinada com o algoritmo backpropagation. A rede analisa os valores contidos no vetor de características para classificar a lesão como nevo benigno ou melanoma. Ao final o sistema apresenta ao usuário as informações extraídas na análise da borda e de cor, e o pré-diagnóstico obtido pela rede neural. O usuário pode optar por realizar uma nova análise ou sair do sistema. Em seguida os módulos apresentados nesta sessão são discutidos em detalhes.

### 5.2.1 Aquisição de Imagens

Para a etapa de aquisição de imagens, inicialmente foi utilizado um conjunto de imagens dermatoscópicas da base PH<sup>2</sup> (MENDONÇA et al., 2013). Essa base foi construída a partir de uma parceria entre a Universidade do Porto, o Instituto Superior Técnico de Lisboa e o serviço de Dermatologia do Hospital Pedro Hispano em Matosinho, Portugal. As imagens foram obtidas sob as mesmas condições utilizando o sistema *Tuebinger Mole Analyzer* com uma ampliação de 20 vezes. A base é formada por um conjunto de 200 imagens no formato bmp com dimensão média de  $768 \times 560$  pixels.


As 200 imagens dermatoscópicas que constituem essa base estão divididas em três classes, sendo elas: 80 nevos comuns, 80 nevos atípicos e 40 melanomas. Exemplos de cada um dos tipos de lesões são apresentados na Figura 12.

Todas as imagens foram avaliadas por um dermatologista, que avaliou as lesões atendendo aos seguintes critérios:

- Segmentação manual da lesão de pele;
- Diagnóstico clínico e histológico (quando disponível);
- Critérios dermatoscópicos (assimetria, cores, rede de pigmento, pontos/glóbulos, estrias, áreas de regressão, véu azul-esbranquiçado).



Para a segmentação manual, os dermatologistas utilizaram um *software* de anotação personalizado para imagens dermatoscópicas chamado DerMat (FERREIRA et al., 2012).




**Figura 12** – Imagens da base PH<sup>2</sup>. A primeira linha apresenta imagens de nevos comuns, na segunda linha nevos atípicos e na terceira linha melanoma.

Fonte: (MENDONÇA *et al.*, 2013).

As imagens da base PH<sup>2</sup> foram utilizadas no desenvolvimento do sistema apresentado neste trabalho, onde as mesmas foram carregadas no cartão de memória do simulador Android, servindo como entrada para o sistema. Ao iniciar o sistema instalado no simulador Android, o mesmo utiliza uma imagem previamente carregada no cartão de memória ao invés de uma imagem capturada pela câmera. Este recurso foi adotado apenas durante a fase de desenvolvimento e testes dos algoritmos desenvolvidos para o sistema, sendo utilizado na versão final câmera do dispositivo móvel e um dermatoscópio.

Durante a realização dos testes com as imagens da base PH<sup>2</sup>, percebeu-se que algumas imagens se apresentaram inaptas a serem utilizadas pelo sistema por não favorecerem ao processo de segmentação e a análise de características, como: a lesão não está totalmente dentro do espaço da imagem (Figura 13(a)), excesso de pelos (Figura 13(b)) e baixo nível de contraste entre a lesão e a pele (Figura 13(c)).

Para os casos onde a lesão se apresenta fora dos limites da imagem (Figura 13(a)), as imagens foram retiradas devido à impossibilidade de definir a borda dessas lesões, tornando falho o processo de segmentação e consequentemente a extração de características das mesmas.



**Figura 13** – Modelo de imagens retiradas que não foram utilizadas no sistema de classificação: (a) lesão fora dos limites da imagem, (b) excesso de pelos e (c) baixo nível de contraste entre a região da lesão e a cor da pele.

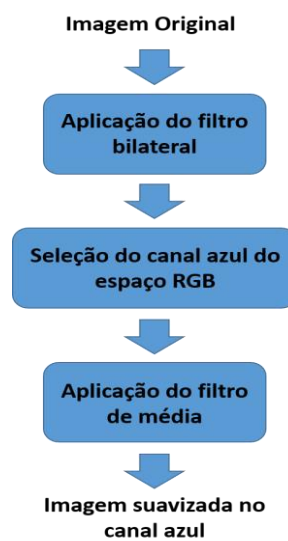
Fonte: Autoria própria

Para o caso apresentado na Figura 13(b), foi detectado excesso de pelos principalmente nas lesões de nevos comuns e nevos atípicos. As imagens com esse tipo de característica foram retiradas devido à quantidade excessiva de pelos, gerando problemas na segmentação e na análise da borda e da cor. As lesões que apresentaram baixo nível de contraste entre a região da lesão e a cor da pele (Figura 13) também foram retiradas devido ao baixo nível de contraste prejudicar em alguns casos o processo de segmentação onde o algoritmo não conseguiu identificar a região da lesão por completo.

Ao retirar as imagens das lesões que se apresentaram inviáveis para serem utilizadas no sistema, a base PH<sup>2</sup> foi reduzida de tamanho tendo na sua nova configuração 40 imagens de nevos benignos (20 nevos comuns e 20 nevos atípicos) e 10 melanomas. Para as lesões do tipo apresentado na Figura 13(a), foram identificadas 30 imagens com lesões do tipo melanoma, sendo assim das 40 imagens desse tipo de nevo apenas 10 se apresentaram aptas para o sistema. Os demais casos (Figura 13(b) e (c)) foram identificados em lesões de nevo comum e nevo atípico, sendo retiradas da base 35 imagens dessas lesões. Além das 35 imagens inaptas para o sistema, outras imagens dessas lesões foram retiradas no intuito de deixar a base com as mesmas proporções da base original, ou seja, para a base original as lesões do tipo melanoma representam 20% das imagens da base, sendo assim essa mesma proporção foi aplicada para a base com imagens aptas para esse trabalho. A diminuição também se deu devido ao processo de treinamento do algoritmo de classificação, que caso a base apresente uma diferença muito grande entre as classes contidas na mesma, pode vir a influenciar o algoritmo a classificar as informações para a classe com maior quantidade existente na base. A próxima seção apresenta os métodos desenvolvidos, testados e aplicados no módulo de pré-processamento.

### 5.2.2 Pré-Processamento

A etapa de pré-processamento é necessária para melhorar as imagens que serão utilizadas no sistema. Algumas estruturas presentes nessas imagens, tais como pequenas manchas existentes na pele, a textura apresentada por algumas lesões, pelos ou até mesmo o gel aplicado sobre a pele para realizar o exame de dermatoscopia, podem prejudicar o desempenho do sistema. As etapas do pré-processamento podem ser visualizadas na Figura 14.




**Figura 14** – Etapas do pré-processamento.

Fonte: Autoria própria

Para melhorar o desempenho do sistema, a imagem é redimensionada para 35% do seu tamanho original, resultando em uma nova imagem com tamanho menor e sem perda de características.

Para minimizar os ruídos existentes na imagem, inicialmente foi aplicado um filtro de suavização chamado filtro Bilateral (TOMASI; MANDUCHI, 1988). Esse filtro é capaz de suavizar tanto imagens em tons de cinza como imagens coloridas, preservando a borda por meio de uma combinação não linear dos pixels mais próximos de uma imagem. O filtro combina os níveis de cinza ou as cores de acordo com a proximidade geométrica e sua semelhança fotométrica, sempre escolhendo os valores mais próximos de sua vizinhança. O método utilizado pelo filtro para suavizar as imagens difere de outras técnicas pelo fato de não produzir sombras ao longo das bordas em imagens coloridas, resultando em um melhor aguçamento da

borda (TOMASI; MANDUCHI, 1988). A Figura 15 apresenta o resultado da aplicação do filtro Bilateral em uma imagem de câncer de pele do tipo melanoma.




