

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
INSTITUTO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

ELIEZER EMANUEL BERNART

**Detecção e Qualificação de Lesões Melanocíticas  
Através de Evidências Locais e de Contexto**

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Sérgio Bampi  
Co-orientador: Prof. Dr. Jacob Scharcanski

Porto Alegre  
2016

## CIP – CATALOGAÇÃO NA PUBLICAÇÃO

Bernart, Eliezer Emanuel

Detecção e Qualificação de Lesões Melanocíticas Através de Evidências Locais e de Contexto / Eliezer Emanuel Bernart. – Porto Alegre: PPGC da UFRGS, 2016.

60 f.: il.

Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR–RS, 2016. Orientador: Sergio Bampi; Co-orientador: Jacob Scharcanski.

1. Segmentação. 2. Classificação. 3. Lesões melanocíticas. 4. Imagens macroscópicas. I. Bampi, Sergio. II. Scharcanski, Jacob. III. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitor de Pós-Graduação: Prof. Vladimir Pinheiro do Nascimento

Diretor do Instituto de Informática: Prof. Luís da Cunha Lamb

Coordenador do PPGC: Prof. Luigi Carro

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

*“Cogito ergo sum.”*

— RENÉ DESCARTES

## AGRADECIMENTOS

Ao professor Dr. Sérgio Bampi e ao professor Dr. Jacob Scharcanski pela oportunidade de desenvolver este trabalho junto ao Programa de Pós-Graduação em Computação (PPGC-UFRGS), por terem acreditado no meu potencial antes e depois de iniciar as pesquisas, pelas orientações e sugestões de disciplinas, temas de pesquisa e abordagens que certamente influenciaram e fizeram com que a minha maneira de pensar em computação, processamento de imagens e reconhecimento de padrões fosse ampliada. Agradeço também pelas reuniões e noites de trabalho no Instituto de Informática e remotamente, as quais foram essenciais para a realização deste trabalho.

Aos meus pais, Jocelino e Nilce, pelo apoio e compreensão nesta mudança de rumo que me trouxe até Porto Alegre. Agradeço por terem me ensinado as lições que nenhuma universidade poderá ensinar, ensinaram a honrar meus compromissos, assumir as minhas responsabilidades, e batalhar pelos meus sonhos.

Aos meus familiares que me auxiliaram durante esta jornada, emocionalmente e financeiramente, pedindo em troca apenas que fizesse o possível para ajudar as pessoas. Espero um dia retribuir tudo que recebi, fazendo o bem, apoiando outros que como eu buscam encontrar seu lugar e cumprir seu papel em meio a sociedade.

Aos meus avós, que são as melhores pessoas do mundo, que nunca deixaram de acreditar e que são exemplos de perseverança e trabalho duro.

Aos meus amigos e colegas de laboratório, especialmente Pablo e Maciel, cujas conversas renderam sempre excelentes reflexões e boas ideias. Não existem palavras para descrever a satisfação que é poder trabalhar todos os dias com cada um de vocês.

Aos meus amigos, de todas as cidades por onde passei, que nunca desistiram de me apoiar e sempre estiveram presentes nos momentos de felicidade e de dificuldade.

Aos professores e funcionários da Universidade do Oeste de Santa Catarina (Unoesc) que até hoje são companheiros de jornada e que sempre se fazem presentes tanto na minha vida pessoal como profissional. Agradeço em especial ao professor Dr. Lückmann e ao professor MSc. Karl Phillip por serem mentores do mais alto nível e terem me inspirado nessa busca pelo conhecimento.

A todas as pessoas que cruzaram a minha vida e contribuíram direta ou indiretamente na minha jornada, muito obrigado!

## RESUMO

Neste trabalho, um novo método não-supervisionado para segmentação de lesões melanocíticas em imagens macroscópicas é proposto levando em consideração regiões suspeitas, e também uma nova abordagem para classificação de lesões que faz uso de evidências locais e de contexto para estimar um índice de probabilidade para malignidade em cada lesão. O método proposto realiza a segmentação das imagens em três tipos de regiões disjuntas: ‘pele saudável’, ‘região de incerteza’ e ‘lesão’. Regiões de incerteza são refinadas através da utilização de feições estocásticas também de forma não-supervisionada, resultando em uma máscara binária que discrimina a pele da lesão. As máscaras obtidas apresentam um erro XOR comparável aos métodos estado da arte. A imagem é segmentada utilizando um algoritmo de *superpixels* e as sub-regiões que intersectam a máscara obtida são categorizadas como evidências locais. Estas evidências são representadas por uma descrição especializada que explora as características como cor e textura. Estas sub-regiões são então associadas à evidências de contexto definidas pela borda da lesão de onde foram extraídas e classificadas de forma independente através de uma abordagem supervisionada. Com o resultado da classificação destas evidências é possível obter um indicador probabilístico para malignidade associado a cada lesão, e levando em consideração um valor de tolerância é possível identificar lesões malignas em potencial. Os resultados obtidos com o método proposto são promissores e apresentam maior acurácia do que os métodos existentes na literatura apesar do erro XOR da segmentação das lesões ser maior, o que tende a confirmar o potencial do método proposto para discriminar lesões melanocíticas benignas e malignas.

**Palavras-chave:** Segmentação, Classificação, Lesões melanocíticas, Imagens macroscópicas.

## ABSTRACT

In this work, a novel unsupervised method for melanocytic macroscopic image segmentation is proposed considering suspicious regions, and also a novel approach for lesion classification using local and context evidence to estimate a probabilistic index of malignity or benignity in each lesion. The proposed method segment the macroscopic images in three types of disjoint regions: 'healthy skin', 'suspicious region' and 'lesion'. Suspicious areas are refined using stochastic texture features also in an unsupervised approach, resulting in a binary mask discriminating skin and lesion. The resulting masks present an XOR error similar to other state-of-art methods. In the next step, the image is segmented using a superpixels algorithm and subregions that intersect the obtained mask categorized as local evidence. A specialized representation describes color and texture information present in the local evidence region. The border of the segmented skin lesion defines the context evidence and using a supervised approach, local and context evidence are combined and classified independently. With the evidence classification results is possible to obtain a probabilistic index of malignity and benignity associated to each lesion, and considering a tolerance value is possible to identify potential malignant lesions. The results achieved with the proposed method are promising and present greater accuracy than other techniques in the literature, even with a greater XOR error in segmentation step, confirming the proposed method's potential to discriminate benignant and malignant melanocytic lesions.

**Keywords:** Segmentation, Classification, Melanocytic lesions, Macroscopic images.

## LISTA DE FIGURAS

Figura 3.1 – Fluxograma ilustrando o processo de segmentação .....	25
Figura 3.2 – Processo de segmentação inicial.....	27
Figura 3.3 – Representação das regiões obtidas pela segmentação inicial .....	28
Figura 3.4 – Fluxograma ilustrando o processo de refinamento.....	29
Figura 3.5 – Exemplos de máscaras resultantes do processo de refinamento.....	30
Figura 3.6 – Representação das máscaras obtidas e segmentação resultante .....	31
Figura 4.1 – Fluxograma ilustrando o processo de classificação.....	36
Figura 4.2 – Segmentação utilizando <i>superpixels</i> .....	37
Figura 4.3 – Intersecção entre sub-regiões e máscaras .....	38
Figura 4.4 – Representação das lesões melanocíticas.....	38
Figura 4.5 – Representação gráfica das evidências de contexto .....	41
Figura 4.6 – Classificação das sub-regiões da lesão .....	44
Figura 4.7 – Resultado da classificação utilizando evidências de contexto.....	46
Figura 4.8 – Classificação das sub-regiões utilizando evidências locais .....	48
Figura 4.9 – Classificação das sub-regiões utilizando evidências locais e de contexto.....	51
Figura 4.10 –Gráfico demonstrando o impacto do valor de tolerância na classificação final..	55

## LISTA DE TABELAS

Tabela 3.1 – Comparativo para o Erro XOR.....	33
Tabela 3.2 – Comparativo para especificidade.....	34
Tabela 4.1 – Classificação das sub-regiões utilizando evidências de contexto.....	46
Tabela 4.2 – Classificação final das lesões usando evidências de contexto.....	47
Tabela 4.3 – Classificação de sub-regiões utilizando evidências locais.....	49
Tabela 4.4 – Classificação final das lesões usando evidências locais.....	50
Tabela 4.5 – Classificação de sub-regiões combinando evidências locais e de contexto.....	52
Tabela 4.6 – Classificação final das lesões usando evidências locais.....	53
Tabela 4.7 – Comparativo de classificação entre máscaras de segmentação.....	54
Tabela 4.8 – Comparativo para com métodos estado da arte.....	55



## LISTA DE ABREVIATURAS E SIGLAS

CAD	<i>Computer-Aided Diagnosis</i>
RGB	<i>Red, Green and Blue</i>
HSV	<i>Hue, Saturation and Value</i>
PCA	<i>Principal Component Analysis</i>
ICA	<i>Independent Component Analysis</i>
ABCD	Assimetria, Borda, Cor, Diâmetro
SLIC	<i>Simple Linear Iterative Clustering</i>
CIE	<i>International Commission on Illumination</i>
KNN	<i>K-Nearest Neighbors</i> ou <i>K-vizinhos mais próximos</i>
SVM	<i>Support Vector Machine</i>
TP	<i>True Positive</i> ou Verdadeiro Positivo
FP	<i>False Positive</i> ou Falso Positivo
TN	<i>True Negative</i> ou Verdadeiro Negativo
FN	<i>False Negative</i> ou Falso Negativo
GT	<i>Ground Truth</i>

## LISTA DE SÍMBOLOS

$I$	Imagem digital
$R$	Canal vermelho
$G$	Canal verde
$B$	Canal azul
$c$	Índice para os canais de cor RGB
$(x,y)$	Par de índices em $I$
$i$	Índice de um vetor
$\mathcal{G}$	Filtro Gaussiano
$\sigma$	Desvio padrão
$\mu$	Média
$\tilde{I}$	Imagem filtrada por filtro Gaussiano
$t$	Valor de limiar
$T_R$	Canal vermelho limiarizado por um valor $t_R$
$T_G$	Canal verde limiarizado por um valor $t_G$
$T_B$	Canal azul limiarizado por um valor $t_B$
$\phi$	Mapa das regiões suspeitas
$\nabla$	Operador de gradiente Sobel
$G$	Magnitude do Gradiente
$K$	Mapa de estocasticidade textural
$X$	Vetor de feições
$N$	Número de amostras de treinamento
$\tau$	Número máximo de sub-regiões
$n$	Número obtido de sub-regiões

$S$	Conjunto de sub-regiões de uma imagem $I$
$s$	Sub-região da imagem
$M$	Máscara binária obtida durante a segmentação
$\cap$	Intersecção
$\hat{S}$	Sub-regiões que intersectam a área de lesão
$\hat{s}$	Sub-região da lesão
$L$	Canal de luminância
$a$	Canal de cor a do espaço de cor CIE L*a*b*
$b$	Canal de cor b do espaço de cor CIE L*a*b*
$\hat{I}_1$	Canal de variação textural
$\hat{I}_2$	Canal de variação local de intensidade
$\hat{I}_3$	Canal de coloração
$\psi$	Representação da lesão por canais especializados
$E_{local}$	Matriz de evidências locais
$\beta$	Número de células do histograma
$A$	Área da lesão
$p$	Perímetro da lesão
$L_1$	Maior eixo da lesão
$L_2$	Menor eixo da lesão
$B_1$	Área de do lado direito de um dos eixos da lesão
$B_2$	Área de do lado esquerdo de um dos eixos da lesão
$E_{contexto}$	Matriz de evidências de contexto
$E$	Matriz de evidências
$\hat{E}$	Matriz de evidências normalizada
$\gamma$	Escala da função base radial

$C$	Margem para o classificador SVM
$\mathcal{I}_{malignidade}$	Índice de malignidade
$\mathcal{I}_{benignidade}$	Índice de benignidade
$\varepsilon$	Valor de tolerância
$m$	Parâmetro de compactação para o algoritmo de <i>superpixels</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
1.1	Objetivo.....	17
1.2	Contribuições deste Trabalho .....	17
1.3	Organização do Trabalho.....	17
<b>2</b>	<b>TRABALHOS RELACIONADOS</b> .....	<b>18</b>
2.1	Representação de Imagens Macroscópicas de Lesões Melanocíticas.....	18
2.2	Segmentação de Lesões Melanocíticas em Imagens Macroscópicas .....	20
2.3	Representação de Lesões Melanocíticas em Imagens Macroscópicas.....	22
2.4	Classificação de Lesões Melanocíticas em Imagens Macroscópicas.....	23
<b>3</b>	<b>UMA ABORDAGEM PARA SEGMENTAÇÃO DE LESÕES MELANOCÍTI- CAS UTILIZANDO LIMIARES ADAPTATIVOS E FEIÇÕES ESTOCÁSTICAS</b>	<b>25</b>
3.1	Segmentação Inicial .....	26
3.2	Refinamento de Regiões Suspeitas.....	27
3.3	Pós-Processamento.....	30
3.4	Resultados Experimentais e Discussões .....	30
<b>4</b>	<b>CLASSIFICAÇÃO E QUALIFICAÇÃO DE LESÕES MELANOCÍTI- CAS ATRAVÉS DE EVIDÊNCIAS LOCAIS E DE CONTEXTO</b> .....	<b>35</b>
4.1	Obtenção e Representação de Evidências Locais Utilizando <i>Superpixels</i> .....	36
4.2	Extração de Evidências de Contexto .....	39
4.3	Classificação de Evidências Locais e de Contexto de Forma Independente.....	42
4.4	Obtenção de Indicador Probabilístico para Malignidade e Benignidade.....	42
4.5	Resultados Experimentais e Discussões .....	43
4.5.1	Evidências de Contexto .....	45
4.5.2	Evidências Locais.....	47
4.5.3	Evidências Locais e de Contexto.....	48
4.5.4	Discussão.....	50

<b>5 CONCLUSÃO .....</b>	<b>56</b>
<b>5.1 Trabalhos Futuros.....</b>	<b>57</b>
<b>Referências.....</b>	<b>58</b>

## 1 INTRODUÇÃO

Diversos métodos para auxílio ao diagnóstico médico vêm sendo desenvolvidos como forma de colaborar com a identificação precoce de doenças e tumores. Uma das áreas que recebeu grande atenção foi a dermatologia, onde imagens de lesões melanocíticas são analisadas diariamente por especialistas que precisam realizar um diagnóstico utilizando, na maioria dos casos, apenas a informação visual.

Apesar do constante aumento no número de dermatologistas que recebem treinamento e afirmam saber como utilizar um dermatoscópio (NOOR; NANDA; RAO, 2009; MURZAKU; HAYAN; RAO, 2014), pesquisas ainda apontam que mesmo nestas condições, 58% dos especialistas ainda não possuem o equipamento que é capaz de adquirir imagens de alta qualidade de uma lesão (PILIOURAS; BUETTNER; SOYER, 2014). Estes dispositivos combinam a emissão de uma luz não-polarizada e uma lente que permite ampliar a região observada de forma a obter informações detalhadas sobre a anomalia, oferecendo assim subsídio para que o especialista possa realizar o diagnóstico. Porém, em regiões distantes dos grandes centros o acesso a dermatologistas pode levar tempo, o que implica em um atraso na chegada do paciente até o especialista, levando ao agravamento do quadro do paciente, que em alguns casos pode levar ao seu óbito.

