



SCD: UMA FERRAMENTA PARA EXTRAÇÃO DE INFORMAÇÃO DE SINAIS NA PELE PARA IDENTIFICAÇÃO DE MELANOMA

Trabalho de Conclusão de Curso

Engenharia da Computação

Henrique da Costa Siqueira

Orientador: Prof. Dr. Bruno José Torres Fernandes



UNIVERSIDADE
DE PERNAMBUCO

Henrique da Costa Siqueira

**SCD: UMA FERRAMENTA PARA EXTRAÇÃO
DE INFORMAÇÃO DE SINAIS NA PELE PARA
IDENTIFICAÇÃO DE MELANOMA**

Monografia apresentada como requisito parcial para
obtenção do diploma de Bacharel em Engenharia de
Computação pela Escola Politécnica de Pernambuco
– Universidade de Pernambuco.

Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação

Recife, junho de 2014.

MONOGRAFIA DE FINAL DE CURSO

Avaliação Final (para o presidente da banca)*

No dia 7 de 7 de 2014, às 10:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente HENRIQUE DA COSTA SIQUEIRA, orientado pelo professor Bruno José Torres Fernandes, sob título SCD: Uma ferramenta para extração de informação de sinais na pele para identificação de melanoma, a banca composta pelos professores:

Byron Leite Dantas Bezerra

Bruno José Torres Fernandes

Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada Aprovada com Restrições* Reprovada

e foi-lhe atribuída nota: 9,5 (nove e meio)

*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 7 dias para entrega da versão final da monografia a contar da data deste documento.


BYRON LEITE DANTAS BEZERRA


BRUNO JOSÉ TORRES FERNANDES

* Este documento deverá ser encadernado juntamente com a monografia em versão final.

*Dedico este trabalho especialmente à meu pai Carlos Fernando B. Ferreira,
à minha família, Goretti, Eglantine, Fernanda e à minha noiva Eleneida.*

Agradecimentos

Agradeço, primeiramente, a Deus e a Jesus Cristo por ter me dado tantas oportunidades e por caminhar junto a mim no caminho da vida, foi daí que busquei a força, a coragem e a esperança em momentos de dificuldade.

Agradeço especialmente à meu pai e inspirador, Carlos Fernando Bandeira Ferreira, aquele que foi a pessoa mais importante da minha vida, com seus preciosos conselhos, atos, dedicação, paciência, confiança e amor, sem ele nada disso seria possível.

Agradeço à Celeste, Goretti, Eglantine e Fernanda por toda dedicação, exigência, carinho, criação e educação, acima de tudo, por estarem sempre ao meu lado. Por tudo que foi ensinado, por todos os valores adquiridos e por todas as vitórias.

Agradeço à minha noiva e companheira, Eleneida, por todo o amor, dedicação e paciência, por me fazer sorrir e sonhar. Por estar sempre presente, cobrando e orientando. Foi essencial para chegar onde estou, desde o primeiro dia que à conheci.

Agradeço à toda minha família, em especial Alice, Elizabete, Helena, Aldemir, Ricardo e Humberto, pela criação, educação, carinho, amor e suporte que me deram em todas as fases da minha vida.

Agradeço a todos amigos da POLI-UPE, por todos momentos que passamos, e todo conhecimento compartilhado, principalmente André, Felipe e Gildo, pelo grupo que formamos, quase sempre inseparáveis, estudando, trabalhando e nos divertindo, deixando na memória momentos inesquecíveis.

Agradeço a meu professor e orientador, Bruno Fernandes, pelo apoio constante durante a graduação e neste trabalho. Sua ajuda foi além do esperado.

Por fim, agradeço à todos os amigos do CESAR, em particular Lucas Schmitz e Darlan Florêncio por todo ensinamento, apoio e pelos grande momentos. Além de João Carlos Quintino que contribuiu mais que o necessário no *design* da ferramenta.

Resumo

O câncer de pele está entre os tipos de câncer mais frequentes no mundo. O melanoma é o tipo da doença que mais preocupa, por ser o mais grave devido à sua alta possibilidade de metástase e por ser fatal caso não tratada. Seu índice mundial de ocorrência é cerca de 133.000 pessoas por ano. O método mais comum de diagnóstico é feito visualmente baseado em cinco características: assimetria, borda, cor, diâmetro e elevação, conhecido como o método ABCDE (iniciais das características). Todavia, a maior parte da população não tem acesso ao exame. Este trabalho propõe um sistema móvel, SCD – *Skin Cancer Detection*, capaz de extrair informação de sinais na pele, utilizando técnicas de processamento de imagens e visão computacional para identificação de melanoma. A análise dos resultados obtidos é realizada através da curva ROC (*Receiver Operating Characteristic*) utilizando as bases *Atlas of Clinical Dermatology* e *DermNet NZ*, e por testes de usabilidade para definir as condições em que o sistema proposto apresenta uma melhor eficácia.

Abstract

Skin cancer is among the most frequent types of cancer worldwide. Melanoma is a type of disease that most worries, to be the most serious because of its high ability to metastasize and be fatal if untreated. Its worldwide occurrence rate is about 133,000 people a year. The most common method of diagnosis is visually based on five characteristics: asymmetry, border, color, diameter and elevation, known as the ABCDE (initial characteristics) method. However, most of the population does not have access to the exam. This paper proposes a mobile system, SCD - Skin Cancer Detection, able to extract information from signals in the skin, using techniques of image processing and computer vision to identify melanoma. The analysis of the results is performed through the ROC (Receiver Operating Characteristic) using the Atlas of Clinical Dermatology and DermNet NZ bases, and usability testing to define the conditions under which the proposed system shows better efficacy.

Sumário

Capítulo 1 Introdução	1
1.1 Objetivos	2
1.2 Estrutura da Monografia	2
Capítulo 2 Fundamentos e Processamento de Imagens Digitais	3
2.1 Aquisição da Imagem	3
2.1.1 Elementos da Percepção Visual Humana	3
2.1.2 Sensoriamento e Aquisição de Imagem	5
2.1.3 Amostragem e Quantização de Imagens Digitais	7
2.1.4 Relacionamento Básico entre Pixels da Imagem	9
2.1.5 Imagens Digitais Coloridas	10
2.2 Pré-processamento de Imagens	11
2.2.1 Fundamentos da Filtragem Espacial	12
2.2.2 Filtros Espaciais de Suavização	13
2.3 Segmentação de Imagens	14
2.3.1 Segmentação por Limiarização	15
Capítulo 3 Identificação de Câncer de Pele	17
3.1 Melanoma	17
3.2 Caracterização do Melanoma	18
Capítulo 4 Modelo Proposto	20
4.1 Sistema Móvel	20
4.2 Algoritmo de Captura	25
4.3 Pré-processamento e Segmentação	27
4.4 Extração de Informação	30
4.4.1 Taxa de Assimetria	31

4.4.2	Desvio Padrão da Borda	34
4.4.3	Taxa da Cor	36
Capítulo 5 Resultados Obtidos		39
5.1	Experimentos	39
5.2	Resultados	41
5.2.1	Resultados da Extração de Informação do Sinal	41
5.2.2	Resultados de Usabilidade do SCD	42
Capítulo 6 Considerações Finais		47
6.1	Trabalhos Futuros	47
Bibliografia		49

Índice de Figuras

Figura 1. Diagrama esquemático de um corte transversal do olho humano, retirado do trabalho de Stolfi.	4
Figura 2. Comparação do olho humano com a máquina fotográfica.	5
Figura 3. Ilustração da transformação da energia em sinal por sensor, adaptada do livro de Gonzalez e Woods.....	6
Figura 4. Ilustração da aquisição de imagem digital, adaptada do livro de Gonzalez e Woods.	7
Figura 5. Processo de amostragem e quantização de imagem analógica, adaptada do livro de Gonzalez e Woods.....	8
Figura 6. Representação de imagem digital, adaptada.	9
Figura 7. Ilustração de conectividade entre pixels: (a) Matriz bidimensional de pixels (b) Pixels que são 8-con (c) Pixels que são m-con.	10
Figura 8. Bandeira de Pernambuco adaptada ilustrando a decomposição de pixels nos sistemas RGB e HSL.....	11
Figura 9. Funcionamento da filtragem espacial com máscara 3 x 3, adaptada do livro de Gonzalez e Woods.	12
Figura 10. Exemplo da aplicação do filtro de mediana.	13
Figura 11. Gráfico com distribuição Gaussiana.....	14
Figura 12. Máscara para filtro Gaussiano.....	14
Figura 13. Imagem de melanoma adaptada em tons de cinza (esquerda) e o histograma da imagem (direita).....	15
Figura 14. Imagem original da pele com câncer (esquerda) e imagem segmentada pelo método de Otsu (direita).....	16
Figura 15. Camadas da pele adaptada do trabalho de Randy.	17

Figura 16. Ilustração das características do sinal, (a) comparação de assimetria, (b) comparação de irregularidade da borda, (c) variância do histograma da cor e (d) diâmetro.	19
Figura 17. Arquitetura do sistema do <i>Skin Cancer Detection</i>	21
Figura 18. Diagrama de caso de uso do <i>Skin Cancer Detection</i>	21
Figura 19. Design do <i>Skin Cancer Detection</i>	23
Figura 20. Diagrama de classes do <i>Skin Cancer Detection</i>	24
Figura 21. Imagem nítida (esquerda) e não nítida (direita).	25
Figura 22. Resultado da diminuição da área de foco.	27
Figura 23. Imagem original (esquerda). Imagem convertida para escala de cinza (direita).	27
Figura 24. Imagem em escala de cinza (esquerda). Imagem com aplicação do filtro Gaussiano (direita).	28
Figura 25. Imagem suavizada (esquerda). Imagem segmentada (direita).	28
Figura 26. Algumas regiões de fundo classificados como sinal destacadas em verde e alguns buracos da região do sinal destacados em laranja.	29
Figura 27. Imagem segmentada (esquerda), resultado da aplicação do algoritmo 3 (direita).	30
Figura 28. Relação de dimensão entre imagem real e digital.	30
Figura 29. Relação entre ângulos.	31
Figura 30. (1) Imagem original, (2) Imagem segmentada (3), Imagem com o eixo de orientação, (4) Imagem rotacionada.	32
Figura 31. (1) Imagem rotacionada, (2) Imagem com retângulo de menor área, (3) Imagem cortada pela dimensão do retângulo de menor área.	33
Figura 32. Assimetria com eixo y (a) e (e), metades sobrepostas em relação ao eixo y (b) e (f), assimetria com eixo x (c) e (g), metades sobrepostas em relação ao eixo x(d) e (h). Melanoma (a), (b), (c) e (d), sinal normal (e), (f), (g) e (h). Imagens adaptadas de Dermnet NZ.	34

Figura 33. Imagem adaptada da base Dermnet NZ e segmentada pelo SCD: Ilustra a aplicação do teorema de Pitágoras para obtenção da distância do centroide para o ponto de contorno.	35
Figura 34. Imagem adaptada da base Dermnet NZ e segmentada pelo SCD: (a) comparação das distâncias do melanoma (b) com o sinal normal.	35
Figura 35. Histogramas do sinal para cada canal de cor: (a) Imagem original, (b) Histograma do canal vermelho, (c) Histograma do canal azul, (d) Histograma do canal verde e (e) Histograma do sinal em escala de cinza.	37
Figura 36. Histograma do melanoma (cima) e sinal normal (baixo). Histograma obtido pelo Adobe Photoshop.	38
Figura 37. Exemplos de imagens dos bancos de dados: (a) Casos de melanoma do <i>DermNet NZ</i> , (b) Sinais normais do <i>DermNet NZ</i> , (c) Casos de melanoma do <i>Atlas of Clinical Dermatology</i>	40
Figura 38. Comparação entre as características extraídas dos sinais.	42
Figura 39. Comparação do resultado da segmentação para o cenário da luminosidade.	43
Figura 40. Comparação do resultado da segmentação para o cenário da obstrução.	44
Figura 41. Comparação do resultado da segmentação para o cenário da distância.	46

Índice de Tabelas

Tabela 1 Requisitos técnicos do sistema.....	20
Tabela 2 AUC das características dos sinais.....	42
Tabela 3 Informações extraídas no cenário da luminosidade.....	43
Tabela 4 Informações extraídas no cenário de obstrução.....	44
Tabela 5 Informações extraídas no cenário de distância.....	45

Tabela de Símbolos e Siglas

4-con - 4-conectividade

8-con - 8-conectividade

ABCD - Assimetria, Borda, Cor e Diâmetro

ABCDE - Assimetria, Borda, Cor, Diâmetro e Elevação

API - *Application Programming Interface* (Interface de Programação de Aplicação)

CBC - Carcinoma Basocelular

CEC - Carcinoma Espinocelular

FPS - Fator de Proteção Solar

HSL - *Hue, Saturation, Luminance* (Matiz, Saturação e Luminância)

INCA - Instituto Nacional de Câncer José Alencar Gomes da Silva

JNI - *JAVA Native Interface* (Interface Nativa JAVA)

m-con - m-conectividade

OpenCV - *Open Source Computer Vision Library* (Biblioteca de Visão Computacional de Código Aberto)

PDI - Processamento Digital de Imagens

RAM - *Random Access Memory* (Memória de Acesso Aleatório)

RGB - *Red, Green, Blue* (Vermelho, Verde e Azul)

ROC - *Receiver Operating Characteristic* (Característica de Operação do Receptor)

SBD - Sociedade Brasileira de Dermatologia

SCD - *Skin Cancer Detection* (Detecção de Câncer de Pele)

Std Dev - *Standard Deviation* (Desvio Padrão)

UC - *User Case* (Caso de Uso)

UML - *Unified Modeling Language* (Linguagem de Modelagem Unificada)

Capítulo 1

Introdução

Atualmente, o câncer de pele está entre os tipos mais frequentes de câncer no mundo, sendo o tipo de tumor mais comum no Brasil, segundo pesquisa realizada pelo INCA (Instituto Nacional de Câncer José Alencar Gomes da Silva) [24]. Sua incidência tem aumentado rapidamente a taxas, aproximadamente, de 3% a 7% para a população de peles claras [29]. Existem três principais tipos de câncer de pele: o carcinoma basocelular (CBC), o carcinoma espinocelular (CEC), e o melanoma [38] [44], o último representa 4% dos diagnósticos da doença e sua maior incidência está em adultos de cor branca. Contudo, é o caso mais grave devido à sua alta possibilidade de metástase [34].

O procedimento mais comum de identificação do melanoma é feito pela dermatoscopia, exame normalmente realizado através do dermatoscópio, aparelho com lente de aumento de 10 vezes. Com isso é feita a análise de cinco principais características, conhecidos como ABCDE (Assimetria, Borda, Cor, Diâmetro e Elevação).

O sucesso do tratamento desse tipo de câncer aumenta consideravelmente se identificado nos estágios iniciais [34], podendo ser completamente curados [5].

Uma matéria jornalística divulgou uma pesquisa realizada pela Sociedade Brasileira de Dermatologia, onde foi constatado que a maior incidência da doença está no interior do país, aonde o acesso ao exame é árduo ou inacessível [25]. O sistema proposto neste trabalho é uma ferramenta para extrair informação do sinal. Visa atender essa população, para que a identificação do melanoma ocorra em fase inicial.

1.1 Objetivos

O trabalho tem o objetivo de desenvolver um sistema móvel para a plataforma Android, o SCD – *Skin Cancer Detection*. Com a finalidade de extrair informação de sinais na pele humana para identificação de melanoma, tipo mais perigoso de câncer de pele. Visa servir de auxílio para a população que o acesso à saúde é precário ou inexistente.

A engenharia do sistema proposto está voltada para o baixo custo e a usabilidade, com *design* simples e objetivo. O trabalho proposto tem como meta desenvolver uma aplicação de suporte ao combate do câncer de pele, facilitando o atendimento à população que não tem acesso aos departamentos médicos dermatológicos, onde é realizado o exame. Porém, não deve eliminar a consulta com o médico.

1.2 Estrutura da Monografia

O trabalho está estruturado em seis capítulos. No Capítulo 2, são apresentados os fundamentos e técnicas de processamento digital de imagens. No Capítulo 3, é abordado o melanoma e sua caracterização. No Capítulo 4, está presente o modelo proposto, SCD, para extrair informação de sinais na pele para identificação de melanoma. No Capítulo 5, serão mostrados os experimentos e os resultados obtidos. Finalmente, no Capítulo 6 serão apresentadas as conclusões e trabalhos futuros.

Capítulo 2

Fundamentos e Processamento de Imagens Digitais

Neste Capítulo são apresentados alguns fundamentos e técnicas de processamento digital de imagens, dividido em três etapas principais: a aquisição, o pré-processamento e a segmentação de imagens.

2.1 Aquisição da Imagem

Nesta Seção são apresentados conceitos básicos do processamento de imagens. Uma breve explicação da mecânica do sistema visual humano. O processo de obtenção de imagens e como são representadas no meio digital, através da amostragem e quantização. Por fim, serão explicadas algumas relações básicas entre os pixels e como é representada a imagem colorida.

2.1.1 Elementos da Percepção Visual Humana

O processamento digital de imagens tem como base a matemática e a estatística. Contudo a análise humana é um fator crucial na escolha de uma técnica em detrimento de outra, apoiado, em sua maioria, em aspectos visuais subjetivos. Desta forma, é apropriado ter uma compreensão básica da percepção visual humana.

A Figura 1 corresponde a um corte transversal simplificado do olho humano. O olho tem a forma semelhante a uma esfera, com cerca de 20 mm de diâmetro. É revestido por três membranas: a córnea, a retina e a coroide. Esta última, exerce o papel de nutrição do olho, por conter uma rede de vasos sanguíneos, e também ajuda na redução de luz indesejável que incide no globo ocular, em razão de ser envolvida por uma substância pigmentada [21].

