Silvio Moreto Pereira

*Caracterização de Imagens de Úlceras
Dermatológicas para Indexação e
Recuperação por Conteúdo*

Dissertação de mestrado apresentado ao Programa de Pós-Graduação Interunidades em Bioengenharia - Escola de Engenharia de São Carlos / Faculdade de Medicina de Ribeirão Preto / Instituto de Química de São Carlos da Universidade de São Paulo - como parte dos requisitos para a obtenção do título de mestre em Ciências.

Área de Concentração: Bioengenharia

Orientador: Prof. Dr. Paulo Mazzon-
cini de Azevedo Marques

São Carlos

2012

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

P436c   Pereira, Silvio Moreto
             Caracterização de Imagens Dermatológicas para
             Indexação e Recuperação por Conteúdo / Silvio Moreto
             Pereira; orientador Paulo Mazzoncini de
             Azevedo-Marques. São Carlos, 2012.

             Dissertação (Mestrado) - Programa de Pós-Graduação
             Interunidades Bioengenharia e Área de Concentração em
             Bioengenharia -- Escola de Engenharia de São Carlos;
             Faculdade de Medicina de Ribeirão Preto; Instituto de
             Química de São Carlos, da Universidade de São Paulo,
             2012.

             1. processamento de imagens coloridas. 2.
             segmentação de imagens coloridas. 3. quantificação de
             cores. 4. úlceras dermatológicas. 5. aprendizado de
             máquinas. 6. reconhecimento de padrões. 7. recuperação
             baseada em conteúdo. 8. CBIR. I. Título.

Programa de Pós-Graduação Interunidades em Bioengenharia
EESC / FMRP / IQSC

SILVIO MORETO PEREIRA

Título: "Caracterização de imagens de úlceras dermatológicas para indexação e recuperação por conteúdo".

DISSERTAÇÃO APRESENTADA AO PROGRAMA DE PÓS-GRADUAÇÃO
INTERUNIDADES BIOENGENHARIA EESC/FMRP/IQSC DA UNIVERSIDADE
DE SÃO PAULO PARA OBTENÇÃO DO TÍTULO DE MESTRE EM CIÊNCIAS
NA ÁREA DE BIOENGENHARIA.

Aprovado (a) em: 01/11/2012

Prof. Dr. Paulo Mazzoncini de Azevedo Marques
(Orientador)

Faculdade de Medicina de Ribeirão Preto - USP

Resultado: Aprovado

Assinatura:

Prof. Dr. Marcello Henrique Nogueira Barbosa

Faculdade de Medicina de Ribeirão Preto - USP

Resultado: Aprovado

Assinatura:

Prof. Dr. Lauro Wichert Ana

Faculdade de Medicina de Ribeirão Preto - USP

Resultado: Aprovado

Assinatura:

À Thais Mayumi Oshiro

Agradecimentos

Primeiramente gostaria de agradecer a Deus por ter me proporcionado a oportunidade de viver e vislumbrar de todas as experiências que a vida nos proporciona, sejam elas boas ou más. Pois no final, aprendemos que o importante é viver, buscar a felicidade e extrair de nós mesmos o máximo que podemos, afinal tudo isso vai passar... e o que teremos afinal?

Agradeço aos meus familiares, em especial ao meu pai e minha mãe que sempre estiveram do meu lado nos momentos felizes e tristes sempre incentivando.

Agradeço enormemente a minha namorada Thais Mayumi Oshiro, que nunca me abandonou e me ajudou de maneira imensurável desde o nossa época de graduação até a atual. E quando tudo passa, percebemos o que realmente foi bom e o que não foi, hoje olho para trás e vejo o quanto você me engrandeceu e completou minha vida. Espero pelo menos ser para você um quarto do que você é para mim.