**Figura 15** – Aplicação do filtro bilateral: (a) Imagem normal; (b) Imagem após a aplicação do filtro.

Fonte: Autoria própria

Para a obtenção do resultado apresentado acima foi utilizada a função *bilateralFilter* do pacote OpenCV. A imagem apresentada na Figura 15(a) mostra a presença de pequenos pelos, estruturas formadas pelo gel aplicado para realizar o exame de dermatoscopia e manchas naturais da pele. Percebe-se, na Figura 15(b), que a utilização do filtro eliminou os pelos, diminuiu e eliminou algumas estruturas formadas pelo gel e melhorou a textura da imagem. Também é possível notar que aplicação do filtro não alterou a estrutura da borda da lesão.

Após a aplicação do filtro Bilateral, são separados os 3 canais de cores da imagem. O canal azul foi selecionado para as próximas etapas, pois, conforme experimentos realizados no trabalho apresentado por Rosado (2009), esse canal é o que melhor discrimina a lesão. A Figura 16(a) apresenta imagem no canal de cor azul.

Separado o canal azul da imagem, a mesma é submetida novamente a um filtro de suavização, mas dessa vez é utilizado um filtro de média (*medianBlur*: função do OpenCv) com uma matriz 13x13. Esse processo é necessário para melhorar ainda mais as condições da imagem, removendo eventuais ruídos que venham a persistir na mesma. Na Figura 16(a) pode-se observar a presença de ruídos, nesse caso, o gel que persistiu na imagem mesmo depois da aplicação do filtro Bilateral. O uso do filtro de média foi utilizado para complementar o pré-processamento da imagem, removendo os últimos ruídos existentes na mesma. O resultado pode ser observado na Figura 16(b).




**Figura 16** – Melhora nas condições da imagem para realizar a segmentação. Em (a) seleção do canal azul e (b) resultado do filtro de mediana.

Fonte: Autoria própria

#### 5.2.2.1 Segmentação

Antes de iniciar o processo de extração das características, é necessário identificar a área de interesse, ou seja, a região onde se encontra a lesão. O processo de segmentação consiste em separar a região doente da região saudável, para que as lesões possam ser detectadas. Para este trabalho o processo de segmentação foi escolhido através de testes realizados com os métodos de limiarização de Otsu (1979), limiarização adaptativa (*adaptive threshold*) (MENDONÇA et al., 2007) e *watershed* (BEUCHER, 1982). Os resultados obtidos com a utilização dessas três técnicas foram comparados com a segmentação manual realizada por especialistas e encontram-se disponíveis na base PH<sup>2</sup>. A Figura 17 apresenta a segmentação manual realizada pelos especialistas e os resultados obtidos pelas três técnicas citadas acima.

Na Figura 17(a), temos a imagem segmentada manualmente por um dermatologista, enquanto que, na Figura 17(b), temos o resultado do método de limiarização de Otsu, na Figura 17(c), o método de limiarização adaptativa e, na Figura 17(d), o método *watershed*.




**Figura 17** – Resultado dos métodos de segmentação. Em (a) imagem segmentada manualmente por um dermatologista, (b) limiarização de Otsu, (c) limiarização adaptativa e (d) *watershed*.

Fonte: Autoria própria.

Comparando o resultado da Figura 17(b) com a segmentação realizada pelo dermatologista (Figura 17(a)), podemos observar que a mesma atingiu um resultado próximo à segmentação manual, sendo que o método utilizado na Figura 17(b) apresenta pequenos recuos da borda em algumas regiões. No caso da Figura 17(c), a mesma apresenta ruídos dentro e fora da região detectada. O resultado também apresenta má formação da lesão. O método apresentado em Figura 17(d) apresentou uma alta quantidade de ruídos, formação de regiões disjuntas e má formação da lesão. A Figura 18 apresenta outros resultados obtidos com utilização das três técnicas utilizadas.

De acordo com os resultados obtidos na Figura 18, percebe-se que o método *watershed* mostra ser sensível aos tons de cores das imagens, e isso reflete na quantidade de bacias formadas nas imagens e, conseqüentemente, no processo de segmentação das mesmas. Para o método de limiarização adaptativa, é observada a presença de ruídos em todas as imagens. Também é possível observar nas três últimas imagens que o mesmo conseguiu detectar as lesões, mas utilizando um espaço visivelmente maior que a segmentação manual. Para o método de Otsu, observa-se em todas as linhas da figura que os resultados apresentados por essa técnica são os que mais se assemelham com os das lesões segmentadas pelo especialista.

As técnicas de pré-processamento aplicadas na Secção 5.2.2 influenciam no processo de segmentação dessas lesões. Para os métodos de limiarização adaptativa e *watershed*, o pré-processamento não se mostrou tão eficaz como para o método de Otsu. De acordo com os resultados obtidos com os testes realizados, o método de Otsu apresentou o melhor desempenho na segmentação das imagens, sendo assim o mesmo foi escolhido para ser utilizado no processo de segmentação do sistema apresentado neste trabalho.



**Figura 18** – Resultados obtidos com utilização das três técnicas. a) Segmentação manual, b) Limiarização de Otsu, c) Limiarização Adaptativa e d) *Watershed*.

Fonte: Autoria própria

O método proposto em OTSU (1979) é uma técnica baseada nas características de distribuição dos tons das imagens. É um método não paramétrico e não supervisionado, que busca selecionar automaticamente um limiar  $L$  ótimo que possa separar ou segmentar as regiões de interesse em uma imagem, por meio da análise dos tons de cinza. Essa técnica busca encontrar o melhor limiar para a segmentação das classes, atribuindo a  $L$  um valor que minimize a variância intra-classe  $\sigma_{intra}^2$ . Essa variância pode ser definida como a soma ponderada das variâncias das classes, como pode ser visto na Equação 9.

$$\sigma_{intra}^2 = W_a * \sigma_a^2 + W_b * \sigma_b^2 \quad (9)$$


onde  $W$  é a probabilidade de ocorrência de cada classe delimitada pelo limiar  $L$ . Para o cálculo da Equação 9, é necessário o cálculo das equações 10, 11 e 12, onde a variável  $P_i$  corresponde à probabilidade de ocorrência do pixel com intensidade  $i$  e  $\mu$  é a média da intensidade para a classe correspondente (SIQUEIRA, 2014).

$$W = \sum_{i=Ini}^{Sup} (P_i) \quad (10)$$

$$\mu = \frac{\sum_{i=Ini}^{Sup} i * (P_i)}{W} \quad (11)$$

$$\sigma^2 = \sum_{i=Ini}^{Sup} [i - \mu]^2 * \frac{P_i}{W} \quad (12)$$


Após a definição das equações, o método percorre todos os pixels da imagem, começando pelo valor inicial 0 para uma determinada classe, e, em seguida, o mesmo percorre o restante dos valores até o limite, no caso deste trabalho até o valor 255. A Figura 19 apresenta o resultado da segmentação com o método de Otsu. A imagem utilizada como entrada desse processo é apresentada na Figura 16(b).



**Figura 19** – Segmentação com o método de Otsu.  
Fonte: Autoria própria

A região que se apresenta na cor branca é a região da lesão encontrada pelo método de limiarização de Otsu. Para concluir o processo de segmentação, é realizado uma conjunção entre a região detectada e a imagem original de entrada. Esse processo é realizado para definir a região de interesse a ser analisada. O resultado final desse processo é apresentado na Figura 20.





**Figura 20** – Resultado da conjunção da região segmentada e imagem original.  
Fonte: Autoria própria

### 5.2.3 Extração de Características

A extração de características é a etapa responsável por identificar e extrair as informações contidas nas lesões de pele. Neste trabalho, a análise dessas lesões é realizada de acordo com a regra ABCD (NACHBAR *et al.*, 1994). Essa regra descreve as estruturas das lesões observando as características de assimetria (A), borda (B), cor (C) e estruturas diferenciais (D). Neste trabalho, as regras A e D não foram totalmente concluídas e por isso as mesmas serão apresentadas apenas como trabalhos futuros. Sendo assim, essa seção descreve o método desenvolvido para análise das características B e C.