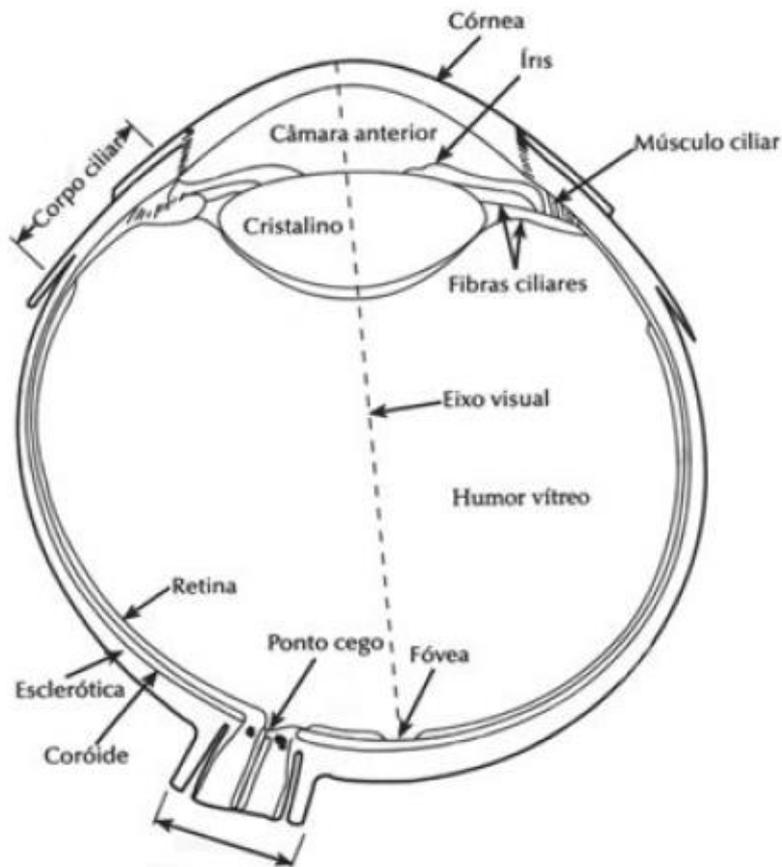


Figura 1. Diagrama esquemático de um corte transversal do olho humano, retirado do trabalho de Stolfi [42].

A íris situa-se no extremo anterior da coróide, tem como função o controle da quantidade de luz que entra no olho, podendo variar a abertura central de 2 a 8 mm.

O cristalino é colorido por uma pigmentação amarelada, que com o avanço da idade se intensifica, podendo causar a catarata, doença que causa problemas na discriminação de cores e até a perda de nitidez das imagens [21].

A retina é a membrana mais interna do olho, onde as imagens são formadas. Isto é possível pela visão de padrões obtidas pela distribuição de receptores discretos de luz ao longo de sua superfície, os cones e os bastonetes. O número de cones presente em cada olho é de 6 a 7 milhões. Eles estão concentrados na parte central da retina, chamada de fóvea, região circular com aproximadamente 1,5 mm. São sensíveis as cores e responsáveis pela distinção dos detalhes das imagens.

Os bastonetes tem um número bem superior aos cones, aproximadamente 75 a 150 milhões em cada olho, dispersados na superfície da retina. São responsáveis por uma visão mais ampla da imagem sem levar em conta os detalhes e cores. Por serem estimulados com baixo nível de iluminação, os bastonetes tornam possível a visualização de objetos à noite, explicando o fato de vermos as imagens em escala de cinza nesta situação [21].

A formação das imagens no olho humano pode ser comparado com o mecanismo de geração em máquinas fotográficas, Figura 2.

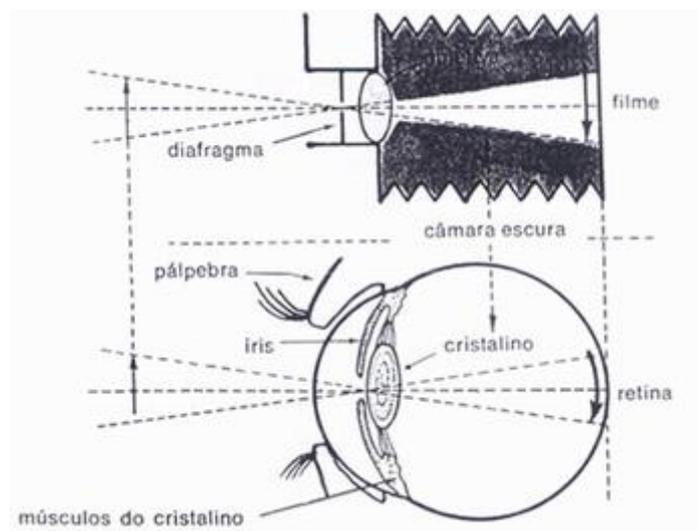


Figura 2. Comparação do olho humano com a máquina fotográfica [13].

Resumidamente, na câmera a lente tem a função de foco, que é ajustada variando a distância entre a lente e o plano que forma a imagem, em máquinas antigas, este plano era o filme fotográfico. No olho humano, o cristalino atua como lente e a retina como o plano de formação da imagem. Como a distância entre o cristalino e a retina é fixo, o foco é dado variando o formato da retina, através dos músculos do cristalino. Por fim, a percepção ocorre pela excitação dos receptores de luz, já mencionados, que transformam a energia radiante em impulsos elétricos transmitidos para o cérebro para que seja gerada a informação.

2.1.2 Sensoriamento e Aquisição de Imagem

Imagens são geradas pela associação de uma fonte de iluminação e elementos de uma cena, que são capazes de refletir ou absorver energia desta fonte.

A fonte de iluminação pode ser de diversas origens, a mais conhecida é a luz visível que ilumina uma cena tridimensional, mas também pode ser originada de outras fontes como: fonte eletromagnética, sistema de raios X e infravermelho.

Os elementos de uma cena podem ser objetos do cotidiano, como carro, casa e pessoas, como também podem ser elementos menos tradicionais, como moléculas, formações rochosas e órgãos humano.

A Figura 3 apresenta um esquema da transformação da energia em sinal por sensor simples. Este modelo pode ser estendido para uma matriz de sensores, e o conjunto dos sinais captados por cada sensor podem ser quantificados digitalmente para constituir uma imagem digital, como ilustra a Figura 4.

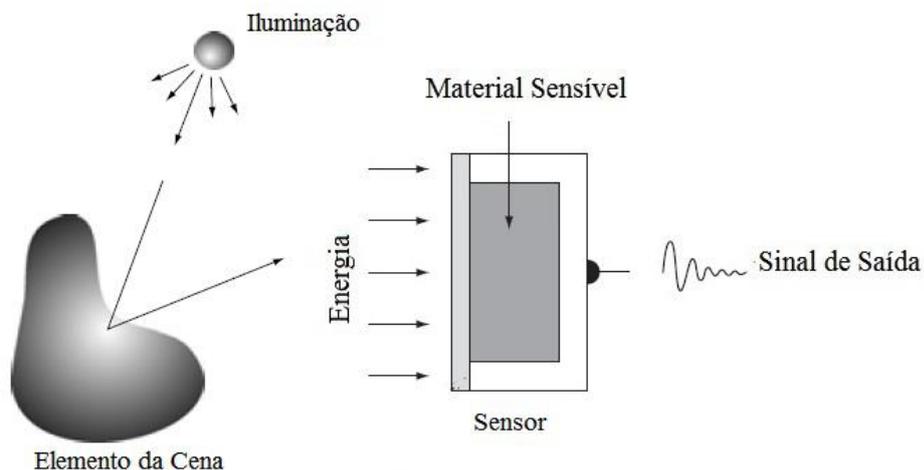


Figura 3. Ilustração da transformação da energia em sinal por sensor, adaptada do livro de Gonzalez e Woods [21].

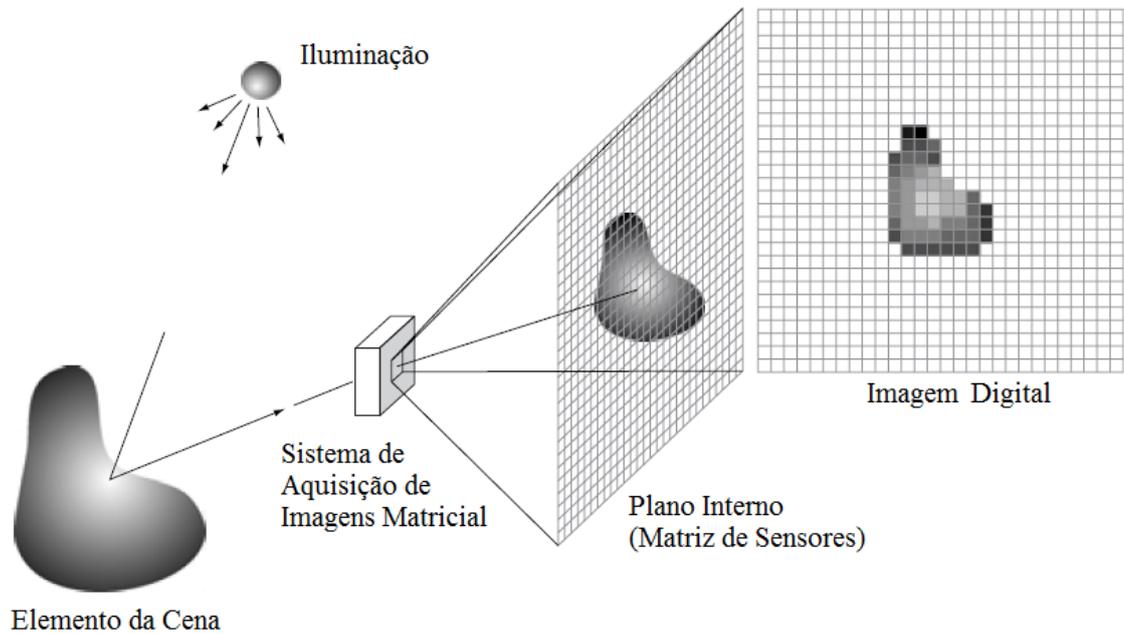


Figura 4. Ilustração da aquisição de imagem digital, adaptada do livro de Gonzalez e Woods [21].

2.1.3 Amostragem e Quantização de Imagens Digitais

No processo de criação de uma imagem digital, é preciso converter os dados captados pelos sensores que estão em formato de onda contínua em formato digital. Esta conversão é feita pela realização de dois processos: a amostragem e a quantização.

A Figura 5 mostra o processo de amostragem e quantização de uma imagem analógica que é convertida para uma imagem digital. A imagem analógica é representada por uma função contínua, tanto a respeito de coordenadas x e y , quanto à amplitude. A amostragem é o processo que digitaliza os valores das coordenadas, e a quantização é o processo que digitaliza a amplitude da função para cada ponto (x, y) da coordenada digitalizada [21].

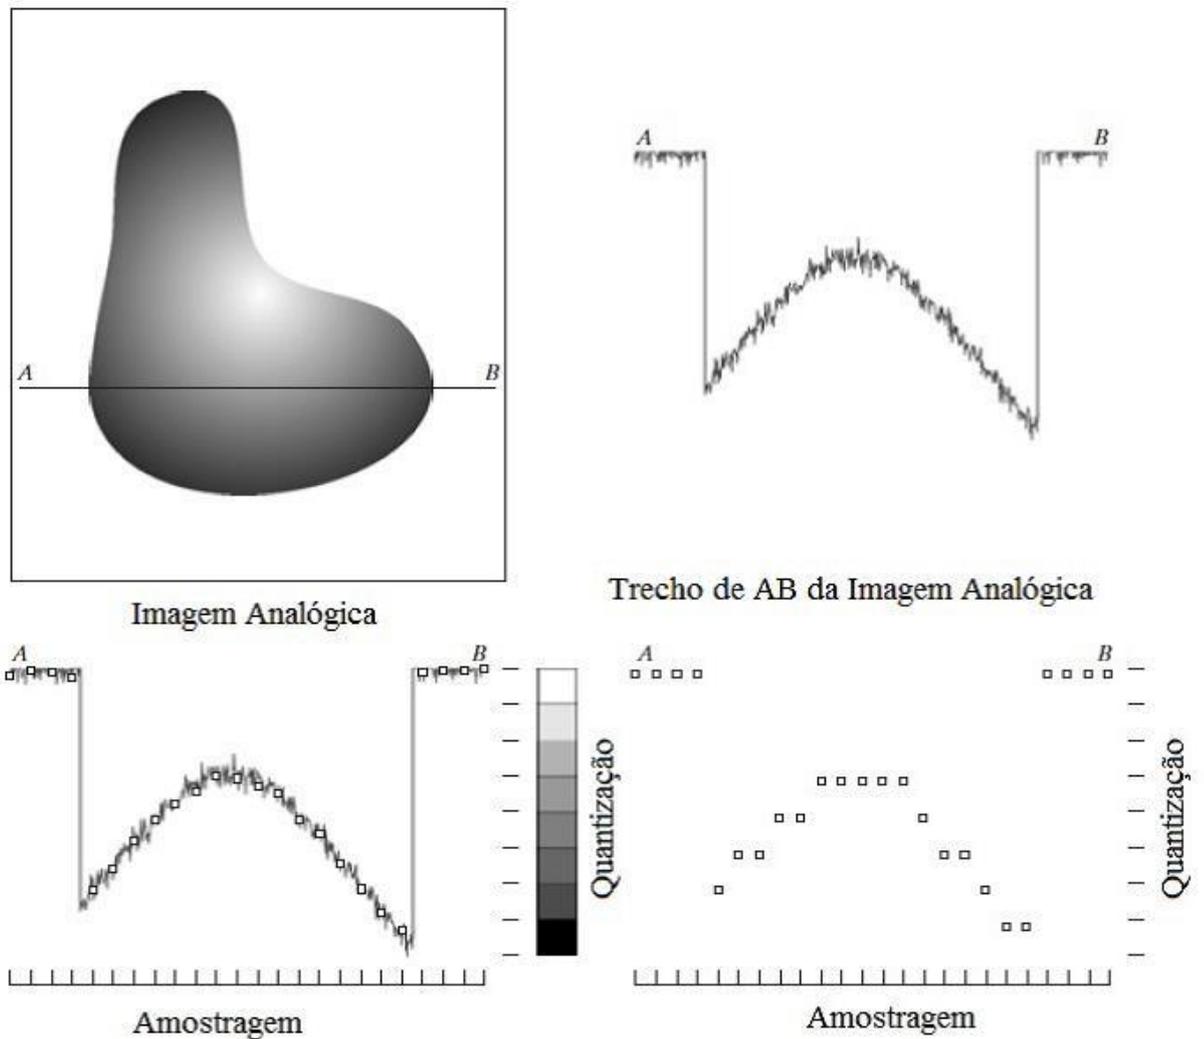


Figura 5. Processo de amostragem e quantização de imagem analógica, adaptada do livro de Gonzalez e Woods [21].

Por fim, a imagem digital é representada por uma matriz bidimensional formada por linhas e colunas, onde o valor da coordenada (*linha, coluna*) corresponde a intensidade naquele ponto, conhecido também como pixel, abreviação do inglês *picture element* (elemento da figura). A Figura 6 ilustra esse modelo.

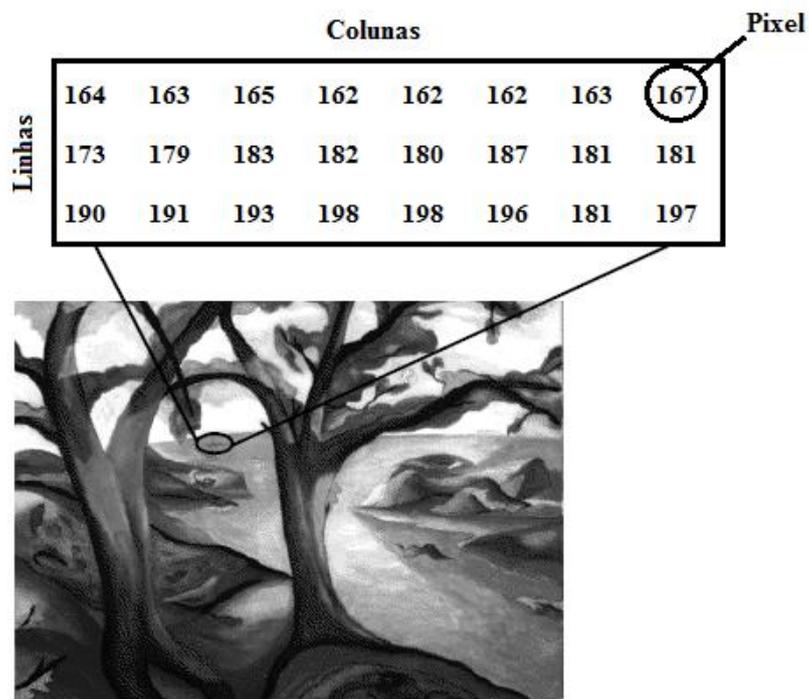


Figura 6. Representação de imagem digital, adaptada [40].

2.1.4 Relacionamento Básico entre Pixels da Imagem

Um pixel de uma imagem é representado por $f(l, c)$, sendo l a linha e c a coluna. Podemos definir o conceito de vizinhança de um pixel da seguinte forma: (I) vizinhos horizontais e verticais são definidos pelas coordenadas $f(l + 1, c)$, $f(l - 1, c)$, $f(l, c + 1)$ e $f(l, c - 1)$, formando o conjunto conhecido como vizinhança-4 ou $N_4(f)$; (II) vizinhos diagonais são definidos pelas coordenadas $f(l + 1, c + 1)$, $f(l + 1, c - 1)$, $f(l - 1, c + 1)$ e $f(l - 1, c - 1)$, formando o conjunto conhecido como vizinhança-D ou $N_D(f)$. A junção da vizinhança-D com a vizinhança-4 forma-se o conjunto conhecido como vizinhança-8 ou $N_8(f)$.

Outro conceito é a conectividade entre pixels que é fundamental para estabelecer o contorno de regiões presentes na imagem, propriedade que será formalizada posteriormente. Para estabelecer a conectividade de dois pixels eles devem ser adjacentes, para tal, dado $V = \{1\}$ um conjunto de valores de interesse de uma imagem binária, consideram-se três tipos de conectividade:

- **4-conectividade (4-con):** Dois pixels p e q com valores pertencentes a V , tal que q pertença ao conjunto $N_4(p)$;

- **8-conectividade (8-con):** Dois pixels p e q com valores pertencentes a V , tal que q pertença ao conjunto $N_8(p)$, Figura 7 (b);
- **m-conectividade (m-con), conectividade mista:** Dois pixels p e q com valores pertencentes a V , tal que q está em $N_4(p)$ ou q está em $N_D(p)$ e a interseção de $N_4(p)$ e $N_4(q)$ é vazio, Figura 7 (c).

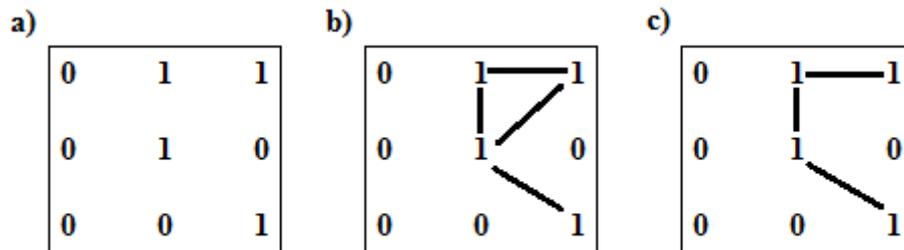


Figura 7. Ilustração de conectividade entre pixels: (a) Matriz bidimensional de pixels (b) Pixels que são 8-con (c) Pixels que são m-con.