Gostaria de agradecer ao meu orientador Prof. Dr. Paulo Mazzoncini de Azevedo Marques por todo conselho e auxílio recebido, seja ele acadêmico ou de vida. Gostaria de agradecer também ao Prof. Dr. Rangaraj M. Rangayyan pelos seus conselhos e orientação para realização deste projeto. Gostaria de agradecer ao Prof. Dr. Marco Andrey Cipriani Frade pelo auxílio no desenvolvimento do projeto. Gostaria de agradecer a todos do CCIFM, em especial ao Henrique do Amaral, Rodrigo de Pádua e Juliana Souza, pela ajuda recebida. Gostaria de agradecer ao Ricardo Amaral pelo companheirismo durante o período.

Também agradeço à FAPESP pelo apoio financeiro recebido através do processo 2010/04526-9 , bolsa no país - regular - mestrado.

São necessários anos para centrar-se em si próprio,
e mais algum tempo para entender e ser *agora*.

Fritz Perls

Resumo

PEREIRA, S. M. **Caracterização de Imagens de Úlceras Dermatológicas para Indexação e Recuperação por Conteúdo.** 2012. 108 f. Dissertação (Mestrado) - Programa de Pós-graduação Interunidades Bioengenharia - Escola de Engenharia de São Carlos / Faculdade de Medicina de Ribeirão Preto / Instituto de Química de São Carlos, Universidade de São Paulo, São Carlos, 2012.

Úlceras de pele são causadas devido à deficiência na circulação sanguínea. O diagnóstico é feito pela análise visual das regiões afetadas. A quantificação da distribuição de cores da lesão, por meio de técnicas de processamento de imagens pode auxiliar na caracterização e análise da dinâmica do processo patológico e resposta ao tratamento. O processamento de imagens de úlceras dermatológicas envolve etapas relacionadas a segmentação, caracterização e indexação. Esta análise é importante para classificação, recuperação de imagens similares e acompanhamento da evolução de uma lesão. Este trabalho apresenta um estudo sobre técnicas de segmentação e caracterização de imagens coloridas de úlceras de pele, baseadas nos modelos de cores RGB, HSV, $L^*a^*b^*$ e $L^*u^*v^*$, utilizando suas componentes na extração de informações de textura e cor. Foram utilizadas técnicas de Aprendizado de Máquina e algoritmos matemáticos para a segmentação e extração de atributos, utilizando uma base de dados com 172 imagens. Nos testes de recuperação, foram utilizadas diferentes métricas de distância para avaliação do desempenho e técnicas de seleção de atributos. Os resultados obtidos evidenciam bom potencial para apoio ao diagnóstico e acompanhamento da evolução do tratamento com valores de até 75% de precisão para as técnicas de recuperação, 0,9 de área embaixo da curva receiver-operating-characteristic na classificação e 0,04 de erro médio quadrático entre a composição de cores da imagem segmentada automaticamente e a segmentada manualmente. Nos testes utilizando seleção de atributos, foi observado uma redução nos valores de precisão de recuperação (60%) e valores similares nos testes de classificação (0,85).

Palavras-chave: processamento de imagens coloridas, segmentação de imagens coloridas, quantificação de cores, úlceras dermatológicas, aprendizado de máquinas, reconhecimento de padrões, recuperação baseada em conteúdo, CBIR.

Abstract

PEREIRA, S. M. **Characterization of Dermatological Ulcers Images for Indexing and Content-based Retrieval**. 2012. 108 p. Dissertação (Mestrado) - Programa de Pós-graduação Interunidades Bioengenharia - Escola de Engenharia de São Carlos / Faculdade de Medicina de Ribeirão Preto / Instituto de Química de São Carlos, Universidade de São Paulo, São Carlos, 2012.

