



**Universidade Católica Dom Bosco**  
Curso de Bacharelado em Engenharia de Computação

**Combinação de Atributos de Textura e Cor  
para Avaliação Automática de Estrias  
Atróficas**

Víctor Borges Jussiani

Prof. Dr. Hemerson Pistori

*Trabalho de Conclusão de Curso apresentado à Co-  
ordenação do Curso de Bacharelado em Engenha-  
ria de Computação da Universidade Católica Dom  
Bosco como parte dos requisitos para a obtenção do  
título de Bacharel em Engenharia de Computação.*

UCDB - Campo Grande/MS - 06/2015

# Agradecimentos

Primeiramente gostaria de agradecer a Deus por todas as oportunidades concedidas até hoje e pelas que ainda virão.

A minha família, especialmente aos meus pais, Miguel Ângelo Jussiani e Rosa Dalva Oliveira Borges Jussiani por estarem sempre ao meu lado me apoiando e proporcionando a ótima educação que tive e as oportunidades de estudo, em especial a minha mãe que me ajudou a revisar os textos deste trabalho e a melhorar minhas habilidades de escrita.

A minha namorada Natália Valério Barbosa pela paciência e apoio durante essa caminhada cheia de obstáculos e pela ajuda e companherismo.

Ao orientador Professor Dr. Hemerson Pistori pela paciência, dedicação e apoio durante todo o decorrer desse projeto, me incentivando sempre a superar as expectativas.

Aos meus professores que conhecimento que me proporcionaram, ajudando diretamente na formação profissional e moral da turma.

Aos companheiros do grupo INOVISÃO que sempre estiveram dispostos a me auxiliar, preocupados com a melhoria do grupo como um todo.

Aos meus colegas de turma, os poucos “sobreviventes” que restaram e dividiram comigo essa importante etapa da vida, muitos se tornaram verdadeiros amigos, em especial ao Diogo Sant’Ana Sarath que trabalhou diretamente comigo no projeto, na implementação dos métodos e no decorrer de seu projeto de graduação.

Ao meu amigo e sócio Anderson Vasconcelos dos Santos, que sempre foi compreensivo com minhas responsabilidades relativas a faculdade e sempre apoiou o meu desenvolvimento profissional e intelectual.

A Dra. Juliana Prati Salvador e Dra. Romilda Arce Barbosa que idealizaram esta pesquisa e nos permitiram desenvolvê-la neste projeto de conclusão de curso.

A todos que acreditaram neste projeto e ofereceram sua ajuda, tornando-se imprescindíveis para a realização deste projeto, em especial a Prof. Dra. Edileia Bagatin, a Dra. Fabíola Picosse e o Dr. Rogério Ranulfo que dedicaram seu tempo a nos auxiliar no desenvolvimento desta pesquisa.

# Resumo

Atualmente os protocolos para avaliação das estrias são baseados no exame clínico visual da pele estriada e da mensuração por régua ou fita métrica de seu comprimento e largura, porém, estes métodos podem incorrer em falhas técnicas de execução. Não foi encontrado na literatura nenhum trabalho que tivesse como foco auxiliar os profissionais de Dermatologia no diagnóstico e acompanhamento do tratamento de estrias, a partir desse fato, este trabalho vem apresentar uma solução para este problema. Para facilitar o uso da aplicação, ela tem como foco os dispositivos móveis, tornando mais prático a coleta de imagens. Este projeto utilizou técnicas de visão computacional e aprendizagem automática para analisar as imagens coletadas através da câmera do dispositivo móvel. Primeiramente foi montado um banco de imagens com o auxílio de parceiros pelo Brasil, em seguida foi implementada técnica de segmentação de imagens baseadas em superpixel com a utilização de atributos de cor e textura. Posteriormente foram usadas métricas de desempenho de segmentadores para comparar as segmentações realizadas com diferentes técnicas de aprendizagem automática.

# Sumário

<b>1</b>	<b>Introdução</b>	<b>10</b>
<b>2</b>	<b>Trabalhos Correlatos</b>	<b>13</b>
2.1	Diagnóstico de doenças de pele . . . . .	13
<b>3</b>	<b>Fundamentação Teórica</b>	<b>15</b>
3.1	Estrias Atróficas . . . . .	15
3.2	Visão Computacional . . . . .	17
3.3	Segmentação de Imagens . . . . .	17
3.3.1	Segmentação por Superpixels . . . . .	18
3.4	Extração de Atributos . . . . .	22
3.4.1	Cor . . . . .	22
3.4.2	Textura . . . . .	24
3.5	Aprendizagem automática . . . . .	26
3.5.1	Árvore de Decisão . . . . .	27
3.5.2	SVM - Máquinas de Vetores de Suporte . . . . .	29
3.6	Métricas de avaliação de segmentadores . . . . .	30
3.6.1	Taxa de detecção ( <i>Recall</i> ) . . . . .	31
3.6.2	Precisão ( <i>Precision</i> ) . . . . .	32
3.6.3	Medida-F ( <i>F-measure</i> ) . . . . .	32
<b>4</b>	<b>Metodologia</b>	<b>33</b>
4.1	Captura de imagens e montagem do banco . . . . .	33
4.2	Modelo proposto baseado em superpixel . . . . .	39
4.2.1	Aprendizagem . . . . .	39
4.2.2	Segmentação . . . . .	43
<b>5</b>	<b>Resultados, Análise e Discussão</b>	<b>46</b>
5.1	Análise da Taxa de Acerto dos Classificadores . . . . .	46
5.2	Resultados da Segmentação por Superpixel . . . . .	47
5.3	Comparação . . . . .	54

---

5.4 Análise . . . . .	55
<b>6 Trabalhos Futuros</b>	<b>58</b>
<b>A Termo de consentimento livre e esclarecido</b>	<b>60</b>
<b>B Termo de autorização das clínicas</b>	<b>61</b>
<b>C Termo de autorização de uso de imagem</b>	<b>62</b>

# Lista de Figuras

3.1	Imagem ilustrativa da estria albae . . . . .	16
3.2	Imagem ilustrativa da estria rubrae . . . . .	16
3.3	Imagem ilustrativa da estria nigra . . . . .	16
3.4	Imagem ilustrativa da segmentação em superpixels . . . . .	19
3.5	Imagem ilustrativa das iterações do algoritmo SLIC . . . . .	22
3.6	Representações do modelo de cores RGB . . . . .	23
3.7	Representações do modelo de cores HSB . . . . .	24
3.8	Exemplo de uma árvore de decisão para o problema de espera para jantar em um restaurante [29] . . . . .	28
3.9	Modelo de funcionamento das <i>Support Vector Machines</i> . . . . .	30
3.10	Matriz de confusão . . . . .	31
4.1	Tela de imagens enviadas ao sistema . . . . .	35
4.2	Tela de autenticação do sistema . . . . .	36
4.3	Tela de envio imagens ao sistema . . . . .	36
4.4	Imagem obtida da lista de imagens a serem analisadas . . . . .	37
4.5	Imagem da tela de análise . . . . .	37
4.7	Fluxo da segmentação por superpixel . . . . .	39
4.8	Fluxo de aprendizagem . . . . .	40
4.9	Imagem de pele estriada segmentada em superpixel . . . . .	41
4.10	Imagem ilustrativa da marcação realizada por um especialista . . . . .	41
4.11	Imagem ilustrativa dos superpixels colocados sobre a imagem da marcação . . . . .	42
4.12	Imagem ilustrativa do programa de segmentação por superpixels . . . . .	44
4.13	Imagem ilustrativa do fluxo de segmentação . . . . .	45
5.1	Exemplo da segmentação de imagem para classe Alba . . . . .	49
5.2	Exemplo da segmentação de imagem para classe Nigra . . . . .	50
5.3	Exemplo da segmentação de imagem para classe Rubra . . . . .	51
5.4	Exemplo da segmentação de imagem para classe Pele . . . . .	52
5.5	Exemplo da segmentação de imagem para classe Fundo . . . . .	53

5.6	Fototipos de pele . . . . .	57
5.7	Proximidade da cor de estrias com alguns fototipos de pele . .	57

# Lista de Tabelas

5.1	Validação cruzada das técnicas de aprendizagem automática . . . . .	47
5.2	Avaliação do segmentador utilizando <i>Random Forest</i> . . . . .	48
5.3	Avaliação do segmentador utilizando <i>J48</i> . . . . .	48
5.4	Avaliação do segmentador utilizando SVM . . . . .	48
5.5	Dados usados para calcular a ANOVA . . . . .	54
5.6	Resultados do teste estatística ANOVA . . . . .	55
5.7	Métricas de desempenho para as técnicas utilizadas . . . . .	55

# Capítulo 1

## Introdução

A parceria entre profissionais de áreas diferentes tem contribuído para o grande avanço tecnológico e científico nos últimos anos. Devido a essa relação de conhecimentos entre essas áreas, formas de tratamento e diagnósticos diversificadas e sofisticadas foram possibilitadas, proporcionando aos profissionais de saúde a utilização de novas tecnologias.

A tendência para os próximos anos é que o acesso à informação seja basicamente através de dispositivos móveis devido às facilidades que eles oferecem para o acesso à internet, independente de onde as pessoas estejam. Além disso, novos modelos são lançados a cada ano, sempre mais potentes em processamento e com câmeras mais sofisticadas e maior definição das imagens, aumentando a sua eficiência e popularização.

Atualmente uma das vantagens oferecidas por esses dispositivos móveis é o alto poder de processamento, tornando viável a implementação de técnicas de visão computacional que permitem a interpretação de imagens através de atributos como cor e forma. Sendo assim, muitas técnicas antes executadas em computadores tradicionais passaram a ser utilizadas em dispositivos móveis com uma eficiência equivalente. Considerando os benefícios oferecidos, bem como a utilização em massa dos dispositivos móveis, seu uso torna-se um recurso eficaz em prol da melhoria da qualidade de vida das pessoas.

Nesta perspectiva propomos através desse trabalho um programa de visão computacional para auxiliar os profissionais da saúde no controle e tratamento de estrias. Este programa irá auxiliar na busca de soluções para um problema que atinge ambos os sexos de grande parte da população mundial, especialmente o sexo feminino a partir da adolescência.

As estrias são lesões resultantes do estiramento das fibras de colágeno e elastina, tendo sua aparência antiestética, como uma espécie de depressão com reação inflamatória. Inicialmente sua cor é mais rubra, mas durante o processo evolutivo ela torna-se esbranquiçada.

Na mulher adulta a incidência de estrias é 2,5 vezes mais frequente que no homem nas mesmas condições e normalmente está associada à fase de exacerbação hormonal como a gravidez ou doenças endocrinológicas [19]. Seu tratamento envolve uma equipe interdisciplinar que inclui médicos, fisioterapeutas, esteticistas, entre outros profissionais [32].

Atualmente os protocolos para avaliação das estrias são baseados no exame clínico visual da pele estriada e da mensuração por régua ou fita métrica de seu comprimento e largura. Porém, estes métodos podem incorrer em falhas técnicas de execução, pois são influenciados por fatores como iluminação do local, pequena dimensão da lesão, cansaço visual do examinador, grande número de lesões, os quais muitas vezes inviabilizam a contagem.

Levando em consideração que as técnicas de avaliação podem ser imprecisas, justifica-se, construir uma aplicação móvel que utilizará a visão computacional no sentido de tornar os critérios de avaliação mais confiáveis, os quais possam servir de parâmetro preciso para controle da progressão da patologia, bem como do sucesso da terapêutica prescrita.

Foi criado um banco de imagem com amostras suficientes para realizarmos os primeiros experimentos propostos por este trabalho, para tal contamos com a ajuda de parceiros de todo Brasil, entre eles a Prof. Dra. Edileia Bagatin da Universidade Federal de São Paulo (UNIFESP), a Dra. Fabíola Picosse e o Dr. Rogério Ranulfo. De forma a auxiliar os parceiros na coleta de imagens e marcação da patologia, foi desenvolvido um software adaptado para Smartphone, permitindo o uso da câmera como recurso para facilitar a coleta.

A partir da marcação realizada pelos especialistas foi possível extrair informações que caracterizam as áreas afetadas pela patologia, para isso utilizamos atributos de cor como o RGB, HSB e atributos de textura calculados através de uma Matriz de Co-ocorrência como o Contraste, Correlação, Homogeneidade, Energia e Entropia.

De forma a simplificar uma das principais etapas do processamento das imagens, a segmentação, que tem como objetivo isolar os objetos de interesse da imagem, foi utilizada uma técnica conhecida com Superpixel que consiste em

agrupar a maior quantidade de pixels que contenham informações semelhantes, diminuindo assim a quantidade de informações a serem processadas.

Para consolidar o conhecimento obtido através dos atributos foram utilizadas técnicas de aprendizagem automática, que visam induzir uma forma de conhecimento a partir de amostras previamente conhecidas. Com o intuito de encontrar a melhor abordagem para resolver o problema foram utilizadas três técnicas de aprendizagem automática, são elas: *J48*, *Random Forest* e *SVM*.

Os resultados obtidos foram analisados utilizando métricas para avaliação de segmentadores como a Taxa de detecção, Precisão e a Medida-F e comparadas utilizando um método estatístico conhecido como Análise de Variância (ANOVA), mais detalhes sobre os resultados podem ser encontrados na sessão 5.

# Capítulo 2

## Trabalhos Correlatos

Esta seção descreve os trabalhos correlatos que foram encontrados na literatura referente às técnicas desenvolvidas com visão computacional para ajudar no diagnóstico e tratamento de doenças de pele, bem como os resultados obtidos.

### 2.1 Diagnóstico de doenças de pele

Atualmente várias pesquisas estão sendo desenvolvidas para auxiliar os profissionais da área de Dermatologia no diagnóstico e controle das doenças de pele. Um exemplo é o software desenvolvido por [32], que apresenta uma solução para auxiliar na detecção de melanomas, um tipo de câncer de pele dos mais agressivos. Segundo recentes artigos, aproximadamente 70.000 pessoas são diagnosticadas com melanoma e 9.000 morrem nos Estados Unidos todo ano em decorrência dele. A detecção prematura do melanoma ajuda a diminuir as taxas de mortalidade nos portadores desse tipo de câncer.