Um caminho é uma sequência de pixels distintos e conectados, tendo um ponto inicial $p_0(l_0, c_0)$ e um ponto final $p_n(l_n, c_n)$:

$$p_0(l_0, c_0), p_1(l_1, c_1), p_2(l_2, c_2), \dots, p_{n-1}(l_{n-1}, c_{n-1}), p_n(l_n, c_n).$$

Caso $p_0(l_0, c_0) = p_n(l_n, c_n)$ se caracteriza-se um *caminho fechado*. O subconjunto formado por esses pixels juntamente com todos os pixels conectados a eles, é denominado *conjunto conexo* da imagem, e cada ponto pertencente a esse conjunto é denominado *componente conexo*.

Por fim, o contorno, fronteira ou borda é o subconjunto formado por pixels que tem conectividade com pixels do conjunto conexo e pelo menos um pixel que não pertença ao conjunto V .

2.1.5 Imagens Digitais Coloridas

A cor tem um papel importante na imagem, pois é um poderoso descritor na identificação de um objeto, descrevendo melhor as características da imagem. Em imagens digitais, foram definidos modelos para melhor representá-las de forma padronizada. Serão apresentados os modelos *RGB* (*Red, Green, Blue*), do

português vermelho, verde e azul, e *HSL* (*Hue*, *Saturation*, *Luminance*), do português matiz, saturação, luminância.

O modelo de cores RGB é baseado na teoria de visão colorida tricromática, de Young-Helmholtz [45], composta pelas três cores primárias e sua combinação formam outras cores. Na Figura 8 pode-se observar a decomposição de pixels no sistema RGB, sendo possível observar que o maior valor do componente no pixel detalhado corresponde a cor predominante.

O modelo de cores HSL, ilustrado na Figura 8, descrito por Joblove, George Greenberg e Donald [28] estabelece como componentes a matiz que representa a cor pura, a saturação que é a matiz misturada com a cor branca e a luminosidade refere-se a intensidade da luz refletida pelos objetos.

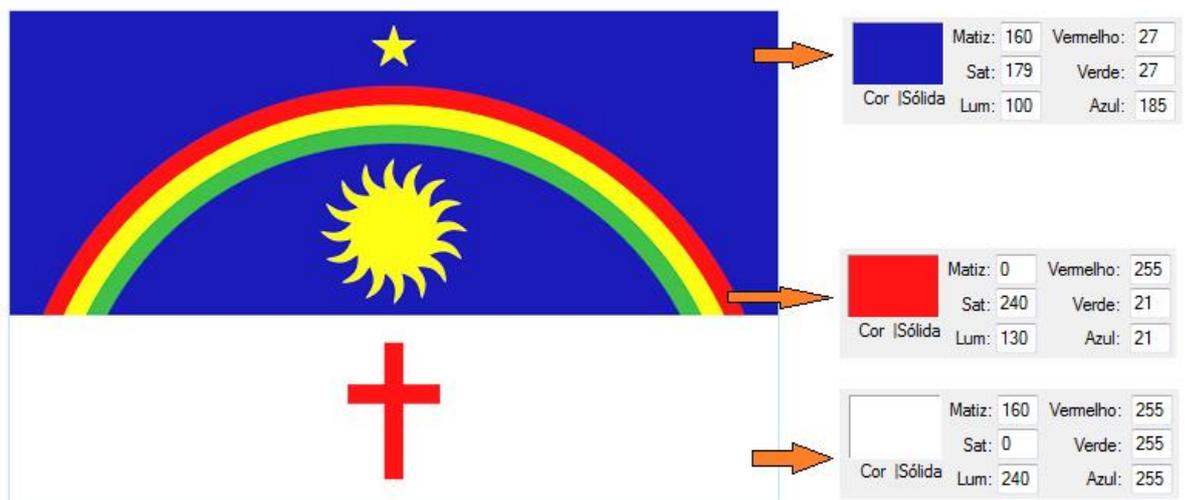


Figura 8. Bandeira de Pernambuco adaptada ilustrando a decomposição de pixels nos sistemas RGB e HSL [7].

2.2 Pré-processamento de Imagens

Nesta Seção, são apresentadas técnicas aplicadas no processamento inicial da imagem, a fim de corrigir distorções geométricas e remover ruídos.

2.2.1 Fundamentos da Filtragem Espacial

São operações efetuadas no pixel da imagem que dependem deste pixel e dos pixels de sua vizinhança. Essas operações são realizadas através da convolução de uma máscara (ou janela) com a imagem a ser tratada [36].

A máscara é uma matriz bidimensional, normalmente de pequena dimensão (por exemplo 3×3), que percorre a imagem realizando operações, como descrito na Figura 9.

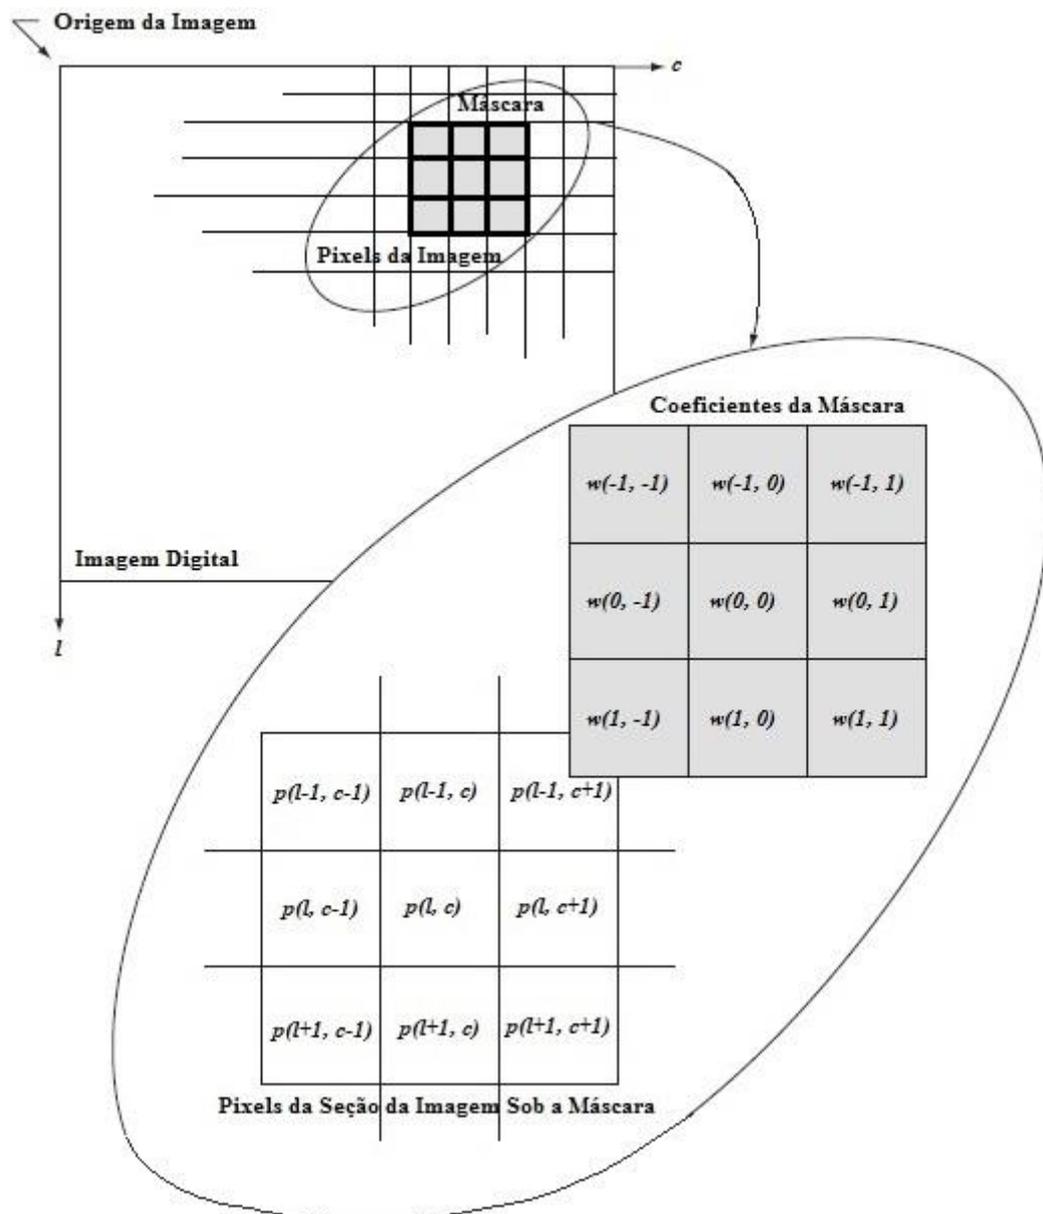


Figura 9. Funcionamento da filtragem espacial com máscara 3×3 , adaptada do livro de Gonzalez e Woods [21].

O pixel $p(l, c)$ terá o novo valor $g(l, c)$, que é o resultado da soma dos produtos dos coeficientes do filtro com os pixels da imagem, conforme seguinte equação,

$$g(l, c) = w(-1, -1) * p(l - 1, c - 1) + w(-1, 0) * p(l - 1, c) + \dots + w(0, 0) * p(l, c) + \dots + w(1, 1) * p(l + 1, c + 1). \quad (1)$$

2.2.2 Filtros Espaciais de Suavização

Filtro de suavização, também conhecidos como *filtros de média* ou *filtros passa-baixa*, é a operação de média dos pixels contidos na vizinhança da máscara de filtragem [21].

O filtro de mediana é um filtro espacial não linear, onde o valor do pixel central é substituído pela mediana dos pixels da imagem que estão sob a máscara. A mediana é o valor que separa uma amostra na metade. A Figura 10 descreve essa operação.

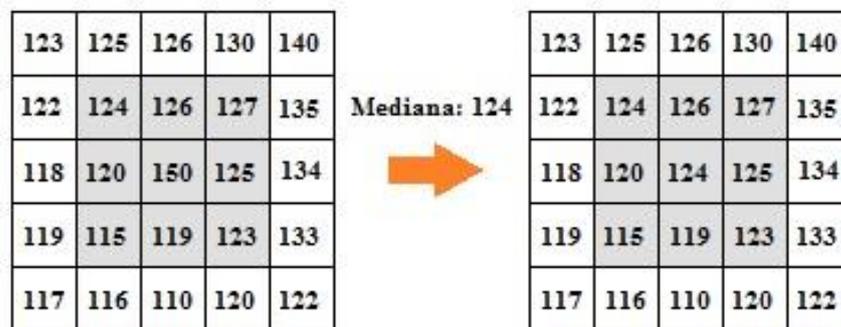


Figura 10. Exemplo da aplicação do filtro de mediana.

O filtro Gaussiano é uma operação de convolução, onde sua máscara deve ter pesos baseados na distribuição Gaussiana. A Figura 11 é um gráfico com distribuição gaussiana de média zero e desvio padrão igual a 1 e a Figura 12 é um exemplo de uma máscara desse filtro. Após a aplicação da equação (1), o resultado é dividido pelo somatório dos pesos.

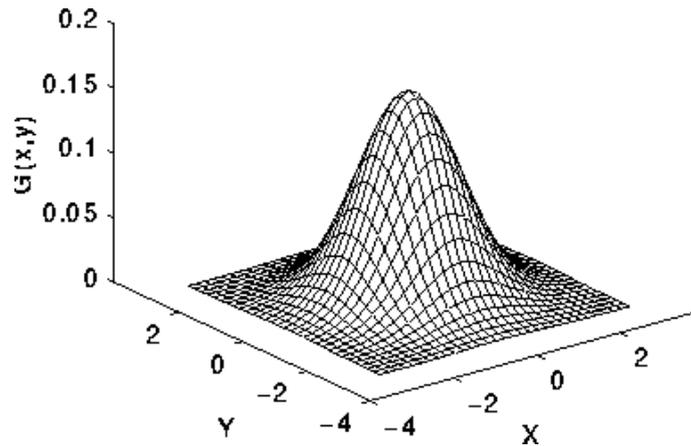


Figura 11. Gráfico com distribuição Gaussiana [22].

1	4	7	4	1
4	16	26	16	4
7	26	41	26	7
4	16	26	16	4
1	4	7	4	1

Figura 12. Máscara para filtro Gaussiano.

2.3 Segmentação de Imagens

A segmentação é o processo responsável por subdividir uma imagem monocromática (na escala de cinza) em regiões ou objetos de interesse. O sistema visual humano tem diferente percepção para cada canal de cor *RGB*. A equação

$$g(l, c) = 0.299 * p(l, c)[R] + 0.587 * p(l, c)[G] + 0.114 * p(l, c)[B], \quad (2)$$

é utilizada para a conversão de uma imagem no modelo *RGB* para o modelo em níveis de cinza [15].

As técnicas de segmentação se baseiam em duas propriedades: a descontinuidade e a similaridade. Por descontinuidade, a imagem é segmentada conforme sejam identificadas mudanças bruscas nos níveis de cinza dos pixels. Como exemplos dessa propriedade, tem-se é a detecção de pontos, linhas ou bordas na imagem através de filtros como o de Sobel [21].

Por similaridade, a imagem é dividida com base em um padrão de características semelhantes, de acordo com os critérios estabelecidos. A limiarização, o crescimento, divisão e fusão de regiões são exemplos da aplicação desta propriedade [21].

2.3.1 Segmentação por Limiarização

Segmentação por limiarização tem como base a análise do histograma. O histograma é uma representação gráfica da distribuição de frequências de uma amostra associados em classes. No processamento digital de imagens, o histograma é uma função discreta que indica a frequência dos pixels para cada intensidade na imagem. A Figura 13 é uma imagem da ocorrência do melanoma com o gráfico de seu histograma.

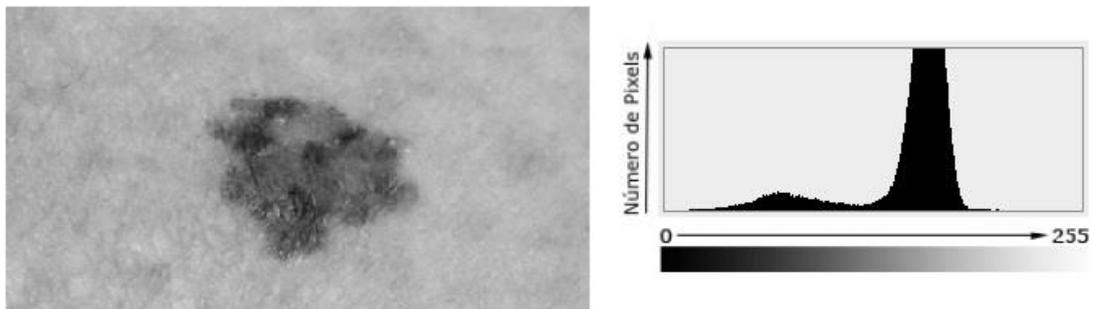


Figura 13. Imagem de melanoma adaptada em tons de cinza (esquerda) [9] e o histograma da imagem (direita).

A limiarização é um método específico que consiste em dividir a imagem em duas classes: o fundo e a região de interesse (objeto à ser analisado). Essa divisão é feita a partir de um determinado limiar L que separa o histograma em duas partes. Para cada pixel da imagem é realizada a operação descrita na equação a seguir:

$$g(l, c) = \begin{cases} 255, & p(l, c) < L \\ 0, & p(l, c) \geq L \end{cases} \quad (3)$$

Uma técnica bastante eficiente de segmentação é o método de Otsu [33]. Esse método assume que a imagem, é composta por duas classes, o objeto e o fundo. Para que se encontre o melhor limiar de segmentação das classes, deve-se atribuir o valor a L que minimize a variância intra-classe σ^2_{intra} . Essa variância pode ser definida como a soma ponderada das variâncias das classes,

$$\sigma_{intra}^2 = W_a * \sigma_a^2 + W_b * \sigma_b^2, \quad (4)$$

onde o W é a probabilidade de ocorrência de cada classe delimitada pelo limiar L . Para o cálculo da equação (4) é necessário outras três equações (5), (6) e (7), cuja variável P_i corresponde a probabilidade de ocorrência do pixel com intensidade i e μ é a média da intensidade para a classe correspondente, descritas a seguir:

$$W = \sum_{i=Ini}^{Sup} (P_i), \quad (5)$$

$$\mu = \frac{\sum_{i=Ini}^{Sup} i * (P_i)}{w}, \quad (6)$$

$$\sigma^2 = \sum_{i=Ini}^{Sup} [i - \mu]^2 * \frac{P_i}{W}. \quad (7)$$

Definidas as equações, deve-se percorrer todo o intervalo de intensidades. Para a classe a , o intervalo deve ser de 0 (valor inicial em imagens digitais) até L ; para a classe b , o restante, de $L+1$ até o limite superior, 255 no caso de imagens em tons de cinza com 256 níveis.

A Figura 14 ilustra o resultado de uma imagem da pele com câncer e a segmentação por Otsu, a fim de detectar a representação do sinal na imagem.



Figura 14. Imagem original da pele com câncer (esquerda) [9] e imagem segmentada pelo método de Otsu (direita).

Capítulo 3

Identificação de Câncer de Pele

Neste Capítulo é apresentada uma descrição do melanoma e como ele é caracterizado.

3.1 Melanoma

O melanoma é um tipo de câncer de pele que afeta as células que dão cor a pele, os melanócitos [16], Figura 15, localizado na parte inferior da epiderme. Embora represente a menor porcentagem na incidência dos tipos de câncer de pele, apenas 4%, é o mais grave, pois apresenta uma alta possibilidade de metástase, multiplicação da lesão cancerígena a partir da primeira, e a maior taxa de mortalidade, chegando a 65% [37]. Sua maior incidência está em adultos de cor branca, tendo 20 vezes mais chance de ter a doença, que afrodescendentes [17].

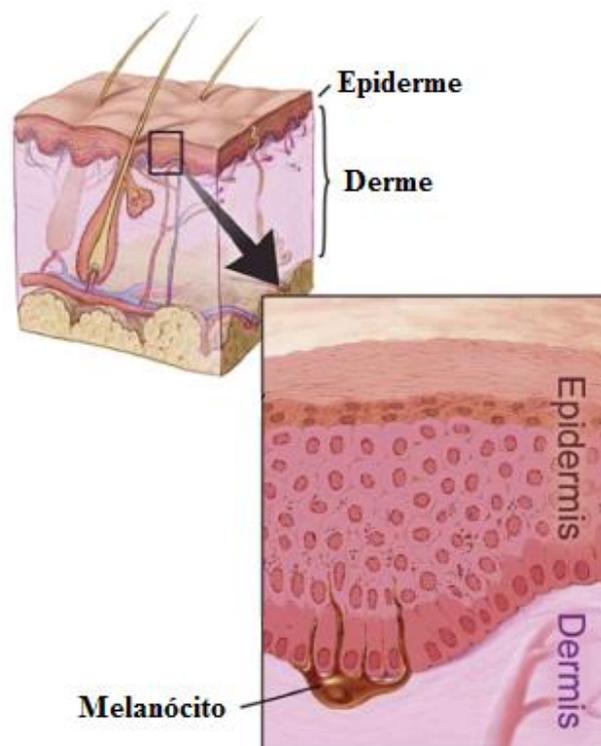


Figura 15. Camadas da pele adaptada do trabalho de Randy [37].