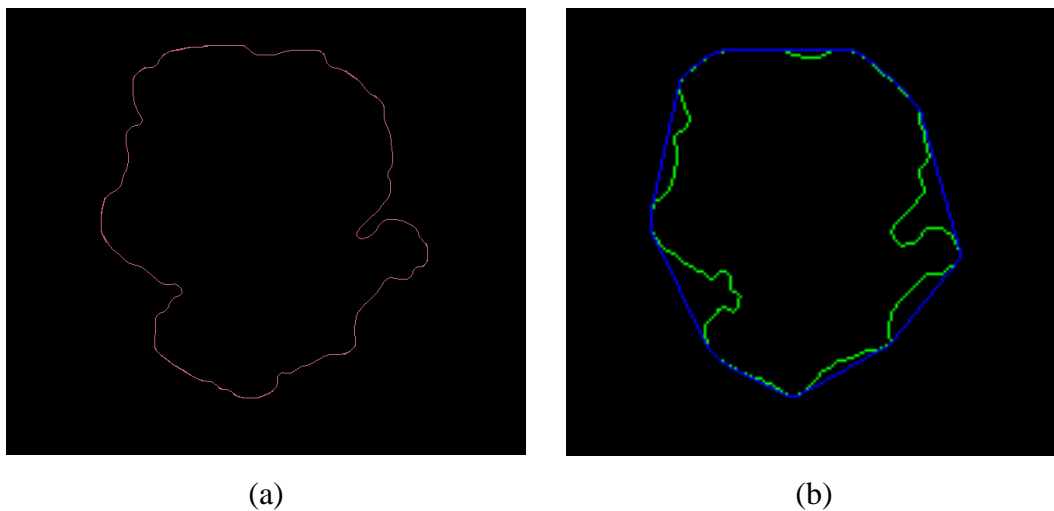
#### 5.2.3.1 Análise da Borda

A análise das bordas de uma lesão é feita observando a presença de irregularidades, caracterizadas por áreas de transição abruptas nas margens da lesão. Essas áreas representam um indício de que a lesão pode ser maligna. Segundo regra ABCD (DERMOSCOPY, 2015), para realizar a análise da borda, a imagem deve ser dividida em 8 segmentos, onde para cada corte abrupto que for identificado dentro do segmento deve ser adicionado um ponto ao cálculo

da pontuação, que pode variar de 0 (mínimo) até 8 (máximo). A quantidade de pontos identificados na imagem da lesão é que vai determinar o tipo de borda, onde, segundo a regra ABCD, caso a lesão obtenha uma pontuação entre 0 e 2, a mesma é classificada como regular, obtendo valores acima de 3 pontos, a mesma é classificada como irregular.

O passo inicial para analisar a borda da lesão é identificar o contorno da mesma, para isso, foi utilizado a função *findContours* do OpenCv. Essa função recupera os contornos de uma imagem binária utilizando o algoritmo proposto em (SUZUKI et al., 1985). A Figura 21(a) apresenta o resultado da função aplicada a imagem da Figura 19.

Após identificar a borda da lesão, faz-se necessário utilizar a função *convexHull* do OpenCv. Essa função utiliza o algoritmo proposto por Graham e Frances (1983), que encontra os pontos convexos da região da lesão. O resultado apresentado pela aplicação dessa função é apresentado pela linha azul da Figura 21(b), onde o traçado resultante em forma de polígono representa a forma ideal para que a borda da lesão fosse classificada como regular.



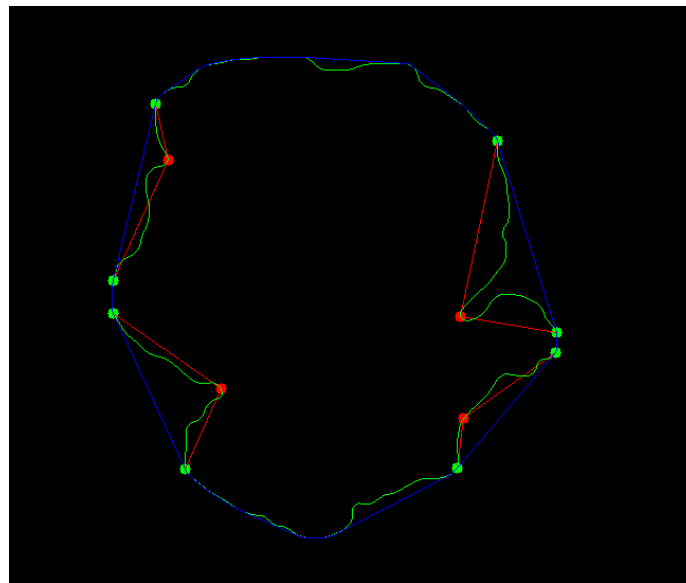
**Figura 21** – Identificação da lesão: (a) Borda identificada pelo método de Suzuki *et al.* (1985) e (b) Lesão identificada pelo método de Graham e Frances (1983).

Fonte: Autoria própria

A aplicação da função *convexHull* torna possível identificar os cortes abruptos na borda da lesão. Após identificar a borda e as irregularidades, é necessário localizar todos os defeitos de convexidade existentes no contorno da lesão. Para isso foi utilizado o método *convexityDefects* do OpenCv. As irregularidades são identificadas semelhante ao que propõe a regra ABCD, onde o método analisa a existência de defeitos de convexidade em uma região que vai de A – H. Os pontos em vermelho apresentados na Figura 22 representam o resultado da busca por irregularidades na borda da lesão.

Para a que o sistema possa identificar quais irregularidades podem caracterizar a região como irregular, vários testes foram realizados com o objetivo de identificar um limiar adequado para os mais diferentes tamanhos de irregularidade. Como não foi possível contar com ajuda de um especialista para validar a técnica, o limiar foi definido somente através dos testes<sup>8</sup>. A Figura 23 apresenta alguns resultados obtidos nos testes.

Na Figura 23(a) são apresentados os pontos candidatos a representar uma irregularidade. Nessa imagem é possível observar diferentes irregularidades com diferentes profundidades, onde os pontos marcados como “B” e “E” são os mais suaves, “A” e “D” são um pouco maiores que os pontos apresentados anteriormente e “C” e “F” são os mais profundos. O cálculo do limiar foi realizado de acordo com a quantidade de pontos existentes entre o ponto convexo apresentado na cor verde na Figura 23(b), (c) e (d) e a extremidade da irregularidade apresentado pela cor vermelha.




**Figura 22** – Aplicação do método *convexityDefects*.  
Fonte: Autoria própria

A relação entre o limiar e o tamanho da irregularidade é inversamente proporcional, ou seja, quanto maior o valor do limiar menor será a quantidade de irregularidades encontradas (Figura 23(b)), e quanto menor o valor do limiar, maior será a quantidade de regiões identificadas (Figura 23(c)). O limiar utilizado na Figura 23(c) mostrou ser muito sensível na realização dos testes. Analisando as irregularidades representadas nos pontos “B” e “E” da

<sup>8</sup> A falta de disponibilidade e de tempo para acompanhar o desenvolvimento do sistema, foi o principal fator que inviabilizou a participação de um dermatologista neste trabalho.

Figura 23(a), percebe-se que esses pontos aparecem visivelmente próximos à região desejada (contorno representado nas imagens pela linha azul). Assim como na Figura 23(c), outras imagens também se mostraram sensíveis a esse limiar.

Quanto aos pontos “A” e “D” (Figura 23(a)), é possível observar que ambos são mais profundos que os pontos “B” e “E”, e os pontos “C” e “F” são visivelmente os mais irregulares. O resultado de melhor limiar encontrado é observado na Figura 23(d). A presença de ruídos em algumas imagens dificultou a análise das irregularidades de algumas lesões, mas mesmo assim o método conseguiu identificar irregularidades em 88,5% das imagens.