Outro projeto que foi desenvolvido por [14], apresenta uma solução para auxiliar no tratamento de acnes, uma doença de pele que tem grande frequência entre os adolescentes. Seus impactos são relacionados à preocupação com a estética gerando efeitos psicossociais devastadores, podendo levar seus portadores até ao suicídio. Geralmente, os métodos usados para detecção e acompanhamento são baseados na inspeção visual do profissional, podendo assim acarretar falhas no diagnóstico. Para evitar pseudos diagnósticos, [14] propõe um software baseado em visão computacional que possa, através de fotografias das áreas afetadas pelas acnes, identificá-las e classificá-las, facilitando assim a eficácia do tratamento.

A Psoríase Eritema é uma doença crônica, inflamatória e não contagiosa que se caracteriza pelo aparecimento de placas vermelhas na pele e embora não haja nenhuma cura existem muitos tratamentos que ajudam no seu controle. Atualmente 3% da população mundial encontra-se afetada por essa doença.

O projeto desenvolvido em [3], apresenta uma solução para avaliação da Psoríase Eritema pelo método de pontuação PASI. Esse método é utilizado para determinar a gravidade da lesão e acompanhar a eficácia do tratamento. Para realizar a pontuação PASI e facilitar o acompanhamento do tratamento foi proposta uma solução baseada em Visão Computacional.

# Capítulo 3

## Fundamentação Teórica

### 3.1 Estrias Atróficas

A estria é uma alteração dermatológica que pode ser vista a olho nu, apesar de estar situada na derme, a camada mais profunda da pele [42]. Podem se apresentar em pequenas ou grandes quantidades em um determinado local da pele e em geral estão expostas de forma paralela umas às outras e perpendicularmente às linhas de clivagem da pele. Podem ser onduladas, salientes, planas ou deprimidas, possuindo um caráter de bilateralidade. As estrias são mais comuns em áreas passíveis de estiramento da pele como mamas, glúteos, abdômen, coxa e região lombo-sacra, embora possam ocorrer em qualquer local do corpo [10].

As estrias são ditas atróficas por apresentarem uma diminuição de espessura da pele, decorrente da redução do número e volume de seus elementos e é representada por adelgaçamento, pregueamento, secura, menor elasticidade e rarefação dos pelos. Clinicamente, podem ser descritas como uma tira, banda ou linha, na qual há uma mudança na cor e textura, com depressão ou elevação do tecido, onde é encontrada [9].

A coloração das estrias depende da combinação do componente microvascular e da atividade dos melanócitos, sua aparência clínica é influenciada pelo fototipo do paciente, em indivíduos de pele escura essa dupla percepção pode ser modificada, uma vez que os olhos humanos detectam a diferença de cor entre as estrias distensíveis e a pele ao redor [32].

Nos indivíduos com fototipo entre I e IV, as estrias, inicialmente, são avermelhadas pela resposta inflamatória aguda (*striae rubrae*, como apresentado

na Figura 3.2) e evoluem para a maturação tornando-se pálidas, deprimidas e enrugadas (striae albae, como apresentado na Figura 3.1) [13].



Figura 3.1: Imagem ilustrativa da estria albae



Figura 3.2: Imagem ilustrativa da estria rubrae

Em indivíduos que utilizaram corticóides por tempo prolongado, pode surgir estrias azuladas, denominadas cerúleas. Em relação às estrias nigras (Figura 3.3), elas podem acontecer em pacientes de fototipos V e VI e nesse caso, a coloração parece ser controlada por processo mecano-biológico que ativa ou inibe a melanogênese em pessoas negras [32].



Figura 3.3: Imagem ilustrativa da estria nigra

## 3.2 Visão Computacional

Os seres humanos obtêm a grande maioria de sua entrada sensorial através de seu sistema visual, e um enorme esforço tem sido feito para melhorar artificialmente esse sentido como óculos, binóculos, telescópios, radares, sensores infravermelhos e fotomultiplicadores [24]. Atualmente o homem tem procurado fazer com que as máquinas façam muito do seu trabalho, para tarefas mecânicas simples isso não é particularmente difícil, entretanto para tarefas mais complexas deve ser dado a máquina o sentido da visão [12].

A visão computacional é um campo relativamente novo e de rápido crescimento, os primeiros experimentos foram realizados no final de 1950, e muitos dos conceitos essenciais foram desenvolvidos durante os últimos cinco anos. Com este crescimento rápido, ideias cruciais surgiram em áreas díspares, tais como: a inteligência artificial, psicologia, computação gráfica e processamento de imagem [4].

Segundo [20], a visão computacional é entendida como o conjunto de técnicas para adquirir, processar, analisar e compreender dados complexos de altas dimensões do nosso meio ambiente para a exploração científica e técnica.

Como apresentado em [15], a visão computacional tem um ampla variedade de aplicações como: navegação de robôs móveis, inspeção industrial, inteligência militar, interação homem-computador, recuperação de imagens em bibliotecas digitais, análise de imagem médica e a renderização realista de cenas sintéticas em computação gráfica.

## 3.3 Segmentação de Imagens

O campo da visão computacional é voltado à extração de informações a partir de imagens, sendo que em muitos desses métodos o primeiro passo é a segmentação de imagens que serve para simplificar o problema através do agrupamento de pixels de maneira lógica. Entretanto, é difícil defini-la claramente porque existem muitos níveis de detalhes em uma imagem e, portanto, muitas formas possíveis de agrupar significativamente os pixels [5].

A segmentação é um processo natural e comum para o ser humano, porém complexo para um computador, pois nossos sistemas biológicos reconhecem e interpretam os objetos assim que os veem a partir de um conjunto de informações que são combinadas e processadas em paralelo no cérebro, as-

sim para que ele veja, é preciso interpretar o significado das variações de intensidade de luz e cor que chegam aos olhos. Computacionalmente é complexo conseguir reproduzir com exatidão esse reconhecimento e interpretação. Por outro lado, em alguns casos a visão computacional pode compensar as privações da visão humana para identificar algumas frequências mais altas ou mais baixas de imagens que os limites suportados pela visão humana [16, 17].

### 3.3.1 Segmentação por Superpixels

Os algoritmos de superpixel agrupam os pixels em regiões homogêneas, como apresentado na figura 3.4, as quais podem ser usadas para substituir a estrutura rígida da matriz de pixels. Eles capturam as redundâncias na imagem, fornecendo uma maneira para computar atributos da imagem e reduzir significativamente a complexidade das tarefas subsequentes do processamento de imagem [1].

Um superpixel deve conter pixels que são semelhantes em cor e textura, portanto, são susceptíveis de pertencerem ao mesmo objeto do mundo físico [27]. O pressuposto de que todos os pixels em um superpixel pertencem ao mesmo objeto conduz a vantagem dos superpixels sobre os pixels. A primeira vantagem é a eficiência computacional, quando é necessário calcular uma propriedade que permanece aproximadamente constante pelo objeto, a representação de superpixel é mais eficiente, uma vez que o número total de possibilidades é muito reduzida [37].

Desta maneira os superpixels devem formar um bom agrupamento de pixels resultando em uma boa segmentação da imagem em regiões, de modo que seja possível identificar uma mesma região em partes diferentes da imagem [23].

A desvantagem do uso dos superpixels se dá pela etapa de pré-processamento que exige um maior esforço computacional para construção das unidades e pelo risco de perder dados relativos às bordas da imagem colocando-as dentro de um superpixel. Por isso é importante escolher corretamente qual algoritmo será utilizado e seus parâmetros [1, 23].



Figura 3.4: Imagem ilustrativa da segmentação em superpixels

## SLIC

*Simple Linear Iterative Clustering* (SLIC) foi proposto em 2010, este algoritmo é frequentemente utilizado como base, e é especialmente interessante devido à sua simplicidade. Em particular, ele executa o agrupamento local por *K-means* onde o espaço de busca para cada superpixel é restrito a uma área local em torno do seu centro [36].

O SLIC gera superpixels agrupando pixels com base em sua semelhança e proximidade de cor no plano da imagem, isso é feito no espaço de cinco dimensões (5D)  $labxy$ , onde  $lab$  é o vetor de cor do pixel no espaço de cor CIELAB, que é amplamente considerada como perceptualmente uniforme para distâncias pequenas de cor, e  $xy$  é a posição de cada pixel [2].

A transformação CIELAB incorpora o fato de que as diferenças de percepção entre as cores não são uniformes em um espaço de cor linear. Desta forma ela transforma cores para uma representação que é perceptualmente aproximada de forma uniforme, de maneira que a distância Euclidiana entre cores diferentes neste espaço correspondam aproximadamente às diferenças de cores perceptíveis [41].

Por padrão, o algoritmo aceita uma entrada  $k$  que corresponde ao número de superpixels com aproximadamente o mesmo tamanho. Para imagens coloridas no espaço de cor CIELAB, o processo do agrupamento começa com a etapa de inicialização, na qual os  $k$  centros dos agrupamentos  $C = [l_i a_i b_i x_i y_i]$ , são em cada pixel  $i$ , expressos por uma matriz regularmente espaçada em  $S$  [1].

Para que os superpixels tenham aproximadamente o mesmo tamanho, o intervalo da matriz é determinado pela seguinte equação:

$$S = \sqrt{\frac{\text{Largura} * \text{Altura}}{k}}$$

Assim, os centros do superpixel são movidos para locais com baixa magnitude de gradiente, numa vizinhança  $3 \times 3$ , para evitar que um superpixel tenha seu centróide colocado sobre regiões de borda e para reduzir as chances dele conter pixels ruidosos [1, 36].

Posteriormente, no passo de atribuição, cada pixel  $i$  é associado com o centro mais próximo do agrupamento, cuja região de busca se sobrepõe à sua localização, esta é a chave para acelerar esse algoritmo, pois ao limitar o ta-

manho da região da busca, reduz-se significativamente o número de cálculos de distância, o que resulta em uma vantagem de velocidade significativa sobre o agrupamento *K-means* convencional, no qual cada pixel deve ser comparado com todos os centros de agrupamento [1].

O processo anteriormente descrito só é possível através da introdução da medida de distância  $D$ , a qual determina o centro mais próximo para cada pixel [1], como demonstrado abaixo:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2}$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2}$$

$$D = d_{lab} + \frac{m}{S} * d_{xy}$$

Onde  $D$  é a soma da distância  $d_{lab}$  e a distância  $d_{xy}$  normalizada pelo intervalo  $S$ . A variável  $m$  corresponde ao controle de compactação do superpixel, quanto maior o seu valor, mais a proximidade espacial é enfatizada e mais compactado é o agrupamento [23].

Este procedimento é repetido até a convergência ou até um número máximo de iterações  $T$ . Finalmente, na etapa de pós-processamento, os superpixels não representem necessariamente componentes ligados, de tal forma que o algoritmo precise reforçar a conectividade através da re-atribuição de pixels disjuntos para superpixels próximos [1, 36]. Esse processo pode ser observado na figura 3.5, na qual a iteração 0 apresenta a matriz inicializada e nas iterações seguintes os superpixels convergem de forma a agrupar os pixels de forma homogênea.

Para os experimentos efetuados neste projeto foram utilizado o algoritmo jSLIC disponibilizado no repositório público [www.github.com/Borda/ij-CMP-BIA/](http://www.github.com/Borda/ij-CMP-BIA/).

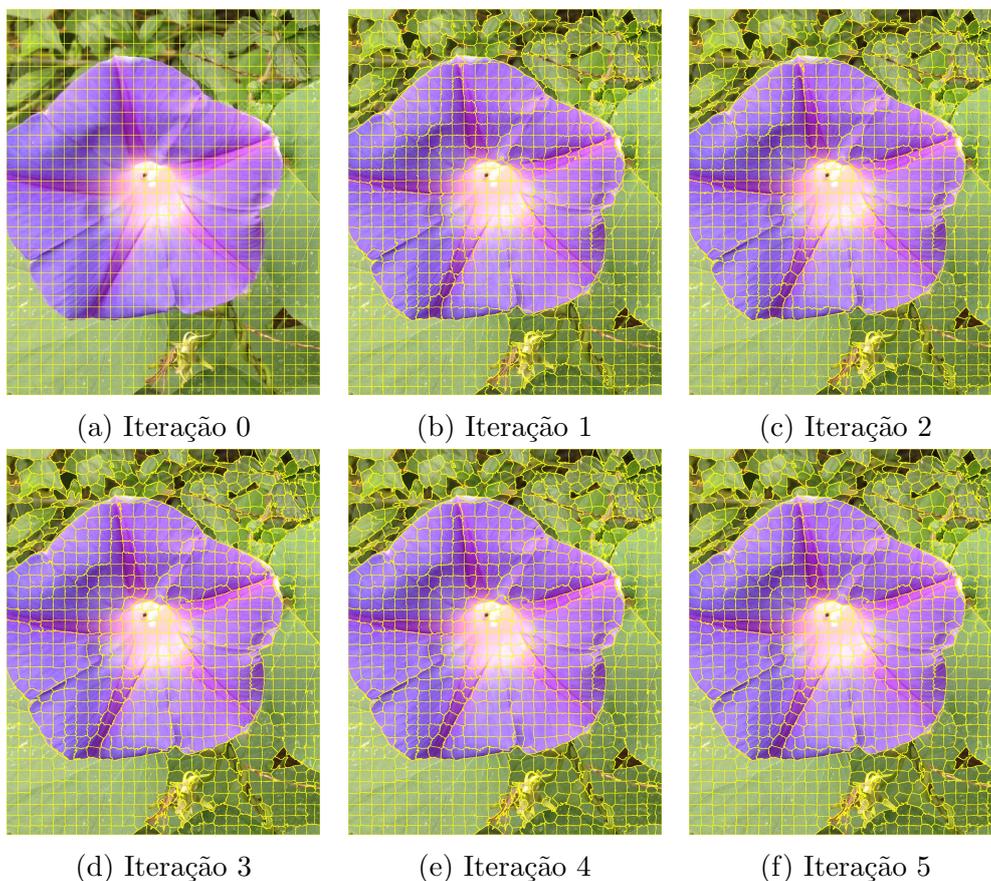


Figura 3.5: Imagem ilustrativa das iterações do algoritmo SLIC

## 3.4 Extração de Atributos

A extração de atributos procura identificar informações relativas às características, de modo que através desses dados possam ser identificados objetos semelhantes por valores semelhantes e diferenciar se os valores forem distintos [25, 30]. Este processo é fundamental para a obtenção de bons resultados na classificação, pois nesta fase é criado o conjunto de características usado para realização de treinamento e geração dos classificadores [30].