Pode começar como um sinal que vai crescendo com o tempo, podendo mudar de cor (qualquer cor: vermelho, azul, bege, marrom, preto, cinza ou branco), apresentar bordas irregulares, ser plana ou elevada na área da pele, ser indolor ou formar feridas e irritações podendo até sangrar. Seu aparecimento independe de qualquer região do corpo, sendo mais provável em regiões mais expostas ao sol, como ombros, cabeça, perna, dentre outros [16].

O sucesso do tratamento desse tipo de câncer aumenta consideravelmente se identificado nos estágios iniciais. Como prova disso, nos últimos anos houve uma grande melhora na sobrevivência dos pacientes com melanoma com detecção precoce, segundo o INCA [34] e cerca de 90% a 95% dos casos que diagnosticados quando o sinal tem diâmetro menor que 1 mm, ficam completamente curados [5].

3.2 Caracterização do Melanoma

O procedimento de identificação do melanoma é feito pela dermatoscopia. Sua realização, mais comum, é feita através do dermatoscópio, aparelho com lente de aumento de 10 vezes. Com isso é feita a análise de cinco principais características, conhecidos como ABCDE [20].

Um trabalho feito por Nachbar [30] desconsidera a última característica, a elevação. Assim, a fim de identificar a presença do melanoma são analisadas quatro características:

- *A assimetria*, que ao dividir o sinal em duas partes as regiões sobrepostas não coincidem. A Figura 16 (a) ilustra claramente que o melanoma (esquerda) é assimétrico e o sinal (direita) simétrico;
- *A borda*, que apresentam irregularidade. Na Figura 16 (b), as duas imagens de cima, apresentam irregularidade na borda (melanoma), em contrapartida, as imagens de baixo (sinal) possui a borda com transições suaves;
- *A coloração*: mais de uma cor no mesmo sinal. A Figura 16 (c) apresenta histogramas dos sinais. No de cima, caso de melanoma, o histograma apresenta uma grande faixa de intensidades, ao contrário da imagem de baixo, com uma faixa pequena;

- O *diâmetro* do sinal, maior que 6 mm. Exemplo de um caso de melanoma com aproximadamente 2 cm na Figura 16 (d).

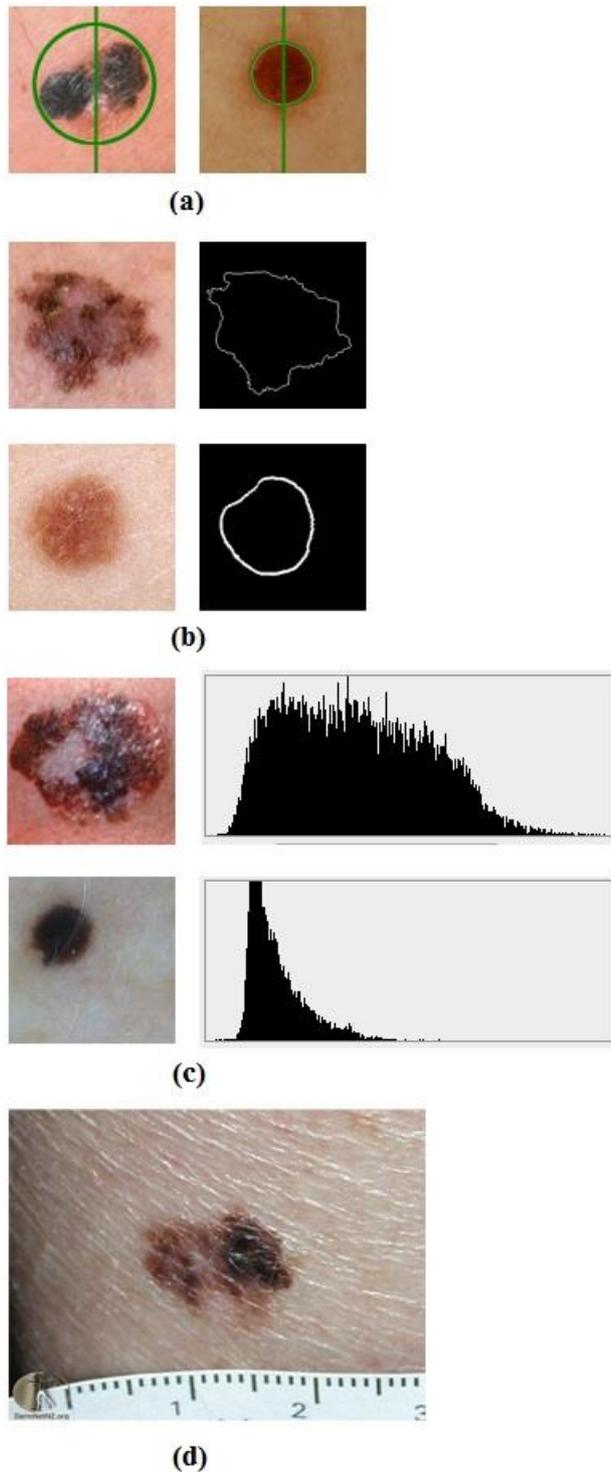


Figura 16. Ilustração das características do sinal, (a) comparação de assimetria [9], (b) comparação de irregularidade da borda [9], (c) variância do histograma da cor [16] [9] e (d) diâmetro [9].

Capítulo 4

Modelo Proposto

O *Skin Cancer Detection* é uma ferramenta de combate ao câncer de pele. Visa atender a população sem acesso a exames dermatológicos e que trabalham com alta exposição solar, em sua maioria, trabalhadores da zona rural nos municípios do interior do país [26].

Este Capítulo descreve o desenvolvimento do sistema de acordo com as teorias apresentadas anteriormente. São apresentadas a arquitetura e características do sistema, e o processo utilizado na captura da imagem. Por fim, com se dá a extração de informação do sinal.

4.1 Sistema Móvel

O *Skin Cancer Detection* (SCD) tem como objetivo facilitar o acesso ao exame dermatológico na identificação do câncer de pele, em particular o melanoma, para que se dê início ao tratamento em sua fase inicial. Tem como principal benefício sua mobilidade, possibilitando que o exame independa de local e horário.

O SCD é um sistema móvel voltado para a usabilidade, com *design* simples e objetivo, promovendo acessibilidade às pessoas não habituadas à tecnologia. Sua confiabilidade deve ser garantida, mas não substitui a consulta com médicos.

A aplicação foi desenvolvida para a plataforma Google Android, sendo necessários os requisitos técnicos descritos na Tabela 1.

Tabela 1. Requisitos técnicos do sistema.

Característica	Requisito
Plataforma	Android
Versão da Plataforma	4.1 ou superior
Câmera	Sim
Resolução	8.0MP ou superior
Foco	Automático e Área

O SCD consiste basicamente de uma funcionalidade, a identificação do melanoma, que está dividida em três fases principais: (a) Captura da imagem; (b) Processamento da imagem; (c) Visualização da informação. A Figura 17, criada no Bizagi [11], ilustra detalhadamente o processo de identificação do sinal e as relações fundamentais entre os módulos do sistema.

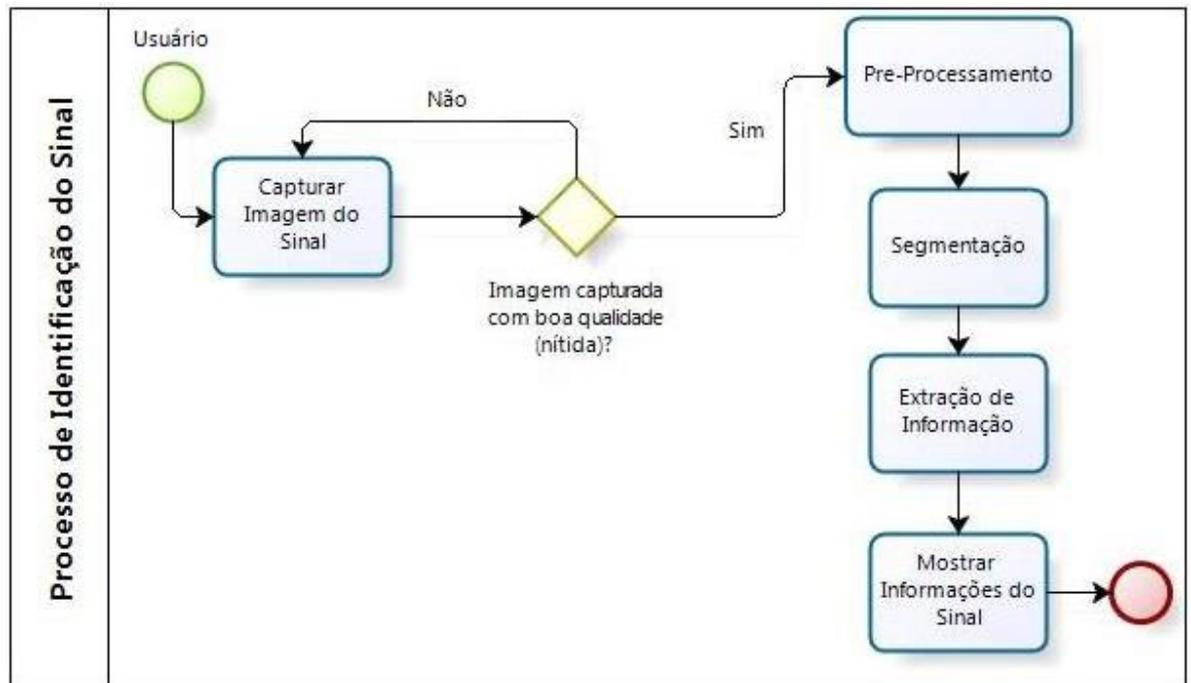


Figura 17. Arquitetura do sistema do *Skin Cancer Detection*.

O diagrama de caso de uso do *Skin Cancer Detection*, descreve a sequência de interações entre o sistema e os agentes externos que o utilizam [10]. A Figura 18 apresenta este diagrama, feita na ferramenta Astah para modelagem UML (*Unified Modeling Language*) [6].

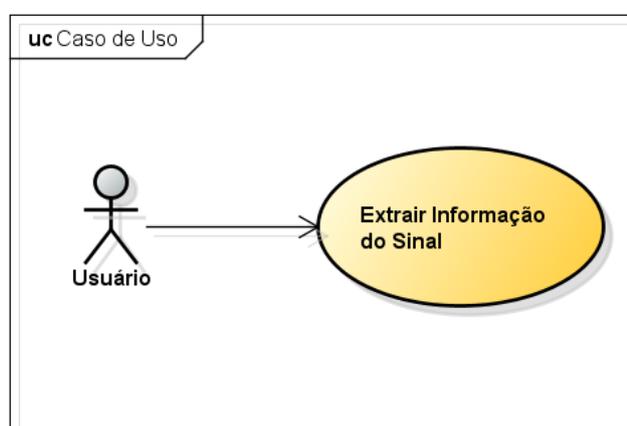


Figura 18. Diagrama de caso de uso do *Skin Cancer Detection*.

O detalhamento do caso de uso Extrair Informação do Sinal está escrito na forma de descrição numerada, narrativa feita através de uma série de passos numerados introduzidos por Wirfs-Brock em 1991 [10]:

1. O Usuário acessa o aplicativo pelo seu *smartphone* e inicia o processo de extração de informação através do botão de captura da imagem.
2. O sistema apresenta a visualização da câmera do aparelho com um retângulo representando a área de foco e corte da imagem.
3. O usuário toca na tela do aparelho para captura da imagem.
4. O sistema foca a área delimitada pelo retângulo e caso obtenha sucesso, realiza a captura da imagem e efetua o corte da imagem com os limites daquela área, caso contrário o Sistema reajusta a área e o Usuário repete a ação.
5. Então, após sucesso do item anterior, o Sistema processa a imagem capturada e exibe a informação do sinal, assimetria, borda irregular, cor não uniforme, diâmetro.

A Figura 19 apresenta o *design* do SCD em sequência numerada da interação do usuário.

Para o desenvolvimento, é utilizada a linguagem JAVA por ser a linguagem convencional da plataforma Android. Pelo fato de ser uma linguagem de programação orientada a objetos, foi factível a definição de seu aspecto estrutural estático. Isto permite a compreensão de como o sistema está estruturado internamente para que as funcionalidades externas visíveis sejam produzidas [10]. Esse aspecto é dito estático por não apresentar como os objetos interagem entre si.

O diagrama da UML utilizado para representar esse aspecto é o diagrama de classes, disponível na Figura 20. Ele é importante na fase de implementação do aplicativo, por definir as principais classes, atributos e métodos que o sistema necessita.

Finalmente, o OpenCV [31] exerce um importante papel no projeto. Primeiramente por ser uma biblioteca rica em métodos de processamento de imagens e visão computacional, com mais de 350 algoritmos.

Outro ponto é a performance do sistema, ainda que aparelhos móveis tem seu poder computacional limitado por memória RAM (do inglês *Random Access Memory*), processamento e capacidade energética. Como minimização deste problema, os código do *OpenCV* são otimizados e implementados de forma nativa para Android, na linguagem C/C++ através do uso do mecanismo JNI (*JAVA Native Interface*) [3] [27]. O JNI permite chamadas a aplicações e bibliotecas escritas em outras linguagens, até mesmo assembly [27].

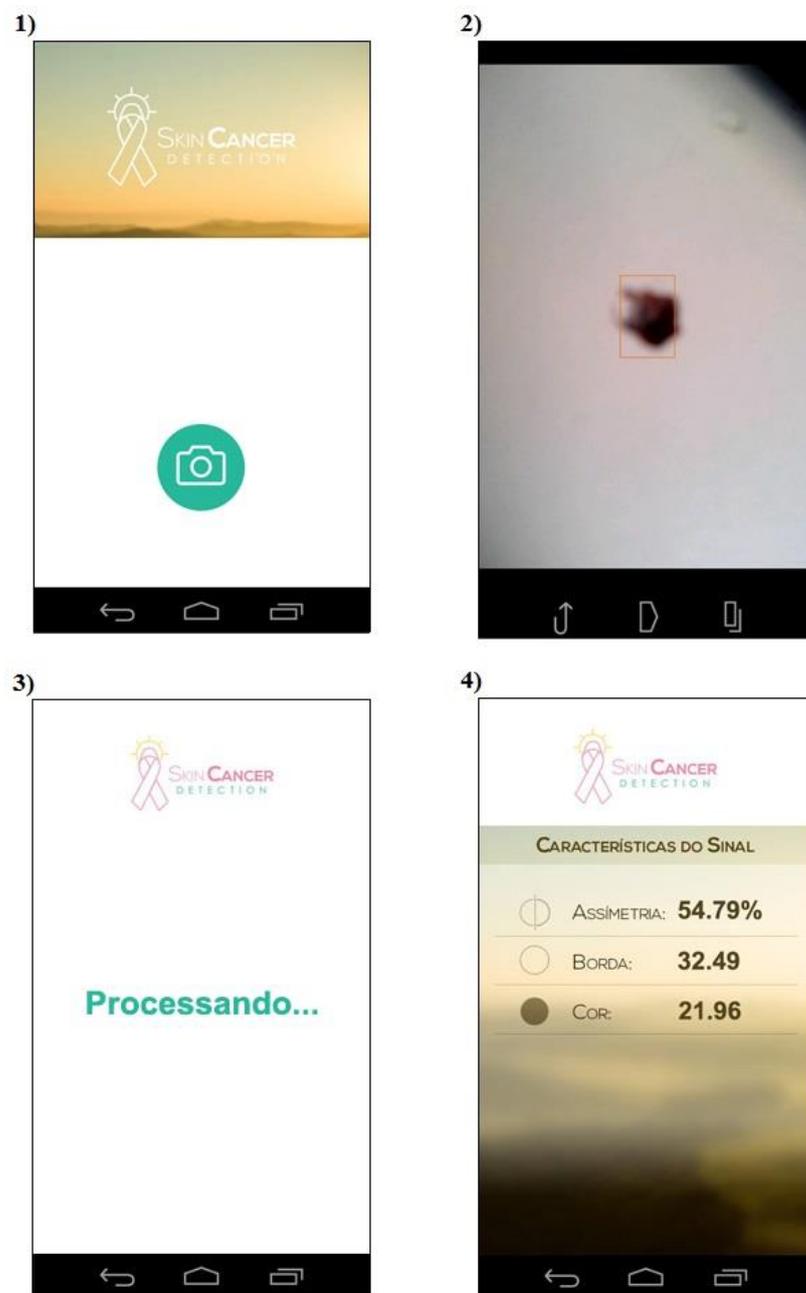
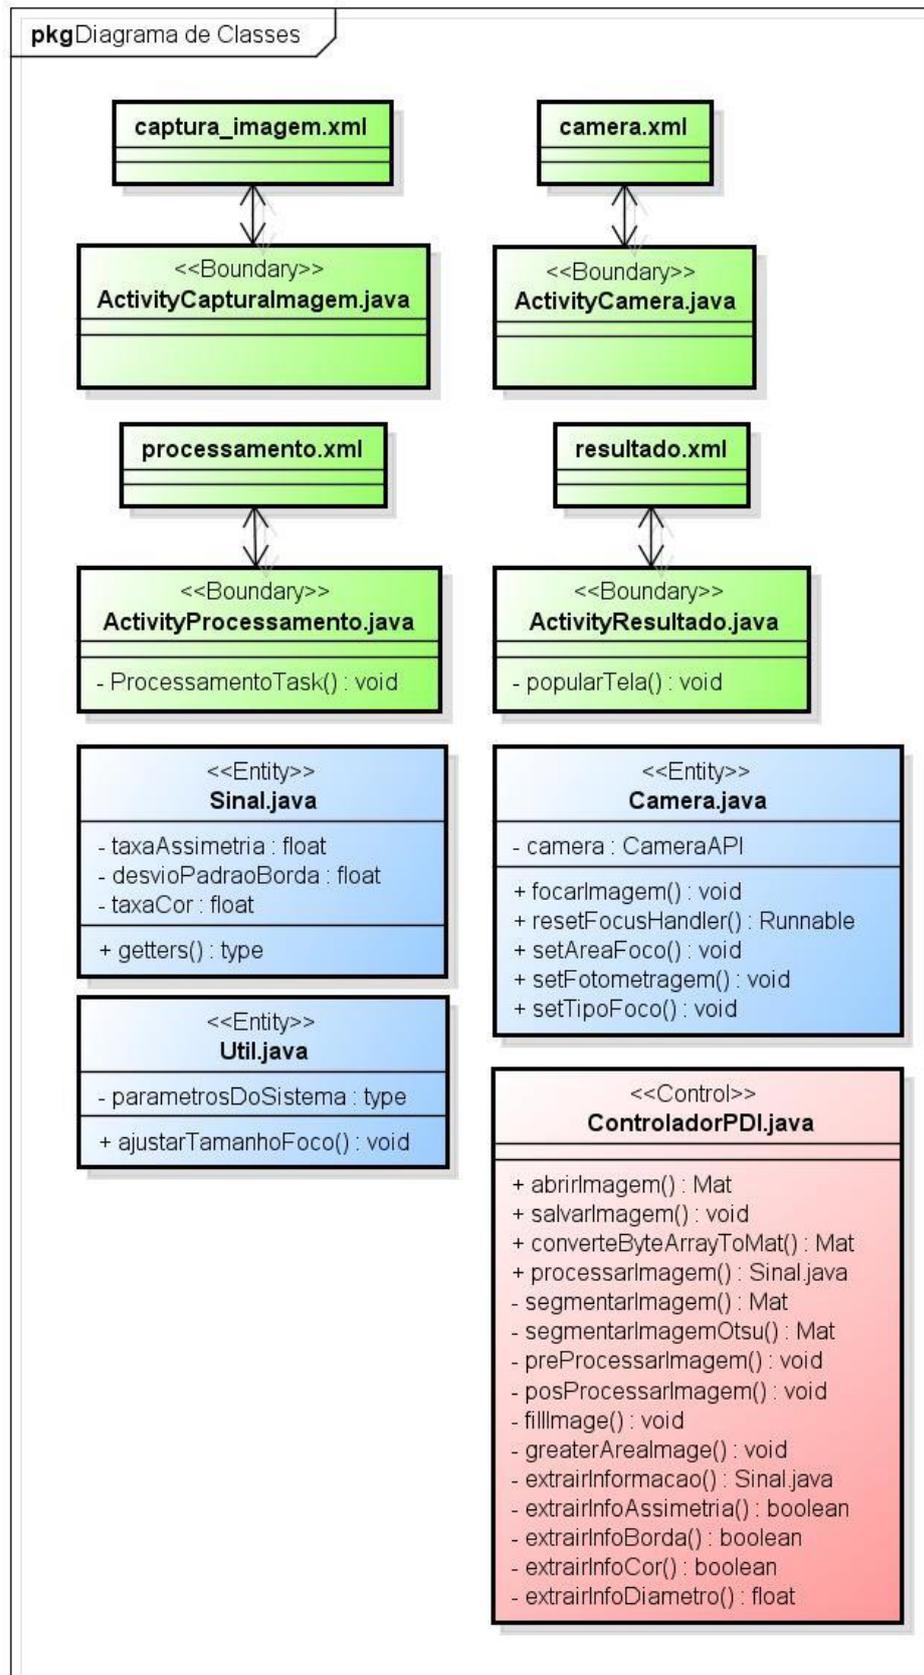