Skin ulcers are caused due to deficiency in the bloodstream. The diagnosis is made by a visual analysis of the affected area. Quantification of color distribution of the lesion by image processing techniques can aid in the characterization and response to treatment. The image processing steps involves skin ulcers related to segmentation, characterization and indexing. This analysis is important for classification, image retrieval and similar tracking the evolution of an injury. This project presents a study of segmentation techniques and characterization of color images of dermatological skin ulcers, based on the color models RGB, HSV, $L^*a^*b^*$ and $L^*u^*v^*$, using their components in the extraction of texture and color information. Were used Machine Learning techniques, mathematical algorithms for segmentation and extraction of attributes, using a database containing 172 images in two versions. In recovery tests were used different distance metrics for performance evaluation and techniques of features selection. The results show good potential to support the diagnosis and monitoring of treatment progress with values up to 75% precision in recovery techniques, 0.9 area under the curve receiver-operating-characteristic) in classification, and 0.04 mean square error between the color composition of the automatically segmented image and the manually segmented image. In tests utilizing feature selection was observed a decrease in precision values of image retrieval (60%) and similar values in the classification's tests (0.85).

Keywords: color image processing, segmentation of color images, color quantification, skin ulcers, machine learning, pattern recognition, content-based retrieval, CBIR.

Lista de Figuras

1	Exemplos de imagens de úlceras dermatológicas com diferentes composições de tecido: (a) predominantemente composta de tecido de granulação; (b) predominantemente fibrina; (c) predominantemente tecido necrótico; e (d) composição mista	p. 21
2	Circulo Cromático	p. 24
3	Modelo de representação de cores no espaço RGB	p. 24
4	Modelo de representação de cores no espaço HSV	p. 25
5	Modelo de representação de cores no espaço XYZ	p. 27
6	Módulos fundamentais em processamento de imagens digitais, adaptado de (GONZALEZ; WOODS, 2008)	p. 28
7	Imagem original e o resultado da segmentação utilizando o algoritmo JSEG (DENG; MANJUNATH, 2001)	p. 30
8	Exemplos de textura	p. 32
9	Tipos de consulta: em (a) consulta por abrangência Q com raio r . (b) Consulta por vizinhos mais próximos com $K=5$	p. 39
10	Estrutura de uma árvore de decisão	p. 42
11	Estrutura do MLP	p. 43
12	Validação cruzada utilizando r folds	p. 45
13	Os três métodos de clusterização: (a) otimização, (b) distribuição e (c) hierárquicas	p. 47
14	Visão geral do fluxo da metodologia adotada	p. 49
15	Régua criada para a normalização das cores das imagens usadas no estudo	p. 50

16	Distribuição das cores na matiz e saturação após a requantização. As cores compreendidas na faixa escura não foram consideradas e as com saturação inferior a 0.2 foram definidas como preto ou branco. Cada segmento determinado pelas faixas de saturação e matiz corresponde então a apenas uma cor	p. 51
17	Requantização das imagens. Em (a) a imagem original e em (b) a imagem requantizada. Os pixels em azul referem-se aos pontos aos quais a matiz está fora da faixa de cores selecionada	p. 53
18	(a) Resultado da imagem após o algoritmo de segmentação JSEG. (b) Resultado da escolha das regiões pertencentes à úlcera pelo clique do usuário nelas	p. 54
19	Exemplo de uma imagem de úlcera dermatológica (a) e seu histograma HS (b)	p. 55
20	Segmentação utilizando um método de clusterização com $N=5$. Em (a) a imagem original; (b) o histograma HS com os <i>clusters</i> formados representando cada um uma tonalidade de cor; e (c) o <i>cluster</i> aplicado à imagem	p. 56
21	Exemplificação da segregação de cores no modelo HSV com matiz entre 0 e 90 graus e saturação entre 20% e 70%. A região selecionada encontra-se em destaque	p. 58
22	Método proposto para correlação existente entre as componentes de cor com as combinações das matrizes de co-ocorrência	p. 60
23	Boxplot mostrando o coeficiente de Jaccard para as 172 imagens da base de dados	p. 66
24	Quatro exemplos de segmentação utilizando um método de clusterização. Para cada imagem são apresentados a imagem original, a segmentada e a imagem com o <i>Convex Hull</i> aplicado	p. 67
25	Precisão obtida usando a distância Euclidiana, com K variando entre 5 e 30 nos experimentos CBIR	p. 68
26	Precisão obtida usando a distância <i>City Block</i> , com K variando entre 5 e 30 nos experimentos CBIR	p. 68