### 3.4.1 Cor

A cor é uma das características mais importantes, pois torna possível o reconhecimento de imagens pelos seres humanos e o atributo de cor é uma das características visuais mais comumente usados em recuperação de imagens. A cor é uma propriedade que depende da reflexão da luz para o olho e o

processamento dessa informação no cérebro [35].

Os atributos de cores são relativamente fáceis de extrair e combinar, e o que se tem verificado é que são eficazes para a indexação e pesquisa de imagens coloridas em bancos de dados de imagem. Um dos principais aspectos da extração de atributos de cor é a escolha de um espaço de cor, que é um espaço multidimensional, no qual as diferentes dimensões representam os diferentes componentes de cor [34].

Um exemplo de espaço de cor é o RGB, que é baseado na variação e combinação de cores primárias (vermelho, verde e azul). Cada cor é representada por 8 bits, ou seja, pode ter 256 variações de tom e ao combinar as variações pode obter-se mais de 16 milhões de cores diferentes [26]. O modelo pode ser representado em um sistema de coordenadas cartesianas  $XYZ$  onde o eixo  $X$  corresponde a cor verde, o eixo  $Z$  a cor vermelha e o  $Y$  a cor azul, nesse caso o ponto  $P1(0, 0, 0)$  corresponde a cor preta e o branco representada no ponto  $P2(1, 1, 1)$ . Também pode ser representado por uma seção plana, onde as cores representadas por círculos combinadas formam outras cores [30].

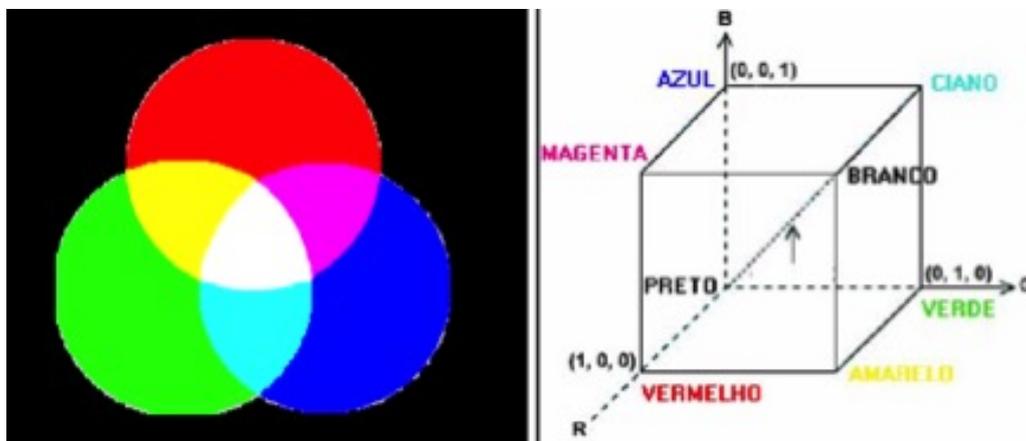


Figura 3.6: Representações do modelo de cores RGB

O espaço de cor RGB não é perceptivelmente uniforme. Mais especificamente, distâncias iguais em diferentes faixas de intensidade e ao longo de diferentes dimensões do espaço de cor RGB não correspondem a igualdade de percepção da cor de dissimilaridade [34]. O espaço de cor RGB pode ser transformado para gerar outros espaços de cores. A ideia para transformação do espaço de cor é desenvolver um modelo que seja perceptivelmente seme-

lhante com a visão de cor humana [35].

Outro espaço de cor amplamente utilizado no campo de visão da cor é o HSB (também chamado de HSV), cujas componentes cromáticas matiz, saturação e brilho correspondem estreitamente com as categorias da percepção humana de cor. Os valores HSB de um pixel podem ser transformados a partir da sua representação RGB, de acordo com a seguinte fórmula:

$$H = \cos^{-1} \frac{\frac{1}{2}[(R - G) + (R - B)]}{\sqrt{(R - G)^2 + (R - B)(G - B)}}$$

$$S = 1 - \frac{3[\min(R, G, B)]}{R + B + G}$$

$$B = \left(\frac{R + G + B}{3}\right)$$

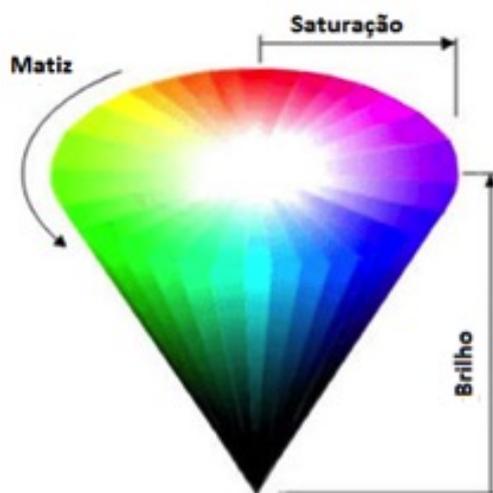


Figura 3.7: Representações do modelo de cores HSB

### 3.4.2 Textura

A textura é definida como a estrutura das superfícies formadas pela repetição de um determinado elemento ou de vários elementos em diferentes posições espaciais relativas. Geralmente, a repetição envolve variações locais de escala, orientação ou outras características geométricas e ópticas dos elementos. Ela contém informações importantes sobre o arranjo estrutural da su-

perfície. Além de descrever a relação da superfície com o ambiente circundante, também descreve a composição física distinta de uma superfície [34].

As três principais abordagens utilizadas no processamento de imagem para descrever a textura de uma região são: a estatística, a estrutural e a espectral. A *Gray-level co-occurrence matrices* (GLCM) é uma das abordagens estatísticas mais comumente usadas para extrair atributos de textura de uma imagem [38].

A GLCM apresenta a probabilidade conjunta que um par de pixels com a posição  $(A_x, A_y)$  irá ocorrer ao mesmo tempo, onde  $A_x$  e  $A_y$  são determinados por um deslocamento especificado  $\delta$  entre o par de pixels e o ângulo  $\theta$ , e eles estão sujeitos a  $A_x = \delta \cos(\theta)$  e  $A_y = \delta \sin(\theta)$ . Não existe um método fixo para determinar os valores de  $\delta$  e  $\theta$ . Como a distribuição de intensidades de cinza será diferente em todas as orientações, oito vizinhos ligados parecem ser o melhor para computar a GLCM, e então será  $\delta = 1; \theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$  para os 8 vizinhos conectados [38].

A partir dos valores escolhidos para  $\delta$  e  $\theta$  é calculada uma GLCM para cada combinação dos mesmos, nas quais podem ser extraídos vários atributos de textura. Supondo que  $p_d(i, j)$  é o valor da posição  $(i, j)$  na GLCM e representa a probabilidade do nível de cinza  $i$  ocorrer a um descolamento  $d$  do nível de cinza  $j$ .

- $N_g$  é o número de níveis de cinza na imagem.
- $p_d(i) = \sum_{j=1}^{N_g} p_d(i, j)$ , significa o  $i$ -ésimo valor da matriz de probabilidade obtido através da soma da  $i$ -ésima linha de  $p_d(i, j)$ .
- $p_d(j) = \sum_{i=1}^{N_g} p_d(i, j)$ , significa o  $j$ -ésimo valor da matriz de probabilidade obtido através da soma da  $j$ -ésima coluna de  $p_d(i, j)$ .
- $\mu_i, \mu_j$  são as médias e  $\sigma_i, \sigma_j$  são os desvios padrões de  $p_d(i), p_d(j)$ , respectivamente.

Os atributos podem ser extraídos utilizando as seguintes fórmulas:

- *Contraste* - mede a intensidade do contraste entre um pixel e seus vizinhos. O contraste é 0 para imagens constantes.

$$\text{Contraste} = \sum_{n=0}^{N_g-1} n^2 \sum_{|i-j|=n} p_d(i, j)$$

- *Correlação* - mede o quanto um pixel está correlacionado com seus vizinhos, sendo que os valores variam entre  $-1$  (não correlacionado) e  $1$  (correlacionado).

$$\text{Correlação} = \frac{\sum_{i=1}^{N_g} \sum_{j=i}^{N_g} (i - \mu_i)(j - \mu_j) p_d(i, j)}{\sigma_i \sigma_j}$$

- *Homogeneidade* - mede a similaridade dos pixels.

$$\text{Homogeneidade} = \sum_{i=1}^{N_g} \sum_{j=i}^{N_g} \frac{p_d(i, j)}{1 + |i - j|}$$

- *Energia* - significa uniformidade, quanto mais homogênea a imagem, maior será o seu valor. Quando a energia for igual a 1 podemos concluir que a imagem é constante.

$$\text{Energia} = \sum_{i=1}^{N_g} \sum_{j=i}^{N_g} p_d^2(i, j)$$

- *Entropia* - é a medida da aleatoriedade das intensidades de uma imagem.

$$\text{Entropia} = - \sum_{i=1}^{N_g} \sum_{j=i}^{N_g} p_d(i, j) \log(p_d(i, j))$$

## 3.5 Aprendizagem automática

O campo da aprendizagem automática foi concebido a cerca de quatro décadas atrás, com o ousado objetivo de desenvolver métodos computacionais que implementassem várias formas de aprendizagem, em particular, de mecanismos que fossem capazes de induzir conhecimento a partir de exemplos ou dados [21].

Segundo [21], tal forma de indução de conhecimento é particularmente desejável em problemas que carecem de solução algorítmica, ou são de difícil definição, tais como: diagnósticos médicos ou técnicos, reconhecimento visual, comportamento de materiais, jogar xadrez ou detecção de regularidades interessantes em grande conjunto de dados.

Sistemas de visão precisam de capacidades de aprendizagem para lidar com problemas para os quais as soluções algorítmicas são desconhecidas ou difíceis de serem obtidas. Elas podem fazer sistemas de visão mais facilmente adaptáveis a diferentes problemas de visão, e também mais flexíveis e avançadas para lidar com condições de percepção variável [21].

Atualmente, existem diversos algoritmos de aprendizagem automática presentes na literatura, sendo que algumas de suas técnicas são utilizadas nesse trabalho e se encontram explicadas a seguir.

### 3.5.1 Árvore de Decisão

A aprendizagem da árvore de decisão é um método para aproximar os valores discretos em funções, em que a função aprendida é representada por uma árvore de decisão. Árvores aprendidas também podem ser representadas como conjuntos de regras *se-então* para melhorar a legibilidade humana. Estes métodos de aprendizagem estão entre os mais populares algoritmos de inferência indutiva e têm sido aplicados com sucesso em uma ampla gama de tarefas, desde aprender a diagnosticar casos médicos à aprender a avaliar o risco de crédito dos candidatos a empréstimos [22].

Árvores de Decisão são basicamente uma forma de classificar os dados em diferentes caminhos, cada um deles acabará por levar a uma classificação. A árvore será semelhante a uma árvore genealógica, cada nó herda todos os valores dos atributos de seus antecessores. Em cada nó da árvore de decisão (com a exceção das folhas), uma questão (ou uma combinação de perguntas) é pedida e de acordo com a resposta, as amostras de dados são atribuídas a um caminho ou outro da árvore. Desta forma, começa a coleção completa de amostras no nó superior da árvore e a partir de então cada nó da árvore de apenas um subconjunto de amostras será atribuído a um ramo específico. Este processo continua até que não haja mais perguntas feitas (não há mais atributos) e uma classificação final é feita [31].

Para melhor compreender o funcionamento de uma árvore de decisão, vamos considerar o exemplo da Figura 3.8, na qual é apresentado o problema

de espera para jantar em um restaurante. Para qualquer problema de árvore de decisão, deve-se inicialmente definir os atributos necessários para descrever exemplos de possíveis casos do domínio. Neste exemplo são adotados os seguintes atributos: alternar de restaurante, ir para um bar, dia da semana, estar com fome, número de fregueses, preço da comida, clima, se foi feita reserva, tipo do restaurante, estimativa de espera. Os atributos preço e tipo de comida, por serem de pouca importância, foram desconsiderados.

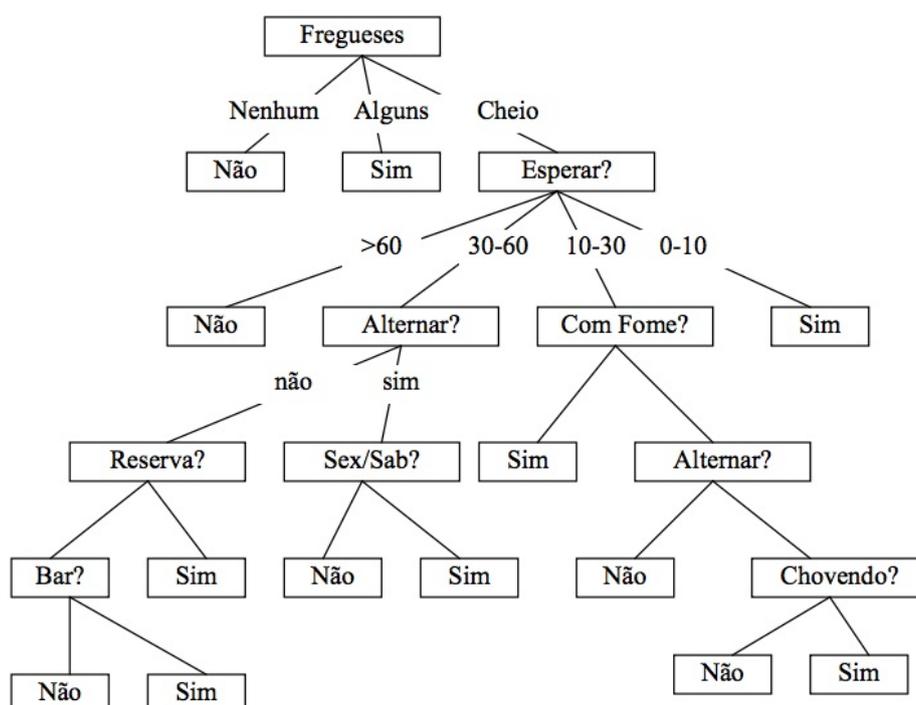


Figura 3.8: Exemplo de uma árvore de decisão para o problema de espera para jantar em um restaurante [29]

Em uma árvore de decisão, o conhecimento é representado em cada nó que, ao ser testado, pode conduzir a busca a um de seus filhos, deste modo, descendo da raiz em direção as folhas da árvore, chegando a classificação final.