Figura 19. Design do *Skin Cancer Detection*.



powered by Astah

Figura 20. Diagrama de classes do *Skin Cancer Detection*.

4.2 Algoritmo de Captura

Para que se tenha um bom resultado na extração de informação do sinal é importante que a imagem capturada, imagem a ser analisada, seja de boa qualidade, isto é, nítida, com pouca interferência da iluminação. A Figura 21 é um exemplo de um mesmo sinal, todavia à direita foi aplicada um filtro de suavização para simular a não nitidez da imagem.



Figura 21. Imagem nítida (esquerda) [9] e não nítida (direita).

Fica evidenciado que as características morfológicas do sinal foram penalizadas, podendo assim, interferir diretamente no resultado final do aplicativo ao indicar um resultado adverso.

Por isso, para minimizar esses problemas foram elaborados dois algoritmos para focar a imagem, um global e outro em área, e um terceiro algoritmo para cortar a região de interesse da imagem já capturada. Esses foram implementados utilizando a API (*Application Programming Interface*) disponibilizada pelo Google [4] para controle do hardware da câmera do aparelho.

O Algoritmo 1, é responsável por realizar o foco global automaticamente em um determinado intervalo de tempo, para que o usuário possa visualizar a imagem com nitidez através do aparelho.

Algoritmo 1: Pseudocódigo para foco global automático.

```

1 Camera.configurar();//Configuração inicial de hardware
2 t = Camera.TEMPO_ESPERA_FOCO_GLOBAL;
3 do {
4     Camera.focarImagem();
5     Thread.sleep(t);
6 } while(!SCD.FLAG_FOTO_CAPTURADA);

```

O Algoritmo 2 é executado quando um evento de toque na tela é capturado. Tem a função de efetuar o foco em área, a fotometragem e a captura da imagem. A área do foco é delimitada por um retângulo desenhado na tela, seu tamanho é

variável para permitir que a área se ajuste ao tamanho do sinal. A fotometragem é a maneira pela qual a câmera determina a abertura e velocidade da lente no momento da fotografia.

Algoritmo 2: Pseudocódigo para foco manual em área.

```
//Evento: Toque na tela

1  Camera.configurar();//Configuração inicial de hardware
2  retangulo = Camera.getDimensaoFocoArea();
3  coordenadaRetCentralizado = new CordRet(
4      Android.RES_TELA_LARGURA/2 - retangulo.getLargura()/2,
5      Android.RES_TELA_LARGURA/2 + retangulo.getLargura()/2,
6      Android.RES_TELA_ALTURA/2 - retangulo.getAltura()/2,
7      Android.RES_TELA_ALTURA/2 + retangulo.getAltura()/2);
8  Camera.setAreaFoco(coordenadaRetCentralizado);
9  Camera.setFotometragem(SCD.FOTOMETRAGEM);
10 Camera.setTipoFoco(Camera.FOCO_MANUAL);
11 flagSucesso = Camera.focarImagem();
12 if(flagSucesso) {
13     Camera.capturarImagem();
14     SCD.FLAG_FOTO_CAPTURADA = true;
15 } else {
16     Camera.setAreaFoco(null);
17     Camera.setFotometragem(null);
18     Camera.setTipoFoco(Camera.FOCO_AUTOMATICO);
19     Camera.diminuirDimensaoFocoArea();
20 }
```

A linha 11 no Algoritmo 2 espera como retorno um booleano, pois a API do Google Android define que o método de foco tem como retorno um tipo booleano referente ao sucesso da ação de foco. Já os ajuste realizado na dimensão da área de foco na linha 19, parte do pressuposto que o foco não teve sucesso pela distância da câmera ao sinal ser pequena. Assim, é feito a diminuição da área para que a ação de captura seja realizada numa distância maior da câmera para o sinal. A Figura 22 apresenta o resultado da diminuição da área de foco.

Por fim, espera-se que o sinal esteja contido na área retangular de foco, definida anteriormente. Assim, é efetuado o corte desta área na imagem capturada para processar apenas a área de interesse, área que contém informação na imagem, facilitando o processo para a extração de informação.

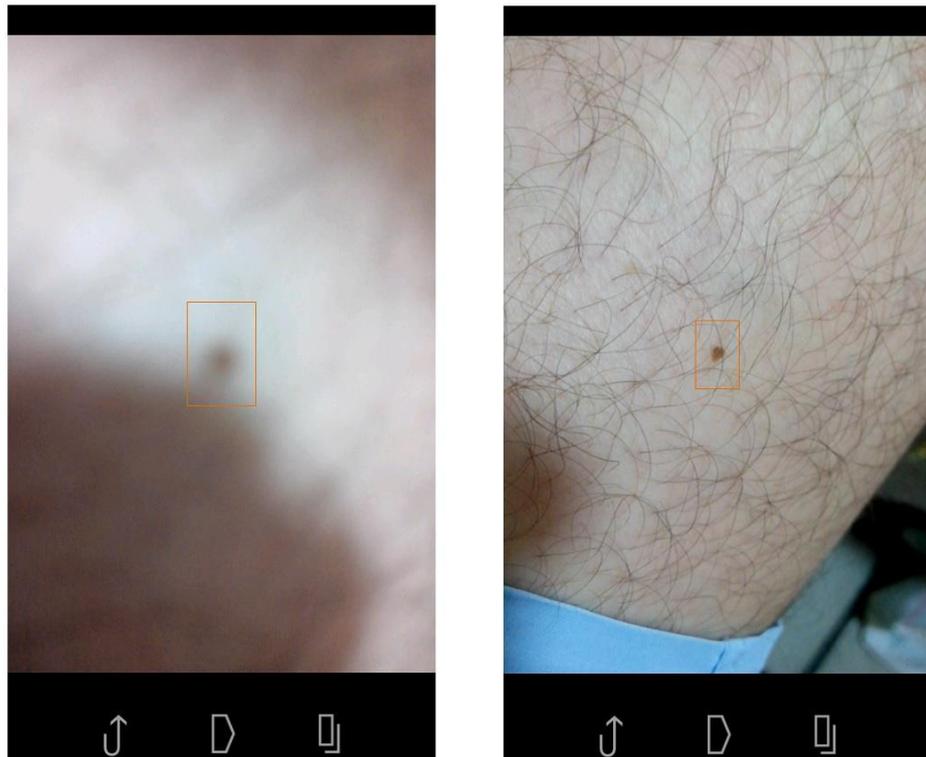


Figura 22. Resultado da diminuição da área de foco.

4.3 Pré-processamento e Segmentação

Nesta Seção, são apresentados os métodos que devem ser aplicados na imagem antes de extrair a informação do sinal.

Primeiramente, a imagem é convertida de RGB para a escala de cinza, como ilustrado na Figura 23, utilizando a equação (2).

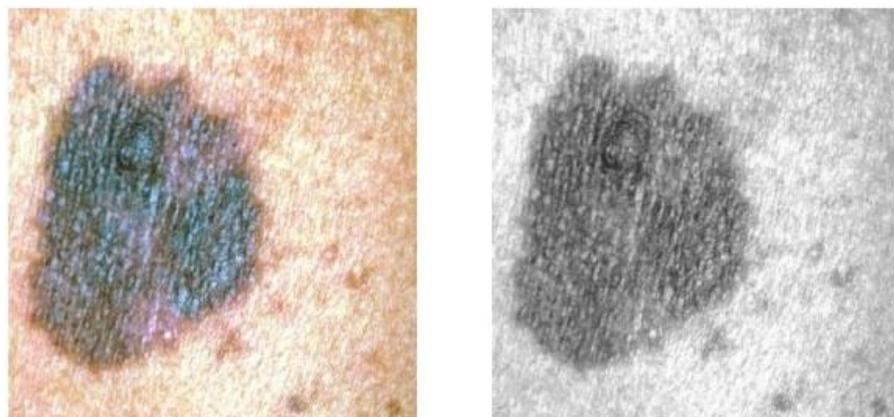


Figura 23. Imagem original (esquerda) [9]. Imagem convertida para escala de cinza (direita).

Com a imagem em escala de cinza, é aplicado o filtro de suavização Gaussiano, para borrar e remover ruídos da imagem. Para isso, é utilizado o método *GaussianBlur()* do OpenCV [19]. Os parâmetros utilizados neste filtro são: $\sigma = 0.8$ (desvio padrão da distribuição) e filtro de dimensão 3×3 . A Figura 24 apresenta o resultado da aplicação deste método.

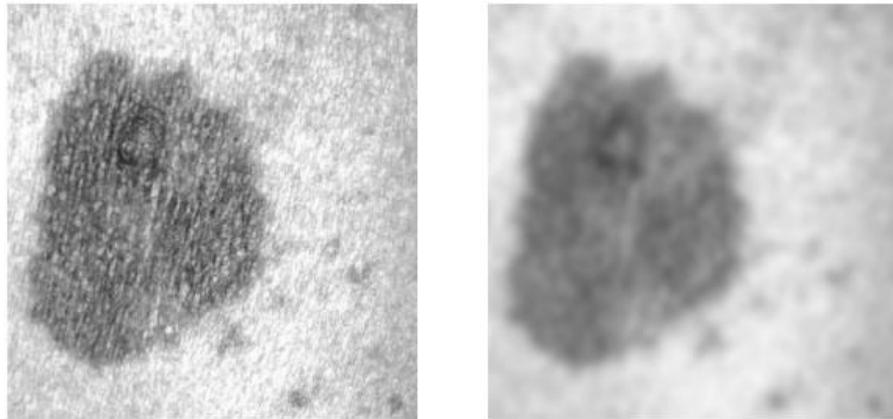


Figura 24. Imagem em escala de cinza (esquerda). Imagem com aplicação do filtro Gaussiano (direita).

Pode-se observar que pontos brancos no sinal, causados por incidência da luz, foram removidos após a aplicação do filtro Gaussiano.

Para segmentar a imagem é aplicado o método de segmentação por Otsu [33] na imagem suavizada, Figura 25. Segundo trabalho feito por Amran, Bhuiyan, Ibrahim, Uddin [2], que compara métodos de segmentação em sinais na pele, este método obteve o melhor resultado. Além de ser um método que não precisa de ajustes de parâmetros, por ser totalmente não supervisionado.

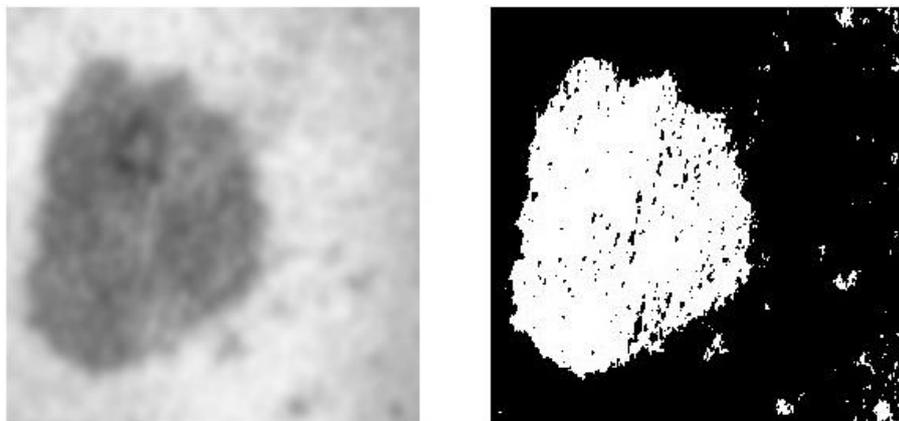


Figura 25. Imagem suavizada (esquerda). Imagem segmentada (direita).

O resultado esperado desse método é a divisão da imagem em duas classes: o sinal e o fundo. Porém, a Figura 26 destaca regiões de fundo classificadas como sinais (verde) e buracos na região do sinal (laranja). Um buraco é uma região de fundo rodeado por pixels que representam o objeto. Estes problemas são solucionados através do Algoritmo 3.

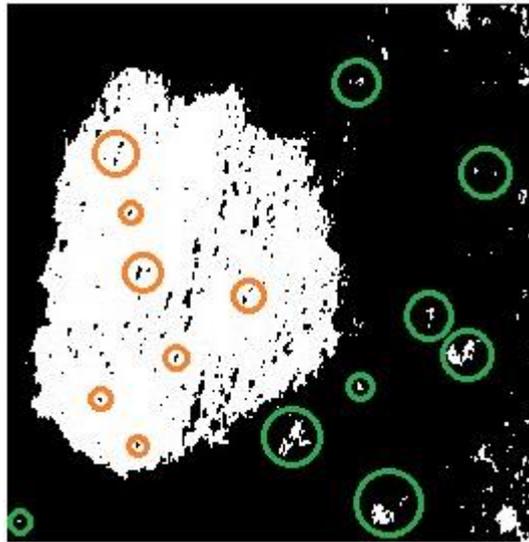


Figura 26. Algumas regiões de fundo classificadas como sinal destacadas em verde e alguns buracos da região do sinal destacados em laranja.

Algoritmo 3: Pseudocódigo para remover regiões de fundo e preencher buracos.

```
//Entreda: Imagem segmentada por Otsu, imgSegmt

1 contornos = OpenCV.findContours(imgSegmt);
2 //Recupera região com maior contorno
3 foreach(contorno : contornos) {
4     if(contorno.size() > maiorContorno.size()) {
5         maiorContorno = contorno;
6     }
7 }
8 OpenCV.fillPoly(maiorContorno);
```

No primeiro momento, deve-se encontrar todos os contornos na imagem, isto foi possível pelo método *findContours()* do OpenCV [14], que utiliza o algoritmo de Suzuki [43] para recuperar contornos em imagens binárias. Em seguida, percorrem-se todos os contornos encontrados para identificar o que possui maior número de componentes conexos, indicando o sinal. Finalmente, aplica-se o método *fillPoly()* do OpenCV [35] para preenchimento da área delimitada pelo maior contorno. A Figura 27 mostra o resultado do Algoritmo 3.

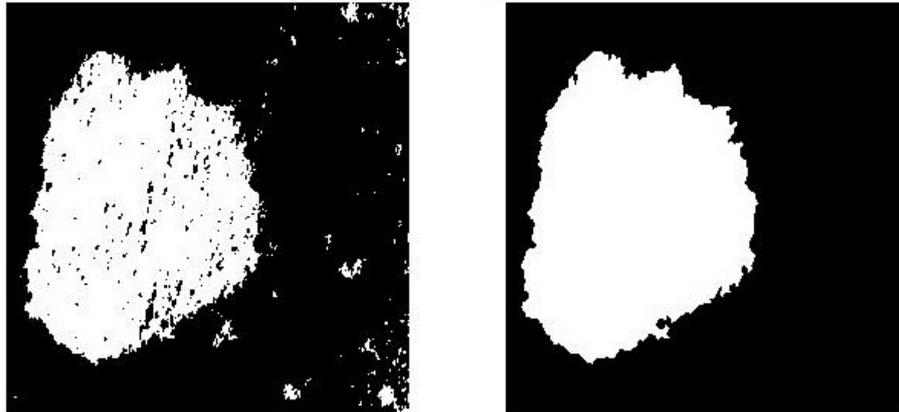


Figura 27. Imagem segmentada (esquerda), resultado da aplicação do algoritmo 3 (direita).