27	Precisão obtida utilizando a distância <i>Chebychev</i> , com K variando entre 5 e 30 nos experimentos CBIR	p. 69
28	Precisão obtida utilizando a métrica cosseno, com K variando entre 5 e 30 nos experimentos CBIR	p. 69
29	Precisão obtida utilizando a métrica correlação, com K variando entre 5 e 30 nos experimentos CBIR	p. 70
30	Precisão média obtida utilizando diferentes métricas de distância nos testes de recuperação com K variando entre 5 e 30	p. 70
31	Experimentos CBIR mostrando os cinco casos mais relevantes (com $K=5$) para cada imagem de consulta e a precisão correspondente, usando a medida de distância Euclidiana	p. 72
32	Precisão obtida usando a distância Euclidiana nos experimentos CBIR .	p. 72
33	Precisão obtida usando a distância <i>City Block</i> nos experimentos CBIR	p. 73
34	Precisão obtida utilizando a distância <i>Chebychev</i> nos experimentos CBIR	p. 74
35	Precisão obtida utilizando a métrica Cosseno nos experimentos CBIR .	p. 75
36	Precisão obtida utilizando a métrica Correlação nos experimentos CBIR	p. 75
37	Comparação da precisão média para as diferentes medidas ou métricas de distância utilizadas	p. 76
38	Precisão obtida usando a distância Euclidiana, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR .	p. 76
39	Precisão obtida usando a distância <i>City Block</i> , com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR .	p. 77
40	Precisão obtida utilizando a distância <i>Chebychev</i> , com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR	p. 77
41	Precisão obtida utilizando a métrica cosseno, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR . .	p. 78
42	Precisão obtida utilizando a métrica correlação, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR .	p. 78
43	Comparação da precisão média para as diferentes medidas ou métricas de distância utilizando imagens segmentadas automaticamente	p. 79

44	Comparação da precisão média para as diferentes medidas ou métricas de distância utilizando imagens segmentadas automaticamente	p. 80
45	Precisão obtida usando a distância Euclidiana, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR .	p. 81
46	Precisão obtida usando a distância <i>City Block</i> , com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR .	p. 81
47	Precisão obtida utilizando a distância <i>Chebychev</i> , com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR	p. 82
48	Precisão obtida utilizando a métrica cosseno, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR . .	p. 82
49	Precisão obtida utilizando a métrica correlação, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR .	p. 83
50	Curva ROC para cada uma das classes utilizando o indutor Naive Bayes	p. 84
51	Curva ROC para cada uma das classes utilizando o indutor MLP . . .	p. 85
52	Curva ROC para cada uma das classes utilizando o indutor K-NN . . .	p. 85
53	Curva ROC para cada uma das classes utilizando o indutor Árvore de Decisão	p. 86
54	Curva ROC para cada classe de úlcera obtida utilizando o classificador MLP com o segundo subconjunto de imagens	p. 87
55	Curva ROC para cada classe de úlcera obtida utilizando o classificador MLP com o terceiro subconjunto de imagens	p. 88
56	Porcentagem de imagens classificadas corretamente com cada classificador utilizando diferentes limiares da frequência de seleção dos atributos. O rótulo no eixo horizontal indica os números de características nos diversos subconjuntos de características utilizadas, começando com as 111 características calculadas, as características selecionadas uma vez (99), duas vezes (71), e assim por diante até oito vezes (2)	p. 94

57	Média ponderada dos valores de AUC para cada classificador utilizando diferentes limiares da frequência de seleção dos atributos. O rótulo no eixo horizontal indica os números de características nos diversos subconjuntos de características utilizadas, começando com as 111 características calculadas, as características selecionadas uma vez (99), duas vezes (71), e assim por diante até oito vezes (2).	p. 95