**Figura 23** - Resultado dos testes para obtenção do limiar. Em (a) resultado da detecção da lesão e das irregularidades da lesão, (b), (c) e (d) apresentam as irregularidades com diferentes valores para o limiar.

Fonte: Autoria própria

### 5.2.3.2 Análise de Cor

A análise da cor para os dermatologistas é uma das principais formas de identificar se uma lesão é maligna ou benigna. Isso por que a variância de cores é um forte indício de que a lesão pode ser maligna, pois as lesões benignas geralmente apresentam somente uma tonalidade e as malignas podem apresentar uma variação de até seis tonalidades diferentes. A variação de cores entre uma lesão benigna e uma lesão maligna é apresentado na Figura 24.

Segundo a regra ABCD (DERMOSCOPY, 2015), deve-se analisar nas lesões a presença de seis cores, são elas: preto, branco, azul-cinza, vermelho, castanho-claro e castanho-escuro. A imagem a ser processada é utilizada no formato RGB, onde o R, o G e o B representam a intensidade do canal vermelho, verde e azul, respectivamente, que juntos formam a intensidade da cor naquele pixel. Neste trabalho, para realizar a análise das cores da lesão, a imagem foi processada utilizando a técnica adaptada do trabalho de Rosado (2009).


Para esse processo, os pixels contidos na imagem são analisados procurando identificar as cores estabelecidas pela regra ABCD. Neste caso, é preciso definir as cores que serão analisadas e os seus respectivos valores. A Figura 24 apresenta os valores que queremos encontrar, com exceção do valor (0,0,0), que não foi utilizado na cor preta devido o mesmo representar o fundo da imagem da lesão, e estar presente em todas as imagens.

Preto		Branco		Azul-Cinza	
Código RGB	Cor	Código RGB	Cor	Código RGB	Cor
(0,0,0)		(255,255,255)		(150,125,150)	
(10,10,10)		(245,245,245)		(125,125,150)	
(20,20,20)		(235,235,235)		(100,100,125)	
(30,30,30)		(225,225,225)		(100,125,150)	
(50,40,40)		(215,215,215)		(50,100,150)	
(50,50,50)		(205,205,205)		(0,100,150)	
Vermelho		Castanho Claro		Castanho Escuro	
Código RGB	Cor	Código RGB	Cor	Código RGB	Cor
(255,0,0)		(200,150,100)		(150,100,100)	
(255,50,50)		(200,100,0)		(125,75,75)	
(200,0,0)		(200,100,50)		(100,50,50)	
(200,50,50)		(150,100,50)		(100,50,0)	
(150,0,0)		(150,100,0)		(100,0,0)	
(150,50,50)		(150,50,0)		(50,0,0)	

**Figura 24** – Cores a serem analisadas e seus respectivos valores.  
Fonte: (ROSADO, 2009)

A Figura 20 é utilizada nessa etapa, onde a mesma apresenta a região de interesse que se deseja analisar. A verificação das cores é realizada através de uma iteração que analisa a cor de cada um dos pixels. As cores identificadas são armazenadas no final do processo em um vetor de características. O uso da cor preta com o valor (0,0,0) foi utilizado para substituir a região da pele que não faz parte da lesão. Sendo assim, os pixels que possuem essa cor não são contabilizados no processo de detecção das cores.

Para verificar os resultados obtidos na análise de cor, foram observados os resultados obtidos pela técnica utilizada nesse trabalho comparando com os valores atribuídos pelos especialistas às imagens dermatoscópicas da base PH<sup>2</sup>.



**Figura 25** – Lesões de pele.

Fonte: Autoria própria

Observando os resultados do método desenvolvido com os valores apresentados na base, temos: para a Figura 25(a), o método desenvolvido identificou na lesão a mesma quantidade de cores descritas pela base, sendo elas marrom-claro, marrom-escuro e preto; na Figura 25(b), o método obteve um resultado semelhante ao apresentado na Figura 25(a), sendo identificada para esse caso a cor marrom-claro; na Figura 25(c), a base identifica a presença de quatro cores

para essa lesão, o azul-cinza, o branco, o marrom-escuro e o preto, enquanto que o método desenvolvido identificou apenas as três últimas; na Figura 25(d), tanto a base como o método desenvolvido identificaram a mesma quantidade de cores mas com tonalidades diferentes, onde o método desenvolvido identificou o marrom-claro e marrom-escuro e a base utiliza as cores vermelho e marrom-escuro para descrever as cores da lesão.

No geral, o algoritmo conseguiu identificar na maioria dos casos a mesma quantidade de cores que o descrito na base, mas em alguns casos as cores detectadas pelo método não são as mesmas que se apresentam descritas na base.

## 5.2.4 Classificação

Nessa etapa, as características das lesões que foram identificadas e extraídas das imagens são utilizadas como entrada para um classificador inteligente com um algoritmo de aprendizagem de máquina. O classificador utilizado nesse trabalho é uma RNA do tipo MLP treinada com o algoritmo *backpropagation*, apresentado no Capítulo 4. Antes de apresentar o classificador desenvolvido nesse trabalho é preciso apresentar os testes realizados que justificam a escolha do mesmo. Na Subsecção 5.2.4.1 é apresentada a comparação de trabalhos e na Subsecção 5.2.4.2 é apresentada a rede neural desenvolvida e os resultados obtidos.

### 5.2.4.1 Comparação de Trabalhos

É possível encontrar diversos trabalhos relacionados com o desenvolvimento de sistemas para auxiliar o diagnóstico do câncer de pele, e principalmente para o câncer de pele do tipo melanoma. No decorrer da pesquisa realizada neste trabalho foi encontrado o projeto *Automatic computer-based Diagnosis system for Dermoscopy Images (ADDI Project) (ADDI Project, 2015)*.

O projeto ADDI é um projeto multidisciplinar realizado em parceria com a junta médica do Hospital Pedro Hispano (HPH) e pesquisadores de diferentes áreas da engenharia e matemática da Universidade do Porto, Universidade de Aveiro e o Instituto Superior Técnico. O projeto vem realizando pesquisas a vários anos na área da dermatoscopia, tele-dermatoscopia

e telemedicina no Serviço de Dermatologia do HPH, e em sistemas para análise automática de imagens dermatoscópicas.

No intuito de escolher um classificador para ser utilizado neste trabalho, foi realizado um teste utilizando as informações da base PH<sup>2</sup>, descrita anteriormente da Subseção 5.2.1, com os seguintes algoritmos de aprendizagem de máquina: K – *Nearest Neighbour* (KNN), o *Support Vector Machine* (SVM), Árvore de Decisão (AD) e a Rede *Multilayer Perceptron* (MLP) (FACELI et al., 2011). Os resultados obtidos pela classificação das informações da base foram comparados com os resultados apresentados em um dos trabalhos publicados pelo projeto ADDI, onde o trabalho utilizado para a comparação é apresentado por Barata et al (2013). O autor utiliza dois métodos distintos para classificar imagens dermatoscópicas. O primeiro utiliza métodos globais de classificação e os classificadores KNN, SVM e *AdaBooster*. O segundo utiliza métodos locais para classificação, utilizando o classificador *Bag of Features* (BoF). Ambos classificam as imagens analisando as características de cor e textura.

A escolha do trabalho utilizado para a comparação, justifica-se pelo fato das imagens utilizadas para os dois casos serem da mesma fonte, tendo em vista que a base PH<sup>2</sup>, que também pertence ao projeto ADDI, é formada por imagens adquiridas no HPH, que por sua vez são utilizadas no trabalho de Barata et al (2013). Os resultados dos testes realizados com os algoritmos de aprendizagem de máquina foram comparados com os resultados obtidos pelo método global de classificação apresentado em Barata et al (2013).