Em 2013, segundo dados do Instituto Nacional de Câncer (INCA), foram registradas 1.559 mortes por câncer de pele do tipo melanoma maligno no Brasil. A estimativa é que no ano de 2016 sejam registrados 5.670 novos casos. Para outros tipos de tumores, como é o caso dos nevos atípicos, são estimados 175.760 novos casos em 2016 (INCA, 2015). A detecção precoce de ambos os tipos de tumor pode levar ao aumento na sobrevivência de pacientes, evidenciando a importância de ferramentas que auxiliem no diagnóstico inicial de possíveis casos.

Buscando reduzir o atraso na busca por um especialista, diversos estudos buscam o desenvolvimento de aplicações que sejam capazes de oferecer uma avaliação inicial do quadro do paciente fazendo uso de dispositivos mais acessíveis, como câmeras digitais tradicionais e *smartphones*, permitindo a identificação precoce do tumor (CAVALCANTI; SCHARCANSKI, 2011; GLAISTER; WONG; CLAUSI, 2014). Estes sistemas de CAD (*Computer-Aided Diagnosis*) normalmente são constituídos por quatro etapas: 1) pré-processamento, para correções na iluminação e remoção de ruído; 2) segmentação, cujo objetivo é delimitar a região da lesão na pele; 3) extração de características como assimetria, borda, cor e dimensão, componentes da

regra do ABCD da dermatologia (AHNLIDE et al., 2014); 4) classificação da lesão encontrada como maligna ou benigna.

Os sistemas tradicionais para auxílio ao diagnóstico realizam a obtenção de características extraídas das imagens e as utilizam como feições para identificar a qual classe a lesão pertence. Entretanto, uma lesão melanocítica pode ser representada por diferentes estágios de evolução, apresentar características que nem sempre são dominantes, ou que não permitem perfeita distinção entre as classes.

As imagens utilizadas por estes sistemas podem ser dermatoscópicas, obtidas por um dispositivo que faz uso da emissão de luz polarizada e que permite a observação de detalhes do tumor que não são visíveis a olho nu, ou ainda macroscópicas, que exploram a alta qualidade de câmeras comuns, as quais são de fácil acesso devido ao baixo custo para aquisição. Entretanto, o equipamento utilizado para obtenção de imagens dermatoscópicas possui custo elevado e deve ser manuseado por um especialista, não sendo uma alternativa efetiva para auxílio as regiões de difícil acesso. Já a utilização de imagens macroscópicas na qualificação de lesões melanocíticas permite uma maior abrangência da solução, porém seu uso depende da remoção de sombras, da atenuação do ruído introduzido pelo sensor e de técnicas para extração de detalhes visíveis.

O presente estudo propõe um novo método adaptativo não-supervisionado que realiza a segmentação de imagens macroscópicas de lesões melanocíticas em três tipos de regiões disjuntas: ‘pele saudável’, ‘região de incerteza’ e ‘lesão’. Onde as regiões de incerteza são refinadas através da utilização de feições estocásticas também de forma não supervisionada, resultando em uma máscara binária que discrimina a pele da lesão.

Enquanto os métodos presentes na literatura avaliam a lesão como um todo para efetuar a sua classificação, a metodologia proposta faz uso de uma descrição especializada composta de evidências locais associadas a cada uma das sub-regiões da lesão, obtidas por um algoritmo de *superpixels*. As descrições de cada uma das sub-regiões são associadas às evidências de contexto definidas pela borda da lesão de onde foram extraídas, para que possam ser classificadas de forma independente através de uma abordagem supervisionada.

Este trabalho leva em consideração regiões de incerteza, evidências locais e de contexto para atribuir indicadores de malignidade e benignidade para imagens de lesões melanocíticas obtidas por câmeras digitais convencionais e que apresenta vantagens quando comparado aos métodos estado da arte para o referido conjunto de dados utilizados.



## 1.1 Objetivo

Os principais objetivos deste trabalho são a proposição de um novo método para segmentação de lesões melanocíticas em imagens macroscópicas levando em consideração regiões de incerteza, e a proposição de uma abordagem para representação e classificação das regiões de lesão por meio de evidências locais e de contexto que permitem a obtenção de um indicador probabilístico para ocorrência de malignidade e benignidade.

## 1.2 Contribuições deste Trabalho

As principais contribuições deste trabalho são:

- A proposição de um novo método para segmentação de lesões melanocíticas que leva em consideração regiões de incerteza;
- A proposição de uma descrição especializada de *superpixels* que explora características locais presentes em lesões melanocíticas;
- A proposição de um novo método para atribuir indicadores de malignidade ou benignidade à lesões melanocíticas levando em consideração evidências locais e de contexto.

## 1.3 Organização do Trabalho

As demais seções do presente trabalho estão organizadas da seguinte forma: a Seção 2 apresenta uma revisão dos trabalhos relacionados existentes na literatura para segmentação e classificação de lesões melanocíticas. Na Seção 3 está descrito o método proposto para segmentação, bem como seus resultados e comparativos. Na Seção 4 está descrita a abordagem proposta para classificação e seus resultados experimentais. Por fim, na Seção 5 são apresentadas as considerações finais a respeito deste trabalho.

## 2 TRABALHOS RELACIONADOS

Ao longo deste capítulo são apresentados métodos presentes na literatura que realizam a segmentação e classificação de lesões melanocíticas utilizando imagens macroscópicas.

Inicialmente, na Seção 2.1 é descrita uma das abordagens existentes na literatura que diz respeito à representação de imagens macroscópicas de lesões melanocíticas por canais especializados.

Na Seção 2.2 é apresentada uma revisão que diz respeito à segmentação, onde as abordagens fazem uso de limiares adaptativos, fluxo do vetor gradiente, análise de componentes independentes, além de métodos mais recentes que exploram a utilização de aprendizado de dicionários.

Na Seção 2.3 são descritas formas de representar regiões segmentadas de lesões melanocíticas, comparando a utilização de blocos retangulares e de *superpixels*.

Já na Seção 2.4 é realizada a análise de dois métodos de classificação que foram desenvolvidos para o mesmo conjunto de dados, um deles utiliza seleção de feições baseada em correlação (*Correlation-based feature selection*) e modelo de árvores logísticas (*Logist Model Trees*), e outro modelo que utiliza classificadores K-vizinhos mais próximos e árvores de decisão.

### 2.1 Representação de Imagens Macroscópicas de Lesões Melanocíticas

Em CAVALCANTI; SCHARCANSKI (2011) é proposta a representação de imagens macroscópicas contendo uma lesão melanocítica através de três canais que contêm informações para auxiliar na distinção entre região de pele e área de lesão. Estes canais consistem de representações da variação textural, variação na tonalidade local da pele e a coloração da região. Este método foi utilizado no presente trabalho por auxiliar na diferenciação entre áreas malignas e benignas.

O primeiro canal,  $\hat{I}_1$ , é uma representação da variação textural. A fim de extrair informações sobre a variação textural, a imagem de luminância,  $L \in \mathbb{R}^{m \times n}$ , é computada para todo  $(x, y) \in \{1, \dots, m\} \times \{1, \dots, n\}$  por:

$$L_{(x,y)} = \frac{R_{(x,y)} + G_{(x,y)} + B_{(x,y)}}{3}. \quad (2.1)$$

Além disso,  $\eta$  filtros gaussianos  $\{\mathcal{S}^{(s)}\}_{s=1}^{\eta}$  de dimensões  $2\tau - 1 \times 2\tau - 1$  são computados, sendo  $\tau$  o tamanho definido para a janela:

$$\mathcal{I}_{(x,y)}^{(s)} = \frac{1}{2\pi(1 + \frac{\tau s}{2\tau-1})^2} \exp\left(-\frac{(i-\tau)^2 + (j-\tau)^2}{2(1 + \frac{\tau s}{2\tau-1})^2}\right), \quad (2.2)$$

onde  $(x,y) \in \{1, \dots, 2\tau - 1\} \times \{1, \dots, 2\tau - 1\}$ . Assim, o canal de variação textural  $\mathcal{T} \in \mathbb{R}^{m \times n}$  é computado por:

$$\mathcal{T}_{(x,y)} = \max_{s \in \{1, \dots, \eta\}} \left\{ L_{(x,y)} \cdot \left( \frac{1 - (L \otimes \mathcal{S}^{(s)})_{(x,y)}}{(L \otimes \mathcal{S}^{(s)})_{(x,y)}} \right) \right\}, \quad (2.3)$$

onde  $(L \otimes \mathcal{S}^{(s)})_{(x,y)}$  denota o pixel indexado por  $(x,y)$  em  $L \otimes \mathcal{S}^{(s)}$  (“ $\otimes$ ” denota a operação de convolução). O canal de variação textural é normalizado por:

$$\hat{I}_2 = \frac{\mathcal{T}_{(x,y)} - \min\{\mathcal{T}\}}{\max\{\mathcal{T}\} - \min\{\mathcal{T}\}}, \quad (2.4)$$

onde  $\min\{\mathcal{T}\}$  e  $\max\{\mathcal{T}\}$  denotam a menor e a maior intensidade em  $\mathcal{T}$ .

O segundo canal,  $\hat{I}_2$  representa a variação local na tonalidade da pele, e é definido pelo complemento do canal vermelho (i.e., o primeiro canal do espaço de cores *RGB*) e assumindo valores dentro do intervalo de  $[0, 1]$  é definido por:

$$\hat{I}_2(x,y) = 1 - R(x,y). \quad (2.5)$$

O terceiro canal,  $\hat{I}_3$ , descreve a coloração da região e é dado pela normalização da representação da imagem em RGB no seu subespaço de maior variância, o qual é obtido por meio da análise das componentes principais (PCA). Por fim, este canal é filtrado pelo filtro da mediana  $5 \times 5$  para reduzir o ruído impulsivo do canal. O canal  $\hat{I}_3$  apresenta informações importantes assumindo que regiões de lesão e não-lesão têm diferentes distribuições de cor.

Além das representações propostas em CAVALCANTI; SCHARCANSKI (2011) auxiliarem na distinção entre as regiões de pele e de lesão, elas também permitem a extração e análise de informações que auxiliam na diferenciação entre lesões malignas e benignas.

## 2.2 Segmentação de Lesões Melanocíticas em Imagens Macroscópicas

Diferentes abordagens presentes na literatura exploram a utilização de limiares adaptativos para a segmentação das lesões de pele, permitindo separar a área de lesão da pele saudável. Utilizando uma representação em tons de cinza, assumindo que as áreas lesionadas são depigmentações da área de pele saudável, em RUIZ et al. (2008) é proposta a utilização do limiar de Otsu (OTSU, 1979) a fim de definir um valor que permita a separação entre as duas classes, assumindo que elas apresentam a mesma variância e o mesmo desvio padrão. O resultado da segmentação inicial é complementado pela aplicação de operações morfológicas.

No trabalho proposto em CAVALCANTI; YARI; SCHARCANSKI (2010) é feito uso de uma etapa de pré-processamento da imagem macroscópica, onde as variações de iluminação são atenuadas (CAVALCANTI; SCHARCANSKI; LOPES, 2010) seguida da aplicação do limiar de Otsu no canal vermelho do espaço de cores RGB. A justificativa é de que as regiões de pele saudável apresentam tonalidades com maiores intensidades de tons vermelhos e que as lesões são descolorações destas regiões. Como etapa de pós-processamento, as regiões internas da área segmentada são preenchidas e uma operação morfológica de dilatação é aplicada.

Enquanto muitas abordagens fazem uso de espaços de cor como RGB e HSV para a segmentação das lesões melanocíticas, em CAVALCANTI; SCHARCANSKI (2011) é proposta uma representação diferenciada para a imagem macroscópica através de três canais especializados. O primeiro deles, apresentando a variabilidade de textura da imagem, considerando que áreas de pele e de lesão possuem diferentes características; o segundo uma representação das tonalidades de pele, assumindo a diferença nas intensidades da região de lesão; e por fim uma representação das cores através de um único canal usando decomposição por análise de componentes principais (PCA - *Principal Component Analysis*). O limiar de Otsu é calculado para cada um dos canais de forma independente, e quando ao menos duas segmentações indicam a presença de lesão, o referido pixel é marcado como lesão.

Ainda explorando esta representação, em CAVALCANTI; SCHARCANSKI (2013) o cálculo do limiar de Otsu é realizado para o canal que representa a variação textural, onde a maior região segmentada é selecionada e tem suas áreas de borda refinadas por um método de contornos ativos, seguida de operações morfológicas para remoção de artefatos.

Na literatura, também é possível encontrar outras abordagens como é o caso de TANG (2009) onde é utilizada para segmentação da imagem de lesão melanocítica uma abordagem que

faz uso de contornos ativos multidirecionais. Inicialmente é obtida uma estimativa da região onde a lesão está localizada, utilizando como etapa de pré-processamento um filtro anisotrópico robusto à presença de ruído e capaz de reduzir a interferência de pelos, seguida da aplicação de uma limiarização.

Uma vez estimada a região onde a lesão está localizada, um método de contornos ativos baseado no fluxo do vetor gradiente é utilizado para refinar a área segmentada, permitindo a estimativa das regiões de borda mesmo que exista a presença de artefatos nas proximidades.

Após uma etapa de atenuação de sombra, o método proposto em CAVALCANTI et al. (2011) utiliza análise de componentes independentes (ICA - *Independent Component Analysis*), que tende a separar as áreas de lesão, pele e outros artefatos. Com a estimativa gerada através da utilização da ICA é possível obter uma segmentação inicial da área de lesão.

Para refinar a borda da lesão obtida durante a segmentação inicial e adquirir uma estimativa mais precisa de sua localização é realizada a aplicação de um método de contornos ativos (CHAN; VESE, 2001), além disso, uma etapa de pós-processamento também é aplicada para computar a máscara final.

Já o método proposto em FLORES (2015) para segmentação de lesões melanocíticas, inicialmente, para reduzir artefatos indesejáveis, os efeitos de sombra são atenuados e uma pré-segmentação é obtida usando um algoritmo de *watershed* (JUNG, 2007).

Em seguida, uma imagem de variação textural projetada para melhorar a discriminabilidade da lesão em relação ao fundo é obtida e a região pré-segmentada é usada para o aprendizado de um dicionário inicial e de uma representação inicial via um método de fatoração de matrizes não-negativas.

Uma versão não-supervisionada e não-paramétrica do método de aprendizado de dicionário baseado em teoria da informação é utilizada para otimizar esta representação, selecionando o subconjunto de átomos que maximiza a compacticidade e a representatividade do dicionário aprendido. Por fim, a imagem da lesão de pele é representada usando o dicionário aprendido e segmentada com o método de corte normalizado em grafos.

Mesmo com diversas abordagens desenvolvidas para segmentação de lesões melanocíticas, uma solução que seja robusta e ao mesmo tempo computacionalmente eficiente ainda representa um problema em aberto.

### 2.3 Representação de Lesões Melanocíticas em Imagens Macroscópicas

É possível encontrar na literatura métodos que realizam a representação de áreas segmentadas de diversas formas, a mais tradicional delas envolve a utilização de blocos (*patches*) retangulares.

Um bloco retangular é definido pela vizinhança de um pixel, podendo ser utilizado na decomposição de imagens ou regiões e apresentar diferentes dimensões. Este tipo de abordagem é comum em métodos existentes para segmentação de imagens macroscópicas de lesões melanocíticas (FLORES, 2015) pois permite uma representação simples e que facilita a extração de informações como textura e cor. Porém, blocos de tamanho uniforme não são capazes de representar bordas de objetos complexos, o que acaba diminuindo sua precisão.