Lista de Tabelas

1	Comparação do coeficiente de Jaccard entre os métodos de segmentação propostos	p. 64
2	Taxa de acerto e valores de AUC para os quatros classificadores utilizados na segmentação utilizando JSEG e AM	p. 65
3	Erro médio quadrático da quantificação por tipos de lesão	p. 66
4	Valores de precisão em porcentagem para diferentes valores de K utilizando a distância CIEDE2000	p. 73
5	AUC para cada classe dos classificadores testados	p. 84
6	Valor AUC considerando somente os tipos de lesão granulação, fibrina e mista (segundo subconjunto de imagens)	p. 86
7	Valor AUC considerando somente os tipos de lesão granulação e fibrina (terceiro subconjunto de imagens)	p. 89
8	Frequência de seleção de cada atributo no espaço de cores HSV	p. 90
9	Frequência de seleção de cada atributo no espaço de cores $L^*a^*b^*$	p. 91
10	Frequência de seleção de cada atributo no espaço de cores $L^*u^*v^*$	p. 92
11	Frequência de seleção de cada atributo no espaço de cores RGB	p. 93
12	Matriz de confusão da classificação utilizando todas as 111 características extraídas e o classificador MLP. Cada linha representa a classe real da imagem e cada coluna, a classificação do MLP	p. 95
13	Matriz de confusão da classificação utilizando os atributos selecionados seis vezes ou mais e o classificador MLP. Cada linha representa a classe real da imagem e cada coluna, a classificação do MLP	p. 96

Sumário

1	Introdução	p. 19
1.1	Justificativa	p. 21
1.2	Objetivo	p. 22
1.3	Organização da Dissertação	p. 22
2	Ciência das Cores	p. 23
2.1	Modelos de Cores	p. 23
2.1.1	Modelo RGB	p. 24
2.1.2	Modelo HSV	p. 25
2.1.3	Modelo XYZ	p. 26
2.1.4	Modelos CIE (1976) $L^*u^*v^*$ e $L^*a^*b^*$	p. 26
3	Processamento de Imagens Coloridas	p. 28
3.1	Aquisição das Imagens	p. 29
3.2	Segmentação das Imagens	p. 29
3.3	Caracterização das Imagens	p. 30
3.3.1	Características de Cor	p. 31
3.3.1.1	Média	p. 31
3.3.1.2	Desvio Padrão	p. 31

3.3.1.3	Skewness	p. 31
3.3.1.4	Kurtosis	p. 32
3.3.2	Características de Textura	p. 32
3.3.2.1	Matrizes de Coocorrência e Descritores de Haralick . .	p. 33
3.4	Operadores Morfológicos	p. 33
3.5	<i>Convex Hull</i>	p. 34
4	Recuperação de Imagens por Conteúdo	p. 35
4.1	Consulta por Similaridade	p. 35
4.1.1	Espaços Métricos	p. 36
4.1.2	Tipos de Consultas	p. 38
4.1.3	Avaliação das Consultas	p. 38
5	Aprendizado de Máquina	p. 40
5.1	Árvores de Decisão	p. 41
5.2	Redes Neurais Artificiais - RNAs	p. 42
5.3	Aprendizado por Memorização	p. 43
5.4	Classificador Bayesiano	p. 44
5.5	Validação Cruzada	p. 44
5.6	Seleção de Atributos	p. 45
5.6.1	<i>Wrapper</i>	p. 46
5.6.2	Mecanismo de Busca	p. 46
5.7	<i>Clusters</i>	p. 47
5.7.1	<i>Expectation Maximization</i>	p. 48