Os dados quantitativos da base PH<sup>2</sup> foram classificados utilizando a ferramenta WEKA (WEKA, 2015; HALL, 2009), um software desenvolvido pela Universidade de Waikato (Nova Zelândia) que possui uma coleção de algoritmos de aprendizagem de máquina configurados para realizar tarefas de mineração de dados. A base de dados foi convertida para o formato padrão do WEKA (.arff), onde 70% dos dados foram utilizados para o treinamento dos algoritmos e os 30% restantes foram utilizados para os testes. Para cada classificador foram utilizadas diferentes configurações de parâmetros, ou seja, para o KNN variou-se o número de vizinhos e a distância usada pelo algoritmo, para o SVM variou-se o tipo de *kernel* e a semente de aleatoriedade *seed*, para a AD variou-se o tipo de poda e o cálculo do erro de poda, e para a rede MLP variou-se a quantidade de neurônios e a taxa de aprendizado. No geral, considerando todas as combinações, foram testadas cerca de 100 configurações diferentes (ALENCAR; LOPES, 2014). A Tabela 2 apresenta os resultados da classificação obtidos pelo algoritmo KNN.



**Tabela 2** – Resultados da classificação obtidos pelo algoritmo KNN

Valores de k	1	3	5	7	10	13	15
<b>C/Distance Weight</b>	86,66%	86,66%	86,66%	86,66%	83,33%	80%	80%
<b>S/Distance Weight</b>	86,66%	80%	83,33%	83,33%	83,33%	80%	80%

Para o algoritmo KNN foram testadas várias configurações diferentes. O valor de k variou em um intervalo de  $k \in \{1, 3, 5, \dots, 31\}$ , utilizando ou não o parâmetro de ponderação de distância. Durante o teste, pôde-se observar que o algoritmo se manteve estável quanto ao uso ou não do parâmetro de ponderação de distância, e para o valor de k maior que 13, poucas variações de resultados foram identificadas após esse valor. O algoritmo KNN obteve um bom desempenho no processo de classificação, obtendo como melhor resultado 86,66% de acerto na classificação.

Outro algoritmo testado foi a AD utilizando o algoritmo C4.5<sup>9</sup>. O desempenho desse algoritmo foi analisado observando seu comportamento variando os parâmetros de uso ou não do processo de poda e do cálculo do erro de poda. Os resultados da classificação utilizando a AD são apresentados na Tabela 3.

**Tabela 3** – Resultados da classificação obtidos pelo algoritmo AD

Seed	1	3	5	8	10	13	15
<b>S/Poda</b>	83,33%	83,33%	83,33%	83,33%	83,33%	83,33%	83,33%
<b>C/Poda</b>	83,33%	83,33%	83,33%	83,33%	83,33%	83,33%	83,33%
<b>Erro de poda</b>	90%	90%	90%	90%	90%	90%	90%

Esse algoritmo foi o que menos mostrou sensibilidade quanto à variação de seus parâmetros. Como pode-se notar, o uso ou não do processo de poda não melhorou o desempenho do mesmo em nenhum momento. Porém o cálculo de erro de poda melhorou consideravelmente os resultados, onde a utilização do mesmo diminui a quantidade de nós que apresentavam regras de divisão que pouco contribuía para a classificação. Isso porque nós mais profundos refletem mais o conjunto de treinamento e aumentam o erro devido à variância do classificador. Utilizando o cálculo de erro de poda, o algoritmo melhorou em 6% o desempenho da AD, obtendo 90% de acerto para o melhor resultado.

Outro algoritmo utilizado para a classificação dos dados foi o SVM. A Tabela 4 apresenta os melhores resultados obtidos pelo classificador. Para esse algoritmo foi utilizada

<sup>9</sup> O C4.5 é um algoritmo utilizado para gerar uma AD. Proposto por Quilan (1993), esse algoritmo constrói uma AD a partir de um conjunto de dados de treinamento utilizando os conceitos de entropia e ganho de informação. Para cada nó da árvore o algoritmo escolhe o atributo que divide de forma mais eficaz o conjunto de dados. O atributo com o ganho de informação mais alto é escolhido para tomar a decisão (QUILAN, 1993).

uma grande variedade de parâmetros, dentre eles destaca-se o uso dos seguintes núcleos: linear, polinomial, sigmoidal e a função de base radial (RBF). Os melhores resultados foram apresentados utilizando a função linear, variando a semente de aleatoriedade seed em 1, 3 e 7. O algoritmo apresentou um bom desempenho no processo de classificação, atingindo o índice de 93,33% de acerto como melhor resultado.

**Tabela 4** – Resultados da classificação obtidos pelo algoritmo SVM.

<i>Kernel</i>	<i>Seed</i>	<i>Custo</i>	<i>Acerto</i>
<b>Linear</b>	1	1	93,33%
<b>Polinomial</b>	1	1	80%
<b>RBF</b>	1	5	83,33%
<b>Sigmoidal</b>	1	1	83,33%
<b>Linear</b>	1	3	90%
<b>Polinomial</b>	1	5	86,66%
<b>RBF</b>	7	1	86,66%
<b>Sigmoidal</b>	7	5	80%

O último algoritmo utilizado foi a rede MLP treinada com o algoritmo backpropagation. Para esse foram realizadas n variações quanto à quantidade de neurônios, à taxa de aprendizado, à quantidade de ciclos de treinamento, dentre outros parâmetros. A Tabela 5 apresenta os melhores resultados apresentados pela rede MLP.

**Tabela 5** – Resultados obtidos pela Rede MLP.

<b>Iteração</b>	<b>Quantidade de Neurônios</b>	<b>Taxa de Aprendizado</b>	<b>Acerto</b>
<b>100</b>	3	0.1	90%
<b>100</b>	7	0.2	86,6%
<b>100</b>	10	0.3	86,6%
<b>1000</b>	7	0.1	86,6%
<b>1000</b>	10	0.3	86,6%
<b>1000</b>	3	0.1	90%
<b>10000</b>	7	0.1	93,3%
<b>10000</b>	7	0.2	93,3%
<b>10000</b>	10	0.1	86,7%

Assim como o SVM, a rede MLP obteve um bom desempenho no processo de classificação, onde as configurações apresentaram os melhores resultados utilizando sete neurônios na camada oculta, uma taxa de aprendizado com valores iguais a 0.1 e 0.2, executando a 10.000 ciclos de treinamento. O algoritmo conseguiu obter um índice de 93,33% de acerto no processo de classificação.

Quanto ao desempenho, os chamados métodos de otimização, ou seja, a rede MLP e o algoritmo SVM, conseguiram os melhores índices de classificação, coincidindo com o mesmo índice de acerto. Quanto aos algoritmos KNN e AD, o fato dos nevos atípicos possuírem características semelhantes ao melanoma pode ter influenciado no processo de classificação desses algoritmos. Para o KNN, a semelhança dos dados pode ter afetado o cálculo das distâncias dos seus vizinhos e, para a AD, a semelhança entre esses dados pode ocasionar instabilidade na árvore, ou seja, pequenas variações no conjunto de treinamento podem causar grandes variações na árvore final e, conseqüentemente, alterar a classificação. Supõe-se que a mudança na quantidade de classes da base, ou seja, classificar os dados apenas como nevo comum e melanoma, e a utilização de mais exemplos para treinamento e validação possam vir a melhorar os resultados obtidos pelos algoritmos.

Para analisar e comparar os resultados obtidos recorreu-se ao cálculo do nível de SE e SP dos algoritmos aqui testados. Os respectivos níveis são apresentados na Tabela 6.

**Tabela 6** – Níveis de Sensibilidade e Especificidade.

	Algoritmos	Sensibilidade	Especificidade
Algoritmos testados neste trabalho	KNN	60%	100%
	AD	70%	100%
	SVM	80%	100%
	MLP	80%	100%
Algoritmos do trabalho de Barata <i>et al</i> (2013)	AdaBoost	96%	80%
	SVM	92%	72%
	KNN	96%	79%

Observando os resultados apresentados na Tabela 6, percebe-se que a análise das lesões de pele utilizando características de cor e textura, apresentada no trabalho de Barata *et al* (2013), apresenta os melhores resultados quanto ao nível de SE. Para o nível de SP, as características da regra ABCD disponíveis na base PH<sup>2</sup> apresentaram para esse caso os melhores resultados quanto ao nível de SP.