Outro tipo de representação de imagens comum em outros trabalhos é a segmentação através de *superpixels*, servindo como uma etapa de pré-processamento para permitir a aplicação de técnicas mais complexas.

Algoritmos para obtenção de *superpixels* são utilizados como forma de representar regiões similares através de pixels coerentes. Diversos métodos podem ser encontrados na literatura, dentre eles o algoritmo SLIC (*simple linear iterative clustering*) (ACHANTA et al., 2012) que possui como características baixa complexidade computacional e permite de representar regiões de borda fielmente, ao contrário de blocos retangulares.

O método SLIC, de forma resumida, apresenta duas importantes modificações ao tradicional método de *clustering k*-médias. A primeira delas é a redução no número de cálculos de distâncias, o que implica na redução do tamanho do espaço de busca para regiões do tamanho de cada *superpixel*. A segunda é a utilização de uma medida de distância ponderada que permite ao mesmo tempo preservar regiões de borda e permitir o controle do tamanho e da compactação de cada região.

No momento da inicialização devem ser informados dois parâmetros, o número de *superpixels* desejado e o valor utilizado para definir a compactação de cada região. Entretanto, para permitir que algoritmo produza regiões com tamanho similar, o número de *superpixels* resultantes pode ser inferior ao valor informado como parâmetro.

Durante o agrupamento são utilizadas as representações de cada pixel no espaço de cores CIE L\*a\*b\* (GONZALEZ; WOODS, 2008) associada com a sua localização no plano da imagem ponderada pelo parâmetro de compactação. Iterativamente, cada pixel é associado ao cen-

tro de uma grade de tamanho definido pelo número de *superpixels* desejados, de forma similar ao algoritmo *k*-médias.

Uma etapa de pós-processamento força a conectividade de *pixels* que não pertencem a mesma região à qual estão conectados, atribuindo-os para a região cujo centro se encontra mais próximo. Resultando em um mapa de *superpixels* com tamanhos semelhantes, respeitando as regiões de borda e apresentando grande coerência interna.

A representação de forma coerente é imprescindível para métodos de utilizados na classificação de sub-regiões, uma vez que a coerência garante que os *pixels* similares que podem caracterizar uma lesão estarão agrupados em uma mesma região.

## 2.4 Classificação de Lesões Melanocíticas em Imagens Macroscópicas

Sistemas de auxílio ao diagnóstico buscam explorar informações contidas na área de lesão para qualificá-la como sendo maligna ou benigna, para isso, algoritmos buscam analisar a imagem da mesma forma que o especialista. O método mais conhecido para identificar a malignidade em uma lesão é a regra ABCD da dermatologia (AHNLIDE et al., 2014), segundo ela quatro diferentes aspectos necessitam ser verificados: assimetria, borda, coloração e diâmetro. Lesões malignas, em geral, apresentam formas assimétricas, bordas irregulares e pouco definidas, coloração não-uniforme, e apresentam mais de 6 mm de diâmetro (KOROTKOV; GARCIA, 2012).

Uma revisão sobre os métodos de classificação utilizados na identificação de lesões melanocíticas malignas em imagens dermoscópicas pode ser encontrada no trabalho apresentado em KOROTKOV; GARCIA (2012), bem como uma revisão sobre as principais feições utilizadas na etapa de classificação.

A seguir são apresentados métodos que fazem uso de imagens macroscópicas de lesões melanocíticas oriundas da mesma base de dados, permitindo a comparação entre as técnicas utilizadas e seus resultados. Ambos os métodos buscam a diferenciação entre os casos benignos e malignos fazendo uso de um conjunto de imagens previamente analisado por um dermatologista.

O método proposto em ALCÓN et al. (2009), realiza a extração de feições à partir de imagens macroscópicas de lesões melanocíticas obtidas por câmeras digitais convencionais e as combina com informações relacionadas ao paciente.

As feições relacionadas a imagem da lesão consistem em representações da assimetria, borda, cor e estruturas presentes na área afetada. Já as informações do paciente levam em consideração tipo da cor de pele, idade, gênero e parte do corpo onde a lesão ocorreu.

A etapa de classificação se dá inicialmente por meio da utilização de um algoritmo de seleção de feições baseada em correlação e a classificação final é obtida por um modelo de árvores logísticas (*Logistic Model Trees*).

Enquanto a abordagem para classificação de imagens macroscópicas proposta em CAVALCANTI; SCHARCANSKI (2011) utiliza feições também relacionadas às características referentes à regra ABCD da dermatologia (AHNLIDE et al., 2014), adicionalmente faz-se uso de canais especializados para complementar as representações da área de lesão.

No que diz respeito à etapa de classificação, um método para re-amostragem do conjunto de treinamento é utilizando buscando ampliar o número de amostras utilizadas. Como classificador, os autores propõem a utilização do algoritmo *k*-vizinhos mais próximos combinado com classificadores Bayesianos especializados em um subconjunto de feições identificados por árvores de regressão, buscando reduzir o número de falsos negativos gerados pelo método.

Metodologias utilizadas na qualificação de lesões como malignas ou benignas variam na escolha do conjunto de feições utilizadas e na forma que a classificação é realizada. A definição de algoritmos que façam uso de informações compreensíveis e que aproximem o diagnóstico do dermatologista de forma robusta ainda é um problema em aberto, e que se solucionado pode beneficiar inúmeras pessoas no auxílio a identificação precoce de tumores.



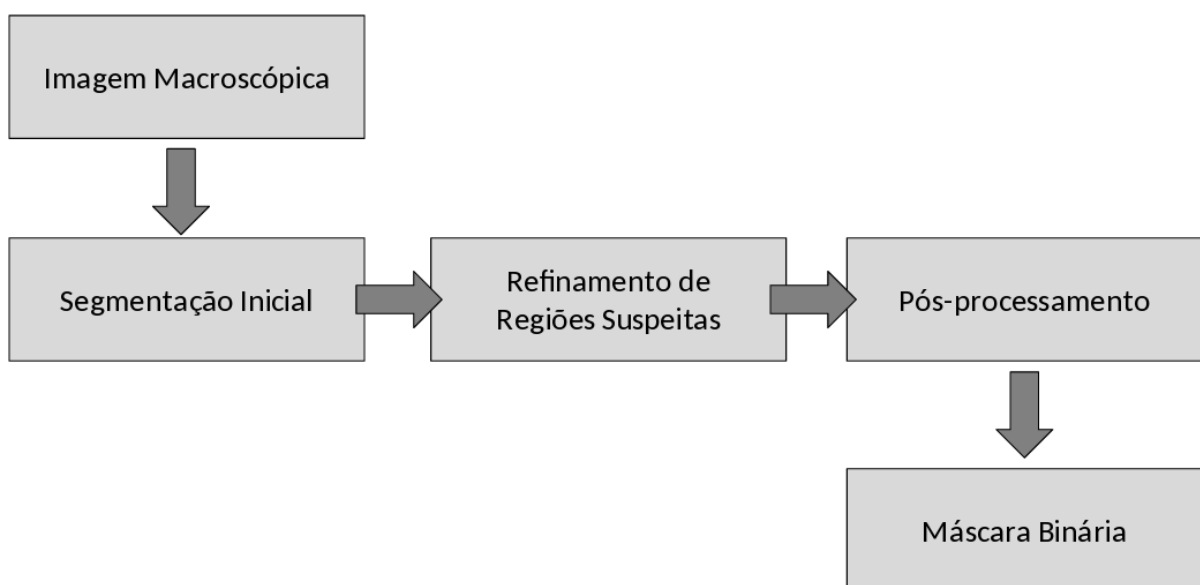
### 3 UMA ABORDAGEM PARA SEGMENTAÇÃO DE LESÕES MELANOCÍTICAS UTILIZANDO LIMIARES ADAPTATIVOS E FEIÇÕES ESTOCÁSTICAS

Existem diferentes métodos na literatura, os quais apresentam abordagens para segmentar lesões melanocíticas cuja eficácia já foi confirmada. Entretanto, a maior parte destes métodos geram bordas determinísticas, mesmo quando a lesão está afetando algumas das áreas em seu entorno com menor intensidade ou quando a lesão retraiu sob a pele.

O método proposto neste trabalho utiliza uma abordagem não-supervisionada que agrupa os *pixels* da imagem macroscópica em três regiões disjuntas, chamadas ‘lesão de pele’, ‘região suspeita’ e ‘pele saudável’. Estas regiões são detectadas levando em consideração a concordância entre a segmentação de diferentes canais utilizando limiares adaptativos. Por fim, são utilizadas feições de textura estocástica como forma de refinar a ‘região suspeita’, resultando na obtenção de uma máscara final de segmentação (BERNART et al., 2015).

Uma visão geral da abordagem proposta pode ser visualizada na Figura 3.1, destacando as etapas de segmentação inicial (descrita na Seção 3.1), refinamento de regiões suspeitas (Seção 3.2) e de pós-processamento (Seção 3.3).

Figura 3.1: Fluxograma ilustrando o processo de segmentação, tendo como entrada uma imagem macroscópica e como saída a máscara binária resultante da segmentação.



Fonte: o autor.

### 3.1 Segmentação Inicial

O método proposto assume como entrada uma imagem macroscópica de uma lesão melano-cítica denotada como  $I$  e representada pelos canais  $c = \{R, G, B\}$ , com índices  $(x, y)$ , onde cada elemento  $I_c(x, y)$  pode assumir valores dentro do intervalo  $[0, 1]$ .

Esta imagem é pré-processada com um filtro Gaussiano  $\mathcal{G}$ ,

$$\tilde{I}(x, y) = \mathcal{G}(I(x, y), \sigma, \mu), \quad (3.1)$$

definindo os parâmetros  $\sigma = 5$  e  $\mu = 0$ , utilizando janelas de tamanho  $5 \times 5$ , atenuando a presença de ruído.

Fazendo o uso do método proposto em Otsu (OTSU, 1979), para cada canal de cor são obtidos de forma independente limiares denominados  $t_c$  utilizados na obtenção de uma estimativa inicial de segmentação, assumindo que quando a informação de cor é analisada no espaço de cores RGB, a área da lesão é mais escura do que a região de pele:

$$T_c(x, y) = \begin{cases} 1, & \text{se } \tilde{I}_c(x, y) < t_c, \\ 0, & \text{caso contrário.} \end{cases} \quad (3.2)$$


Para um dado pixel  $T_c(x, y)$ , quando todos os canais limiarizados indicam para a categorização como ‘pele saudável’ (*pixel* com intensidade maior do que o limiar) ou ‘lesão de pele’ (*pixel* com intensidade menor do que o limiar), estes *pixels* são então associados a suas respectivas regiões. Entretanto, quando não há uma total concordância entre os três canais limiarizados, o pixel é atribuído para categoria ‘região suspeita’.

As regiões obtidas são representadas por  $\phi(x, y)$ , onde o valor 0 indica ‘pele saudável’ (quando todas as representações indicam a presença de pele saudável para um determinado pixel), 1 indica ‘lesão de pele’ (quando todas as representações indicam a presença de lesão para um determinado pixel) e 2 ‘regiões de incerteza’ (quando uma das representações é diferente das demais):

$$\phi(x, y) = \begin{cases} 0, & \text{se } T_R(x, y) = T_G(x, y) = T_B(x, y) = 0, \\ 1, & \text{se } T_R(x, y) = T_G(x, y) = T_B(x, y) = 1, \\ 2, & \text{caso contrário.} \end{cases} \quad (3.3)$$

Na Figura 3.2 é possível observar o processo para obtenção das três regiões disjuntas, utilizando como entrada uma imagem macroscópica no espaço de cores *RGB*. No mapa de saída, as áreas em cinza indicam ‘pele saudável’, em preto ‘lesão de pele’ e em branco as ‘regiões suspeitas’.

Figura 3.2: Processo de segmentação inicial utilizado na obtenção das ‘regiões de incerteza’, utilizando como entrada a imagem macroscópica no espaço de cores *RGB*.



Fonte: o autor.


Ao final da etapa de segmentação inicial, a imagem  $\phi$  apresenta as três regiões disjuntas definidas anteriormente. É possível ainda a utilização de algoritmos mais sofisticados para obtenção de uma estimativa mais precisa destas regiões, aumentando também a complexidade do método de segmentação como um todo. Exemplos do resultado apresentado pela segmentação inicial são ilustrados pela Figura 3.3.

Uma vez definidas as regiões suspeitas, buscando a obtenção de uma máscara binária que seja capaz de distinguir a região de lesão da pele saudável, estas áreas serão refinadas através de um processo de classificação como descrito na Seção 3.2.

### 3.2 Refinamento de Regiões Suspeitas

Sendo que lesões melanocíticas não apresentam forma específica, cor ou textura, é considerado que ‘pele saudável’ e ‘lesão de pele’ apresentam diferentes texturas estocásticas. Como forma de qualificar estas texturas estocásticas em uma imagem de lesão de pele, é assumido

Figura 3.3: Na primeira linha estão dispostas as imagens originais, já na segunda linha as regiões obtidas pelo método proposto. Na cor preta estão as regiões identificadas como ‘lesão de pele’, na cor cinza as regiões identificadas como ‘pele saudável’ e na cor branca as ‘regiões suspeitas’.



Fonte: o autor.

que a distribuição do gradiente em diferentes regiões de pele pode ser representada por uma distribuição assimétrica (e.g. Gamma), desta forma, feições de texturas estocásticas são utilizadas para medir o quanto estas regiões desviam da aleatoriedade (SCHARCANSKI; DODSON, 1996).

Como forma de representar a textura estocástica, a magnitude do gradiente de cada um dos canais de cor  $c$  é calculada utilizando o operador de Sobel (GONZALEZ; WOODS, 2008):

$$G_c = |\nabla I_c|, \quad (3.4)$$

com base nestas informações é possível então estimar um índice de aleatoriedade para janelas de tamanho variável, definido por  $K_c$ :

$$K_c(x,y) = \left( \frac{\text{var}(G_c(x,y))}{\text{mean}(G_c(x,y))} \right)^{-1}, \quad (3.5)$$

onde maiores valores indicam a presença de estruturas e menor aleatoriedade.

Regiões que fazem parte da lesão melanocítica tendem a apresentar um maior número de estruturas e, conseqüentemente, menor aleatoriedade na região de pele saudável em seu entorno, que tende a ser menos agrupada e apresenta maior aleatoriedade.

Desta forma, descrever as magnitudes locais do gradiente por uma distribuição assimétrica auxilia na discriminação entre texturas estocásticas presentes na área interna e externa da região

assumida como ‘lesão de pele’.