Na execução deste projeto foram utilizados dois métodos de árvore de decisão encontrados no Weka versão 3.6.12, são eles: *Random Forest* e *J48*:

- *Random Forest* - Este algoritmo foi proposto por Breiman (Breiman, 2001) e é uma combinação de árvores de decisão, em que cada árvore depende dos valores de vetores aleatórios amostrados de forma independente e distribuídos igualmente para todas as árvores na floresta. Nesse método, depois que um determinado número de árvores são geradas, cada uma lança um voto para uma classe do problema, considerando um vetor de entrada. Então, a classe mais votada é escolhida na predição do classificador [33].
- *J48* - Este algoritmo é uma versão posterior e ligeiramente melhorada chamada de C4.5 revisão 8, que foi a última versão pública desta família de algoritmos antes da implementação comercial C5.0 ser lançada [39]. O algoritmo C4.5 foi desenvolvido por Ross Quinlan (Quinlan, 1993) e se baseia no algoritmo ID3 de Quinlan (Quinlan, 1986). O C4.5 é provavelmente o algoritmo de Árvore de Decisão mais utilizado no aprendizado de máquina, também é um algoritmo de referência para desempenho, no qual qualquer outro algoritmo deve desejavelmente ser comparado. Ele é um *top-down*, *depth-first* algoritmo e usa uma estratégia de dividir para conquistar. Para atributos numéricos, o C4.5 faz uso de divisões binárias e para atributos nominais (classes) pode-se usar outras  $n$  divisões. O procedimento padrão é executar a pós-poda e no processo de treinamento a pré-poda. Os nós são divididos até que eles fiquem puros (isto é, contenham apenas amostras pertencentes a uma única classe) [31].

### 3.5.2 SVM - Máquinas de Vetores de Suporte

As *Máquinas de Vetores de Suporte* (SVM) são utilizadas para treinamento de classificadores e tem como uma de suas vantagens o alto poder de generalização, pois suas hipóteses não se baseiam no número de atributos e sim no grau de separação dos dados [28].

O funcionamento da SVM se dá pela separação dos dados em duas classes através da construção de um hiperplano para separação das mesmas, de forma que os dados pertencentes a um dos lados assumem o valor de 1 e do outro lado é atribuído o valor  $-1$ . Um hiperplano ótimo realiza a separação dos dados com a maior margem possível, para a determinação da margem é feita a soma das distâncias entre os pontos positivos e negativos próximos ao plano, os quais são denominados de vetores de suporte [28, 7], como exemplificado na Figura 3.10.

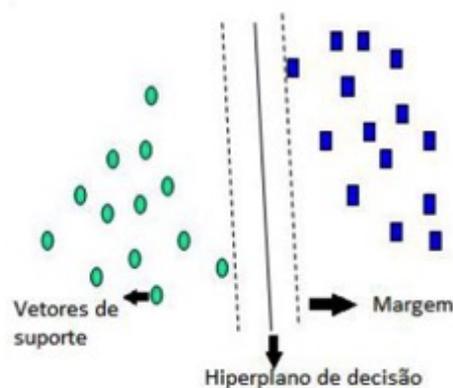


Figura 3.9: Modelo de funcionamento das *Support Vector Machines*

O conjunto de treinamento realiza a coleta de amostras e posteriormente é determinado a qual grupo as amostras pertencem com base no hiperplano. Em casos onde os dados não são separáveis linearmente o hiperplano é criado baseando-se na transformação dos dados iniciais por algoritmos de separabilidade de padrões como funções de núcleos, função polinomial, entre outras [7, 18].

Para a aplicação foi utilizado o método SMO (mínima sequência de Otimização) que está disponível na biblioteca do WEKA. É um algoritmo que visa uma rápida solução para o problema quadrático da SVM, dividindo-o em vários subproblemas mais simples que podem ser resolvidos minimizando o uso de memória ao não armazenar dados [28].

### 3.6 Métricas de avaliação de segmentadores

A segmentação de imagens é uma etapa importante em muitas aplicações de visão computacional. Pesquisas estão sendo desenvolvidas com o intuito de criar diferentes abordagens e algoritmos para segmentação de imagens, mas ainda é difícil avaliar quando um algoritmo produz segmentações mais precisas do que o outro, seja para uma imagem em particular ou para um conjunto de imagens. Atualmente, os métodos mais comuns de avaliar a efetividade de um método de segmentação é a avaliação subjetiva, na qual um humano compara visualmente os resultados da segmentação de imagens para

cada algoritmo de segmentação, sendo um processo cansativo que limita a profundidade de avaliação para um número relativamente pequeno de comparação sobre um conjunto predeterminado de imagens [40].

Geralmente, as métricas de avaliação em problemas de classificação são definidas a partir de uma matriz com os números de exemplos corretamente e incorretamente classificados para cada classe, chamada matriz de confusão [11].

		Valor Verdadeiro (confirmado por análise)	
		positivos	negativos
Valor Previsto (predito pelo teste)	positivos	<b>VP</b> Verdadeiro Positivo	<b>FP</b> Falso Positivo
	negativos	<b>FN</b> Falso Negativo	<b>VN</b> Verdadeiro Negativo

Figura 3.10: Matriz de confusão

Sendo que seus elementos são descritos como:

- *Falso positivo (FP)* - amostra classificada como positiva, porém é negativa.
- *Falso negativo (FN)* - amostra classificada como negativa, porém é positiva.
- *Verdadeiro Positivo (VP)* - amostra classificada corretamente como pertencente a classe positiva.
- *Verdadeiro Negativo (VN)* - amostra classificada corretamente como pertencente a classe negativa.

### 3.6.1 Taxa de detecção (*Recall*)

Segundo [8], a taxa de detecção de um segmentador é a medida que indica a relação entre a área da imagem corretamente classificada como sendo per-

tendente ao objeto que se deseja detectar e a área total deste objeto, a qual é definida pela seguinte equação:

$$R = \frac{VP}{VP + FN}$$

Respectivamente, quanto mais alta a taxa de detecção, maior o nível de acerto do segmentador, pois este conseguiu detectar uma maior quantidade de pixels que era esperado após a segmentação. Porém se usada isoladamente, esta medida não é suficiente para medir a qualidade de um segmentador, pois ela considera somente os acertos, se o resultado da segmentação fosse a imagem original a taxa de detecção seria 100%.

### 3.6.2 Precisão (*Precision*)

Segundo [8], a precisão de um segmentador é a medida que indica a relação entre a área da imagem corretamente classificada como sendo pertencente ao objeto que se deseja detectar e a área total aceita pelo segmentador. Formalmente, a medida da precisão é definida pela equação:

$$P = \frac{VP}{VP + FP}$$

Sendo assim, pode-se dizer que um segmentador de alta precisão acerta a maioria dos pixels que considerou fazerem parte do objeto que se deseja detectar. Por esse motivo, esta técnica soluciona o problema apresentado na taxa de detecção, porém se usada isoladamente ainda não é suficiente para medir a qualidade de um segmentador.

### 3.6.3 Medida-F (*F-measure*)

A solução para o problema da insuficiência das medidas apresentadas é combiná-las em uma única medida, passando assim a considerar todos os aspectos dos segmentadores, e viabilizando uma comparação mais adequada [8].

A medida-F é a média harmônica entre a taxa de detecção e a precisão, sendo

$$F = 2 * \frac{P * R}{P + R}$$

Desta forma é possível afirmar que o segmentador  $\zeta_1$  é melhor que outro segmentador  $\zeta_2$  se  $F(\zeta_1) > F(\zeta_2)$ .

# Capítulo 4

## Metodologia

### 4.1 Captura de imagens e montagem do banco

Com a intenção de criar uma base de conhecimento para que a aplicação reconhecesse estrias, fez-se necessário a coleta imagens em pacientes portadores dessa patologia.

Com a finalidade de formalizar e autenticar nossa pesquisa perante os conceitos éticos, foi elaborado um Termo de Consentimento Livre e Esclarecido (TCLE), juntamente com o Termo de Autorização de Uso de Imagens e a Autorização para Parceiros que foram submetidos ao Comitê de Ética para Pesquisas (CEP) , documento estes que se encontram apêndices a este trabalho.

Para que a coleta destas imagens não possa ser caracterizada como invasão de privacidade ao paciente, ele precisa consenti-la assinando o Termo de Autorização de Uso de Imagens, o qual permite o uso das mesmas para os treinamentos, testes e exposição dos resultados em artigos e trabalhos relacionados à pesquisa.

As coletas foram realizadas por diversos parceiros em várias partes do Brasil, entre eles a Prof. Dra. Edileia Bagatin da Universidade Federal de São Paulo (UNIFESP), a Dra. Fabíola Picosse e o Dr. Rogério Ranulfo, que se interessaram pelo avanço que esta pesquisa poderia proporcionar, e concordaram com os termos da Autorização para Parceiros.

Após a análise do CEP, nos foi concedido Parecer Consubstanciado de número 450.374 que consiste em um documento comprobatório de autorização e cor-

responsabilidade para à execução da pesquisa. A partir desta autorização os parceiros da pesquisa iniciaram as coletas.

Para facilitar a coleta e a marcação de imagens pelos parceiros, foi desenvolvido um software que lhes foi disponibilizado para ser usado através da Internet, o mesmo conta com adaptações que permitem o seu uso em Smartphones, possibilitando a utilização da sua câmera para as coletas. Esse software foi criado com o auxílio do Play Framework<sup>1</sup> na versão 2.3.7 com linguagem de programação Java, onde foram implementados mecanismos de segurança para garantir que as imagens enviadas a ele fossem acessadas somente por pessoas autorizadas.

Como mostrado na Figura 4.2, para ter acesso às funcionalidades do sistema, o usuário precisa se identificar informando um login e uma senha. Após autorizado, o usuário terá acesso ao sistema que libera duas funcionalidades chamadas de “Imagens” e “Análise”.

Na opção “Imagens” o usuário tem opção de visualizar apenas as imagens que ele já submeteu ao sistema, dessa forma ele não terá acesso às imagens enviadas por outros usuários, garantindo assim a integridade. Esta opção também possibilita ao usuário enviar novas imagens através do botão “Enviar imagens”.

Como pode ser observado na Figura 4.3, o usuário conta com diversas opções para enviar as imagens ao sistema, sendo possível selecionar arquivos de imagens que foram capturadas previamente ou capturar a imagem através da câmera, caso o usuário esteja acessando o sistema através de seu Smartphone.

Após o envio das imagens é necessário que o usuário, especialista da área dermatológica, utilize seus conhecimentos sobre a patologia para realizar as marcações nas imagens de forma que posteriormente se possa extrair informações necessárias ao problema, essa é a finalidade da funcionalidade “Análise”, ao acessá-la o usuário irá encontrar as suas imagens que ainda não foram analisadas, como mostrado na Figura 4.4, então ele poderá selecionar uma delas para iniciar a etapa de marcação.

Para realizar a marcação, o usuário precisa pintar na imagem as áreas que correspondem à patologia, distinguindo suas classes pela cor da marcação, como pode ser observado na Figura 4.6a, nas opções laterais da tela ele se-

---

<sup>1</sup>[www.playframework.com](http://www.playframework.com)

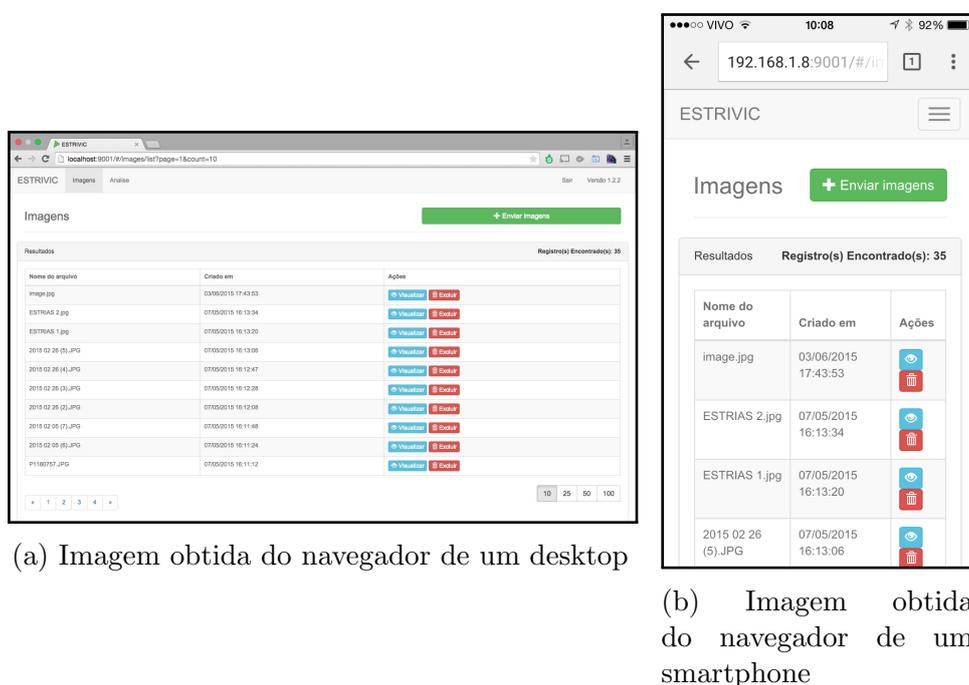


Figura 4.1: Tela de imagens enviadas ao sistema

leciona qual classe do problema irá marcar e também pode determinar o tamanho do pincel para realizar a marcação, facilitando assim, a pintura da área em algumas situações.

O usuário deve analisar a imagem marcando todas as áreas afetadas, sendo que uma mesma imagem pode conter várias classes, conforme mostra a Figura 4.6b. Após realizadas as marcações, o usuário finaliza o processo clicando no botão “Finalizar” e então essa é armazenada no sistema para uso posterior.

Durante o desenvolvimento do projeto os parceiros coletaram 36 imagens, dentre elas a maioria possuía amostras das estrias Rubras e Albas que são mais comuns. Em relação a estria Nigra foi coletada somente uma amostra, por ser encontrada somente em pacientes com fototipo IV e V, e quanto à estria Cerúlea não foi coletada nenhuma amostra pois em sua maioria ocorrem em pacientes com uso extensivo de corticoides o que não é comum.