Outro fator a ser observado é que os tipos de características utilizadas para análise das lesões de pele pode influenciar no processo de classificação, pois algumas características descrevem melhor determinados tipos de lesões. Esse caso pode ser visto nos resultados obtidos pelos classificadores KNN e SVM, pois ambos foram utilizados nos dois testes e apresentam resultados distintos, justificando a afirmação feita anteriormente.

Contudo a classificação utilizando características da regra ABCD apresentadas pela base PH<sup>2</sup> e as características de cor e textura, ambas as técnicas se apresentam como boas opções para a classificação de imagens dermatoscópicas. Os testes realizados os algoritmos SVM e a Rede MLP conseguiram classificar melhor as características da regra ABCD quando comparado ao KNN e à AD, obtendo um resultado de 93,3% de acerto na classificação.

Pode-se afirmar que tanto o SVM quando a Rede MLP são bons candidatos para o processo de classificação de dados dermatoscópicos. Sendo assim, a Rede MLP foi escolhida para desempenhar o processo de classificação utilizado neste trabalho. A próxima subseção apresenta a rede MLP desenvolvida e os resultados obtidos pela mesma.

#### 5.2.4.2 Classificador

O processo de classificação é a penúltima etapa do sistema proposto. Nessa etapa, as características das lesões que foram identificadas e extraídas das imagens são utilizadas como entrada para um classificador inteligente com um algoritmo de aprendizagem de máquina. O classificador utilizado nesse trabalho é uma RNA do tipo MLP treinada com o algoritmo backpropagation.

A escolha desse algoritmo foi realizada a partir dos testes realizados na Subseção 5.2.4.1. Os testes realizados também serviram para definir a configuração da rede a ser utilizada para a classificação dos dados. A rede foi implementada na linguagem Java, sendo a mesma composta por sete neurônios na camada oculta e dois na camada de saída, utilizando a função de ativação do tipo sigmoide. Para o treinamento a rede utiliza o algoritmo backpropagation executando a 10.000 ciclos de treinamento e com a taxa de aprendizado de 0,3. O resultado da classificação é obtido através da combinação dos resultados dos neurônios da camada de saída, ou seja, o valor de saída 0 e 1 classifica o nevo como melanoma e o valor 1 e 0 classifica o nevo como benigno.

Inicialmente o algoritmo implementado foi utilizado em um dispositivo móvel para treinar e classificar os dados da base PH<sup>2</sup>, como é visto em (ALENCAR; LOPES, 2014). O processo de treinamento foi realizado utilizando a metodologia Holdout (FACELI et al., 2011). Esse método consiste em separar os dados em dois conjuntos, 70% dos dados para realizar o treinamento e 30% para validação, onde os dados de treinamento contêm as informações das lesões e a classe à qual ela pertence. Os dados foram distribuídos no conjunto de forma aleatória.

O conjunto de validação, por sua vez, não possui as informações sobre a classe e é aplicado logo após a fase de treinamento. A rede MLP classificou os dados como nevo benigno, nevo atípico e melanoma.

Os dados da base PH<sup>2</sup> foram inseridos em dois arquivos do tipo .txt (um para treinamento e outro para validação) e carregados para a memória do dispositivo Android. Em seguida, o primeiro arquivo a ser carregado pela rede MLP é o que contém os dados para o treinamento. Após a realização do treinamento, o arquivo contendo os dados de validação é carregado e aplicado a rede já treinada.

Para os nevos comuns, o algoritmo classificou de forma correta 100% dos casos apresentados. Para os nevos atípicos, o algoritmo obteve um índice de acerto de 90%, e para o melanoma, o mesmo obteve um índice de acerto de 70%. No geral, o algoritmo conseguiu obter 86,66% de acerto na classificação de lesões em uma faixa de tempo entre 2 e 5 segundos.

Após validar o uso da rede em um dispositivo móvel, a mesma foi reconfigurada para classificar as informações extraídas pelo sistema apresentado neste trabalho, ou seja, a rede foi configurada para analisar as características de borda e cor extraídas das imagens dermatoscópicas (subseções 5.2.3.1 e 5.2.3.2) e classificá-las como nevo comum e melanoma. Para isso, foram utilizadas as 50 imagens selecionadas na Subseção 5.2.1. As características de borda e cor das 50 imagens selecionadas foram extraídas e utilizadas para montar dois arquivos, um para o treinamento e outro para a validação da rede, assim como foi anteriormente. Utilizando as características de borda e cor extraídas pelo sistema aqui apresentado, a rede conseguiu classificar de forma correta 86,66% dos casos.

Contudo, o sistema conseguiu atingir um resultado satisfatório quanto à análise das lesões dermatoscópicas, a diminuição da quantidade de casos apresentados para o treinamento e validação não afetou o desempenho do classificador fazendo com que o mesmo atingisse um bom resultado. Na próxima subseção é descrito o módulo de apresentação dos resultados.

### **5.2.5 Apresentação dos Resultados**

A apresentação dos resultados é a última etapa do sistema proposto. Nessa etapa o sistema apresenta ao usuário um pré-diagnóstico da lesão analisada e as informações das características de borda e cor analisadas pelo sistema. Por fim, o usuário pode sair do sistema ou fazer uma nova análise.

## 6 CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho foi apresentado o desenvolvimento de um sistema de classificação de imagens dermatoscópicas para dispositivos móveis, utilizando redes neurais do tipo MLP. O objetivo desse sistema é fornecer uma ferramenta que possa auxiliar médicos e profissionais de saúde na análise do câncer de pele do tipo melanoma através de um dispositivo móvel. O uso do sistema deve possibilitar e facilitar o acesso ao exame de dermatoscopia nas regiões mais interioranas, na zona rural e nas regiões onde não existe a presença de especialistas. Uma outra aplicação para esse sistema é facilitar o processo de triagem de pacientes, além de possibilitar a formação de uma base de imagens que pode ser utilizada para o acompanhamento do paciente, para possíveis estudos sobre dermatoscopia e para testes com outras técnicas para análise de lesões de pele.

Como trabalhos futuros, é essencial o uso de um conjunto com uma maior quantidade de imagens dermatoscópicas, pois um conjunto de dados maior pode vir a melhorar o desempenho do classificador implementado. Como o sistema apresentado não faz uso de todas as características da regra ABCD, sugere-se a implementação das características de assimetria e estruturas diferenciais da regra ABCD.

Para as imagens que apresentam excesso de pelos e pouco contraste entre a cor da pele e a lesão, pretende-se pesquisar ou desenvolver métodos que tratem a existência desses fatores nas imagens dermatoscópicas. Para a análise das características de borda e cor, faz-se necessário aplicar outras técnicas de análise para essas características, no intuito de buscar resultados mais refinados.

Seria também interessante expandir o sistema quanto à gerência dos dados adquiridos, onde o usuário possa organizar e melhorar o acesso aos dados referentes a cada paciente, utilizando um serviço web ou na nuvem, assim como desenvolver aplicações que executem em outras plataformas como iOS e Windows Phone. Outro fator a ser considerado é a busca de parcerias com especialistas e/ou hospitais com o objetivo de adquirir imagens e validar as funções do sistema.