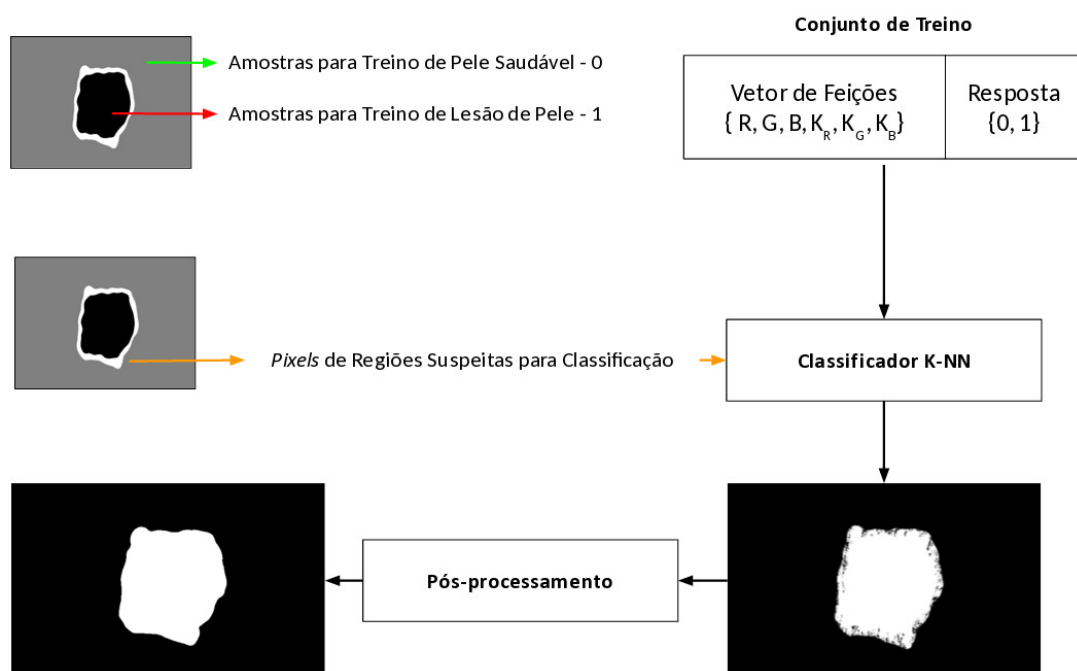
Uma vez computadas as feições de textura estocásticas para cada um dos canais de cores, estas informações são combinadas com os dados originais da imagem formando uma representação para cada elemento, dada por um vetor de feições definido por:

$$X(x, y) = \{I_R(x, y), I_G(x, y), I_B(x, y), K_R(x, y), K_G(x, y), K_B(x, y)\}. \quad (3.6)$$

Como forma de classificar as ‘regiões suspeitas’,  $N$  amostras de ambas as classes (‘pele saudável’ e ‘lesão de pele’) são selecionadas aleatoriamente, garantindo que ambos os conjuntos possuam o mesmo número de amostras. Sendo que a seleção automática de amostras oriundas da própria imagem como conjunto de treinamento torna possível a abordagem não-supervisionada.

Um classificador não-paramétrico KNN (*K-Nearest Neighbors* ou K-vizinhos mais próximos) (COVER; HART, 1967) é treinado fazendo uso das amostras coletadas dentro da própria imagem, e utilizado para refinar as regiões detectadas anteriormente como suspeitas, cujo processo pode ser observado na Figura 3.4. O resultado desta etapa é uma imagem binária contendo apenas regiões classificadas como lesão ou pele, ilustrada na Figura 3.5.

Figura 3.4: Fluxograma ilustrando o processo de refinamento, responsável pela classificação dos *pixels* pertencentes as regiões suspeitas.



Fonte: o autor.

Nos experimentos, o valor de  $N$  foi definido como 3000 amostras de cada uma das classes, já para os casos onde o número de *pixels* existentes era menor que o valor definido, o mesmo número de amostras da menor classe foi utilizado.

Figura 3.5: Exemplos de máscaras resultantes do processo de refinamento das ‘regiões suspeitas’ utilizando cores e texturas estocásticas.



Fonte: o autor.

O método proposto realiza uma etapa adicional com a aplicação de pós-processamento descrita na Seção 3.3 para eliminar artefatos e gerar a segmentação final.

### 3.3 Pós-Processamento


Considerando que as imagens pertencentes ao conjunto de dados utilizado para avaliação do método proposto apresentam apenas uma lesão melanocítica por imagem, as etapas iniciais de pós-processamento são: a seleção do maior objeto presente na máscara resultante da etapa de refinamento e o preenchimento de eventuais aberturas em sua região interior.

Uma etapa adicional é utilizada para suavizar as bordas da região que delimitam a lesão utilizando um filtro Gaussiano, buscando aproximar as marcações realizadas manualmente por um dermatologista e preservar as regiões resultantes da etapa de refinamento. Na Figura 3.6, é possível observar algumas das máscaras resultantes e um comparativo com a segmentação manual realizada por um dermatologista.

### 3.4 Resultados Experimentais e Discussões

O conjunto de dados escolhido para avaliação foi proposto em ALCÓN et al. (2009), uma vez que tem sido utilizado em diversos trabalhos presentes na literatura, consistindo de 152 imagens macroscópicas de lesões melanocíticas (45 nevos atípicos e 107 melanomas malignos) retirados do DERMNET SKIN DISEASE ATLAS (2015), onde em cada imagem contém apenas uma região de lesão. Este conjunto, além das imagens, apresenta o diagnóstico e a segmen-

Figura 3.6: Na primeira linha estão dispostas as máscaras geradas automaticamente. Na segunda linha, os contornos na cor azul representam a marcação manual realizada pelo dermatologista e em vermelho o resultado do método proposto.



Fonte: o autor.

tação da área que delimita a lesão, ambas realizadas por um dermatologista. Todas as imagens foram pré-processadas pelo algoritmo para atenuação de sombras proposto em CAVALCANTI; SCHARCANSKI; LOPES (2010), de forma a tornar a iluminação constante.

Para cada imagem presente no conjunto utilizado para avaliação do método foram geradas máscaras binárias com as marcações indicando a região onde a lesão está localizada, e por meio da comparação com a marcação realizada manualmente pelo dermatologista foram calculadas as seguintes medidas:

- TP: valor correspondente ao número de *pixels* pertencentes a regiões de lesão corretamente identificadas como lesão na segmentação automática;
- FP: valor correspondente ao número de *pixels* pertencentes a regiões de não-lesão incorretamente identificadas como lesão na segmentação automática;
- TN: valor correspondente ao número de *pixels* pertencentes a regiões de não-lesão corretamente identificadas como não-lesão na segmentação automática;
- FN: valor correspondente ao número de *pixels* pertencentes a regiões de lesão incorretamente identificadas como não-lesão na segmentação automática

Com base nestas informações é possível computar métricas que permitem avaliar o método proposto e compará-lo com os métodos presentes na literatura. Dentre as métricas comumente apresentadas estão o erro XOR e a especificidade.

O erro XOR é definido por:

$$\text{erro XOR} = \frac{FP + FN}{TP + FN}, \quad (3.7)$$

e permite avaliar a quantidade de *pixels* onde as máscaras de segmentação diferem, comumente utilizada na avaliação de métodos que tem como objetivo a segmentação de lesões.

A especificidade, definida por:

$$\text{especificidade} = \frac{TN}{FP + TN}, \quad (3.8)$$

permite avaliar a quantidade de *pixels* que são corretamente identificados como pele saudável em uma imagem.

Para que possa ser utilizado, um método de segmentação precisa apresentar baixos valores para o erro XOR, e altos valores para especificidade. Na Tabela 3.1 é possível verificar a comparação do método proposto com os demais métodos presentes na literatura no que diz respeito ao erro XOR e na Tabela 3.2 os resultados referentes à especificidade.

Com base nos resultados experimentais é possível comprovar que o método proposto apresenta erro e especificidade da segmentação comparáveis com as demais abordagens presentes na literatura. Apesar de métodos como o proposto em FLORES (2015) apresentar erros menores quando comparado com a segmentação realizada por um dermatologista, a abordagem proposta apresenta vantagens como a obtenção de ‘regiões suspeitas’ permitindo extensões e maior flexibilidade ao segmentar a lesão.

Diferentemente de outros métodos existentes na literatura, a abordagem proposta neste trabalho se destaca por propor uma etapa de segmentação inicial que pode fazer uso tanto de métodos de baixa complexidade, como de algoritmos mais elaborados. Além disso, faz uso de três regiões disjuntas, identificando possíveis áreas onde a lesão retraiu sob a pele, encontra-se em expansão, ou ainda regiões com uma variação na tonalidade da pele. Por fim, a abordagem proposta é inovadora por utilizar informações da própria imagem, obtidas através de uma etapa de segmentação inicial, no treinamento de um classificador utilizado na qualificação de ‘regiões suspeitas’.



Tabela 3.1: Comparativo entre o erro XOR gerado pelo método proposto e por outras abordagens presentes na literatura.

<b>Método</b>	<b>Erro XOR (%)</b>		
	Média	Mediana	Desvio Padrão
Limiar de Otsu na imagem em tons de cinza (RUIZ et al., 2008)	42.33	13.13	192.15
Limiar de Otsu no canal <i>R</i> (CAVALCANTI; YARI; SCHARCANSKI, 2010)	38.63	15.01	160.49
Esquema baseado no Fluxo do Vetor Gradiente (TANG, 2009)	59.60	50.32	40.96
Limiar de Otsu na representação em três canais (CAVALCANTI; SCHARCANSKI, 2011)	34.83	21.90	107.37
Segmentação baseada em ICA (CAVALCANTI et al., 2011)	28.33	12.88	108.00
Limiar de Otsu no canal de variação textural (CAVALCANTI; SCHARCANSKI, 2013)	15.60	12.33	11.93
Abordagem utilizando dicionários (FLORES, 2015)	14.87	11.86	10.58
Método proposto (BERNART et al., 2015)	15.40	11.66	10.48

Tabela 3.2: Comparativo entre a especificidade gerada pelo método proposto e por outras abordagens presentes na literatura.

<b>Método</b>	<b>Especificidade (%)</b>		
	<b>Média</b>	<b>Mediana</b>	<b>Desvio Padrão</b>
Limiar de Otsu na imagem em tons de cinza (RUIZ et al., 2008)	97.95	99.20	5.33
Limiar de Otsu no canal <i>R</i> (CAVALCANTI; YARI; SCHARCANSKI, 2010)	98.49	99.47	4.70
Esquema baseado no Fluxo do Vetor Gradiente (TANG, 2009)	99.62	99.89	0.76
Limiar de Otsu na representação em três canais (CAVALCANTI; SCHARCANSKI, 2011)	99.72	99.89	2.08
Segmentação baseada em ICA (CAVALCANTI et al., 2011)	98.34	99.59	8.38
Limiar de Otsu no canal de variação textural (CAVALCANTI; SCHARCANSKI, 2013)	99.11	99.41	2.16
Abordagem utilizando dicionários (FLORES, 2015)	99.12	99.33	1.41
Método proposto (BERNART et al., 2015)	99.02	99.29	1.41

## **4 CLASSIFICAÇÃO E QUALIFICAÇÃO DE LESÕES MELANOCÍTICAS ATRAVÉS DE EVIDÊNCIAS LOCAIS E DE CONTEXTO**

Neste capítulo é apresentada uma nova abordagem para classificação e qualificação de lesões melanocíticas fazendo uso de evidências locais e de contexto, permitindo a atribuição de um indicador de probabilidade para malignidade e benignidade em cada imagem.

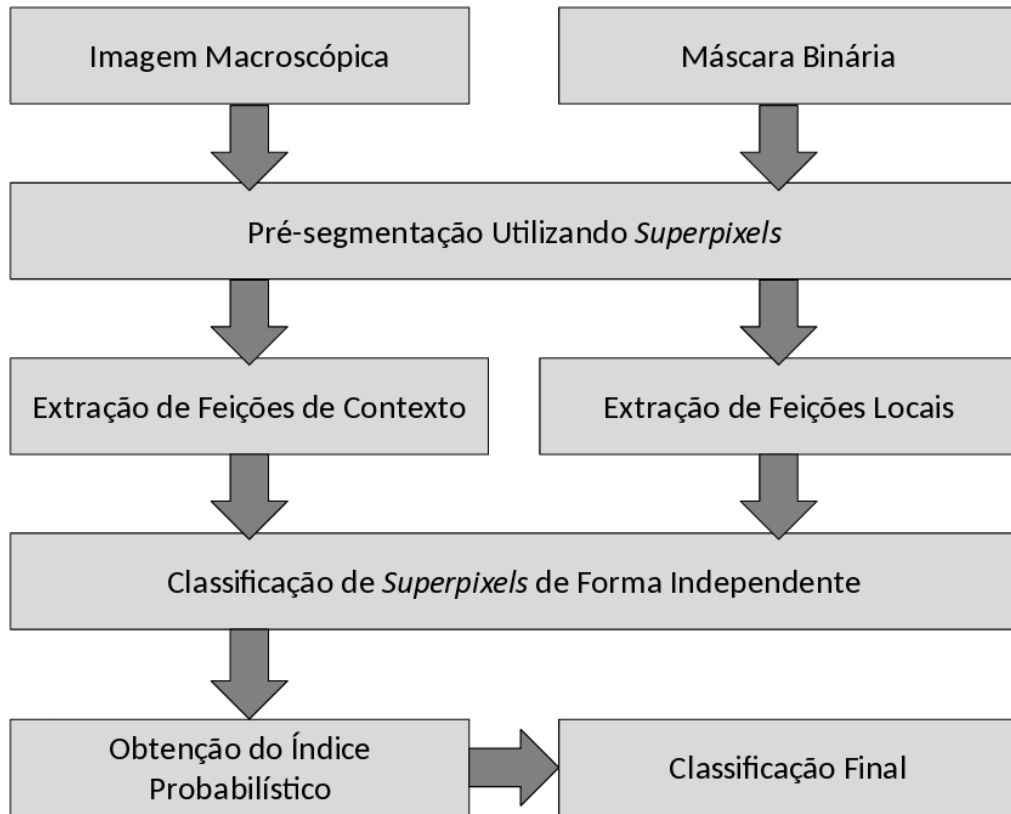
Trata-se de uma abordagem inovadora por analisar uma lesão inicialmente de forma local, através da representação de sub-regiões extraídas da área segmentada por evidências que descrevem cor e textura, e posteriormente combina estas representações com evidências de contexto referentes à região de onde foram extraídas (e. g. dados de contorno, estrutura e borda). Cada uma destas sub-regiões da lesão é classificada de forma independente através de uma abordagem supervisionada, permitindo a obtenção de um indicador probabilístico de malignidade e benignidade para cada lesão melanocítica, que leva em consideração o tamanho das áreas identificadas como benignas ou malignas.

Como etapa inicial, é necessário separar a região de pele saudável da lesão melanocítica fazendo uso de métodos de segmentação existentes na literatura. O presente trabalho faz uso da abordagem proposta no Capítulo 3, uma vez que apresenta resultados comparáveis aos métodos de maior complexidade e cujas máscaras binárias preservam informações referentes às bordas tidas como suspeitas.

As demais etapas do método proposto são detalhadas nas próximas seções da seguinte forma: na Seção 4.1 e 4.2 são descritos procedimentos para obtenção e representação de evidências locais e de contexto; na Seção 4.3 é descrita a etapa de classificação; a Seção 4.4 aborda o cálculo referente ao índice de probabilidade atribuído à cada lesão; e por fim na Seção 4.5 são apresentados os resultados da abordagem proposta, bem como uma comparação com outros métodos presentes na literatura e com a utilização das máscaras definidas por dermatologistas, buscando avaliar a potencialidade do método proposto e o impacto do erro de segmentação no momento da classificação.

Na Figura 4.1, é possível observar o fluxo do processo de classificação que tem como entrada a imagem macroscópica de uma lesão melanocítica e a máscara binária delimitando a área afetada pelo tumor, como saída o método proposto apresenta a qualificação da lesão como maligna ou benigna.