Figura 4.2: Tela de autenticação do sistema

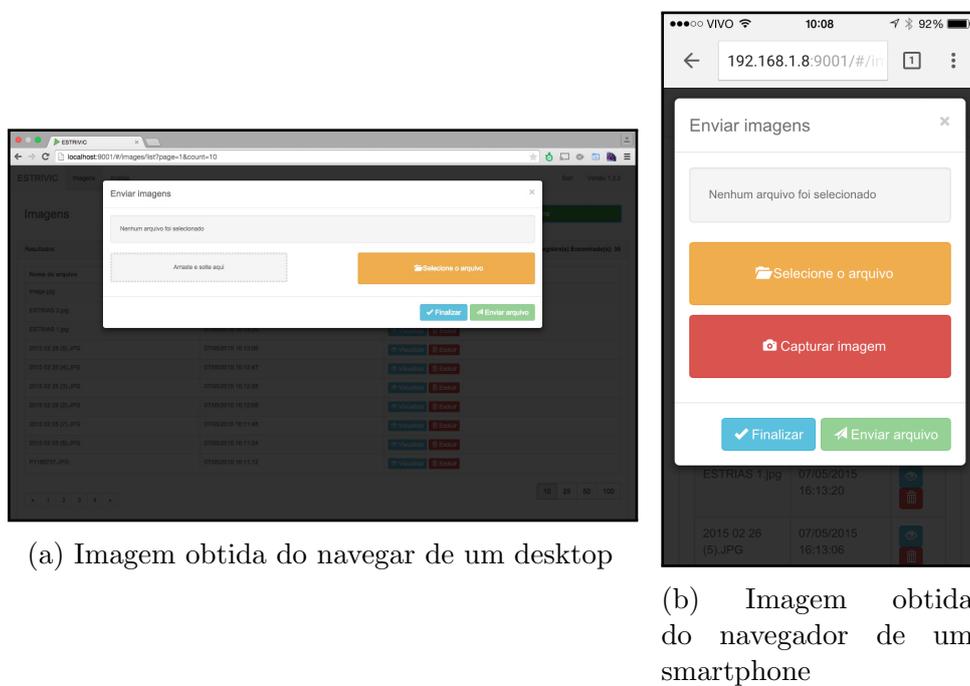
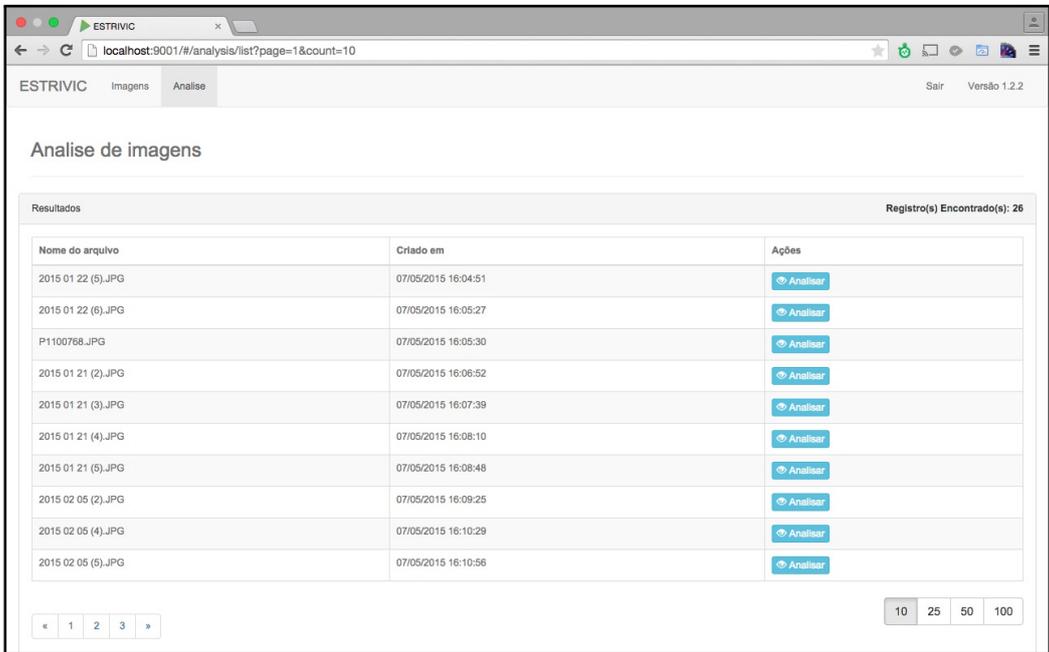


Figura 4.3: Tela de envio imagens ao sistema



The screenshot shows the 'Análise de imagens' page in the ESTRIVIC application. The page title is 'Análise de imagens' and it displays a table of image analysis results. The table has three columns: 'Nome do arquivo', 'Criado em', and 'Ações'. There are 10 rows of data, each representing an image file. The 'Ações' column contains a blue 'Analisar' button for each row. The page also includes a navigation bar with 'Imagens' and 'Análise' tabs, and a version number 'Versão 1.2.2'. The URL in the browser is 'localhost:9001/#/analysis/list?page=1&count=10'.

Nome do arquivo	Criado em	Ações
2015 01 22 (6).JPG	07/05/2015 16:04:51	Analisar
2015 01 22 (6).JPG	07/05/2015 16:05:27	Analisar
P1100768.JPG	07/05/2015 16:05:30	Analisar
2015 01 21 (2).JPG	07/05/2015 16:06:52	Analisar
2015 01 21 (3).JPG	07/05/2015 16:07:39	Analisar
2015 01 21 (4).JPG	07/05/2015 16:08:10	Analisar
2015 01 21 (6).JPG	07/05/2015 16:08:48	Analisar
2015 02 05 (2).JPG	07/05/2015 16:09:25	Analisar
2015 02 05 (4).JPG	07/05/2015 16:10:29	Analisar
2015 02 05 (6).JPG	07/05/2015 16:10:56	Analisar

Figura 4.4: Imagem obtida da lista de imagens a serem analisadas

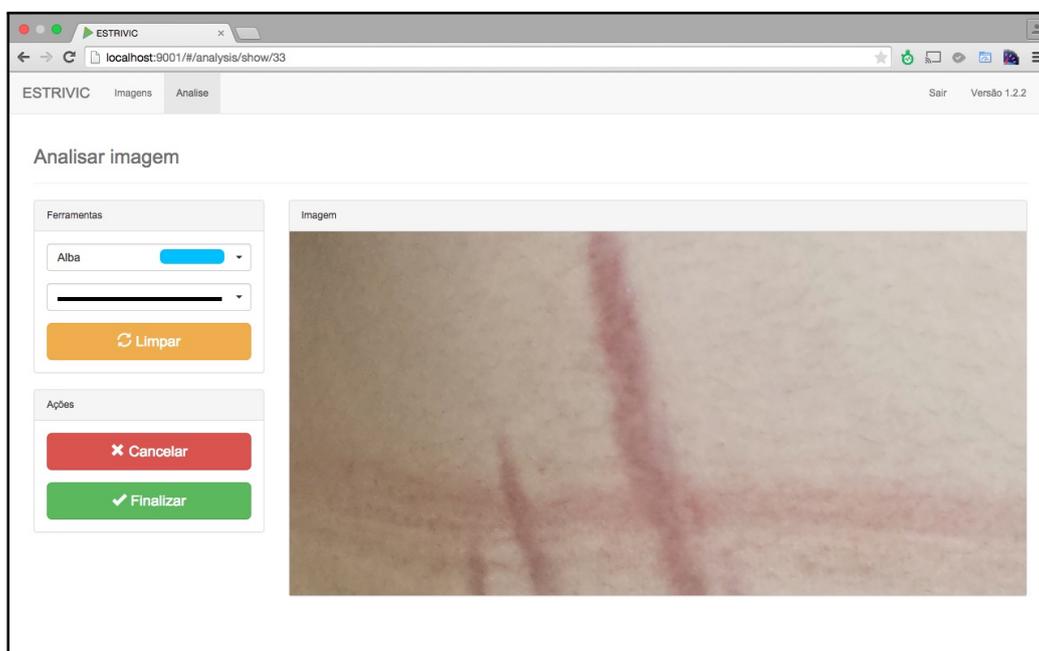
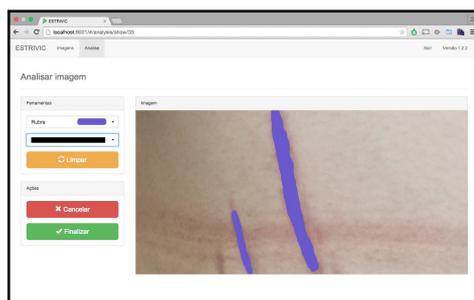
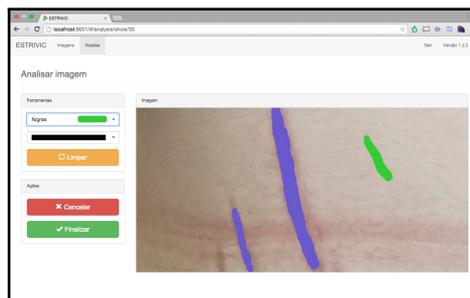


Figura 4.5: Imagem da tela de análise



(a) Estria rubra sendo marcada por especialista



(b) Imagem ilustrando a possibilidade de várias classes na mesma imagem

## 4.2 Modelo proposto baseado em superpixel

O modelo proposto baseado em superpixel foi dividido em duas etapas, na primeira foi feita a aprendizagem por parte da aplicação, na qual é utilizada a marcação realizada pelos usuários para o treinamento dos classificadores. E a segunda etapa realiza a segmentação através dos classificadores obtidos na etapa anterior, esse fluxo pode ser visualizado na Figura 4.7.

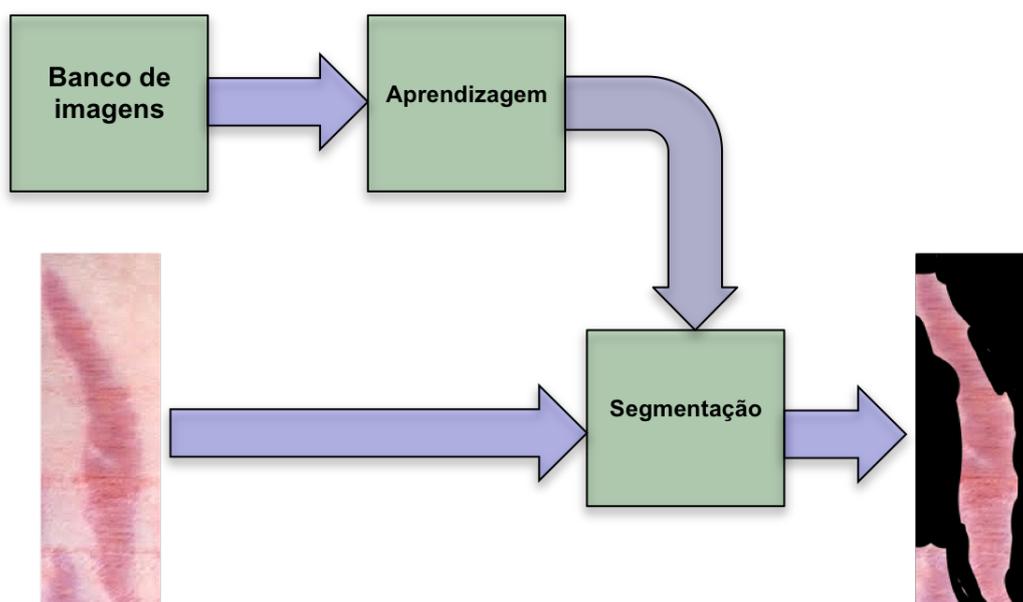


Figura 4.7: Fluxo da segmentação por superpixel

### 4.2.1 Aprendizagem

Inicialmente é preciso construir uma base de conhecimento para que posteriormente o software, através desta, consiga identificar e classificar as estrias. A etapa da aprendizagem é composta por subtarefas como exposto na Figura 4.8.

#### Segmentação em superpixel

A primeira sub tarefa do fluxo de aprendizagem é a segmentação das imagens em superpixels, que é feito com o objetivo de agrupar pixels semelhantes e que provavelmente pertençam ao mesmo objeto na imagem. Essa sub tarefa demanda um custo computacional adicional em relação às técnicas convencionais de pixel-a-pixel, porém nas próximas etapas o custo computacional é

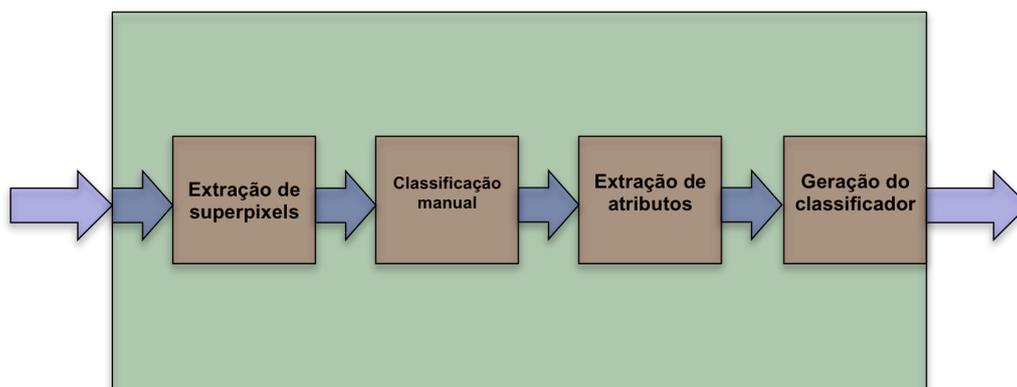


Figura 4.8: Fluxo de aprendizagem

reduzido, como o demonstrado anteriormente na seção 3.3.1.

Para realizar a segmentação em superpixels foi utilizada a técnica SLIC com a implementação na linguagem de programação Java (jSLIC) proposto por [6], que segundo ele, conta com melhorias de performance devido à paralelização do processamento.

Devido ao fato desta implementação ser liberada publicamente, foi possível realizar alguns aprimoramentos de performance na conversão de espaços de cores para otimizar o consumo de memória e adaptar algumas interfaces para que tivessem uma integração maior com o software desenvolvido durante esse projeto.

### **Classificação dos superpixels**

Após a imagem ser segmentada em superpixels é preciso identificar quais deles pertencem à patologia e a qual classe da mesma, classificando-os. Para tanto, utiliza-se a marcação realizada pelos especialistas na criação do banco de imagens, onde ela é armazenada de modo a não interferir nos dados da imagem original, então é gerada uma nova imagem somente com a marcação. Como pode ser observado na Figura 4.10.