4.4 Extração de Informação

São aplicadas técnicas para quantificar as características de assimetria, borda e cor. O diâmetro e a elevação são desconsiderados por não haver como obter as dimensões reais do sinal, uma vez que a distância d_1 em que a foto foi capturada é desconhecida. A Figura 28 ilustra como é obtida a dimensão real em uma imagem digital através da equação

$$\frac{h1}{d1} = \frac{h2}{d2}. \quad (8)$$

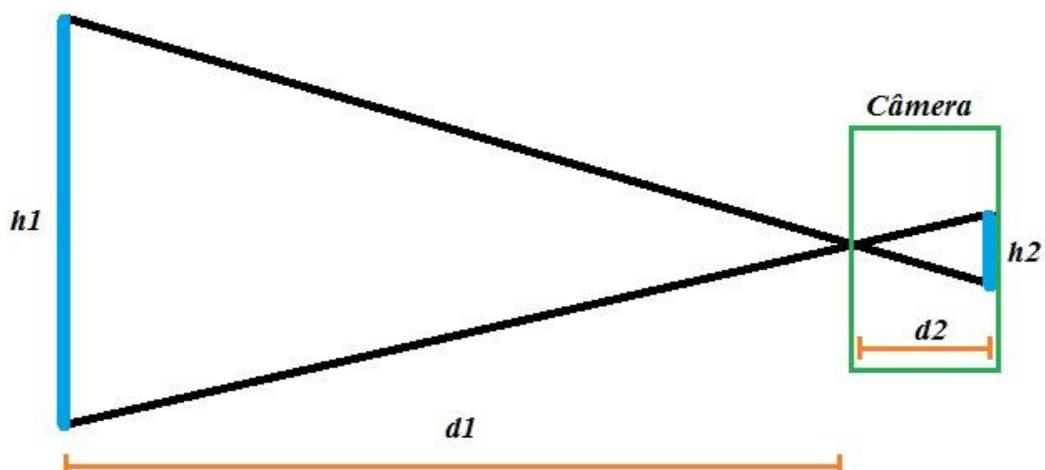


Figura 28. Relação de dimensão entre imagem real e digital.

Nesta Seção, são apresentados os algoritmos para extrair a taxa de assimetria, o desvio padrão da borda e a taxa da cor.

4.4.1 Taxa de Assimetria

Para extrair a característica de assimetria, é usado um algoritmo que mensura a taxa de assimetria do sinal em porcentagem.

Primeiramente é feito o alinhamento do sinal, rotacionando a imagem por um ângulo r entre o eixo de orientação do sinal e o eixo x da imagem. A Figura 29 ilustra o sinal em verde, os eixos e a relação entre os ângulos. Antes de obter o valor de r é preciso calcular as coordenadas do ponto $cent(l_{cent}, c_{cent})$ da centroide do sinal

$$cent(l_{cent}, c_{cent}) = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right), \quad (9)$$

onde m_{xy} são momentos espaciais de ordem xy , obtidos através do método `moments()` do OpenCV, que calcula todos os momentos da imagem.

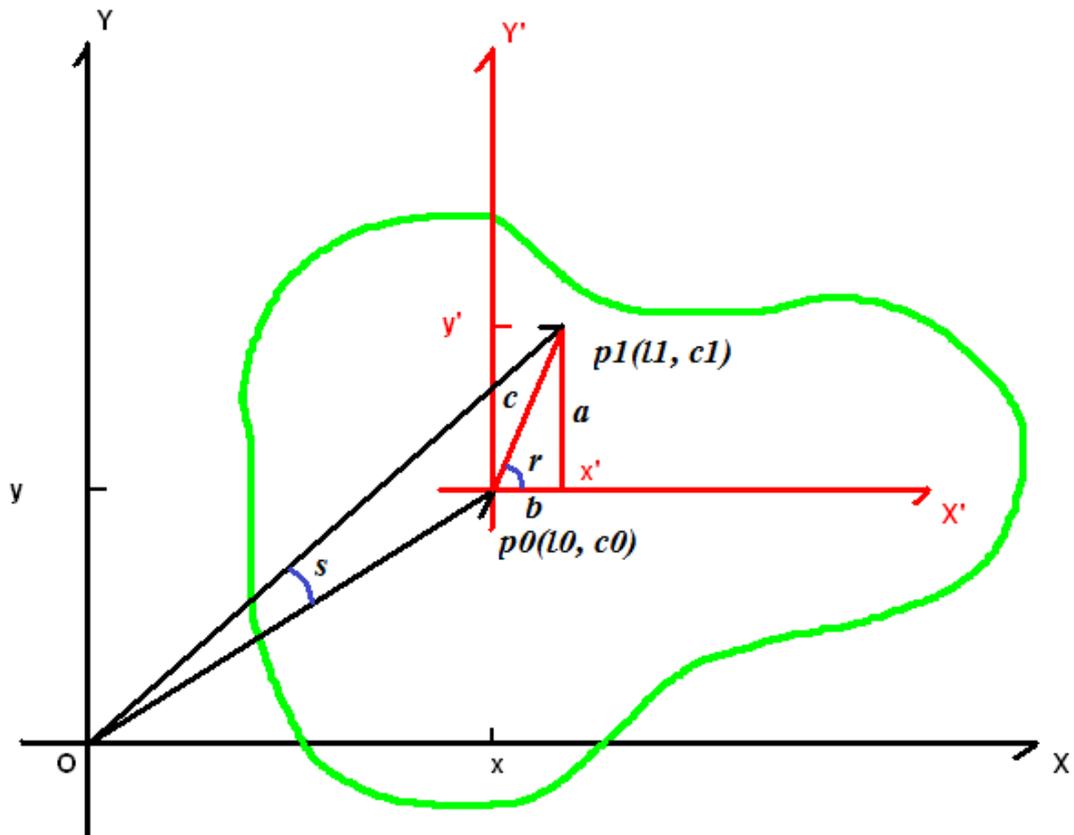


Figura 29. Relação entre ângulos [39].

Segundo Horn [23], para traçar o eixo de orientação passando pelo centroide do sinal deve-se obter dois pontos: $p_0(l_0, c_0)$ e $p_1(l_1, c_1)$ baseado em um ângulo s . As equações a seguir mostram como são obtidos:

$$s = 0.5 \tan^{-1} \left(\frac{2mu_{11}}{mu_{20} - mu_{02}} \right), \quad (10)$$

$$p_0(l_0, c_0) = (l_{cent} - (100 * \cos(s)), c_{cent} - (100 * \sin(s))), \quad (11)$$

$$p_1(l_1, c_1) = (l_{cent} + (100 * \cos(s)), c_{cent} + (100 * \sin(s))), \quad (12)$$

onde mu_{xy} são momentos centrais de ordem xy .

Por fim, r é obtido por cálculo simples de trigonometria, a lei das tangentes, como descrito na equação

$$r = \tan^{-1} \left(\frac{a}{b} \right) * \frac{180}{\pi}, \quad (13)$$

a multiplicação por $\frac{180}{\pi}$ é necessária para converter o ângulo r de radianos para graus. Esta conversão é necessária para a chamada ao método de rotação do OpenCV, que espera como parâmetro o ângulo em graus. Já a variável a é obtida pela subtração de c_1 por c_0 e b pela subtração de l_1 por l_0 . A Figura 30 ilustra em sequência os passos dessas operações.

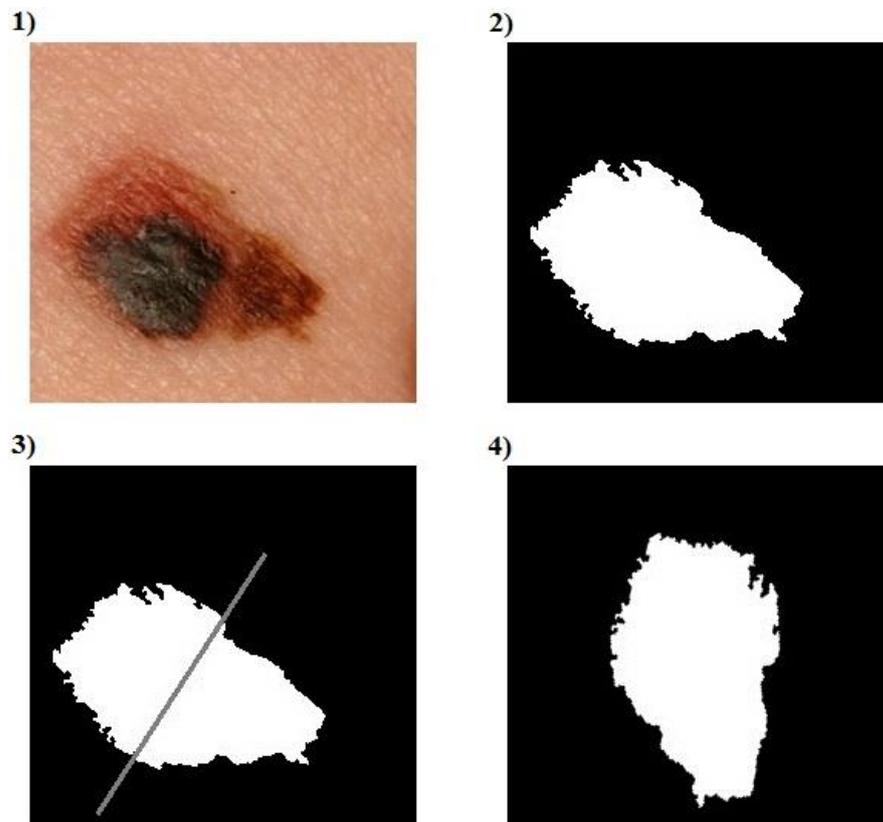


Figura 30. (1) Imagem original [9], (2) Imagem segmentada (3), Imagem com o eixo de orientação, (4) Imagem rotacionada.

Em seguida é aplicada uma técnica para delimitar o sinal com o menor retângulo possível, através do método *boudingRect()* do OpenCV [41] . Assim, uma nova imagem é criada apenas com o sinal, como ilustra a Figura 31.

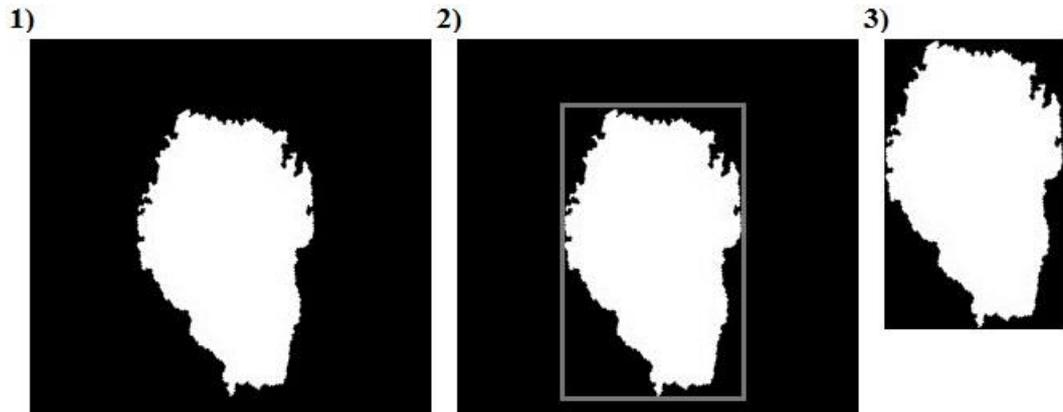


Figura 31. (1) Imagem rotacionada, (2) Imagem com retângulo de menor área, (3) Imagem cortada pela dimensão do retângulo de menor área.

Finalmente, o método que calcula a taxa de assimetria é executado na imagem cortada com o sinal. A Figura 32 mostra que a assimetria pode ocorrer tanto em relação ao eixo y, verticalmente, quanto em relação ao eixo x, horizontalmente. Mostra também a diferença da assimetria entre o melanoma (Figura 32 (a), (b), (c) e (d)) e sinal normal (Figura 32 (e), (f), (g) e (h)), onde a região branca são os pixels que coincidem ao sobrepor as partes da imagem dividida pelo respectivo eixo.

Pode-se observar que no caso do melanoma as regiões em amarelo e azul, pixels que não coincidem, ocupam uma maior área relativa ao sinal na imagem. Ao contrário do caso normal, onde essa área é uma pequena parcela do sinal.

Deste modo, é calculada uma taxa de assimetria para cada eixo da seguinte forma:

$$\frac{\text{Número de pixels que não coincidem}}{\text{Total de pixels do sinal}}, \quad (14)$$

como apresenta o Algoritmo 4 (em relação ao eixo y). Por fim, a taxa de assimetria apresentada no SCD é a média aritmética da taxa obtida em relação ao eixo y com a taxa obtida em relação ao eixo x.

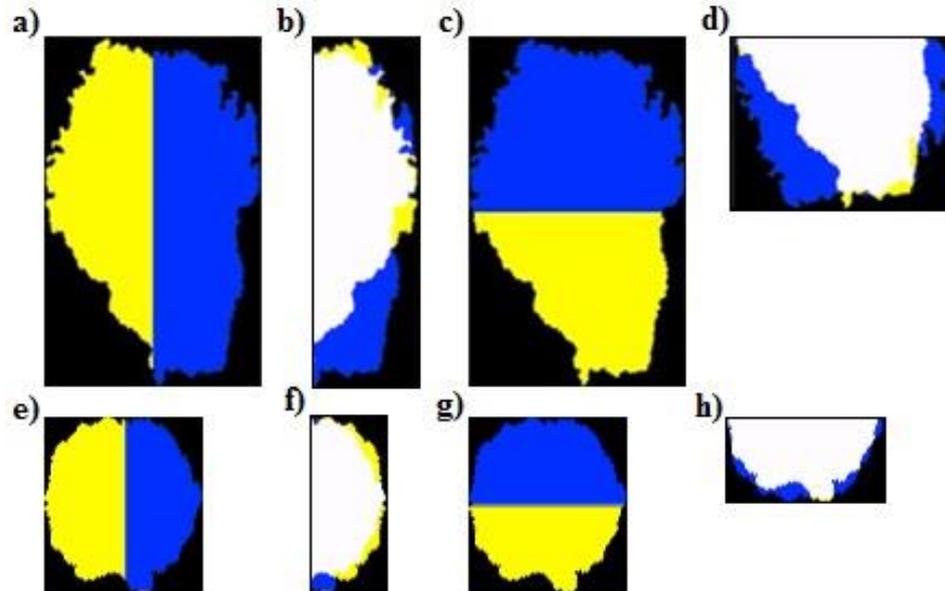


Figura 32. Assimetria com eixo y (a) e (e), metades sobrepostas em relação ao eixo y (b) e (f), assimetria com eixo x (c) e (g), metades sobrepostas em relação ao eixo x(d) e (h). Melanoma (a), (b), (c) e (d), sinal normal (e), (f), (g) e (h). Imagens adaptadas de Dermnet NZ [9].

Algoritmo 4: Pseudocódigo para calcular taxa de assimetria em relação ao eixo y.

//**Entreda:** Imagem cortada com o sinal, img

```

1 meioHor = img.getQdtColunas()/2;
2 for (cont = 1; cont < meioHor; cont++) {
3     for (linha = 0; linha < img.getQdtLinhas(); linha++) {
4         if(img.getValor(linha, meioHor - cont) ==
5             img.getValor(linha, meioHor + cont)) {
6             if(isSinal(img.getValor(linha, meioHor - cont)))
7                 qdtPixelSinal += 2;
8             } else {
9                 qdtPixelSinal++;
10                qdtPixelAssimetricos++;
11            }
12        }
13    }
14 taxaDeAssimetria = qdtPixelAssimetricos/qdtPixelSinal;

```

4.4.2 Desvio Padrão da Borda

Para mensurar a irregularidade da borda, calcula-se o desvio padrão da assinatura do sinal. Assinatura é o conjunto de distâncias d do centroide $cent(I_{cent} C_{cent})$, para cada pixel do contorno do objeto $p_i(I_{icont} C_{icont})$. Essa distância pode ser obtida com base no teorema de Pitágoras, como ilustra a Figura 33:

$$d = \sqrt{(l_{cent} - l_{icont})^2 + (c_{cent} - c_{icont})^2}. \quad (15)$$

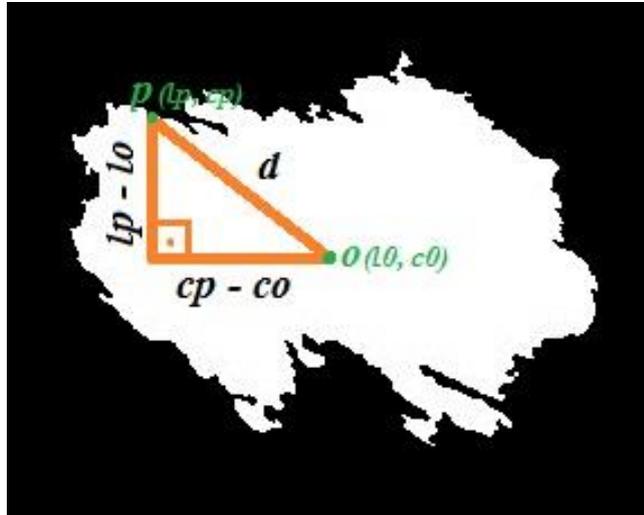


Figura 33. Imagem adaptada da base Dermnet NZ [9] e segmentada pelo SCD: Ilustra a aplicação do teorema de Pitágoras para obtenção da distância do centroide para o ponto de contorno.

Na Figura 34 pode-se verificar que essas distâncias em sinais normais tendem a permanecer constantes, enquanto na presença de melanoma apresentam uma grande variância.

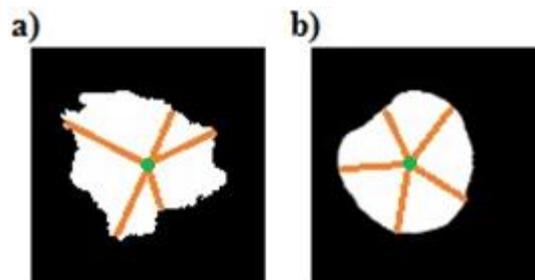


Figura 34. Imagem adaptada da base Dermnet NZ [9] e segmentada pelo SCD: (a) comparação das distâncias do melanoma (b) com o sinal normal.

Visto isso, é calculado o desvio padrão σ da assinatura, pelas equações:

$$\mu = \frac{1}{n} \sum_{k=0}^n d_k, \quad (16)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=0}^n (d_k - \mu)^2}, \quad (17)$$

onde, n é o total de distâncias, μ é a média.

4.4.3 Taxa da Cor

É aplicado um método simples da estatística para medir a taxa da cor do sinal, a variância σ^2 . Este método é aplicado no histograma do sinal, para isso, a imagem segmentada é utilizada como máscara. Desta forma, apenas os pixels do objeto da imagem, o sinal, são considerados.

A imagem utilizada neste processo está em escala de cinza, pois a conversão não apresenta perdas significativas nessa informação, além de haver ganho de performance, já que a variância é calculada apenas um vez. A Figura 35 apresenta o histograma do sinal, obtido pelo Adobe Photoshop [1], para cada canal de cor: vermelho, verde, azul e cinza. Pode-se observar que o atributo Std Dev (*Standard Deviation*), desvio padrão, apresenta variação pequena.