6	Materiais e Métodos	p. 49
6.1	Base de Imagens	p. 50
6.2	Préprocessamento das Imagens	p. 50
6.3	Segmentação de Imagens	p. 51
6.3.1	JSEG	p. 52
6.3.2	Segmentação utilizando algoritmo JSEG e técnicas de Aprendi- zado de Máquinas	p. 54
6.3.3	Segmentação utilizando histogramas de cores e <i>Clusters</i>	p. 55
6.4	Quantificação da Composição de Cores da Lesão	p. 57
6.5	Extração de Características	p. 57
6.5.1	Recuperação por Conteúdo	p. 59
6.5.2	Classificação das Imagens	p. 61
6.5.3	Seleção de Atributos	p. 62
7	Resultados e Discussão	p. 64
7.1	Segmentação das Imagens	p. 64
7.2	Quantificação da Composição de Cores da Lesão	p. 65
7.3	Recuperação por Conteúdo	p. 66
7.3.1	Recuperação Utilizando Imagens Segmentadas Automaticamente	p. 74
7.4	Classificação das Imagens	p. 80
7.4.1	Utilizando toda base de dados	p. 80
7.4.2	Base de dados somente com as classes Granulação, Fibrina e Mista	p. 83
7.4.3	Base de dados somente com as classes Granulação e Fibrina . .	p. 86
7.5	CBIR versus reconhecimento de padrões	p. 87

7.6	Seleção de atributos	p. 89
8	Conclusão	p. 97
8.1	Contribuições do Trabalho	p. 98
8.2	Trabalhos Futuros	p. 99
	Referências	p. 100
	Anexo A – Ofício de aprovação obtido pelo Comitê de Ética	p. 107

1 *Introdução*

Um sistema que possibilita a busca de imagens de exames a partir de informações sobre o seu conteúdo pictórico é denominado de sistema de consulta a imagens baseada em conteúdo (*Content-based Image Retrieval* - CBIR) (MULLER et al., 2004). Em um sistema CBIR, quando uma imagem é apresentada ao sistema de arquivamento o módulo de indexação calcula um vetor de características a partir da extração de determinadas informações dessa imagem. No processo de recuperação, o usuário fornece uma imagem referência da qual são extraídas as mesmas características das imagens armazenadas. O módulo de recuperação, então, calcula a distância entre os vetores e recupera as imagens consideradas semelhantes dentro de um critério de aproximação. Além da otimização no processo de organização da informação, a recuperação de imagens a partir de conteúdo possui potencial para o auxílio ao diagnóstico, possibilitando não somente a recuperação de casos de pacientes com exames por imagem e diagnósticos semelhantes, mas também de casos de pacientes com imagens semelhantes e eventuais diagnósticos diferentes. Essa capacidade pode fornecer informações fundamentais para o ensino, pesquisa e melhoria nos processos de interpretação de imagens (AZEVEDO-MARQUES, 2005). Uma vez que a comparação direta entre objetos complexos, como é o caso das imagens, é geralmente uma operação computacionalmente cara e demorada, uma abordagem usual é extrair características das imagens, para que os atributos extraídos possam ser indexados permitindo a recuperação baseada em conteúdo. Desse modo, em um sistema CBIR a etapa de análise da imagem para reconhecimento de padrões é de fundamental importância, pois será responsável pela escolha apropriada e extração das características cujos valores serão utilizados no processo de caracterização da informação presente na imagem (TRAINA et al., 2009).

Na radiologia, o conceito de CBIR pode ser considerado bem estabelecido em termos de pesquisas e divulgação de seus benefícios. Mas existem outros ambientes fora da radiologia que também utilizam imagens - Citologia (MEYER, 1986; MATTIE et al., 2000; BERRETTI; BIMBO; PALA, 2001); Patologia (COMANICIU et al., 1998; WANG, 2000);

Histopatologia (JAULENT et al., 2000); Histologia (TANG et al., 1998, 1999); Cardiologia (OGIELA; TADEUSIEWICZ, 2001; NIBLACK et al., 1993) e Dermatologia (WILD et al., 2008).