Para identificar se a área possui marcações, o usuário deve informar um parâmetro na etapa de aprendizagem, conhecido como “Limiar de preenchimento do superpixel”, esse parâmetro define a porcentagem mínima de preenchimento da marcação sobre um superpixel para considerar que o mesmo

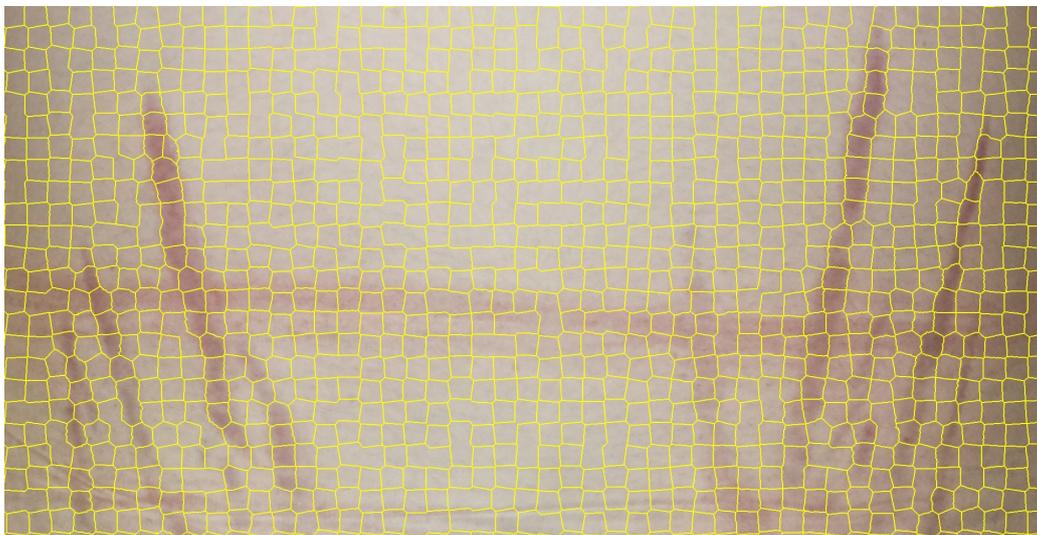


Figura 4.9: Imagem de pele estriada segmentada em superpixel



Figura 4.10: Imagem ilustrativa da marcação realizada por um especialista

pertença a alguma classe do problema.

Sendo assim, para que o software consiga identificar a classe de cada superpixel ele precisa colocar os contornos que o definam sobre a imagem da marcação, dessa maneira recortando um superpixel da imagem marcada, depois o histograma de cores é obtido para calcular a porcentagem de preenchimento de marcação, se ela for maior que o parâmetro definido no início

do processo, o superpixel é separado para posterior processamento e é classificado conforme a cor da marcação.

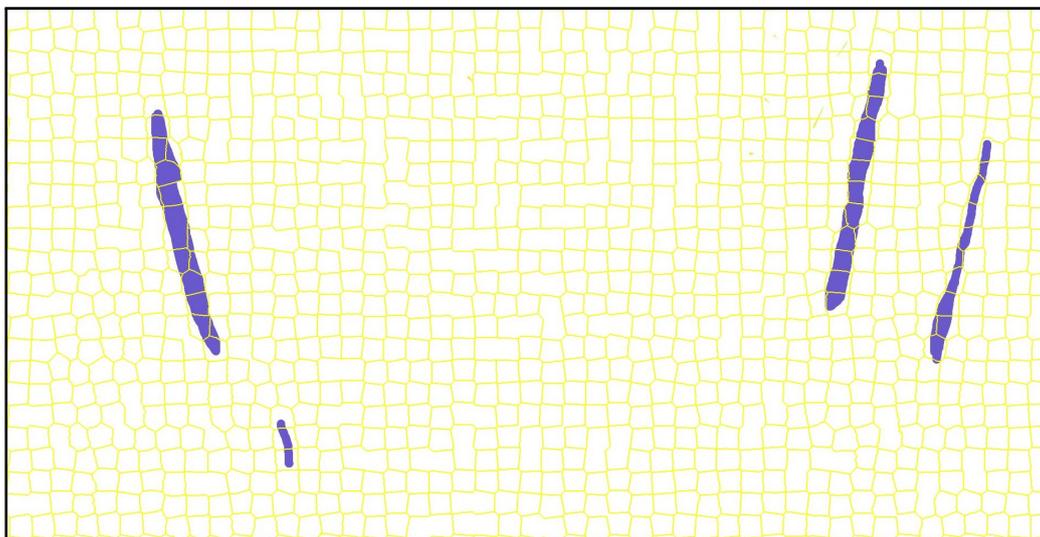


Figura 4.11: Imagem ilustrativa dos superpixels colocados sobre a imagem da marcação

### Extração de atributos

Após os superpixels que contêm informações da patologia serem separados e classificados, eles são usados para extrair informações que serão utilizados posteriormente para criar os classificadores que consolidam o conhecimento.

Para realizar a extração de atributos foi utilizada uma ferramenta implementada pelo grupo de pesquisa INOVISÃO, que durante o desenvolvimento desse projeto foi melhorada e otimizada, além de receber a implementação de extratores para novos atributos.

Em suma, foram utilizados atributos de cor e textura que já foram revisados anteriormente neste trabalho na seção 3.4. Resumidamente, foram utilizados como atributos os espaços de cor RGB e HSV, para textura foram extraídos os atributos Contraste, Correlação, Homogeneidade, Energia e Entropia da GLCM. No final dessa sub tarefa foi gerado um arquivo com a extensão “arff” que consolida os dados extraídos.

### Treinamento dos classificadores

Os classificadores são gerados a partir das informações extraídas na etapa anterior de forma a criar um conhecimento. Para geração desses classificadores foi utilizado o framework Waikato Environment for Knowledge Analysis (Weka) desenvolvido pela Universidade de Waikato licenciado sob abrigo da General Public License, o que possibilitou estudar e alterar o respectivo código fonte.

O Weka tem como objetivo agregar algoritmos provenientes de diferentes abordagens/paradigmas na sub-área da inteligência artificial dedicada ao estudo da aprendizagem por parte de máquinas. Essa sub-área tem a função de desenvolver algoritmos e técnicas que permitam à um computador “aprender”.

Foram utilizadas as técnicas Random Forest, SVM, J48, que já foram revisadas anteriormente na seção 3.5. Como resultado desta subtarefa foi gerado um arquivo para cada classificador, com a extensão “model“ que consolidou o conhecimento gerado, finalizando assim a etapa de aprendizagem.

#### 4.2.2 Segmentação

A segmentação é a segunda etapa do processo, no qual é utilizado os classificadores gerados na etapa de aprendizagem para classificar novas instâncias (superpixels de outras imagens não utilizadas no treinamento), simplificando o processo de segmentação que ao invés de analisar pixel a pixel pode analisar um conjunto de pixels com características semelhantes.

Após a segmentação, o software oferece a opção de visualizar a imagem segmentada, permitindo que esse resultado seja salvo, processo do qual é gerada uma imagem binarizada para cada classe do problema, isolando assim o resultado da segmentação para cada classe em uma imagem.

Foi desenvolvido um novo software com o intuito de realizar a segmentação a partir do conhecimento obtido na etapa anterior, na Figura 4.12 é apresentada a interface deste programa junto com a descrição de suas funcionalidades exposta abaixo:

1. Lista de imagens a serem segmentadas

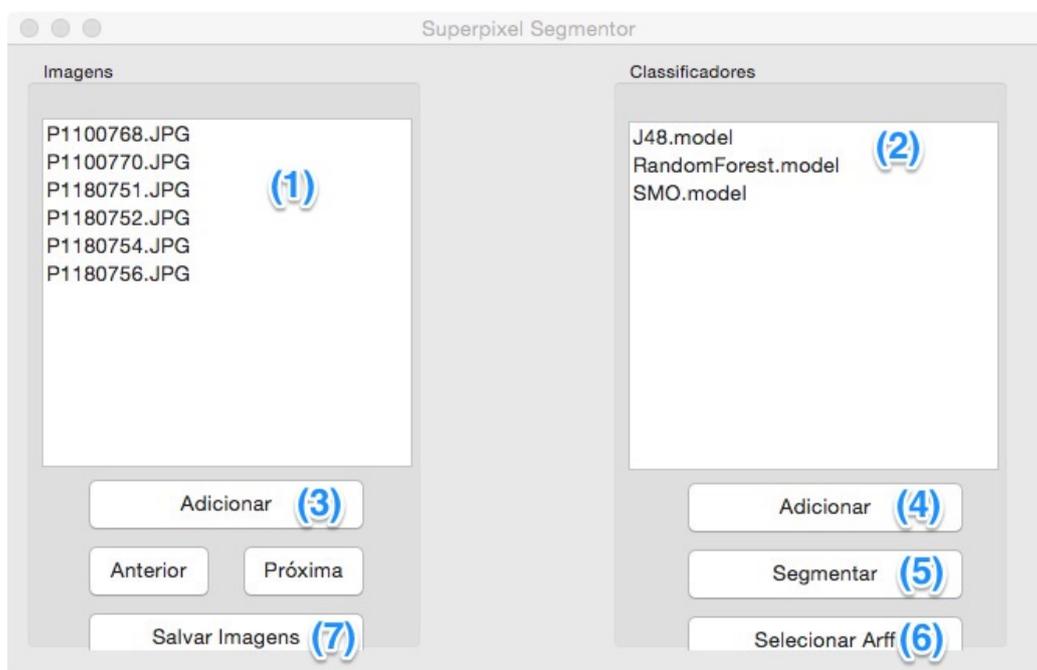


Figura 4.12: Imagem ilustrativa do programa de segmentação por superpixels

2. Lista de classificadores a serem usados na segmentação
3. Botão para adicionar novas imagens a lista
4. Botão para adicionar novos classificadores a lista
5. Botão para segmentar a imagem selecionada na lista, utilizando o classificador que também esteja selecionado.
6. Botão para selecionar o ARFF
7. Botão para segmentar todas as imagens da lista com o classificador que esteja selecionado.

Inicialmente na tela apresentada pela Figura 4.12, o usuário precisa adicionar as imagens que deseja segmentar na lista através do botão (3), em seguida adicionar os classificadores que serão utilizados para segmentação (4), por fim deve ser adicionado o ARFF que foi utilizado na geração dos classificadores (6). O arquivo ARFF é necessário, pois é através dele que a aplicação consegue identificar quais atributos devem ser extraídos das novas imagens, bem como as possíveis classes em que os superpixels serão classificados, fazendo com que as informações utilizadas na aprendizagem sejam as

mesmas utilizadas no processo de segmentação.

O usuário pode segmentar somente uma imagem, para isso, deve selecioná-la na lista de imagens e selecionar o classificador com o qual será realizada a segmentação, finalmente clicar no botão Segmentar (5).

A segmentação é realizada em um processo semelhante ao da aprendizagem, como pode ser visualizado na Figura 4.13, no qual a imagem é segmentada em superpixel, depois são extraídos os atributos para cada um deles com base nas informações do arquivo ARFF. Esses atributos são usados para classificar os superpixels através do classificador selecionado. Essa etapa utiliza-se do conhecimento adquirido previamente na etapa de aprendizagem para conseguir segmentar imagens que ainda não haviam sido expostas ao software.

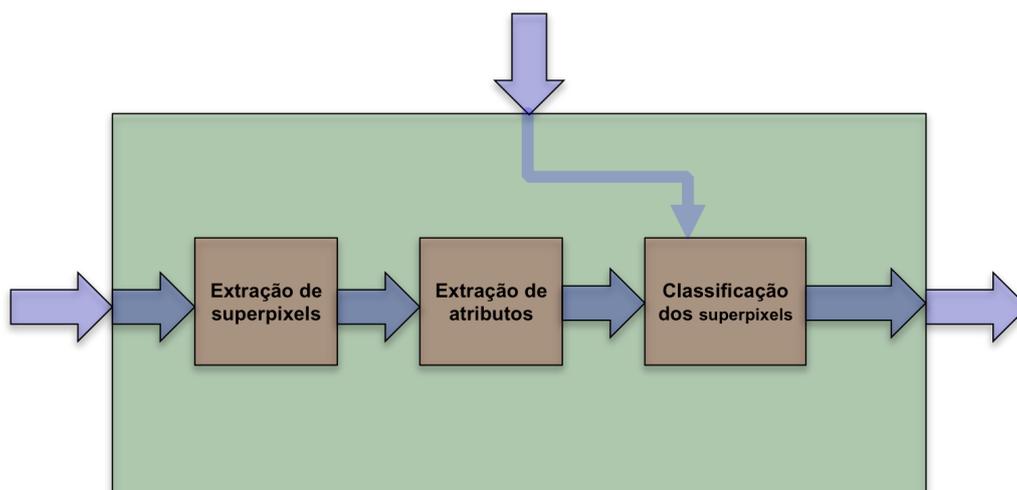


Figura 4.13: Imagem ilustrativa do fluxo de segmentação

O sistema também possibilita o processamento de todas as imagens da lista, no qual cada imagem passa pelo procedimento descrito anteriormente e o resultado é gravado em um arquivo compactado contendo as segmentações para cada imagem separada pelas suas classes.

# Capítulo 5

## Resultados, Análise e Discussão

Nesta seção são apresentados os resultados das técnicas implementadas para segmentação de estrias, bem como a efetuação dos testes estatísticos para verificar quais deles teriam um melhor desempenho no problema.

Para os experimentos, o banco de imagem foi separado em duas partes, uma utilizada para a etapa de aprendizagem e a outra para testar a etapa de segmentação. Para os testes foram separadas 13 imagens compostas com as seguinte amostras: 6(seis) de estrias rubras, 6(seis) de estrias albas e uma (1) de estrias negra. Em virtude de existir apenas uma amostra dessa última no banco de imagem, ela teve que ser usada nas duas etapas (aprendizagem e teste segmentação).

No aprendizado foram utilizadas as 24 imagens restantes do banco de imagens, delas foram extraídos 3017 superpixels, os quais continham as seguintes quantidades de superpixels: 312 de estria rubra, 220 da estria alba, 112 da estria negra, 1201 de pele sem estria e 1172 de fundo. Para calcular as métricas de segmentação, foram empregadas como referência as marcações realizadas pelos especialistas.

### 5.1 Análise da Taxa de Acerto dos Classificadores

Os algoritmos de aprendizagem supervisionada foram construídos a partir dos atributos extraídos dos superpixels separados por suas classes, como descrito anteriormente. Para evitar que os classificadores “decorem” as respostas de classificação quando fossem utilizados nesse experimento foram utilizadas imagens diferentes na etapa de aprendizagem e teste dos segmentadores.