Inicialmente é calculada a intensidade média μ do sinal,

$$\mu = \sum_{k=0}^{L-1} i_k p(i), \quad (18)$$

onde, i é o valor da intensidade no intervalo de 0 a L , que é igual a 256, intensidade máxima na escala de cinza de 8 bits, e $p(i)$ é a probabilidade do pixel na imagem, com base no histograma. Então, a variância é calculada da seguinte forma:

$$\sigma^2 = \frac{1}{L} \sum_{k=0}^{L-1} (i_k - \mu)^2. \quad (19)$$

Por fim, para que tivéssemos uma taxa da variação da cor do sinal tC , foi utilizada a equação

$$tC = 1 - \frac{1}{1 + \frac{\sigma^2}{L^2}}, \quad (20)$$

para normalizar o resultado, deixando no intervalo de 0 a 1 [21].

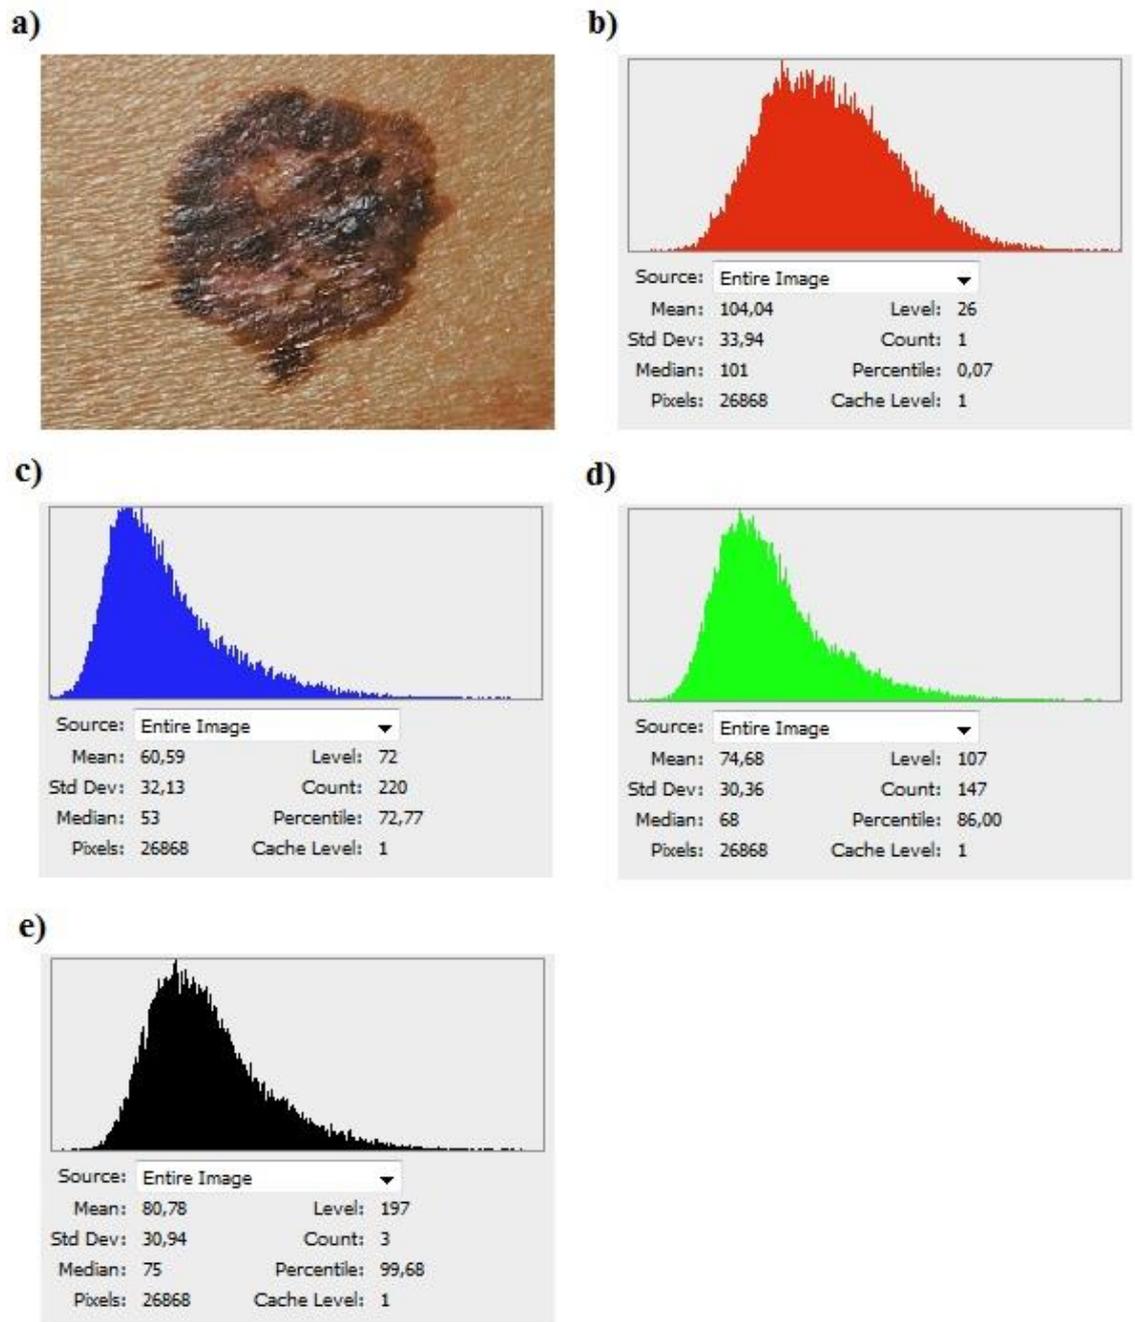


Figura 35. Histogramas do sinal para cada canal de cor: (a) Imagem original, (b) Histograma do canal vermelho, (c) Histograma do canal azul, (d) Histograma do canal verde e (e) Histograma do sinal em escala de cinza.

A Figura 36 apresenta o histograma de um melanoma e o histograma de um sinal normal. Observa-se que o desvio padrão do histograma em sinais normais é pequeno, pois a cor do sinal é uniforme, diferente de casos de melanoma, onde esta medida é mais elevada.

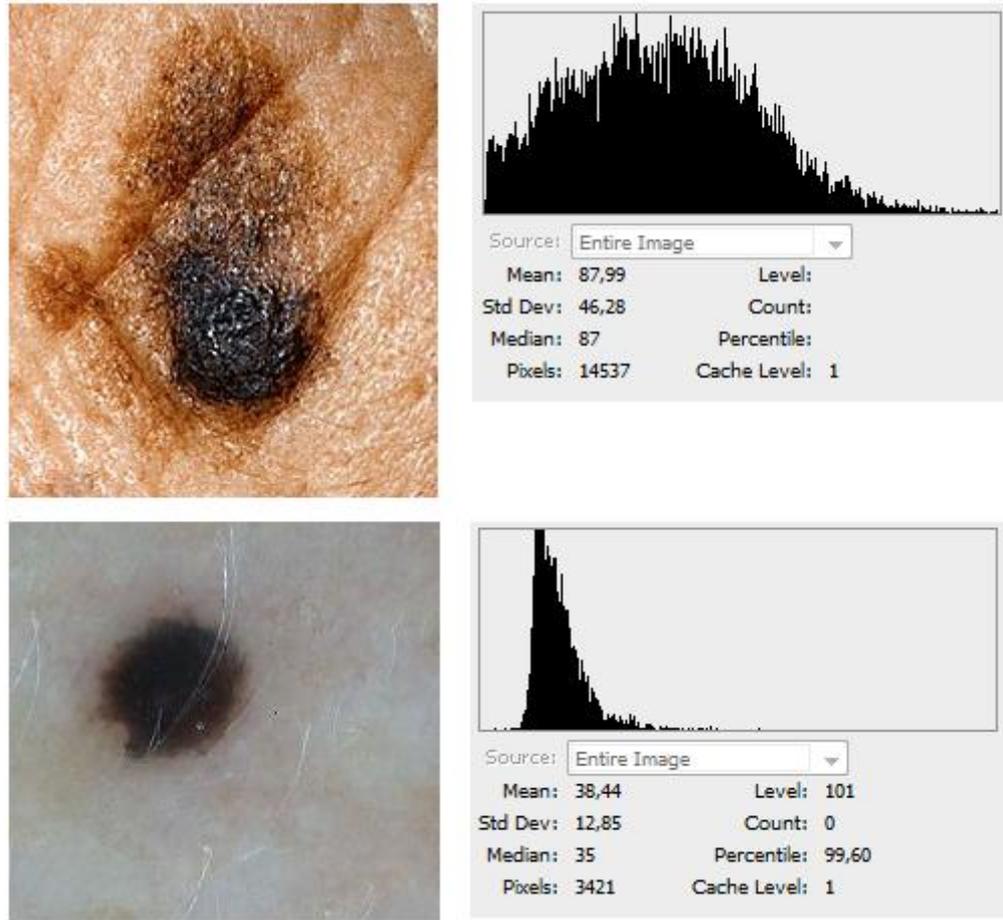


Figura 36. Histograma do melanoma (cima) e sinal normal (baixo). Histograma obtido pelo Adobe Photoshop [1].

Capítulo 5

Resultados Obtidos

Neste Capítulo, será mostrado o arranjo experimental da extração de informação do sinal e como serão avaliadas as condições em que o sistema proposto apresenta uma melhor eficácia. Por fim, serão mostrados os resultados dos experimentos.

5.1 Experimentos

Para avaliar a informação extraída no modelo proposto, foram utilizadas imagens provenientes de dois bancos de dados dermatológicos: *Atlas of Clinical Dermatology* e *DermNet NZ*. O primeiro, é um atlas de dermatologia clínica que possui aproximadamente 3000 imagens de doenças dermatológicas, todas obtidas por Niels K. Veien em sua clínica privada [8]. Essas imagens são destinadas para uso em estudo da dermatologia. O segundo, lançado desde 1996 pela *New Zealand Dermatological Society Incorporated*, possui imagens e artigos relacionados a pele. É escrito e revisado por profissionais de saúde e escritores médicos, tendo acesso livre à base via internet [9]. A Figura 37 apresenta exemplos de algumas imagens desses bancos.

São transferidas para o celular 80 imagens de sinais na pele, onde 65 dessas são casos de melanoma e 15 são sinais normais, o fluxo de captura não é realizado. O *Skin Cancer Detection* extrai a informação do sinal de cada imagem, resultando em três características: taxa de assimetria, desvio padrão da borda e taxa de cor.

Uma forma de demonstrar a relação antagônica entre o melanoma e sinais normais para cada característica é a curva ROC (*Receiver Operating Characteristic*) [18]. A curva ROC é um gráfico com taxas de verdadeiros-positivos, casos de melanoma, contra taxas de verdadeiros-negativos, sinais normais. Permite evidenciar os valores para os quais o sistema apresenta a melhor configuração, que corresponde ao ponto superior esquerdo, uma vez que o verdadeiro positivo é 1 e o verdadeiro negativo 0. A qualidade do resultado de uma curva ROC é determinada

pela área sob a curva (AUC, *Area Under the Curve*) [12], isso indica que quanto maior a área, mais a curva se aproxima do ponto superior esquerdo.

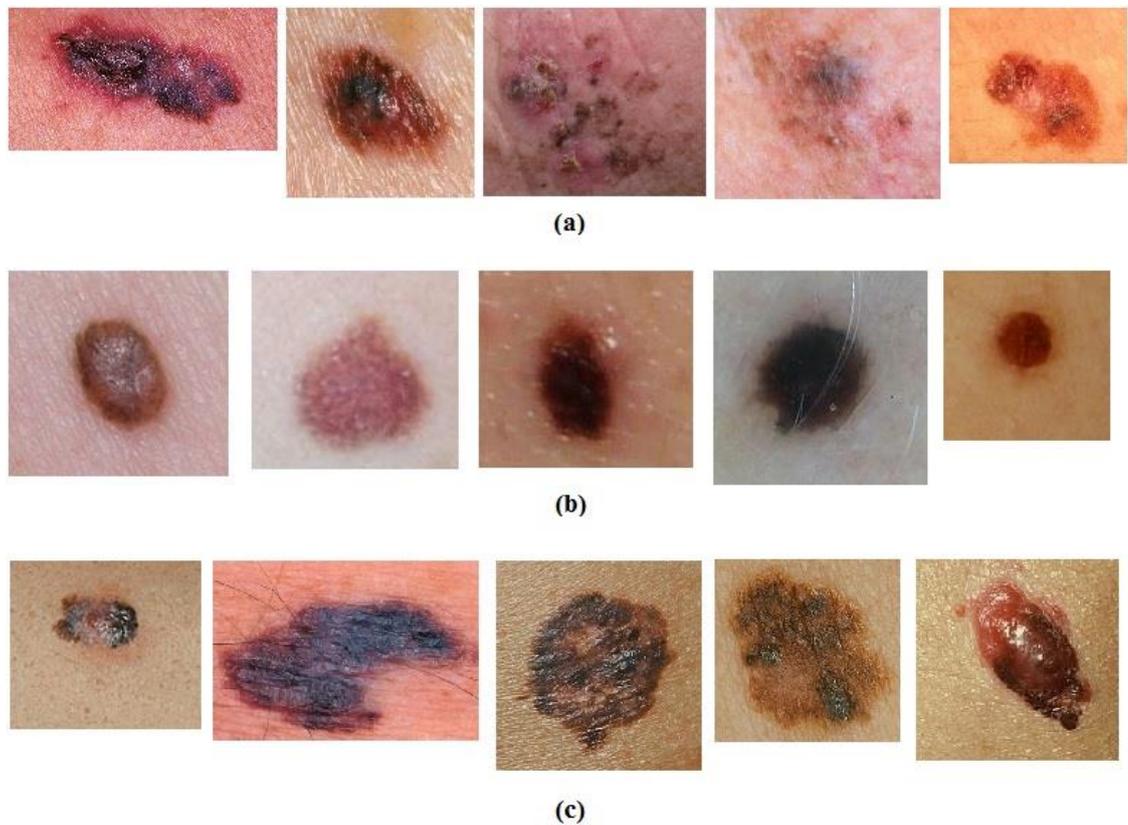


Figura 37. Exemplos de imagens dos bancos de dados: (a) Casos de melanoma do *DermNet NZ* [9], (b) Sinais normais do *DermNet NZ* [9], (c) Casos de melanoma do *Atlas of Clinical Dermatology* [8].

Para a segunda parte do experimento, são feitos testes de usabilidade que expõem o sistema a influência da luminosidade, imagem do sinal obstruída por pelos e diferentes distâncias de captura. Neste caso, deve ser realizado o fluxo completo de extração de informação. As informações extraídas desses cenários procuram definir as condições em que o SCD apresenta uma melhor eficácia.

Todos os experimentos deste trabalho são realizados sobre um Motorola RAZR D3, com processador de 1.2GHz, 4-GB de RAM, câmera de 8MP e plataforma Android 4.1.2.

5.2 Resultados

Nesta Seção são apresentados primeiramente os resultados obtidos da extração de informação, depois são apresentadas as condições que o SCD tem a melhor eficácia.

5.2.1 Resultados da Extração de Informação do Sinal

A Figura 38 e a Tabela 2 apresentam comparações entre as características extraídas dos sinais. A característica de desvio padrão da borda do sinal apresenta a maior AUC, com 0.93. Isso implica que o desvio padrão da borda consegue melhor identificar casos de melanoma de casos normais.

Ao definir os pontos de corte através linha vertical laranja têm os seguintes valores: taxa de assimetria em 18% (0.1878), desvio padrão da borda em 7.6832 (7.6832) e taxa da cor em 9.204 (0.009204). No primeiro, aproximadamente 69.23% de todas as amostras dos melanomas são corretamente identificadas como tal. No segundo este índice aumenta para 89.23% e o último é 64.62%. Por fim, para as três características, 13.33% de todas as amostras do sinal normal poderiam ser incorretamente identificadas como melanoma.

Sobretudo, a combinação das três características pode resultar em uma melhor classificação em casos de melanoma e casos normais, todavia não é o foco deste trabalho.

Tabela 2. AUC das características dos sinal.

Característica	AUC
Taxa de Assimetria	0.82
Desvio Padrão da Borda	0.93
Taxa de Cor	0.83

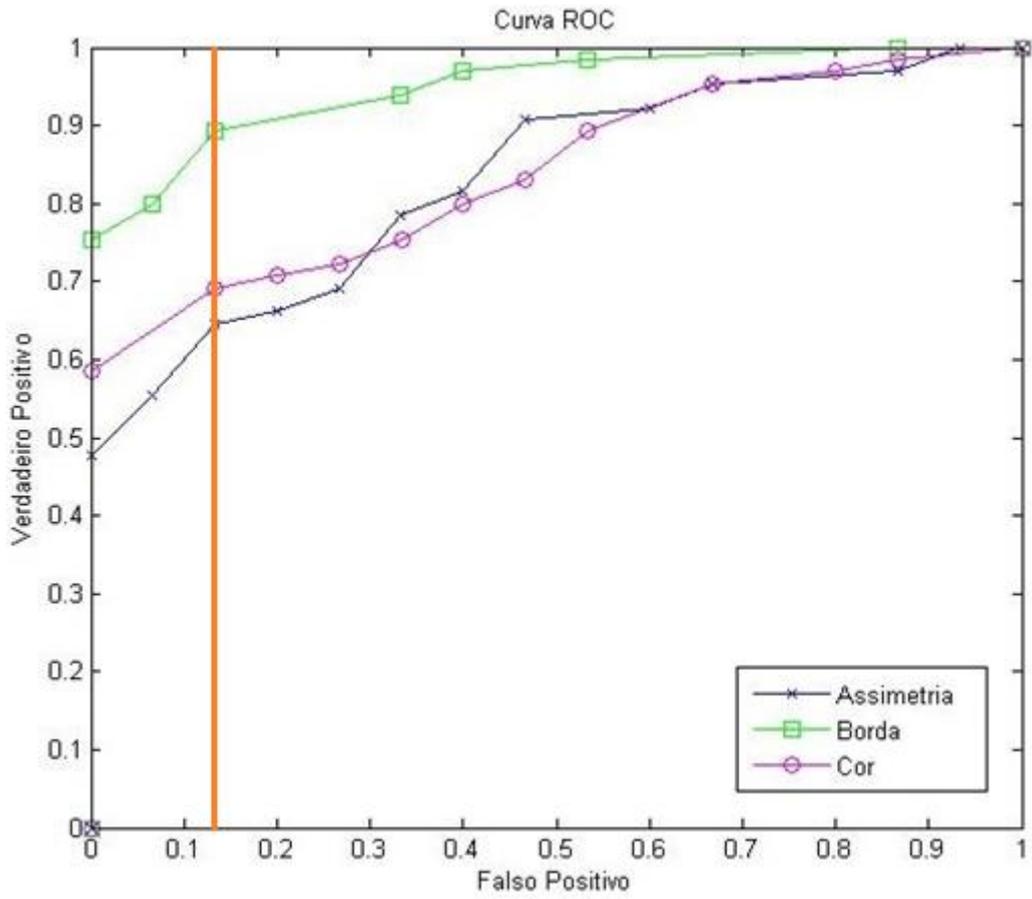


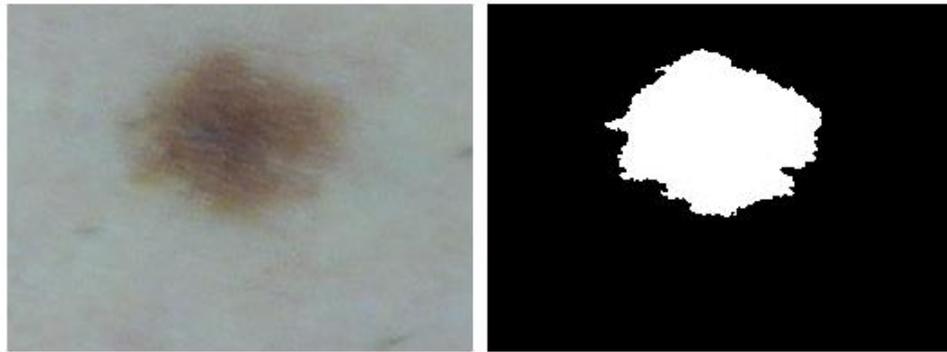
Figura 38. Comparação entre as características extraídas dos sinais.