Figura 4.1: Fluxograma ilustrando o processo de classificação, tendo como entrada uma imagem macroscópica e a máscara binária que delimita a região de lesão, como saída a resposta indicando se a lesão foi qualificada como maligna ou benigna.



Fonte: o autor.

#### 4.1 Obtenção e Representação de Evidências Locais Utilizando *Superpixels*


O conceito de evidências locais está relacionado à representação da imagem macroscópica de uma lesão melanocítica através de agrupamentos de regiões semelhantes. Uma das maneiras de obter estas regiões é fazendo o uso de um algoritmo de *superpixels* (ACHANTA et al., 2012), onde é informada a imagem original  $I$  e o número máximo de sub-regiões  $\tau$ , obtendo conjunto definido por:

$$S(I, \tau) = \{s_0, \dots, s_n\}, \quad (4.1)$$

onde  $n \leq \tau$ , devido às características do método utilizado para realizar a decomposição. Na Figura 4.2 é possível observar o resultado da segmentação utilizando o algoritmo de *superpixels*

SLIC.

Figura 4.2: Resultado da etapa de pré-processamento utilizando um algoritmo de *superpixels*



Fonte: o autor.

Uma vez que a imagem é representada por suas sub-regiões é necessário selecionar aquelas que estão presentes dentro da área de lesão, delimitada pela máscara  $M$  obtida durante a etapa de segmentação. Sendo assim, as regiões de lesão são obtidas da seguinte forma:

$$\hat{S}(S, M) = S \cap M, \quad (4.2)$$

onde  $\hat{S}$  contém as sub-regiões que apresentam intersecção com a área de lesão. Nos casos onde uma sub-região  $s_i$  fica dividida entre a área de pele e lesão, a classe atribuída para  $\hat{s}_i$  é definida levando em consideração a classe na qual a maior quantidade de *pixels* está associada.


Esta abordagem permite preservar as bordas originais da lesão, uma vez que explora a capacidade que os *superpixels* possuem de representar regiões com grande relação entre seus *pixels*. Os resultados da etapa de seleção das sub-regiões pode ser visualizado na Figura 4.3.

Buscando descrever cada uma das sub-regiões de lesão  $\hat{S}$ , cada subconjunto de *pixels* presentes em  $s_i$  é representado por:

$$\psi(\hat{s}_i) = \{L(\hat{s}_i), a(\hat{s}_i), b(\hat{s}_i), \hat{I}_1(\hat{s}_i), \hat{I}_2(\hat{s}_i), \hat{I}_3(\hat{s}_i)\}, \quad (4.3)$$

sendo que  $\{L, a, b\}$  são os valores correspondes para a imagem original no espaço de cores CIE  $L^*a^*b^*$  e  $\{\hat{I}_1, \hat{I}_2, \hat{I}_3\}$  representações de variabilidade textural, tonalidade da pele e coloração, propostas em CAVALCANTI; SCHARCANSKI (2011) e que visam descrever características


Figura 4.3: A primeira imagem representa a máscara obtida durante a etapa de segmentação, a segunda imagem a máscara obtida pela intersecção entre as sub-regiões que se encontram na área segmentada, e a terceira imagem mostra as sub-regiões obtidas pela segmentação.



Fonte: o autor.

específicas para imagens de lesões melanocíticas. Na Figura 4.4 é possível visualizar estas representações para uma dada região de lesão.

Figura 4.4: Na primeira linha são representados os canais  $L^*$ ,  $a^*$  e  $b^*$ , nesta ordem. Já na segunda linha os canais de variação textural  $\hat{I}_1$ , tonalidade da pele  $\hat{I}_2$  e representação da coloração  $\hat{I}_3$ .



Fonte: o autor.

As representações definidas por  $\psi$  podem apresentar diferentes quantidades de elementos devido aos tamanhos variados das sub-regiões  $\hat{s}_i$ , e além disso, armazenam evidências locais para caracterizar fragmentos da lesão. Devido a isso é necessário uniformizar o número de valores de forma que o máximo de informações seja preservada. Duas abordagens podem ser utilizadas: o cálculo de descritores para a distribuição ou então histogramas de frequência.

Ao optar pelo cálculo de descritores da distribuição de valores, as evidências são computadas para todas as diferentes representações com base nas medidas de média, mediana, valor mínimo e máximo presentes em cada uma das sub-regiões. A vantagem oferecida por esse tipo de abordagem é a compactação de grandes conjuntos de valores com poucos descritores:

$$E_{local}(\psi, \hat{s}_i) = \{\text{média}(\psi(\hat{s}_i)), \text{mediana}(\psi(\hat{s}_i)), \min(\psi(\hat{s}_i)), \max(\psi(\hat{s}_i))\}. \quad (4.4)$$

Já com a utilização de histogramas, um número de células ou *bins*  $\beta$  é definido para determinar o tamanho do intervalo usado para calcular a frequência de ocorrência dos valores para cada uma das representações. Um maior valor atribuído a  $\beta$  está associado a evidências locais de maior dimensionalidade. A representação de evidências por histogramas permite descrever de forma detalhada a ocorrência de valores em uma dada sub-região, entretanto, dependendo do valor utilizado como parâmetro pode ocasionar no uso de maior custo computacional:

$$E_{local}(\psi, \hat{s}_i, \beta) = \{\text{histograma}(\psi(\hat{s}_i, \beta))\}. \quad (4.5)$$

Ambas as representações são avaliadas posteriormente na Seção 4.5, bem como seu impacto nos resultados da classificação final.

Ao término desta etapa, a matriz de evidências locais  $E_{local}$  possui número de linhas definido pelo total de regiões contidas em  $\hat{S}$ , e número de colunas dado em função da quantidade de descritores calculados para a distribuição de valores das sub-regiões, ou o número de intervalos utilizado no cálculo dos histogramas de frequência, multiplicado pela quantidade de representações em  $\psi$ , neste caso seis.

## 4.2 Extração de Evidências de Contexto

Além das evidências locais obtidas por meio da análise de sub-regiões da lesão, outros tipos de indicadores também podem ser utilizados como forma de caracterizar lesões melanocíticas benignas e malignas. Neste trabalho, como forma complementar a descrição das lesões são utilizadas evidências de contexto que correspondem a características da lesão relacionadas à assimetria e irregularidades na região de borda da lesão como um todo.

Para avaliar aspectos relacionados à assimetria da área de lesão, são computadas as seguintes

medidas descritas na literatura em CELEBI et al. (2007), ALCÓN et al. (2009) e CAVALCANTI; SCHARCANSKI (2011):

- $f_1$  - Solidez: proporção entre a área da lesão ( $A$ ) e sua envoltória convexa;
- $f_2$  - Extensão: proporção entre a área da lesão ( $A$ ) e sua caixa envoltória;
- $f_3$  - Diâmetro equivalente:  $(4 \times A)/(L_1 \times \pi)$ , onde  $L_1$  representa o maior eixo da lesão, alinhado com o diâmetro mais longo, passando pelo seu centro;
- $f_4$  - Circularidade:  $(4 \times \pi \times A)/(L_1 \times p)$ , onde  $p$  representa o perímetro;
- $f_5$  - Proporção entre os eixos principais ( $L_2/L_1$ ), onde o eixo  $L_2$  é ortogonal ao eixo  $L_1$  e também passa pelo centro da área da lesão;
- $f_6$  - Proporção entre os lados da caixa envoltória da lesão;
- $f_7$  - Proporção entre o perímetro ( $p$ ) da lesão e sua área ( $A$ );
- $f_8$  -  $(B_1 - B_2)/A$ , onde  $B_1$  e  $B_2$  são as áreas em cada um dos lados do eixo  $L_1$ ;
- $f_9$  -  $(B_1 - B_2)/A$ , onde  $B_1$  e  $B_2$  são as áreas em cada um dos lados do eixo  $L_2$ ;
- $f_{10}$  -  $B_1/B_2$ , onde  $B_1$  e  $B_2$  em relação ao eixo  $L_1$ ;
- $f_{11}$  -  $B_1/B_2$ , onde  $B_1$  e  $B_2$  em relação ao eixo  $L_2$ ;

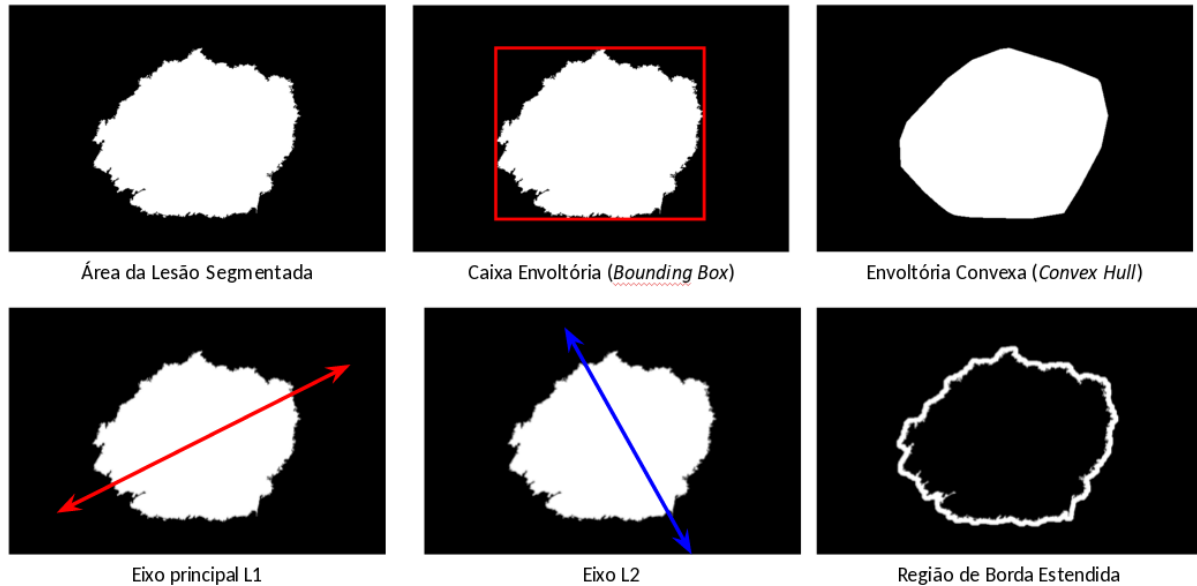
Seguindo a abordagem proposta por CAVALCANTI; SCHARCANSKI (2011), as irregularidades na região de borda são quantificadas pela magnitude do gradiente em cada pixel utilizando o operador de Sobel, analisando uma região estendida da borda obtida com a aplicação de uma operação de dilatação de 2 *pixels*. Esta abordagem torna as informações de borda mais robustas a possíveis erros de segmentação. As informações computadas para caracterizar as irregularidades nas regiões de borda foram:

- $f_{12} - f_{14}$  - média do gradiente dos *pixels* na região estendida de borda, em cada uma das representações  $\{\hat{I}_1, \hat{I}_2, \hat{I}_3\}$ ;
- $f_{15} - f_{17}$  - variância do gradiente dos *pixels* na região estendida de borda, em cada uma das representações  $\{\hat{I}_1, \hat{I}_2, \hat{I}_3\}$ ;



Na Figura 4.5, é possível verificar uma representação gráfica de cada uma das feições que diz respeito a informações das evidências de contexto computadas para a área segmentada da lesão.

Figura 4.5: Representação gráfica das evidências de contexto computadas para a área da lesão.



Fonte: o autor.

Estas propriedades extraídas da lesão de forma contextual compõem o conjunto de evidências de contexto  $E_{contexto}$ :

$$E_{contexto} = \{f_1, \dots, f_{17}\} \quad (4.6)$$

Como o número de contextos é igual ao número de imagens de lesões melanocíticas e inferior ao número total de *superpixels*,  $E_{contexto}$  é re-amostrado utilizando um método conhecido como *Smoothed Bootstrap Resampling* (YOUNG, 1990) com  $\sigma = 0.65$ . Esta técnica permite que o número de contextos seja ampliado eliminando a possibilidade da existência de dois contextos idênticos no conjunto de dados. Desta forma cada sub-região  $\hat{s}_i$  está associada a valores únicos de contexto referentes a lesão de foram extraídos.

A matriz de evidências de contexto  $E_{contexto}$  possui um número de linhas definido pela quantidade de sub-regiões presentes em uma imagem de lesão, e o número de colunas igual ao número de feições computadas.

### 4.3 Classificação de Evidências Locais e de Contexto de Forma Independente

Para a realização da etapa de classificação das informações de evidência, os dados de cada sub-região referentes às evidências locais e de contexto são combinados, formando uma representação que descreve os atributos de cor e textura, além de informações referentes ao seu contexto de origem. Cada sub-região  $\hat{s}_i$  é descrita pelo seguinte vetor de evidências:

$$E(\hat{s}_i) = \{E_{local}(\hat{s}_i), E_{contexto}(\hat{s}_i)\}. \quad (4.7)$$

Um conjunto de evidências é selecionado de forma aleatória usando validação cruzada 10  *folds* para determinar as amostras utilizadas como treinamento, levando em consideração que as sub-regiões são totalmente independentes. Cada amostra usada no treinamento está associada a um valor  $y$  que a identifica como oriunda de uma lesão benigna ( $y = 0$ ) ou maligna ( $y = 1$ ).

O conjunto escolhido como teste para cada *fold* é classificado fazendo uso de um método de classificação. Três classificadores foram avaliados devido suas diferentes propriedades:

- SVM (*Support Vector Machine*) (CORTES; VAPNIK, 1995), utilizando uma função de base radial, cujos parâmetros de escala ( $\gamma$ ) e margem ( $C$ ) foram estimados através de validação cruzada. Adicionalmente as probabilidades para ocorrência de cada uma das classes foi definida como 50%;
- KNN (K-vizinhos mais próximos) (COVER; HART, 1967), utilizando os 5 vizinhos mais próximos e distância Euclidiana;
- Adaboost (FREUND; SCHAPIRE, 1997), utilizando 100 ciclos de aprendizagem e classificadores-base do tipo Análise Discriminante Linear (*Linear Discriminant Analysis*).

Os resultados da classificação de forma independente para cada sub-região podem ser verificados na Seção 4.5, bem como uma discussão sobre os resultados obtidos.

### 4.4 Obtenção de Indicador Probabilístico para Malignidade e Benignidade

Uma vez que todas as sub-regiões foram classificadas, é possível então atribuir um indicador probabilístico para malignidade na lesão melanocítica analisada. Este indicador tem como base as áreas classificadas em cada uma das classes, e pode ser descrito da seguinte forma:

$$\mathcal{I}_{malignidade} = \frac{\text{número de } pixels \text{ em áreas classificadas como malignas}}{\text{número de } pixels \text{ contidos no total de } superpixels \text{ da lesão}}. \quad (4.8)$$

De forma semelhante um índice para benignidade também pode ser estimado,

$$\mathcal{I}_{benignidade} = \frac{\text{número de } pixels \text{ em áreas classificadas como benignas}}{\text{número de } pixels \text{ contidos no total de } superpixels \text{ da lesão}}. \quad (4.9)$$

Fazendo uso destes indicadores que levam em consideração tanto evidências locais quanto de contexto, para atribuir a qual classe a lesão melanocítica pertence é assumido que lesões que apresentam indicadores de malignidade superiores a um valor de tolerância  $\varepsilon$  são consideradas malignas. Durante os experimentos o valor de  $\varepsilon$  foi definido como 50%.

Na 4.6 é possível visualizar os resultados da classificação independente de cada sub-região da lesão melanocítica.