Para realizar os testes de acerto dos classificadores foi utilizada a validação cruzada, onde 10% do conjunto de treinamento foi isolado para a execução dos testes após o treinamento, é importante frisar que no treinamento não existem amostras repetidas, de modo que o conjunto de treinamento seja distinto do conjunto de testes.

Como pode ser observado na tabela 5.1, o algoritmo de aprendizagem automática que obteve melhor resultado foi o *Random Forest*, seguido pelo *J48* e por fim o *SVM*.

Tabela 5.1: Validação cruzada das técnicas de aprendizagem automática

Técnica	Instâncias classificadas corretamente	Instâncias classificadas incorretamente
SVM	94.6508%	5.3492%
Random Forest	99.9299%	0.0701%
J48	99.5276%	0.4724%

Na seção abaixo encontra-se a exposição do resultado da segmentação com a aplicação de cada uma dessas técnicas.

## 5.2 Resultados da Segmentação por Superpixel

Para comparar a eficiência dos segmentadores foram calculadas as métricas para sua avaliação, já apresentadas anteriormente neste trabalho. Para cada técnica de aprendizagem automática é calculada uma métrica, pois essas técnicas são responsáveis pela classificação de cada superpixel da imagem, conseqüentemente o resultado está relacionado diretamente com técnica utilizada. Com propósito de fazermos uma análise mais precisa para facilitar a identificação do problema, foram calculadas também as métricas para a segmentação de cada classe do problema.

As métricas foram obtidas para cada um dos segmentadores utilizando as técnicas de aprendizagem automática estão expostas abaixo em formato de tabela juntamente com exemplos das imagens segmentadas. Por fim esses resultados serão analisados na subseção 5.4.

Tabela 5.2: Avaliação do segmentador utilizando *Random Forest*

Classe	<i>Precisão</i>	<i>Taxa de detecção</i>	<i>Medida-F</i>
Estria Alba	5,09%	8,93%	6,49%
Estria Rubra	36,34%	76,79%	49,31%
Estria Nigra	3,52%	7%	4,62%
Pele	94,44%	89,86%	92,09%
Fundo	79,69%	94,25%	86,36%
Total	85,21%	78,76%	81,86%

Tabela 5.3: Avaliação do segmentador utilizando *J48*

Classe	<i>Precisão</i>	<i>Taxa de detecção</i>	<i>Medida-F</i>
Estria Alba	4,32%	12,27%	6,38%
Estria Rubra	34,13%	84,86%	48,62%
Estria Nigra	3,52%	7%	4,68%
Pele	92,60%	89,11%	90,82%
Fundo	77,83%	93,79%	85,07%
Total	84,93%	72,12%	78%

Tabela 5.4: Avaliação do segmentador utilizando SVM

Classe	<i>Precisão</i>	<i>Taxa de detecção</i>	<i>Medida-F</i>
Estria Alba	0%	0%	0%
Estria Rubra	0%	0%	0%
Estria Nigra	0%	0%	0%
Pele	79,36%	94,29%	86,19%
Fundo	94,57%	91,07%	92,78%
Total	83,36%	80,31%	81,81%



(a) Imagem original

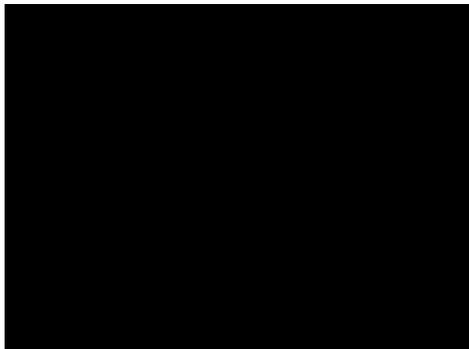
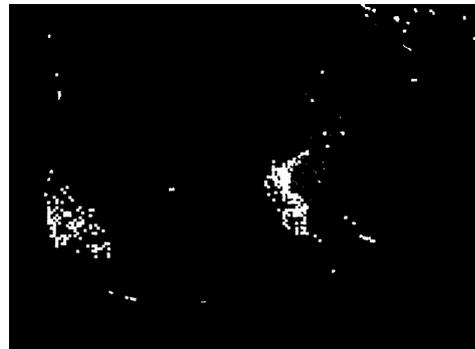
(b) *Random Forest*(c) *SVM*(d) *J48*

Figura 5.1: Exemplo da segmentação de imagem para classe Alba

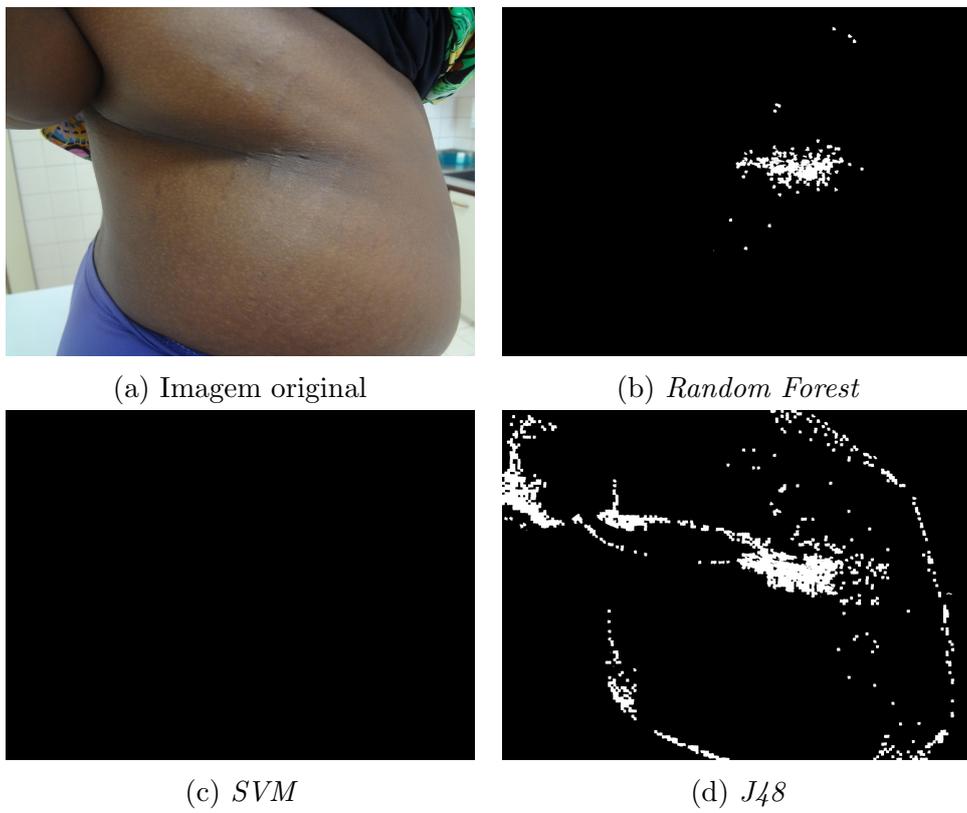


Figura 5.2: Exemplo da segmentação de imagem para classe Nigra



(a) Imagem original

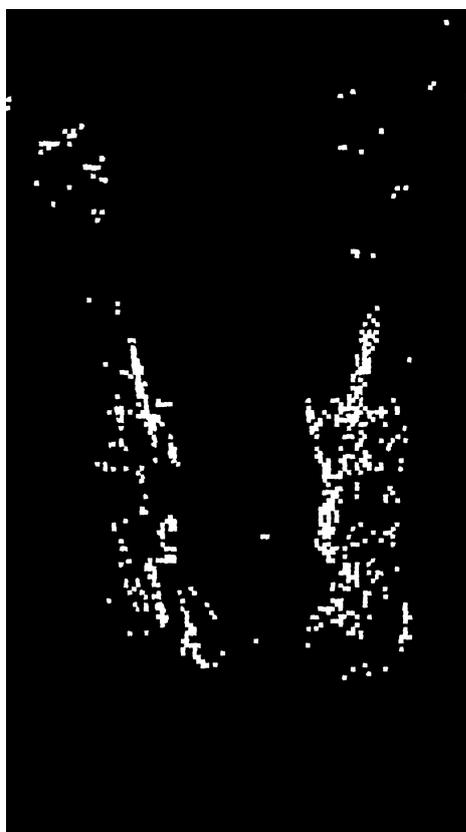
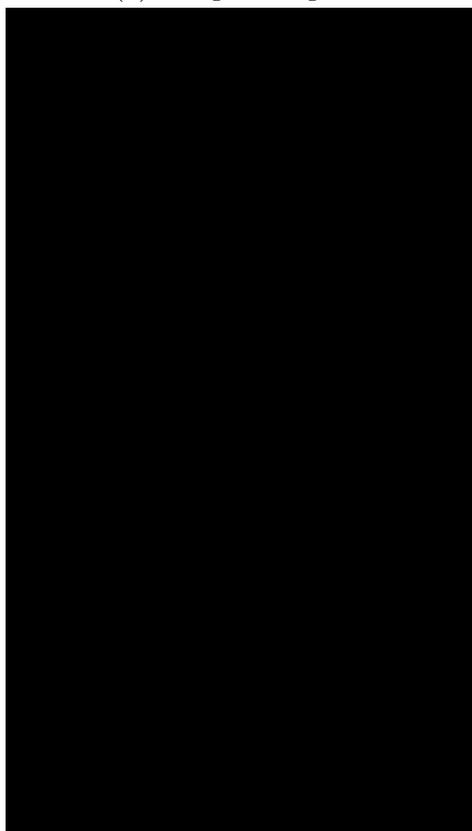
(b) *Random Forest*(c) *SVM*(d) *J48*

Figura 5.3: Exemplo da segmentação de imagem para classe Rubra



(a) Imagem original

(b) *Random Forest*(c) *SVM*(d) *J48*

Figura 5.4: Exemplo da segmentação de imagem para classe Pele



(a) Imagem original

(b) *Random Forest*(c) *SVM*(d) *J48*

## 5.3 Comparação

Para comparar os resultados foi utilizado um método estatístico conhecido como Análise de Variância (ANOVA), que visa a comparação de 2 conjuntos ou mais e determina se a diferença observada é causada apenas por variações aleatórias de uma amostra a outra ou se os dados vêm de populações onde as médias são de fato diferentes. A avaliação é feita verificando o quão diferentes são as médias e quanto as observações estão dispersas ao redor das respectivas médias.

O cálculo da ANOVA foi feito através do software estatístico R com auxílio da interface gráfica RStudio, no qual foram submetidos os valores presentes na Tabela 5.5 para a análise. Antes de realizar os cálculos foram assumidas duas hipóteses:

Tabela 5.5: Dados usados para calcular a ANOVA

Técnica	Classe	Medida-F
Alba	Random Forest	6,49%
Rubra	Random Forest	49,31%
Nigra	Random Forest	4,68%
Pele	Random Forest	92,02%
Fundo	Random Forest	86,36%
Alba	J48	6,38%
Rubra	J48	48,62%
Nigra	J48	4,68%
Pele	J48	90,82%
Fundo	J48	85,07%
Alba	SVM	0%
Rubra	SVM	0%
Nigra	SVM	0%
Pele	SVM	86,19%
Fundo	SVM	92,78%

- $H_0$  - as médias são iguais, não existem evidências estatísticas de que elas sejam diferentes;
- $H_1$  - as médias são diferentes.

No teste de hipóteses, o termo *p-value* é usado para indicar o quão provável é que os itens que estão sendo comparados serem os mesmos, quando

seu valor é abaixo de 0.05, indica que é muito improvável que os itens são o mesmo, ou seja, eles são diferentes. Sendo assim para o  $p$ -value abaixo de 0.05 será considerado a hipótese  $H_1$  como verdadeira, caso contrário a hipótese  $H_0$  será verdadeira.

Tabela 5.6: Resultados do teste estatística ANOVA

<i>Graus de liberdade</i>	<i>Soma dos quadrados</i>	<i>Média dos quadrados</i>	<i>f-value</i>	<i>p-value</i>
2	453	227	1.462	0.288

Como demonstrado na tabela 5.6, o  $p$ -value foi superior ao valor de referência, sendo assim aceitamos a hipótese  $H_0$  como verdadeira, ou seja, não existem evidências estatísticas de que as médias sejam diferentes.

## 5.4 Análise

Após identificar que as três técnicas tiveram desempenho semelhante no problema, a investigação voltou-se para identificar o que havia influenciado nos resultados da segmentação, pois eles apresentavam uma baixa precisão na identificação das estrias. Para realizar essa análise, decidiu-se por verificar as duas métricas que compõe a *Medida-F*, são elas a *Precisão* e a *Taxa de detecção*.

A *Taxa de detecção* que tem como objetivo calcular a porcentagem de acerto somente sobre a área de interesse, ou seja, ela irá calcular a porcentagem da estria que foi classificada de forma correta, enquanto a *Precisão* é uma métrica complementar, pois ela irá analisar em toda a imagem quais partes foram classificadas de forma errada.

Tabela 5.7: Métricas de desempenho para as técnicas utilizadas

Técnica	<i>Taxa de detecção</i>	<i>Precisão</i>	<i>Medida-F</i>
Random Forest	78,76%	85,21%	81,86%
J48	72,12%	84,93%	78,00%
SVM	80,31%	83,36%	81,81%

Se analisarmos as técnicas empregadas utilizando somente suas métricas totais, podemos ser induzidos a acreditar em um resultado que apesar de alto não tenha significância para o problema, esse caso ocorre na utilização da

técnica *SVM*, na qual apresenta um valor de 81,81% para a métrica *Medida-F*, ou seja, ela obteve um bom desempenho na segmentação da imagem, porém se observamos na Tabela 5.4, o seu desempenho na segmentação das classes relativas a estria é 0, a tornando inviável para utilização.

Esse fato ocorre devido a grande parte da imagem ser composta por classes que não são estrias, fazendo com que seu valor tenha baixo impacto sobre as métricas totais, porém se analisadas isoladamente por classes do problema podem revelar informações importantes.

Se observarmos, as técnicas *Random Forest* e *J48*, podemos notar que os valores das métricas calculadas são semelhantes para cada classe do problema. O fato da *Taxa de detecção* ser superior as demais, nos indica que os segmentadores conseguiram classificar uma boa porcentagem da estria corretamente, porém a métrica *Precisão* mostra que, da mesma forma que as estrias têm uma boa taxa de acertos, o restante da imagem está sendo classificado erroneamente, resultando assim com que áreas da imagem que não são estrias sejam classificadas como tal.