5.2.2 Resultados de Usabilidade do SCD

A princípio, é importante frisar que o teste de cada cenário nesta Subseção é realizado com o mesmo sinal.

No primeiro cenário, o SCD é exposto a influência da luminosidade. A Figura 39 apresenta a comparação do resultado da segmentação em dois casos. No caso 1, a imagem do sinal é capturada com boa luminosidade, no caso 2 a captura da imagem é realizada com pouca luminosidade.

Caso 1:



Caso 2:

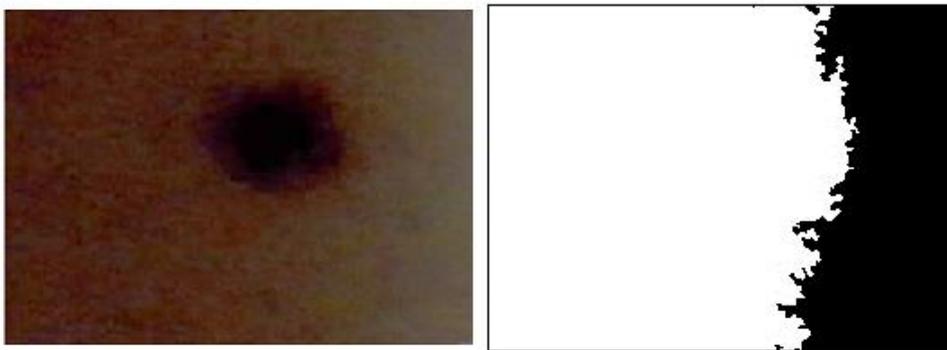


Figura 39. Comparação do resultado da segmentação para o cenário da luminosidade.

É possível perceber o insucesso da segmentação no caso 2, não ficando visível a região do sinal. Deste modo, informação extraída é inválida, já que as características não pertencem ao sinal. A Tabela 3 apresenta as informações extraídas das duas imagens.

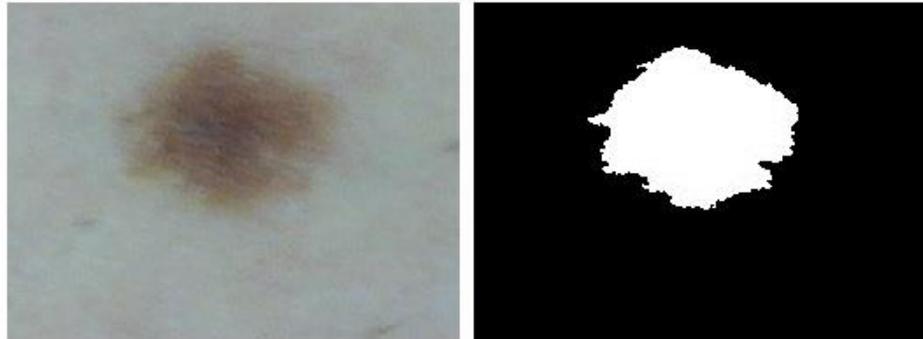
Tabela 3. Informações extraídas no cenário da luminosidade.

Caso	Taxa de Assimetria	Desvio Padrão da Borda	Taxa de Cor
1	0.177	5.602	0.003
2	0.108	11.789	0.005

Nota-se a divergência das informações para o mesmo sinal.

No segundo cenário, o SCD é exposto a obstrução por pelos. A Figura 40 apresenta a comparação do resultado da segmentação em dois casos. No caso 1, a imagem do sinal é capturada sem obstrução, no caso 2 o sinal está obstruído por pelos.

Caso 1:



Caso 2:



Figura 40. Comparação do resultado da segmentação para o cenário da obstrução.

É possível perceber que no caso 2 a forma do sinal sofreu alterações, a segmentação classificou o pelo como sinal. Alteração deste tipo invalida o resultado da informação, visto que a forma do sinal é um fator importante na caracterização do câncer. A Tabela 4 mostra as informações extraídas neste cenário.

Tabela 4. Informações extraídas no cenário de obstrução.

Caso	Taxa de Assimetria	Desvio Padrão da Borda	Taxa de Cor
1	0.177	5.602	0.003
2	0.223	12.408	0.002

Por último, no terceiro cenário as imagens são capturadas em distâncias diferentes. A Figura 41 apresenta a comparação do resultado da segmentação em quatro casos. As imagens estão ordenadas da menor para a maior distância de captura. A Tabela 5 apresenta as informações extraídas no terceiro cenário.

É possível observar a perda de informação conforme a distância de captura aumenta. Em particular o caso 4, onde já não foi possível a visualização do sinal na imagem segmentada, tornando a informação extraída do sinal inválida.

Tabela 5. Informações extraídas no cenário de distância.

Caso	Taxa de Assimetria	Desvio Padrão da Borda	Taxa de Cor
1	0.177	5.602	0.0036
2	0.171	4.723	0.0039
3	0.217	2.417	0.0041
4	0.502	49.246	0.0010

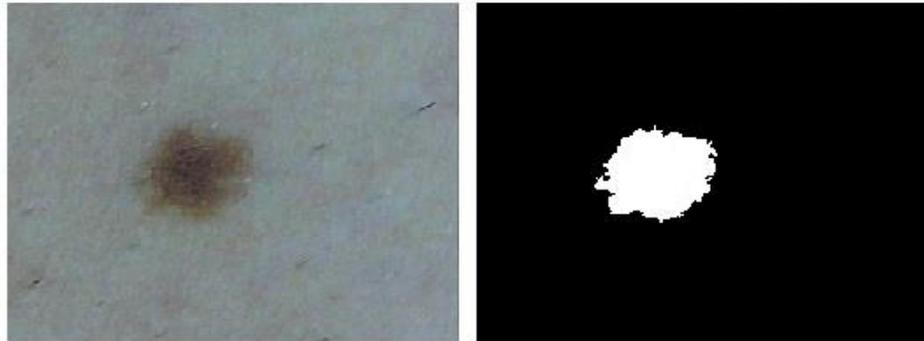
Os resultados obtidos nesse experimento mostra que o SCD sofre grande influência nos três cenários, podendo invalidar o resultado da extração de informação. Assim, é essencial que as imagens sejam capturadas em ambientes com boa iluminação, sinais com ausência de pelos e numa distância onde o sinal ocupe a maior área de foco possível.

Por fim, é importante que o SCD passe a ter critérios de avaliação da imagem mais rigorosos, para indicar que a segmentação ocorreu com sucesso, aumentando assim a confiabilidade da informação extraída.

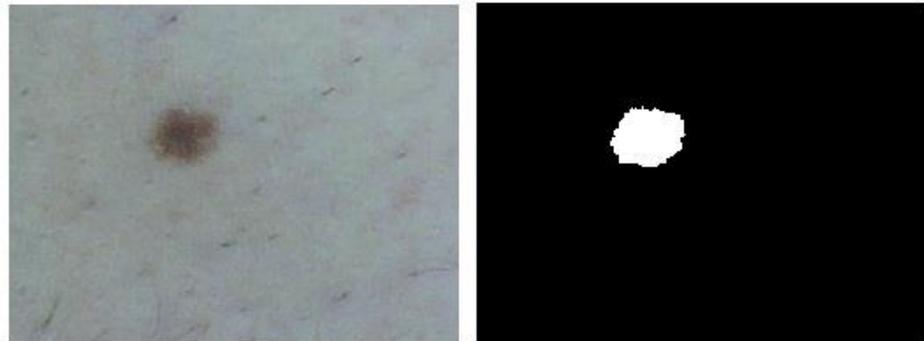
Caso 1:



Caso 2:



Caso 3:



Caso 4:



Figura 41. Comparação do resultado da segmentação para o cenário da distância.

Capítulo 6

Considerações Finais

O objetivo deste trabalho foi o desenvolvimento de uma ferramenta de combate ao câncer de pele, especificamente o melanoma, por apresentar maior mortalidade. Para isso, foram estudadas diversas técnicas de processamento de imagens e visão computacional para que o *Skin Cancer Detection* fosse capaz de extrair informação de sinais na pele.

Com os resultados obtidos na extração de informação do sinal, ficou evidenciado que o SCD pode tornar-se uma ferramenta importante contra o câncer de pele. Mas para isso, é relevante estudar uma forma de extrair a característica do diâmetro do sinal, visto sua relevância pelos dermatologistas em exames. Por fim, é importante o desenvolvimento de um algoritmo para classificação do sinal, a fim de que o SCD possa indicar a presença de câncer de pele ou não. Isto faz com que os usuários possam utilizar o SCD como uma ferramenta de suporte à identificação do câncer de pele. Entretanto, o resultado do SCD jamais deve substituir o exame com médicos especializados.

A análise realizada no experimento de usabilidade apresenta que o modelo sofre influência da iluminação, obstrução e distância de captura. Essas influências podem invalidar o resultado da extração da informação do sinal. Para resolver este problema, é importante o desenvolvimento de uma funcionalidade que permita o usuário confirmar o sucesso da segmentação. Assim, é garantido que a informação a ser extraída é do sinal.

6.1 Trabalhos Futuros

Nos trabalhos que se realizarão, pretende-se desenvolver os seguintes pontos:

- Desenvolvimento de uma funcionalidade para confirmação do sucesso da segmentação, a fim de aumentar a confiabilidade da informação extraída;

- Estudo de técnicas para possibilitar a extração da característica de diâmetro do sinal;
- Desenvolvimento de um algoritmo para classificar o sinal em melanoma ou normal;
- Reescrever o código de PDI e Visão Computacional para não ser necessário o download do *OpenCv Manager*;
- Estudo de outros tipos de câncer de pele, para que o SCD torne-se uma ferramenta de combate a qualquer tipo câncer de pele.

Bibliografia

- [1] Adobe Photoshop. Disponível em <<http://www.adobe.com/br/products/photoshop.html>>. Acesso em 25 de junho de 2014.
- [2] Amran, Bhuiyan, H., Ibrahim, A., Uddin, K. (2013). 'Image Processing for Skin Cancer Features Extraction'. International Journal of Scientific & Engineering Research Volume 4, Issue 2.
- [3] Android binary package using with NDK. Disponível em <http://docs.opencv.org/doc/tutorials/introduction/android_binary_package/android_binary_package_using_with_NDK.html> Acesso em 9 de maio de 2014.
- [4] Android Camera API. Disponível em <<http://developer.android.com/-reference/android/hardware/Camera.html>>. Acesso em 9 de maio de 2014.
- [5] Apoorva, R., Sangani, S. P., Hanabaratti, K. D. (2013). 'Diagnosis of Melanomas by Check-list Method'. 4th ICCCNT, Tiruchengode, India.
- [6] Astah. Disponível em <<http://astah.net/>>. Acesso em 23 de junho de 2014.
- [7] Bandeira de Pernambuco. Disponível em <<http://www.pe.gov.br/conheca/simbolos/>>. Acesso em 07 de junho de 2014.
- [8] Banco de Imagens Atlas of Clinical Dermatology. Disponível em <<http://www.danderp-dv.is.kkh.dk/atlas/index.html>>. Acesso em 18 de junho de 2014.
- [9] Banco de Imagens Dermnet NZ. Disponível em <<http://www.dermnetnz.org/sitemap.html>>. Acesso em 18 de junho de 2014.
- [10] Bezerra, E. (2006). 'Princípios de análise e projeto de sistemas UML: Um guia prático para modelagem de sistemas'. Campus, 3ª Tiragem.
- [11] Bizagi. Disponível em <<http://www.bizagi.com/>>. Acesso em 23 de junho de 2014.
- [12] Bradley, A. P. (1997). 'The use of the area under the ROC curve in the evaluation of machine learning algorithms'. Pattern Recognition 30(7), 1145–1159.

- [13] Comparação do olho humano com a máquina fotográfica. Disponível em <<http://oidealista.com/imagens/saude/olhos3.jpg>>. Acesso em 7 de maio de 2014.
- [14] Contorno de regiões, documentação do OpenCV. Disponível em <http://docs.opencv.org/modules/imgproc/doc/structural_analysis_and_shape_descriptors.html#findcontours>. Acesso em 23 de junho de 2014.
- [15] Conversão do modelo RGB para escala de cinza. Disponível em <[http://docs.opencv.org/modules/imgproc/doc/miscellaneous_transformations.html#cvtColor](http://docs.opencv.org/modules/imgproc/doc/miscellaneous_transformations.html#cvtcolor)>. Acesso em 28 de abril de 2014.
- [16] Denise, M. A. (2004). 'Melanoma'. Nursing2004, Vol.34, Num.4, pp. 52-53.
- [17] Erdmann, F., Lortet-Tieulent, J., Schuz, J. (2013). 'International trends in the incidence of malignant melanoma 1953-2008 are recent generations at higher or lower risk?'. Int J Cancer, 132:385-400.
- [18] Fawcett, T. (2006). 'An introduction to ROC analysis'. Pattern Recognition Letters 27, 861–874.
- [19] Filtro Gaussiano, documentação do OpenCV. Disponível em <<http://docs.opencv.org/modules/imgproc/doc/filtering.html?highlight=gaussianblur#gussianblur>>. Acesso em 23 de junho de 2014.
- [20] Gola, Isasi, A., Zapirain, B. G., Zorrilla, A. M. (2011). 'Melanomas: Non-invasive Diagnosis Application Based on the ABCD Rule and Pattern Recognition Image Processing Algorithms'. ELSEVIER.
- [21] Gonzalez, R. C., Woods, R. E. (2002). 'Digital Image Processing'. Prentice-Hall, Upper Saddle River, NJ, 2ª edição.
- [22] Gráfico com distribuição Gaussiana. Disponível em <<http://homepages.inf.ed.ac.uk/rbf/HIPR2/gsmooth.htm>>. Acesso em 18 de junho de 2014.
- [23] Horn, B. K. P. (1986). 'Robot Vision (MIT Electrical Engineering and Computer Science)'. The MIT Press, 1ª edição.
- [24] INCA Câncer de Pele. Disponível em <http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pele_ao_melanoma>. Acesso em 10 de junho de 2014.

- [25] Incidência de câncer de pele. Disponível em <<http://g1.globo.com/pr/parana/noticia/2012/11/cidades-do-interior-tem-maior-indice-de-cancer-de-pele-que-no-litoral.html>>. Acesso em 10 de junho de 2014.
- [26] Instituto Nacional de Câncer (Brasil). Prevenção e controle do câncer: normas e recomendações do INCA. Rev Bras Cancerol, 48(3):317-32, 2002.
- [27] JNI. Disponível em <<http://docs.oracle.com/javase/7/docs/technotes/guides/jni/>>. Acesso em 9 de maio de 2014.
- [28] Joblove, George, H., Greenberg, Donald. (1978). 'Color spaces for computer graphics'. Computer Graphics 12 (3): 20–25. doi:10.1145/965139.807362.
- [29] Marks, R. (2000). 'Epidemiology of melanoma'. Clin. Exp. Dermatology Vol.25, pp. 459-463.
- [30] Nachbar, F. (1994). 'The ABCD rule of dermatoscopy: High prospective value in the diagnosis of doubtful melanocytic skin lesions'. Journal of the American Academy of Dermatology.
- [31] Open CV Android. Disponível em <<http://opencv.org/platforms/android.html>>. Acesso em 28 de abril de 2014.
- [32] OpenCV Manager no Google Play. Disponível em <https://play.google.com/store/apps/details?id=org.opencv.engine&hl=pt_BR>. Acesso em 23 de junho de 2014.
- [33] Otsu, N. (1979). 'A Threshold Selection Method from Gray-Level Histograms'. IEEE Transactions on Systems, Man, and Cybernetics, p. 62-66.
- [34] Pele Melanoma. Disponível em <http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pele_melanoma>. Acesso em 10 de junho de 2014.
- [35] Preenchimento de buracos, documentação do OpenCV. Disponível em <http://docs.opencv.org/modules/core/doc/drawing_functions.html?highlight=fillpoly#cv.FillPoly>. Acesso em 23 de junho de 2014.
- [36] Queiroz, J.E.R.D., Gomes, H.M. (2006). 'Introdução ao Processamento Digital de Imagens'. RITA, p.11-42.

- [37] Randy, G. (2013). 'Skin Cancer: an Overview of Epidemiology and Risk Factors'. *Seminars in Oncology Nursing*, Vol. 29, No. 3, pp 160-169.
- [38] Rivitti, E., Sampaio, S. A. (2007). 'Dermatologia'. Editora Artes Médicas, 3ª edição.
- [39] Relação entre ângulos. Disponível em <http://en.wikipedia.org/wiki/Parallel_axis_theorem#mediaviewer/File:Steiners_sats.PNG>. Acesso em 18 de junho de 2014.
- [40] Representação adaptada de imagem digital. Disponível em <<http://robotix.in/matlab/gray.png>>. Acesso em 07 de junho de 2014.
- [41] Retângulo mínimo, documentação do OpenCV. Disponível em <http://docs.opencv.org/modules/imgproc/doc/structural_analysis_and_shape_descriptors.html#boundingrect>. Acesso em 23 de junho de 2014.
- [42] Stolfi, G. (2008). 'Percepção Visual Humana'. Technical report, Universidade de São Paulo.
- [43] Suzuki, S. and Abe, K. (1985). 'Topological Structural Analysis of Digitized Binary Images by Border Following'. *CVGIP* 30 1, pp 32-46.
- [44] Tipos de Câncer de Pele Melanoma. Disponível em <<http://www.sbd.org.br/informacoes/sobre-o-cancer-da-pele/tipos-de-cancer-da-pele/>>. Acesso em 28 de abril de 2014.
- [45] Young, T., Bakerian. (1802). 'Lecture: On the Theory of Light and Colours'. *Phil. Trans. R. Soc. Lond.*, p. 12-48.