#### 4.5 Resultados Experimentais e Discussões

O mesmo conjunto de imagens macroscópicas utilizado para avaliar o método de segmentação proposto na Seção 3.4 (ALCÓN et al., 2009) foi utilizado durante a etapa de classificação, contendo 45 lesões melanocíticas benignas e 107 malignas, totalizando 152 imagens.


A extração de sub-regiões da imagem foi realizada utilizando o algoritmo de segmentação em *superpixels* SLIC (ACHANTA et al., 2012), com número máximo de regiões  $\tau = 300$  e o parâmetro referente a compactação de cada *superpixel* seguiu o valor recomendado pelos autores de  $m = 20$ .

As máscaras obtidas pelo método proposto (BERNART et al., 2015) descrito na Seção 3, foram utilizadas para delimitar a área de lesão e para eliminar as sub-regiões que representam pele saudável.


Após representar todas as sub-regiões da lesão utilizando a matriz de evidência  $E$ , elas são normalizadas utilizando:

$$\hat{E}_{i,j} = \frac{(E_{i,j} - \mu_j)}{\sigma_j}, \quad (4.10)$$


Figura 4.6: Imagens resultantes indicando em azul as sub-regiões classificadas como benignas e em vermelho malignas. Na primeira linha duas imagens benignas e na segunda linha duas imagens malignas.




$$\mathcal{I}_{\text{malignidade}} = 5.12\%$$



$$\mathcal{I}_{\text{malignidade}} = 40.91\%$$



$$\mathcal{I}_{\text{malignidade}} = 76.80\%$$



$$\mathcal{I}_{\text{malignidade}} = 91.18\%$$

Fonte: o autor.

onde  $\mu$  e  $\sigma$  são respectivamente a média e o desvio padrão de cada uma das feições, e então divididas entre conjunto de treinamento e teste fazendo uso de validação cruzada com 10-folds.

Para cada partição do conjunto de dados são computadas as seguintes medidas:

- TP: valor correspondente ao número de sub-regiões pertencentes a classe maligna, corretamente classificadas como maligna;
- FP: valor correspondente ao número de sub-regiões pertencentes a classe benigna, incorretamente classificadas como maligna;
- TN: valor correspondente ao número de sub-regiões pertencentes a classe benigna, corretamente classificadas como benigna;

- FN: valor correspondente ao número de sub-regiões pertencentes a classe maligna, incorretamente classificadas como benigna;

Com base nestas informações é possível computar métricas que permitem avaliar o método proposto e compará-lo com os métodos presentes na literatura. Dentre as métricas utilizadas estão a acurácia, que permite identificar a proporção de acertos em relação ao tamanho total de amostras de teste, definida como:

$$\text{acurácia} = \frac{TP + TN}{TP + FP + TN + FN}, \quad (4.11)$$

Outra medida utilizada é a de sensibilidade, definida por:

$$\text{sensibilidade} = \frac{TP}{TP + FN}, \quad (4.12)$$

e métrica de especificidade já introduzida na Seção 3.4.


O resultado final do método proposto é composto por duas etapas, a primeira delas é a classificação de forma independente de cada uma das sub-regiões das imagens de lesão, e a segunda é a utilização do valor de tolerância  $\epsilon$  para definir a classe atribuída à lesão levando em consideração o índice de probabilidade de malignidade  $\mathcal{I}_{\text{malignidade}}$ .

Nas próximas seções são apresentados os resultados dos experimentos realizados utilizando diferentes classificadores e um comparativo entre a classificação de sub-regiões utilizando apenas evidências de contexto, apenas evidências locais e a combinação de ambas. Também é analisado o impacto da representação destas regiões através de descritores da distribuição de valores e do cálculo de histogramas de frequência com diferentes faixas de valores.

#### 4.5.1 Evidências de Contexto

Com o objetivo de comparação, foram realizados experimentos utilizando somente evidências de contexto para classificar as sub-regiões da lesão. Para isso, como mencionado anteriormente, uma vez que o número de contextos é muito menor que o número de sub-regiões, o conjunto foi re-amostrado utilizando *Smoothed Bootstrap Resampling* (YOUNG, 1990), e as novas amostras foram classificadas utilizando três classificadores diferentes, cujos resultados encontram-se apresentados na Figura 4.7.

Figura 4.7: Resultados da classificação das sub-regiões da lesão utilizando apenas evidências de contexto fazendo uso de diferentes classificadores



Fonte: o autor.

Um comparativo detalhado entre SVM e KNN para a classificação independente de cada sub-região pode ser observado na Tabela 4.1. A utilização do classificador KNN apresentou melhores resultados na média para validação cruzada com *10-folds*, com acurácia de 88,10% e especificidade de 80,27%.

Como o objetivo final é a definição da classe que caracteriza a lesão, fazendo uso do indicador  $\mathcal{I}_{malignidade}$  obtido e definindo o valor de tolerância  $\varepsilon = 50\%$ , somente utilizando as evidências de contexto foi possível obter uma acurácia de 95,39% utilizando SVM e 96,71% fazendo uso do classificador KNN, valores que se comparam a métodos apresentados na literatura que fazem uso desta categoria de feições (CAVALCANTI; SCHARCANSKI, 2011). Outros resultados podem ser observados na Tabela 4.2.

Tabela 4.1: Comparativo entre SVM e KNN na classificação das sub-regiões utilizando evidências de contexto para *10-folds*.

	Acurácia		Sensitividade		Especificidade	
	SVM	KNN	SVM	KNN	SVM	KNN
Mínimo	84.93%	86.30%	92.81%	88.73%	68.20%	73.66%
Mediana	87.90%	88.19%	94.81%	91.15%	74.61%	80.28%
Média	87.90%	88.10%	94.65%	91.01%	74.35%	80.27%
Máximo	90.26%	89.65%	96.39%	93.33%	78.14%	85.39%

Fonte: o autor.

Uma das vantagens proporcionadas pelo método proposto é que mesmo que a acurácia na

Tabela 4.2: Comparativo entre os classificadores assumindo como valor de tolerância  $\varepsilon = 50\%$  para indicadores baseados em evidências de contexto.

Classificador	Acurácia	Sensitividade	Especificidade
SVM	95.39%	98.08%	89.58%
KNN	96.71%	97.36%	97.62%
Adaboost	78.95%	78.63%	80.95%

Fonte: o autor.

classificação das sub-regiões seja baixa, ao utilizar o índice de malignidade é possível obter valores que se aproximam ao diagnóstico concedido pelo especialista.

#### 4.5.2 Evidências Locais

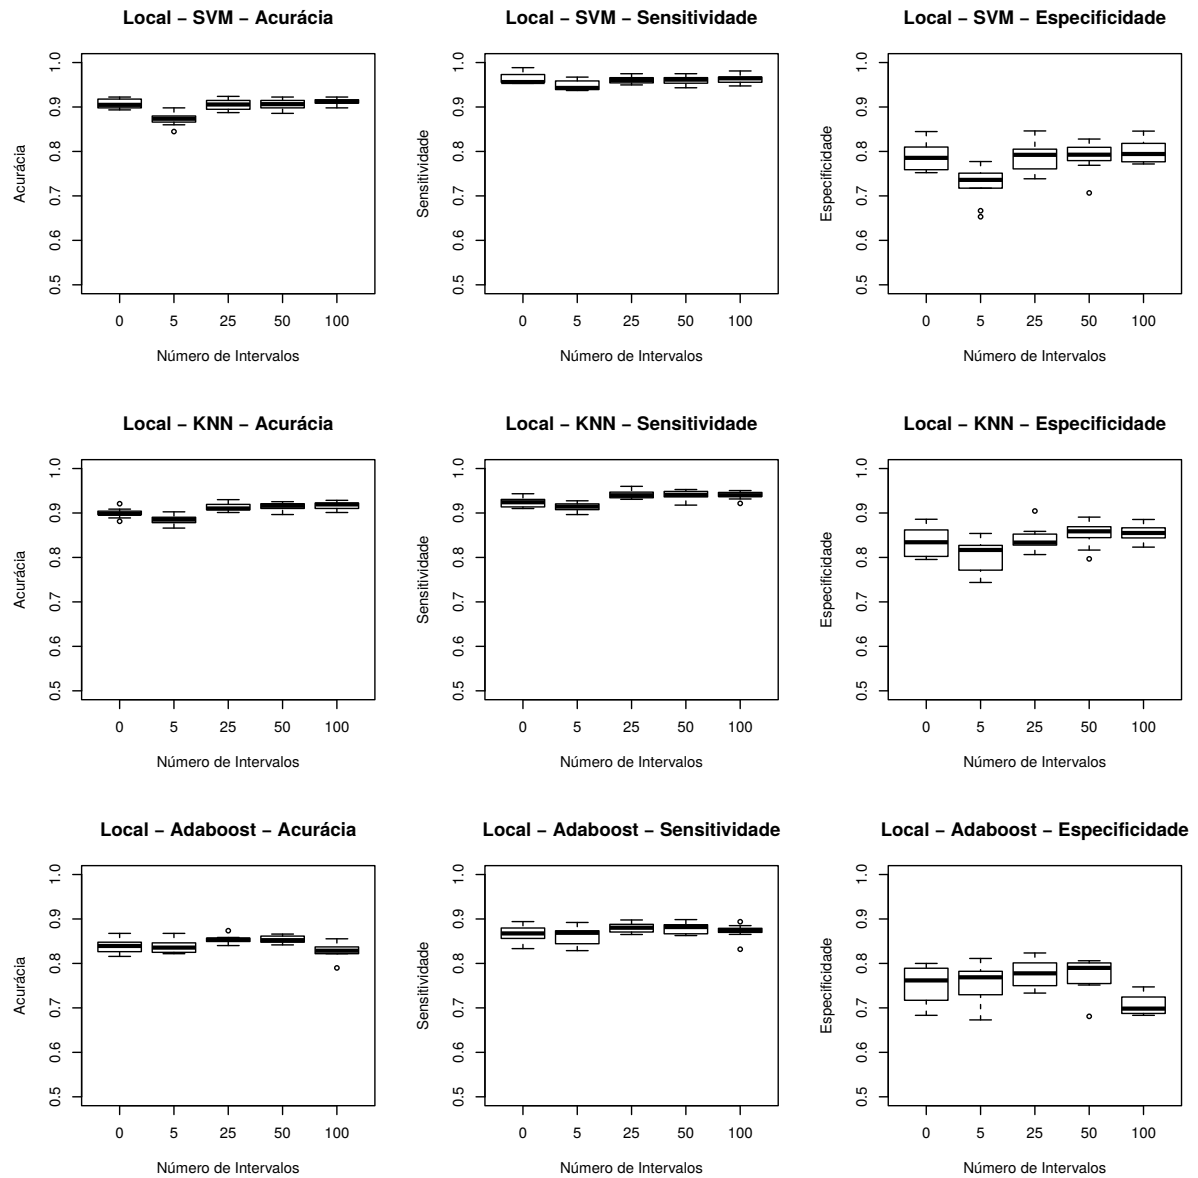
Outro conjunto de experimentos foi realizado visando avaliar o poder discriminativo das evidências locais, uma vez que descrevem diferentes propriedades da lesão melanocítica sem nenhum tipo de associação com informações relacionadas à região de onde foram extraídas.

Na Figura 4.8 é possível verificar um comparativo entre os resultados gerados por três diferentes classificadores, bem como o impacto que a dimensionalidade da representação de cada sub-região tem na classificação. São apresentados os resultados para a utilização de  $\beta = \{5, 25, 50, 100\}$ , e nos casos onde  $\beta = 0$  é o equivalente a utilização dos descritores da distribuição (valor médio, mediana, mínimo e máximo). Na Tabela 4.3 é possível visualizar os resultados com maiores detalhes.

Com base nos experimentos é possível observar que uma representação simples composta apenas por informações como média, mediana, valores mínimo e máximo é em alguns casos capaz de discriminar as sub-regiões de maneira semelhante a utilização de histogramas com 25 faixas de valor, porém com uma dimensionalidade muito menor. Os melhores resultados de classificação de sub-regiões de forma independente apenas com evidências locais foi apresentado pelo classificador KNN, fazendo uso de uma representação de histogramas com 100 faixas de valor, resultando em acurácia média para 10-*folds* de 91,66%.

Analisando o resultado da classificação final utilizando o índice de malignidade  $\mathcal{I}_{malignidade}$ , é possível verificar na Tabela 4.4 que todos os classificadores foram capazes de acertar mais de 90% dos casos com ao menos um tipo de representação. Sendo que o melhor resultado

Figura 4.8: Resultados da classificação das sub-regiões da lesão utilizando apenas evidências locais, para diferentes valores de intervalo e fazendo uso de diferentes classificadores.



Fonte: o autor.

obtido fez uso do classificador KNN e com a representação mais simples ( $\beta = 0$ ), resultando em 94.74% de acurácia, valor inferior aos resultados apresentados pelas evidências de contexto.

#### 4.5.3 Evidências Locais e de Contexto

Por fim, como o método proposto busca combinar as evidências que apresentam características locais com aquelas obtidas no contexto de onde as sub-regiões foram extraídas, são



Tabela 4.3: Comparativo dos resultados da classificação das sub-regiões da lesão utilizando apenas evidências locais, para diferentes valores de  $\beta$  e diferentes classificadores.

	SVM					KNN					Adaboost				
	$\beta$					$\beta$					$\beta$				
Acurácia	0	5	25	50	100	0	5	25	50	100	0	5	25	50	100
Mínimo	89.35%	84.48%	88.74%	88.57%	89.80%	88.13%	86.61%	90.11%	89.65%	90.11%	81.58%	82.19%	84.02%	84.17%	79.00%
Mediana	90.48%	87.36%	90.56%	90.64%	91.17%	89.80%	88.51%	91.01%	91.62%	91.93%	83.93%	83.56%	85.38%	85.24%	82.86%
Média	90.70%	87.26%	90.56%	90.47%	91.09%	89.95%	88.42%	91.28%	91.52%	91.66%	83.80%	83.74%	85.37%	85.36%	82.78%
Máximo	92.24%	89.90%	92.39%	92.24%	92.24%	92.08%	90.26%	93.00%	92.54%	92.85%	86.76%	86.76%	87.37%	86.61%	85.54%
Sensitividade	0	5	25	50	100	0	5	25	50	100	0	5	25	50	100
Mínimo	95.31%	93.71%	94.97%	94.32%	94.74%	79.54%	89.64%	93.07%	91.77%	92.16%	83.33%	82.88%	86.51%	86.27%	83.19%
Mediana	95.61%	94.29%	96.05%	96.15%	96.45%	92.41%	91.43%	93.99%	94.08%	94.00%	86.75%	86.89%	88.03%	88.18%	87.40%
Média	96.35%	94.84%	96.05%	95.96%	96.32%	92.37%	91.36%	94.13%	93.99%	93.98%	86.61%	86.30%	88.00%	88.01%	87.22%
Máximo	98.85%	96.72%	97.48%	97.49%	98.10%	94.33%	92.74%	95.99%	95.28%	95.04%	89.41%	89.22%	89.78%	89.86%	89.38%
Especificidade	0	5	25	50	100	0	5	25	50	100	0	5	25	50	100
Mínimo	75.22%	65.32%	73.85%	70.67%	77.18%	79.54%	74.38%	80.65%	79.68%	82.32%	68.32%	67.30%	73.33%	68.10%	68.32%
Mediana	78.56%	73.61%	79.24%	79.27%	79.42%	83.42%	81.68%	83.35%	85.87%	85.50%	76.18%	76.88%	77.77%	79.00%	69.84%
Média	79.05%	72.68%	79.16%	78.97%	80.08%	83.44%	80.52%	84.18%	85.18%	85.62%	75.09%	75.54%	77.49%	77.34%	70.63%
Máximo	84.48%	77.33%	84.61%	82.79%	84.58%	88.59%	85.39%	90.45%	89.07%	88.54%	80.00%	81.12%	82.35%	80.61%	74.72%

Fonte: o autor.

apresentados os resultados referentes aos experimentos utilizando três classificadores diferentes e com diferentes representações para as evidências locais, cujos resultados estão apresentados na Figura 4.9 e na Tabela 4.5.