Afim de entender o que ocasionou esse efeito, foram analisados os atributos utilizados na solução proposta e foram detectados os dois principais problemas que afetaram diretamente os resultados da segmentação. O primeiro problema identificado foi em relação às cores das estrias.

No banco de imagens montado durante o desenvolvimento deste projeto, foram coletadas imagens de diferentes pacientes, portanto, na sua composição há amostras com diferentes fototipos de pele (Figura 5.6 demonstra as diferenças dos fototipos). Quando analisamos a variação do atributo de cor, podem ocorrer casos que as cores das estrias podem ser confundidas com diferentes fototipos de pele, como pode ser observado na imagem 5.7, na qual temos uma amostra de estria alba que pode ser facilmente confundida com a cor da pele.

Para contornar esse problema, foram usados os atributos de textura para criar descritores mais fortes que não dependessem somente da cor para discriminar as características de uma estria. De modo a identificar a falha nos atributos de textura, foram coletados os atributos de textura da pele, para que ao serem comparados, esses valores pudessem identificar se eles seriam capazes de discriminar uma estria da pele.



Figura 5.6: Fototipos de pele

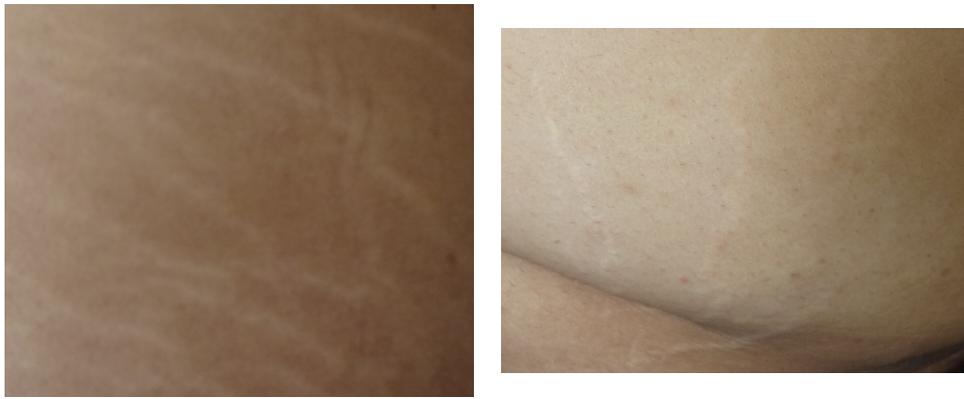


Figura 5.7: Proximidade da cor de estrias com alguns fototipos de pele

A variação dos valores de textura da pele ao serem comparados aos valores de textura das estrias não demonstram uma diferença significativa, de maneira que conseguissem discernir entre um ou outro. As imagens coletadas pelos parceiros e disponibilizadas para a realização desse trabalho, na sua maioria são imagens distantes das estrias e em baixa qualidade, tornando esse um dos fatores que influenciaram na qualidade dos atributos de textura devido à qualidade da imagem.

Diante as circunstâncias e considerando que as imagens nem sempre tinham uma boa qualidade interferindo diretamente na riqueza de detalhes de textura da imagem, influenciando assim nos atributos de textura extraídos da mesma, o atributo de cor, por si próprio não consegue formar um bom discriminador das características de uma estria devido, pois fototipos de pele podem confundir-lo e o atributo de textura que deveria servir para fortalecer o poder discriminatório não consegue extrair características suficientes devido a qualidade das imagens.

# Capítulo 6

## Trabalhos Futuros

Conforme o exposto sobre os resultados obtidos, conclui-se que esse projeto não atingiu os resultados pretendidos que o permitisse ser utilizado como uma ferramenta de análise da patologia. Entretanto foram utilizadas técnicas inovadoras como o superpixel e identificados vários pontos que precisam ser melhorados para que ele possa servir de inspiração para novas pesquisas até alcançar o seu objetivo final, criar uma aplicação que ajude os especialistas a extrair dados da patologia, de forma que os auxilie no tratamento e acompanhamento das estrias.

Para aqueles que se interessarem pela pesquisa e quiserem dar continuidade ao projeto aqui exposto, seguem elencados nesse projeto alguns quesitos já identificados.

Um dos passos mais importantes na manutenção desta pesquisa é a evolução da base de imagens, essa deve se encontrar sempre em crescimento de forma que consiga abranger o máximo de condições possíveis desta patologia, porém devem ser estabelecidos protocolos para a captura de imagens, para evitar que se repitam os problemas com a qualidade das imagens, conforme o exposto na análise dos resultados.

Outro ponto importante é testar novos atributos que tenham um poder de descrição maior, para serem extraídas características que consigam discernir melhor as estrias do restante e que possam aumentar a precisão da segmentação final. Da mesma forma é preciso aprimorar o algoritmo que extrai os atributos dos superpixels, pois atualmente ele analisa todos os pixels que estão contidos no superpixel, perdendo assim uma das maiores vantagens de se utilizar superpixel, que é a redução de informação a ser processada.

Diante aos resultados finais obtidos não serem satisfatórios, não foi implementada nenhuma técnica de medição da área das estrias, porém identificamos alguns pontos que devem ser levados em consideração na implementação da mesma, são eles:

- Para obter o valor da área em centímetros é necessário obtermos um fator de proporcionalidade para que se converta uma área em pixels para centímetro. Uma das maneiras imaginadas para isso foi utilizar um objeto de referência nas imagens, o qual soubéssemos previamente o seu tamanho, para que durante a análise fosse calculado um fator de proporcionalidade que nos diria quantos pixels correspondem a um centímetro, permitindo assim a conversão.
- Nem sempre as estrias se apresentam na imagem de forma plana, por exemplo, uma estria situada ao longo da curvatura do braço, faz com que na captura da imagem ela fique em uma escala diferente da real, influenciando assim na sua medição. Para solucionar esse problema seria necessário aplicar técnicas de ortonormalização para planar essa imagem de modo que não haja curvas, proporcionando uma medição mais precisa.

## Apêndice A

# Termo de consentimento livre e esclarecido

O conteúdo do apêndice está disponível no link: <[https://www.dropbox.com/s/he61okokqtbdkbd/termo\\_de\\_consentimento\\_livre\\_e\\_esclarecido.doc](https://www.dropbox.com/s/he61okokqtbdkbd/termo_de_consentimento_livre_e_esclarecido.doc)>.

## Apêndice B

# Termo de autorização das clínicas

O conteúdo do apêndice está disponível no link: <[https://www.dropbox.com/s/osw6tg3etrlsann/autorizacao\\_clinicas.doc](https://www.dropbox.com/s/osw6tg3etrlsann/autorizacao_clinicas.doc)>.

## Apêndice C

# Termo de autorização de uso de imagem

O conteúdo do apêndice está disponível no link: <[https://www.dropbox.com/s/m15b0gk1f2v7izg/termo\\_de\\_autorizacao\\_de\\_uso\\_de\\_imagens.doc](https://www.dropbox.com/s/m15b0gk1f2v7izg/termo_de_autorizacao_de_uso_de_imagens.doc)>.

# Referências Bibliográficas

- [1] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk. Slic superpixels compared to state-of-the-art superpixel methods. *IEEE Trans. Pattern Anal. Mach. Intell.*, 34(11):2274–2282, November 2012.
- [2] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Süssstrunk. Slic superpixels. Technical report, EPFL, 2010.
- [3] F. M. H. Ahmad, D. Ihtatho, A. M. Affandi, and S. H. Hussein. Objective assessment of psoriasis erythema for pasi scoring. 2008.
- [4] D. H. Ballard and C. M. Brown. *Computer Vision*. Prentice-Hall, 1982.
- [5] A. Blasiak. *A Comparison of Image Segmentation Methods*. PhD thesis, Middlebury College, 2007.
- [6] J. Borovec and J. Kybic. jslic : superpixels in imagej. In *Computer Vision Winter Workshop*.
- [7] B. M. Brandoli. Inferência gramatical aplicada ao reconhecimento de comportamentos em animais, Novembro 2007. Relatório final apresentado à Coordenação do Curso como parte dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação.
- [8] F. H. B. Cardoso. Um método automático para o ajuste de segmentadores de imagens baseados em informações de textura e cor. 2009.
- [9] F. R. Carramaschi, G. Landman, L. P. Vana, and M .C. Ferreira. Estudo das fibras oxitalânicas em estrias: variações em relação à pele normal. *Revista do Hospital das Clínicas da Faculdade de Medicina de SP*, pages 35 – 38, 1995.
- [10] B. K. Cordeiro. Tratamento de estrias. *Revista de Cosmiatria e Medicina Estética*, 1996.

- 
- [11] E. P. Costa, A. C. Lorena, Carvalho, and A. A. Freitas. A review of performance evaluation measures for hierarchical classifiers. In *2007 AAAI Workshop, Vancouver*. AAAI Press, 2007.
- [12] E. R. Davies. *Computer and Machine Vision: Theory, Algorithms, Practicalities*. Elsevier, Amsterdam, Oxford, fourth edition, 2012.
- [13] M. De Maio. *Tratado de medicina estética*. Number v. 2 in Tratado de medicina estética. Roca, 2004.
- [14] B. C. Dey and R. R. Galigekere. Automatic detection of acne scars: Preliminary results. 2013.
- [15] D. A. Forsyth and J. Ponce. *Computer Vision - A Modern Approach*. Pearson, 2012.
- [16] R. Gonzalez. *Digital Image Processing*. Prentice-Hall, Inc, second edition, 2002.
- [17] R. Gonzalez and R. E. Woods. *Processamento Digital de Imagens*. Pearson, third edition, 2009.
- [18] W. N. Gonçalves, V. A. Saueia, B. B. Machado, J. A. Silva, K. P. DE Souza, and H. Pistori. Técnicas de segmentação baseadas em subtração de fundo e modelos de cores: Um estudo comparativo. *XXVIII CI-LAMCE - Iberian Latin American Congress on Computational Methods in Engineering*, 2007.
- [19] E. C. O. Guirro and Guirro R. R. J. Fisioterapia dermato-funcional: Recursos, fundamentos, patologias. 2004.
- [20] B. Jahne and H. Haubecker, editors. *Computer Vision and Applications: A Guide for Students and Practitioners*. Academic Press, Inc., Orlando, FL, USA, 2000.
- [21] R. S. Michalski, I. Bratko, and M. Kubat. *Machine Learning and Data Mining Methods and Applications*. John Wiley & Sons LTD, 1998.
- [22] Thomas M. Mitchell. *Machine Learning*. McGraw-Hill, Inc., New York, NY, USA, 1 edition, 1997.
- [23] P. Neubert and P. Protzel. Superpixel benchmark and comparison. *Chemnitz University of Technology - Department of Electrical Engineering and Information Technology*, 2012.

- 
- [24] J. R. Parker. *Algorithms for Image Processing and Computer Vision*. Wiley Publishing, Inc., second edition, 2011.
- [25] A. L. Pasquali. Extração de características utilizando filtro de gabor aplicado à identificação de defeitos no couro bovino, Novembro 2007. Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação.
- [26] L. N. B. Quinta. Utilização de florestas de caminhos Ótimos para identificação de grãos de pólen. Master's thesis, Universidade Católica Dom Bosco, 2011.
- [27] X. Ren and J. Malik. Learning a classification model for segmentation. In *Proceedings of the Ninth IEEE International Conference on Computer Vision - Volume 2, ICCV '03*, pages 10–, Washington, DC, USA, 2003. IEEE Computer Society.
- [28] R. C. B. Rodrigues and R. H. R Viana. Máquinas de vetores de suporte aplicadas à classificação de defeitos em couro bovino, Novembro 2007. Relatório Final submetido como um dos requisitos para a obtenção do título de Bacharel em Engenharia de Computação.
- [29] S. J. Russell and P. Norvig. *Artificial Intelligence: A Modern Approach*. Pearson Education, 2 edition, 2003.
- [30] J. C. Santos, J. R. F. Oliveira, L. V. Dutra, S. J. S. Sant'Anna, and C. D. Rennó. Seleção de atributos usando algoritmos genéticos para classificação de regiões. In *Seleção de atributos usando algoritmos genéticos para classificação de regiões*.
- [31] V. D. O. Santos. Automatic essay scoring: Machine learning meets applied linguistics. Master's thesis, University of Groningen and University of Saarland, 2011.
- [32] M. S. Sato, A. Fukuda, L. L. G. S. Silva, F. Mulinari-Brenner, and R. Tung. Avaliação clínica da eficácia do ácido tricloroacético e da subcisão, isolados ou combinados, no tratamento de estrias abdominais. *Surgical & Cosmetic Dermatology*, 2009.
- [33] R. M. Silva, T. A. Almeida, and A. Yamakami. Análise de métodos de aprendizagem de máquina para detecção automática de spam hosts. *Anais do 12 Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais*, Novembro 2012.

- 
- [34] S. M. Singh and K. Hemachandran. Content-based image retrieval using color moment and gabor texture feature. *International Journal of Computer Science Issues*, 2012.
- [35] J. R. Smith. *Color for Image Retrieval*, pages 285–311. John Wiley & Sons, Inc., 2002.
- [36] D. Stutz, A. Hermans, and B. Leibe. Superpixel segmentation using depth information. <http://davidstutz.de/>, September 2014.
- [37] A. van den Hengel, A. Dick, T. Thormahlen, B. Ward, and P. H. S. Torr. Videotrace: Rapid interactive scene modelling from video. In *ACM SIGGRAPH 2007 Papers*, SIGGRAPH '07, New York, NY, USA, 2007. ACM.
- [38] X. Wang, Z. Chen, and J. Yun. An effective method for color image retrieval based on texture. *Computer Standards & Interfaces*, 34(1):31 – 35, 2012.
- [39] Ian H. Witten, Eibe Frank, and Mark A. Hall. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 3rd edition, 2011.
- [40] H. Zhang, E. Fritts, J. and S. A. Goldman. Image segmentation evaluation: A survey of unsupervised methods. 2007.
- [41] X. Zhang, D. A. Silverstein, J. E. Farrell, and B. A. Wandell. Color image quality metric s-cielab and its application on halftone texture visibility. In *Compcon '97. Proceedings, IEEE*, pages 44–48, Feb 1997.
- [42] P. Zhenz, R. M. Lavker, and A. M. Kligman. Anatomy of striae. *British Journal of Dermatology*, 112(2):185–193, 1985.