## REFERÊNCIAS

- ADDI Project. *ADDI Project: Automatic computer-based Diagnosis system for Dermoscopy Images*. Disponível em: <<http://www.fc.up.pt/addi/project.html>>. Acesso em: 4 Janeiro 2015.
- ALENCAR, F.E.S.; LOPES, D.C. Sistema para classificação de imagens dermatoscópicas para dispositivos móveis. XIV - Congresso Brasileiro de Informática em Saúde. Santos – SP, 2014.
- ALENCAR, F.E.S.; LOPES, D.C. Análise de Algoritmos para a classificação de dados dermatoscópicos utilizando o WEKA. Escola Potiguar de Computação e suas Aplicações (EPOCA). Santa Cruz – RN. 2014.
- ALMEIDA, V.P.; ENDLER, M.; HAEUSLER, E.H. *Patient-Buddy-Build: Acompanhamento remoto móvel customizável de pacientes com doenças crônicas*. XIII Congresso Brasileiro de Informática em Saúde, 2012.
- ARGENZIANO, G. et al. *Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions: comparison of the ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis*. *Archives of Dermatology*, v. 134, n. 12, p. 1563-1570, 1998.
- AZEVEDO, E.; CONCI, A. *Computação gráfica: teoria e prática*. [S.l.]: Elsevier, 2003. 405 p.
- BARATA, C. et al. *Two Systems for the Detection of Melanomas in Dermoscopy Images using Texture and Color Features*. 965 - 979, 2013.
- BARCELOS, C. A. Z.; BOAVENTURA, M.; SILVA, E. C. Jr. *A well-balanced flow equation for noise removal and edge detection*. *IEEE Transactions on Image Processing*, v. 12, n. 7, p. 751-763, 2003.
- BLEYMED. Bleymed. Disponível em: <<http://www.bleymed.com.br>>. Acesso em: 24 Janeiro 2015.
- BRADSKI, G.; KAEHLER, A. *Learning OpenCV: Computer vision with the OpenCV library*. " O'Reilly Media, Inc.", 2008.
- BURGES, C. J. C. *A tutorial on support vector machines for pattern recognition*. *Data mining and knowledge discovery*, v. 2, n. 2, p. 121-167, 1998.
- CANDES, E. J. et al. *Curvelets: A surprisingly effective nonadaptive representation for objects with edges*. *Department of Statistics, Stanford University*, 1999.
- CANDES, E. J.; DONOHO, D. L. *New tight frames of curvelets and optimal representations of objects with piecewise C<sup>2</sup> singularities*. *Communications on pure and applied mathematics*, v. 57, n. 2, p. 219-266, 2004.
- CAVALCANTE, I. *Técnicas de Processamento Digital de Imagens com Java*. Disponível em: <<http://www.ppgia.pucpr.br/~facon/ComputerVisionBooks/2009ProcessamentoImagensComJava.pdf>>. Acesso em: 19 Dezembro 2014.

CERQUEIRA, P. H. R. Um estudo sobre reconhecimento de padrões: um aprendizado supervisionado com classificador bayesiano. 2010. 81 f. Dissertação (Mestrado em Ciências). Universidade de São Paulo. Piracicaba. 2010.

CHANG, T.; KUO, C. C. J. *Texture analysis and classification with tree-structured wavelet transform. Image Processing, IEEE Transactions on*, v. 2, n. 4, p. 429-441, 1993.

CHOMUTARE, T. et al. *Features of mobile diabetes applications: review of the literature and analysis of current applications compared against evidence-based guidelines. Journal of Medical Internet Research*, v. 13, n. 3, 2011.

CONSULTING, V. W. *mHealth for development: the opportunity of mobile technology for healthcare in the developing world*. Washington Dc and Berkshire, UK, 2009.

CORDEIRO, F. Reconhecimento e Classificação de Padrões de Imagens de Núcleos de Linfócitos do Sangue Periférico Humano com a Utilização de Redes Neurais Artificiais. 2002. 68 f. Dissertação (Mestrado em Ciências da Computação). Universidade Federal de Santa Catarina. Florianópolis. 2002.

CORREIA, R.D. et al. *Nutrimobile: Um Sistema de Avaliação do Estado Nutricional de Pacientes Hospitalizados Para Dispositivos Móveis*. XIII Congresso Brasileiro de Informática em Saúde, 2012.

COSTA, A.C. Um Modelo para Notificações em *mHealth*. 2013. 99 f. Dissertação (Mestrado em Ciências da Computação) - Pontifícia Universidade Católica do Rio Grande do Sul. Porto Alegre, 2013.

DERMOSCOPY. *Dermoscopy Tutorial*. Disponível em: <<http://www.dermoscopy.org/>>. Acesso em 5 Janeiro 2015.

FACELI, K. et al. *Inteligência Artificial: uma abordagem de aprendizagem de máquina*. Editora LTC, 2011. 375p.

FERREIRA, P. M. et al. *An annotation tool for dermoscopic image segmentation. in Proceedings of the 1st International Workshop on Visual Interfaces for Ground Truth Collection in Computer Vision Applications*. ACM, 2012, pp. 5:1-5:6.

FRANGE, V. M. N.; ARRUDA, L. H. F.; DALDON, P. E. C. *Dermatoscopia: importância para a prática clínica*. Revista de Ciências Médicas. 2012. 18(4).

FREUND, Y.; SCHAPIRE, R. E. *A decision-theoretic generalization of on-line learning and an application to boosting. Journal of computer and system sciences*, v. 55, n. 1, p. 119-139, 1997.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 2ª Edição. 2002. USA: Editora Prentice Hall. 779p.

GRAHAM, R. L.; FRANCES Y., F. *Finding the convex hull of a simple polygon. Journal of Algorithms*, v. 4, n. 4, p. 324-331, 1983.



HALL, M. et al. *The WEKA data mining software: an update*. ACM SIGKDD explorations newsletter, v. 11, n. 1, p. 10-18, 2009.

HAYKIN, S. *Redes Neurais: Princípios e Práticas*. 2 Edição. Bookman 2001. 893p.

HUANG, G-B; ZHU, Q-Yu; SIEW, C-K. *Extreme learning machine: a new learning scheme of feedforward neural networks*. In: *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on*. IEEE, 2004. p. 985-990.

INCA. Instituto Nacional de Câncer José Alencar Gomes da Silva. Disponível em: <<http://www2.inca.gov.br/wps/wcm/connect/inca/portal/home>>. Acesso em: 13 Janeiro 2015.

INTEL. *OpenCV: Open source Computer Vision Library*, 2007. <<http://www.intel.com/technology/computing/opencv/index.htm>>. Acesso em: 19 Dezembro 2014.

ITU. *International Telecommunication Union*. Disponível em: <<http://www.itu.int>>. Acesso em: 20 Dezembro 2014.

JAIN, A. K.; DUIN, R. P. W.; MAO, J. *Statistical pattern recognition: A review*. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 22, n. 1, p. 4-37, 2000.

JAIN, A. K.; RICHARD, C. D. *Algorithms for clustering data*. Vol. 6. Englewood Cliffs: Prentice hall, 1988.

KARRAKCHOU, M.; KUNT, M. *From continuous wavelet transform to wavelet packets: application to the estimation of pulmonary micro vascular pressure*. *Time Frequency and wavelets in biomedical signal processing//IEEE Press*,. New York, p. 367-387, 1998.

KAY, M. *mHealth: New horizons for health through mobile technologies*. World Health Organization, 2011.

MAHMOUD, M. K. A.; AL-JUMAILY, A.; TAKRURI, M. *The automatic identification of melanoma by wavelet and curvelet analysis: study based on neural network classification*. In: *Hybrid Intelligent Systems (HIS), 2011 11th International Conference on*. IEEE, 2011. p. 680-685.

MASSONE, C. et al. *Mobile Teledermoscopy - Melanoma Diagnosis by One Click?*. In: *Seminars in Cutaneous Medicine and Surgery*. Elsevier. 2009. p. 203-205.

MENDONÇA, T. et al. *PH<sup>2</sup> - A dermoscopic image database for research and benchmarking*. In: *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*. IEEE, 2013. p. 5437-5440.

MICHALSKI, R. S. "ATTRIBUTIONAL CALCULUS: A Logic and Representation Language for Natural Induction", *Reports of the Machine Learning and Inference Laboratory, MLI 04-2*, George Mason University, Fairfax, VA, 2004.