Com a combinação das evidências locais e de contexto, a acurácia média de maior valor na classificação das sub-regiões utilizando apenas informações locais que era de 94,74% passou para 96,07% (KNN,  $\beta = 0$ ), porém a diferença para o classificador SVM foi inferior a 1% (SVM,  $\beta = 0$ , acurácia média de 95.37%). Já a abordagem utilizando Adaboost, não conseguiu atingir a taxa de 90% de acerto na classificação das sub-regiões.

A análise dos resultados torna claro que o uso de um número demasiadamente grande de informações referentes as evidências locais faz com que menor importância seja atribuída para as evidências oriundas do contexto. É visível também que a representação de sub-regiões por descritores, ao invés de histogramas, mesmo mais simples permite igual ou superior distinção entre as classes analisadas.

Uma vez que as sub-regiões foram classificadas de forma independente, agora é possível estimar o índice de malignidade  $\mathcal{I}_{malignidade}$  para cada uma das lesões. Definindo o valor de tolerância  $\varepsilon = 50\%$ , a acurácia média tanto para o classificador SVM, como para o KNN (ambos com  $\beta = 0$ ) é de 99,34%, sensibilidade de 100% e especificidade de 97,83%. O classificador Adaboost ( $\beta = 100$ ), mesmo apresentando resultados inferiores na classificação das sub-regiões, apresentou 90,79% de acurácia média, sensibilidade de 90.43% e especificidade

Tabela 4.4: Comparativo entre os classificadores assumindo como valor de tolerância  $\varepsilon = 50\%$  para indicadores baseados em evidências locais.

<b>SVM</b>	<b>Acurácia</b>	<b>Sensitividade</b>	<b>Especificidade</b>
$\beta = 0$	91.45%	95.19%	83.33%
$\beta = 5$	86.84%	93.07%	74.51%
$\beta = 25$	90.79%	95.46%	84.44%
$\beta = 50$	90.79%	93.46%	84.44%
$\beta = 100$	92.11%	94.39%	86.67%
<b>KNN</b>	<b>Acurácia</b>	<b>Sensitividade</b>	<b>Especificidade</b>
$\beta = 0$	94.74%	93.81%	97.44%
$\beta = 5$	93.42%	92.92%	94.87%
$\beta = 25$	94.08%	92.98%	97.37%
$\beta = 50$	94.08%	92.98%	97.37%
$\beta = 100$	94.08%	92.98%	97.37%
<b>Adaboost</b>	<b>Acurácia</b>	<b>Sensitividade</b>	<b>Especificidade</b>
$\beta = 0$	86.84%	87.18%	85.71%
$\beta = 5$	84.87%	86.84%	78.95%
$\beta = 25$	87.50%	87.93%	86.11%
$\beta = 50$	87.50%	87.93%	86.11%
$\beta = 100$	90.79%	90.43%	91.89%

Fonte: o autor.

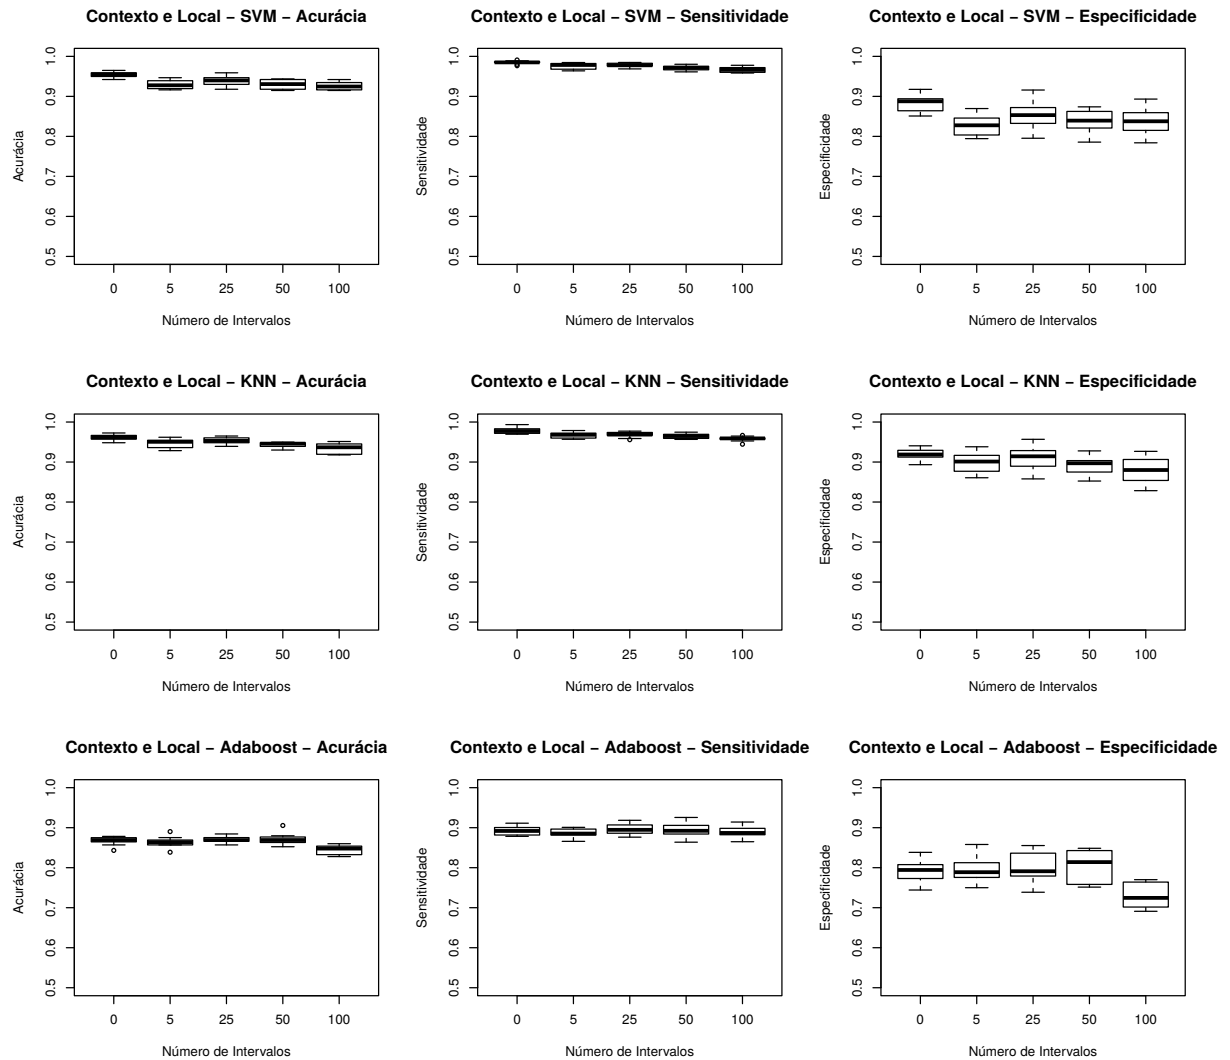
de 91,89% na atribuição de classes para as lesões. Os demais resultados encontram-se descritos na Tabela 4.6.

Dados os presentes resultados é possível comprovar que a classificação de forma independente das sub-regiões da lesão, combinando informações locais e de contexto pode oferecer altos índices de acerto na identificação de malignidade em imagens macroscópicas de lesões melanocíticas.

#### 4.5.4 Discussão

A comparação do presente método foi dividida em duas partes: a primeira delas, comparando os resultados da classificação utilizando máscaras geradas automaticamente pelo método

Figura 4.9: Resultados da classificação das sub-regiões da lesão utilizando evidências locais e de contexto, para diferentes valores de intervalo e fazendo uso de diferentes classificadores.



Fonte: o autor.

proposto no presente trabalho com as máscaras verdade terrestre (*Ground truth* - GT), delimitadas por um dermatologista e que foi disponibilizada juntamente com o conjunto de imagens utilizado, buscando avaliar o impacto do erro de segmentação no momento da classificação das lesões; a segunda comparação é realizada entre os resultados da classificação do método proposto com demais métodos da literatura que utilizam este mesmo conjunto de dados (ALCÓN et al., 2009).

No que diz respeito à primeira comparação, na Tabela 4.7 é possível verificar que em alguns casos utilizando SVM ( $\beta = \{0, 25, 100\}$ ), KNN ( $\beta = \{25, 50\}$ ) ou Adaboost ( $\beta = \{0, 5, 25, 100\}$ ) combinados com as máscaras geradas pelo método não-supervisionado é pos-

Tabela 4.5: Comparativo dos resultados da classificação das sub-regiões da lesão combinando evidências locais e de contexto, para diferentes valores de  $\beta$  e diferentes classificadores.

	SVM					KNN					Adaboost				
	$\beta$					$\beta$					$\beta$				
	0	5	25	50	100	0	5	25	50	100	0	5	25	50	100
<b>Acurácia</b>															
Mínimo	94.22%	91.63%	91.78%	91.48%	91.48%	94.83%	92.85%	93.91%	93.00%	91.78%	84.32%	83.87%	85.69%	85.24%	82.77%
Mediana	95.51%	92.77%	93.98%	93.07%	92.47%	96.12%	95.05%	95.28%	94.60%	93.68%	86.91%	86.38%	86.90%	86.91%	84.78%
Média	95.37%	92.88%	93.91%	92.97%	92.63%	96.07%	94.72%	95.25%	94.34%	93.53%	86.71%	86.41%	87.12%	87.12%	84.50%
Máximo	96.49%	94.66%	95.89%	94.37%	94.21%	97.26%	96.19%	96.50%	94.98%	95.13%	87.82%	89.02%	88.43%	90.55%	86.00%
<b>Sensitividade</b>															
Mínimo	97.67%	96.38%	96.87%	96.13%	95.84%	96.95%	95.68%	95.58%	95.66%	94.46%	87.83%	86.58%	87.63%	86.37%	86.49%
Mediana	98.49%	97.85%	97.77%	97.14%	96.62%	97.75%	96.81%	96.86%	96.50%	95.91%	89.18%	88.53%	89.46%	89.22%	88.69%
Média	98.49%	97.61%	97.83%	97.11%	96.67%	97.83%	96.66%	96.85%	96.48%	95.81%	89.27%	88.69%	89.63%	89.52%	89.03%
Máximo	99.09%	98.46%	98.48%	98.03%	97.77%	99.35%	97.87%	97.72%	97.46%	96.66%	91.12%	90.08%	91.84%	92.55%	91.41%
<b>Especificidade</b>															
Mínimo	85.10%	79.44%	79.54%	78.57%	78.39%	89.34%	86.07%	85.79%	85.25%	82.84%	74.42%	75.00%	73.86%	75.14%	69.10%
Mediana	88.77%	82.77%	85.31%	83.94%	83.77%	91.88%	90.12%	91.43%	89.70%	88.00%	79.43%	78.88%	79.11%	81.39%	72.45%
Média	88.40%	82.93%	85.34%	83.84%	83.67%	91.82%	89.92%	91.26%	89.02%	87.91%	79.34%	79.55%	79.94%	80.18%	72.84%
Máximo	91.75%	86.96%	91.58%	87.38%	89.32%	94.05%	93.81%	95.68%	92.78%	92.67%	83.83%	85.80%	85.54%	84.85%	77.01%

Fonte: o autor.

sível alcançar uma acurácia maior do que com a delimitação realizada por um especialista. Entretanto, em alguns casos utilizando o classificador KNN ( $\beta = \{0,5\}$ ) combinado com a segmentação verdade terrestre seria possível atingir 100% de acurácia na classificação final.

O que significa que o erro gerado na segmentação impede que o método proposto atinja um índice de acerto máximo. Entretanto, a proximidade dos resultados utilizando a máscara gerada automaticamente e a combinação de evidências locais e de contexto (99,34% de acurácia média) para com os resultados fazendo uso da segmentação manual (100% de acurácia média), exemplifica o potencial da abordagem proposta para classificação de lesões melanocíticas.

Quando comparado com os demais métodos de classificação presentes na literatura, é possível perceber que a abordagem fazendo uso de evidências locais e de contexto combinada com as máscaras geradas de forma automatizada é capaz de apresentar resultados que superam o estado da arte, como é possível verificar na Tabela 4.8.

Realizando uma avaliação no que diz respeito ao impacto do valor de tolerância  $\epsilon$  combinado com o índice de malignidade na obtenção dos resultados finais da qualificação, a Figura 4.10 apresenta os valores de acurácia, sensibilidade e especificidade para diferentes casos, com variações de 0 até 100 para  $\epsilon$ , utilizando feições locais e de contexto ( $\beta = 0$  e classificador KNN). Os melhores resultados foram obtidos com valores entre  $\epsilon = 42\%$  e  $\epsilon = 66\%$ , isso se dá devido a região dominante na imagem descrever de forma mais precisa a classe que de fato a

Tabela 4.6: Comparativo entre os classificadores assumindo como valor de tolerância  $\varepsilon = 50\%$  para indicadores baseados em evidências locais.

<b>SVM</b>	<b>Acurácia</b>	<b>Sensitividade</b>	<b>Especificidade</b>
$\beta = 0$	99.34%	100.00%	97.83%
$\beta = 5$	96.05%	99.03%	89.80%
$\beta = 25$	96.71%	98.11%	93.48%
$\beta = 50$	92.76%	95.28%	86.96%
$\beta = 100$	92.76%	94.44%	88.64%
<b>KNN</b>	<b>Acurácia</b>	<b>Sensitividade</b>	<b>Especificidade</b>
$\beta = 0$	99.34%	100.00%	97.83%
$\beta = 5$	99.34%	99.07%	100.00%
$\beta = 25$	98.03%	97.27%	100.00%
$\beta = 50$	96.71%	96.36%	97.62%
$\beta = 100$	95.39%	94.64%	97.50%
<b>Adaboost</b>	<b>Acurácia</b>	<b>Sensitividade</b>	<b>Especificidade</b>
$\beta = 0$	88.82%	89.47%	86.84%
$\beta = 5$	88.82%	89.47%	86.84%
$\beta = 25$	88.82%	89.47%	86.84%
$\beta = 50$	88.82%	89.47%	86.84%
$\beta = 100$	90.79%	90.43%	91.89%

Fonte: o autor.

lesão melanocítica pertence.

Valores de tolerância inferiores a 50% assumem que se apenas algumas partes da lesão forem identificadas como maligna, toda ela deverá ser qualificada como maligna, enquanto valores mais próximos a 100% assumem que todos os *pixels* da imagem devem ser qualificados como malignos para que a lesão seja classificada como maligna, fato que nem sempre é verdadeiro, uma vez que em algumas partes da lesão ainda podem ser encontradas regiões de pele saudável. O valor de tolerância utilizado nos experimentos de 50% é justificado por permitir que a classe que teve mais *pixels* identificados na lesão seja tida como dominante.