MHASKE, H. R.; PHALKE, D. A. *Melanoma skin cancer detection and classification based on supervised and unsupervised learning*. In: *Circuits, Controls and Communications (CCUBE)*, 2013 *International conference on*. IEEE, 2013. p. 1-5.

NACHBAR, F. et al. *The ABCD rule of dermatoscopy: high prospective value in the diagnosis of doubtful melanocytic skin lesions*. *Journal of the American Academy of Dermatology*, v. 30, n. 4, p. 551-559, 1994.

NAVARRO, B.R. et al. ADAFARMA: Aplicativo para Auxílio na Fase de Aderência ao Tratamento. XIII Congresso Brasileiro de Informática em Saúde, 2012.

NIXON, M.; AGUADO, A. *Feature Extration & Image Processing*. Oxford: Academic Press is an imprint of Elsevier. 2008. 399p.

NUNES D.F.S. et al. ACUMAAF: Ambiente de Computação Ubíqua para o Monitoramento e Avaliação de Atividade Física. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/wim/2012/002.pdf>>. Acesso em: 26 Agosto 2012]

NVIDIA. *WHAT IS CUDA?*. Disponível em: <[http://www.nvidia.com/object/cuda\\_home\\_new.html](http://www.nvidia.com/object/cuda_home_new.html)> Acesso em: 19 Dezembro 2014.

OLIVEIRA, A.R. Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de Defeitos em Linhas de Transmissão. 2005. 120 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Juiz de Fora, Juiz de Fora. 2005.

OLIVEIRA, R.B. Método de detecção e classificação de lesões de pele em imagens digitais a partir do modelo de *Chan-Vese* e máquina de vetor de suporte. 113 f. Dissertação (Mestrado em Ciências da Computação). Universidade Estadual Paulista. São José do Rio Preto, 2012.

OLIVEIRA, T.R.; COSTA, F.M.R. Desenvolvimento de aplicativo móvel de referência sobre vacinação no Brasil. *Journal of Health Informatics*, v. 4, n. 1, 2012.

OPENCV ANDRIOD, *OpenCv* para a plataforma Android. 2014. Disponível em: <<http://opencv.org/platforms/android.html>> Acesso em: 19 Dezembro 2014.

OTSU, N. *A threshold selection method from gray-level histograms*. *IEEE Transactions on Systems*, vol. 9, pp. 62-66, 1979.

PAZ, L.F. et al. Acesso Móvel às Informações de Saúde do Paciente Utilizando Computação Ubíqua. XIII Congresso Brasileiro de Informática em Saúde, 2012.

PRADI, T. Software para Detecção de Melanoma Para iOS. 2012. 63 f. Monografia (Graduação em Ciências da Computação) - Universidade Regional de Blumenau. Blumenau, 2012.

PRADO, R. N. A. Implementação de uma Arquitetura Fuzzy Neural com Treinamento Online em *Hardware Field Programmable Gate Array* – FPGA. 2014. 63 f. Tese (Doutorado em Engenharia Elétrica). Universidade Federal do Rio Grande do Norte. Natal. 2014.

PSATY, E. L.; HALPERN, A. C. *Current and emerging technologies in melanoma diagnosis: the state of the art*. *Clinics in dermatology*, v. 27, n. 1, p. 35-45, 2009.

QUINLAN, J. R. C4.5: *Programs for Machine Learning*. 1. ed. [S.l.]: Morgan Kaufmann, 1993.

RAMLAKHAN, K.; SHANG, Y. (2011, November). *A mobile automated skin lesion classification system*. In *Tools with Artificial Intelligence (ICTAI)*, 2011 23rd IEEE International Conference on (pp. 138-141).

RIBEIRO, J. H. B. Desenvolvimento de uma Técnica de Reconhecimento de Padrões Baseada em Distância. 2003. 87 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Santa Catarina. Florianópolis. 2003.

ROLIM, A. L. Um sistema de Identificação Automática De Faces Para Ambientes Vistuais De Aprendizagem. Dissertação (Mestrado em Informática). Universidade Federal da Paraíba, 2009.

ROSADO, L. F. C. M. G. Sistema automático para diagnóstico de lesões cutâneas baseado em imagens dermoscópicas. 2009. 72 f. Dissertação (Mestrado em Engenharia Biomédica) – Instituto Superior Técnico, Universidade Técnica de Lisboa, Lisboa.

RUIZ, D. et al. *A decision support system for the diagnosis of melanoma: A comparative approach*. *Expert Systems with Applications*, v. 38, n. 12, p. 15217-15223, 2011.

RUIZ, D. et al. *A cooperative approach for the diagnosis of the melanoma*. In: *Engineering in Medicine and Biology Society*, 2008. EMBS 2008. 30th Annual International Conference of the IEEE. IEEE, 2008. p. 5144-5147.

SARRAFZADE, O.; BAYGI, M. H. M.; GHASSEMI, P. *Skin lesion detection in dermoscopy images using wavelet transform and morphology operations*. In: *Biomedical Engineering (ICBME)*, 2010 17th Iranian Conference of. IEEE, 2010. p. 1-4.

SBD. Portal da Sociedade Brasileira de Dermatologia. Disponível em: <<http://www.sbd.org.br/>>. Acesso em: 13 Janeiro 2015.

SIKORSKI, J. *Identification of malignant melanoma by wavelet analysis*. *Proceedings of Student/Faculty Research Day, CSIS, Pace University.*, 2004.

SIQUEIRA, H.C. SCD: uma ferramenta para extração de informação de sinais na pele para identificação de melanoma. 49 f. Monografia (Bacharelado em Engenharia de Computação) - Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife. 2014.

SITU, N. et al. *Malignant melanoma detection by bag-of-features classification*. In: *Engineering in Medicine and Biology Society*, 2008. EMBS 2008. 30th Annual International Conference of the IEEE. IEEE, 2008. p. 3110-3113.

SMITH, J. C.; SCHATZ, B. R. *Feasibility of mobile phone-based management of chronic illness*. In: *AMIA Annual Symposium Proceedings*. American Medical Informatics Association, 2010. p. 757.

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. 154 f. Tese (Doutorado em Engenharia Elétrica). Universidade Federal do Rio Grande do Norte. Natal. 2008.

SUROWKA, G.; GRZESIAK-KOPEC, K. *Different learning paradigms for the classification of melanoid skin lesions using wavelets*. In: *Engineering in Medicine and Biology Society*, 2007.

EMBS 2007. *29th Annual International Conference of the IEEE*. IEEE, 2007. p. 3136-3139.

SUZUKI, S. et al. *Topological structural analysis of digitized binary images by border following*. *Computer Vision, Graphics, and Image Processing*, v. 30, n. 1, p. 32-46, 1985.

TOMASI, C. MANDUCHI, R. *Bilateral filtering for gray and color images*. In: *Computer Vision, 1998. Sixth International Conference on*. IEEE, 1998. p. 839-846.

VAPNIK, V. *The Nature of Statistical Learning Theory*. New York: Editora Springer. 1995.

VENNILA, G. S.; SURESH, L. P.; SHUNMUGANATHAN, K. L. *Dermoscopic image segmentation and classification using machine learning algorithms*. In: *Computing, Electronics and Electrical Technologies (ICCEET), 2012 International Conference on*. IEEE, 2012. p. 1122-1127.

VIANA, P. Uma Arquitetura para Aplicações em Processamento de Imagens: um Estudo em Hardware/Software. 2002. 105 f. Dissertação (Mestrado em Ciências da Computação). Centro de Informática, Universidade Federal do Pernambuco, Recife. 2002.

WEISER, M. *Some computer science issues in ubiquitous computing*. *Communications of the ACM*, v. 36, n. 7, p. 75-84, 1993.

WEKA. *WEKA 3: Data Mining Software in Java*. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 5 Janeiro 2015.