A abordagem proposta, diferentemente de outros métodos existentes na literatura, se destaca por utilizar a segmentação da área de lesão utilizando *superpixels* ao invés de blocos retangulares e por realizar a classificação de forma independente de sub-regiões da lesão de pele. Além

Tabela 4.7: Comparativo dos resultados da classificação das lesões utilizando a máscara proposta por este trabalho e a máscara delimitada pelo dermatologista.

<b>SVM</b>	Acurácia (%)		Sensitividade (%)		Especificidade (%)	
	<b>Proposta</b>	<b>GT</b>	<b>Proposta</b>	<b>GT</b>	<b>Proposta</b>	<b>GT</b>
$\beta = 0$	99.34	97.37	100.00	100.00	97.83	91.84
$\beta = 5$	96.05	96.05	99.03	100.00	89.80	88.24
$\beta = 25$	96.71	92.76	98.11	97.06	93.48	84.00
$\beta = 50$	92.76	94.74	95.28	96.26	86.96	91.11
$\beta = 100$	92.76	92.11	94.44	94.39	88.64	86.67
<b>KNN</b>	Acurácia (%)		Sensitividade (%)		Especificidade (%)	
	<b>Proposta</b>	<b>GT</b>	<b>Proposta</b>	<b>GT</b>	<b>Proposta</b>	<b>GT</b>
$\beta = 0$	99.34	100.00	100.00	100.00	97.83	100.00
$\beta = 5$	99.34	100.00	99.07	100.00	100.00	100.00
$\beta = 25$	98.03	97.37	97.27	96.40	100.00	100.00
$\beta = 50$	96.71	96.05	96.36	94.69	97.62	100.00
$\beta = 100$	95.39	96.05	94.64	94.69	97.50	100.00
<b>Adaboost</b>	Acurácia (%)		Sensitividade (%)		Especificidade (%)	
	<b>Proposta</b>	<b>GT</b>	<b>Proposta</b>	<b>GT</b>	<b>Proposta</b>	<b>GT</b>
$\beta = 0$	88.82	86.84	89.47	88.50	86.84	82.05
$\beta = 5$	88.82	86.18	89.47	87.72	86.84	81.58
$\beta = 25$	88.82	86.84	89.47	87.83	86.84	83.78
$\beta = 50$	88.82	89.47	89.47	88.89	86.84	91.43
$\beta = 100$	90.79	90.13	90.43	90.35	91.89	89.47

Fonte: o autor.

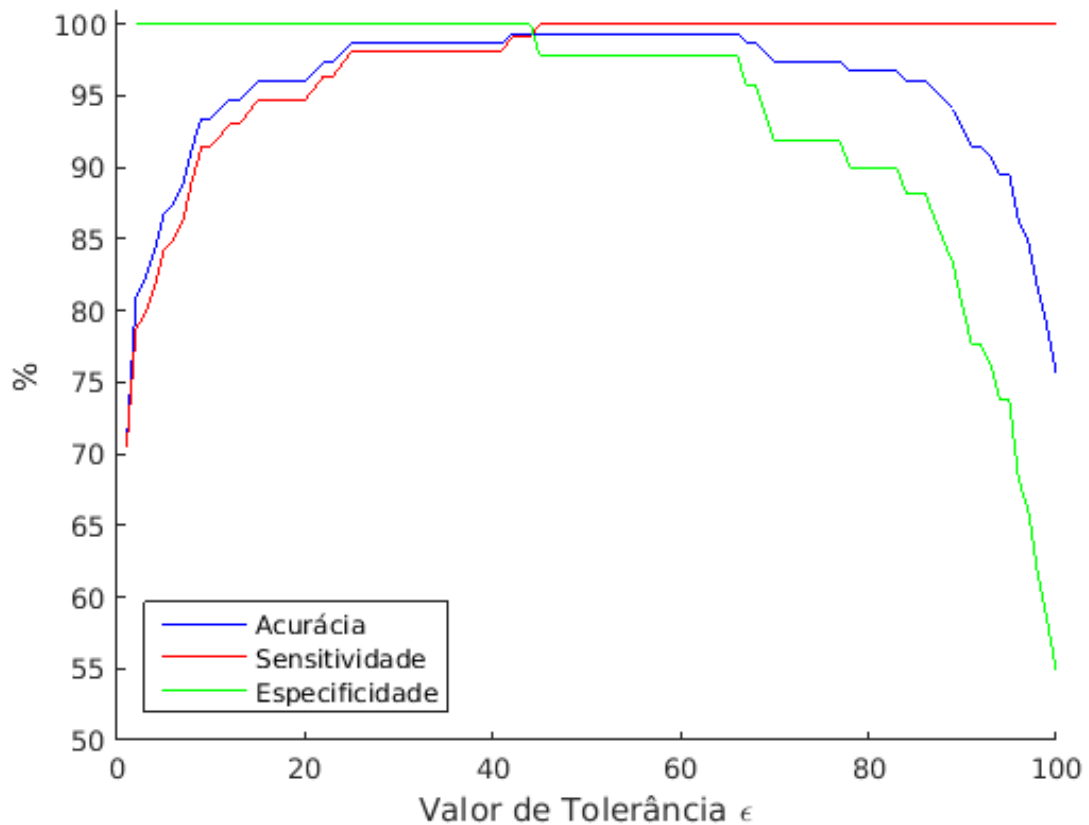
disso, utiliza os resultados da classificação independente na obtenção de um índice probabilístico que leva em consideração o tamanho da área identificada como maligna ou benigna em relação ao tamanho da lesão.

Tabela 4.8: Comparativo entre as taxas de classificação resultantes do método proposto e de outras abordagens presentes na literatura.

Método	(%)		
	Acurácia	Sensitividade	Especificidade
<i>Correlation-based feature selector</i> com LMT (ALCÓN et al., 2009)	94.39	68.89	86.84
KNN com árvores de decisão (CAVALCANTI; SCHARCANSKI, 2011)	96.26	97.78	96.71
Método proposto ( $\beta = 0$ , KNN)	99.34	100.00	97.83

Fonte: o autor.

Figura 4.10: Gráfico demonstrando o impacto do valor de tolerância na classificação final.



Fonte: o autor.

## 5 CONCLUSÃO

Neste trabalho, um novo método não-supervisionado para segmentação de lesões melanocíticas em imagens macroscópicas é proposto levando em consideração regiões suspeitas, e também uma nova abordagem para classificação de lesões que faz uso de evidências locais e de contexto para estimar um índice de probabilidade para malignidade em cada lesão.

O novo método adaptativo não-supervisionado proposto realiza a segmentação de imagens macroscópicas de lesões melanocíticas em três tipos de regiões disjuntas: ‘pele saudável’, ‘região de incerteza’ e ‘lesão de pele’. As ‘regiões de incerteza’ são refinadas através da utilização de feições estocásticas também de forma não-supervisionada, resultando em uma máscara binária que discrimina a pele da lesão. As máscaras obtidas apresentam um erro XOR comparável aos métodos estado da arte.

A imagem é segmentada utilizando um algoritmo de *superpixels* e as sub-regiões que intersectam a máscara obtida pelo método proposto são categorizadas como evidências locais. Estas evidências são representadas por uma descrição especializada que explora as características locais presentes em lesões de pele, como cor e textura.

Estas sub-regiões são então associadas à evidências de contexto definidas pela borda da lesão onde foram extraídas (i.e. diâmetro, assimetria, proporções, entre outros) e classificadas de forma independente através de uma abordagem supervisionada.

Com o resultado da classificação independente destas evidências é possível obter um indicador probabilístico para malignidade ou benignidade associado a cada lesão como um todo, e levando em consideração um valor de tolerância é possível identificar possíveis lesões malignas, sendo que a abordagem proposta apresenta maior acurácia que outros métodos presentes na literatura.

Como forma de avaliar o potencial da solução proposta para representação e classificação de lesões melanocíticas utilizando evidências locais e de contexto, bem como a influência do erro de segmentação, os resultados da classificação utilizando as máscaras propostas foram comparados com o uso da segmentação realizada por dermatologistas. Os resultados obtidos com o método proposto são promissores apesar do erro da segmentação das lesões ser maior, o que tende a confirmar o potencial da etapa responsável por discriminar lesões melanocíticas benignas e malignas.



## 5.1 Trabalhos Futuros

Nas próximas etapas deste trabalho, pretende-se realizar uma expansão do método proposto para a classificação de imagens dermoscópicas, aplicando conceitos de regiões de incerteza e extração de evidências locais e de contexto, uma vez que este tipo de imagens apresenta características marcantes localmente, como detalhes na estrutura e na textura da lesão, características que podem ser exploradas quando representadas por sub-regiões e classificadas de forma independente.

Além disso, experimentos em conjuntos de dados de imagens macroscópicas de lesões melanocíticas que apresentem outros tipos de propriedades também serão conduzidos, avaliando assim o potencial de generalização das metodologias apresentadas.

## REFERÊNCIAS

- ACHANTA, R. et al.. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S.l.], v. 34, n. 11, p. 2274-2282, nov. 2012.
- AHNLIDE, I. et al.. Validity of ABCD Rule of Dermoscopy in Clinical Practice. **Acta Dermato Venereologica**, [S.l.], n. 96, p. 367-372, 2015.
- ALCÓN, J. F. et al.. Automatic imaging system with decision support for inspection of pigmented skin lesions and melanoma diagnosis. **IEEE Journal of Selected Topics in Signal Processing**, [S.l.], v. 3, n. 1, p. 14-25, 2009.
- BERNART, E. E. et al.. Unsupervised Segmentation and Categorization of Skin Lesions Using Adaptive Thresholds and Stochastic Features. **Vision Letters**, Waterloo, ON, v. 1, n. 1, out. 2015.
- CAVALCANTI, P. G. et al. An ICA-based method for the segmentation of pigmented skin lesions in macroscopic images. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 33, 2011, Boston. **Proceedings...** . New York, NY, USA: IEEE, 2011. p. 5993-5996.
- CAVALCANTI, P. G.; SCHARCANSKI, J.. Automated prescreening of pigmented skin lesions using standard cameras. **Computerized Medical Imaging and Graphics**. Oxford, U. K., p. 481-491. 2011.
- CAVALCANTI, P. G.; SCHARCANSKI, J.. A coarse-to-fine approach for segmenting melanocytic skin lesions in standard camera images. **Computer Methods and Programs in Biomedicine**. Maryland Heights, v. 112, n.3, p. 684-693. 2013.
- CAVALCANTI, P. G.; SCHARCANSKI, J.; LOPES, C. B. O.. Shading attenuation in human skin color images. In: INTERNATIONAL SYMPOSIUM ON VISUAL COMPUTING, 6., 2010, Las Vegas. **Proceedings...** . Heidelberg: Springer, 2010. p. 190-198.
- CAVALCANTI, P. G.; YARI, Y.; SCHARCANSKI, J.. Pigmented skin lesion segmentation on macroscopic images. In: INTERNATIONAL CONFERENCE OF IMAGE AND VISION COMPUTING NEW ZELAND, 25., 2010, Queenstown. **Proceedings...** . Piscataway: IEEE, 2010. p. 1-7.
- CELEBI, M. E. et al.. A methodological approach to the classification of dermoscopy images. **Computerized Medical Imaging and Graphics**, Maryland Heights, v. 31, n. 6, p. 362-373, set. 2007.
- CHAN, T.; VESE, L.. Active contours without edges. **IEEE Transactions on Image Processing**, [S.l.], v. 10, n. 2, p. 266-277, 2001.
- CORTES, C.; VAPNIK, V.. Support-vector networks. **Machine Learning**, Heidelberg: Springer, v. 20, n. 3, p. 273-297, set. 1995.

COVER, T.; HART, P.. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, [S.l.], v. 13, n. 1, p. 21-27, jan. 1967.

DERMNET SKIN DISEASE ATLAS. **Melanoma (skin cancer), nevi, and moles**. Disponível em: <<http://www.dermnet.com/images/Melanoma-Skin-Cancer-Nevi-and-Moles>>. Acesso em: 13/02/2015.

FLORES, E. S.. **Segmentação de Lesões Melanocíticas Usando uma Abordagem Baseada no Aprendizado de Dicionários**. 2015. Tese (Doutorado em Ciência da Computação) — Universidade Federal do Rio Grande do Sul, Instituto de Informática.

FREUND, Y.; SCHAPIRE, R. E.. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. **Journal of Computer and System Sciences**, Amsterdam, Netherlands: Elsevier, v. 55, n. 1, p. 119-139, ago. 1997.

GLAISTER, J.; WONG, A.; CLAUSI, D. A.. Segmentation of Skin Lesions From Digital Images Using Joint Statistical Texture Distinctiveness. **IEEE Transactions on Biomedical Engineering**, [S.l.], v.61, n.4, p.1220–1230, abr. 2014.

GONZALEZ, R. C.; WOODS, R. E.. **Digital Image Processing**. 3.ed. Upper Saddle River, New Jersey, USA: Prentice-Hall, 2008.

INCA. **Instituto Nacional de Câncer**. Disponível em: <<http://www2.inca.gov.br/wps/wcm/connect/inca/portal/home>>. Acesso em: 12/12/2015.

JUNG, C. R.. Unsupervised multiscale segmentation of color images. **Pattern Recognition Letters**, Oxford, U. K., v. 28, n. 4, p. 523-533, mar. 2007.

KOROTKOV, K.; GARCIA, R.. Computerized analysis of pigmented skin lesions: a review. **Artificial Intelligence in Medicine**, Amsterdam, Netherlands: Elsevier, v. 56, n. 2, p. 69-90, 2012.

MURZAKU, E. C.; HAYAN, S.; RAO, B. K.. Methods and rates of dermoscopy usage: a cross-sectional survey of us dermatologists stratified by years in practice. **Journal of the American Academy of Dermatology**, [S.l.], v. 71, n. 2, p. 393-395, ago. 2014.

NOOR, O.; NANDA, A.; RAO, B. K.. A dermoscopy survey to assess who is using it and why it is or is not being used. **International Journal of Dermatology**, [S.l.], v. 48, n. 9, p. 951-952, set. 2009.

OTSU, N. A.. Threshold Selection Method from Gray-Level Histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, [S.l.], v. 9, n. 1, p. 62-66, 1979.

PILIOURAS, P.; BUETTNER, P.; SOYER, H. P.. Dermoscopy use in the next generation: a survey of australian dermatology trainees. **Australasian Journal of Dermatology**, [S.l.], v.55, n.1, p.49-52, fev. 2014.

RUIZ, D. et al.. A cooperative approach for the diagnosis of the melanoma. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND

BIOLOGY SOCIETY, 30., 2008, Vancouver. **Proceedings...** . New York, NY, USA: IEEE, 2008. p. 5144-5147.

SCHARCANSKI, J.; DODSON, C. T. J.. Texture analysis for estimating spatial variability and anisotropy in planar stochastic structures. **Optical Engineering**, Bellingham, WA: SPIE, v. 35, n. 8, p. 2302, ago. 1996.

TANG, J.. Multi-direction GVF snake for the segmentation of skin cancer images. **Pattern Recognition**. Oxford, U. K., p. 1172-1179. 2009.

YOUNG, G. A. Alternative Smoothed Bootstraps. **Journal of the Royal Statistical Society. Series B (Methodological)**, [S.l.], v. 52, n. 3, p. 477-484, 1990.