Particularmente na Dermatologia, com a introdução de sistemas digitais, a abordagem do diagnóstico sofreu uma série de mudanças (SCHMID-SAUGEON; GUILLOD; THIRAN, 2003) e, em muitas instituições de saúde, como no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto (HCFMRP), já é comum, dentro da prática clínica, a aquisição de imagens de lesões dermatológicas dos pacientes como forma de registro complementar das informações do prontuário. Essa associação da imagem com informações demográficas e clínicas, como sexo, idade e exposição ao sol, por exemplo, são fundamentais para a identificação precoce de lesões malignas, assim como, para o acompanhamento mais objetivo da evolução do caso clínico (SBONER et al., 2003).

Úlceras dermatológicas crônicas, ou úlceras de pele, são geralmente causadas pela deficiência na circulação sanguínea e são denominadas úlceras arteriais ou venosas. Dentre as causas desta deficiência, estão: traumas, diabetes, tumores, infecções e algumas condições específicas da pele. Na conduta clínica convencional, os dermatologistas normalmente confiam em uma avaliação visual das regiões afetadas, em conjunto com a avaliação de características macroscópicas, para a definição de um diagnóstico da lesão (MAGLOGIANIS; PAVLOPOULOS; KOUTSOURIS, 2005). A aparência da lesão fornece pistas importantes para o diagnóstico, determinação da severidade e para o prognóstico (ODUNCU et al., 2004).

A quantificação da distribuição de cores da lesão, através de técnicas de processamento de imagens pode auxiliar na caracterização e análise da dinâmica do processo patológico, bem como o progresso da cicatrização e a resposta ao tratamento (ODUNCU et al., 2004; TARALLO; GONZAGA; FRADE, 2007; WANNOUS; TREUILLET; LUCAS, 2007; DORILEO et al., 2008; PEREIRA et al., 2011). A informação objetiva obtida dessa maneira pode ser utilizada para definir e acompanhar a aplicação de protocolos de tratamento que facilitem o processo de cicatrização.

As lesões crônicas incluem uma mistura de tecido necrótico preto, fibrina amarela e tecido de granulação vermelho (ver Figura 1), seguidos da fase de cicatrização branca. Um modelo de cores vermelho-amarelo-preto, conforme indicado pela categorização da composição do tecido é utilizado pelos clínicos como uma ferramenta descritiva (ODUNCU et al., 2004; TARALLO; GONZAGA; FRADE, 2007; WANNOUS; TREUILLET; LUCAS, 2007; WILD et al., 2008) e pode ser adaptado com referência para um sistema de indexação e recuperação de imagem por conteúdo. É importante ressaltar, porém, que para a utilização de técnicas de CBIR na prática clínica em Dermatologia existem aspectos importantes que

precisam ser melhor estudados no que se refere à aquisição, tratamento, armazenamento e distribuição das imagens.

Figura 1: Exemplos de imagens de úlceras dermatológicas com diferentes composições de tecido: (a) predominantemente composta de tecido de granulação; (b) predominantemente fibrina; (c) predominantemente tecido necrótico; e (d) composição mista

1.1 Justificativa

A utilização de técnicas de recuperação de imagens a partir do seu conteúdo intrínseco possui o potencial de auxílio ao diagnóstico e viabilização de acesso rápido e otimizado na pesquisa a casos de imagens semelhantes (MULLER et al., 2004). Vários sistemas que utilizam o tratamento de conteúdo pictórico para auxílio ao profissional de Dermatologia, já foram propostos em trabalhos correlatos, demonstrando a importância do tema, tanto na identificação precoce de tumores malignos (ERCAL et al., 1994; LUCAS, 2000; KITTLER et al., 2002), como na assessoria e complementação aos métodos usuais utilizados na prática clínica (SBONER et al., 2004; ACHA et al., 2005; WILD et al., 2008; VEREDAS; MESA; MORENTE, 2010).

O trabalho aqui descrito apresenta um estudo sobre técnicas de processamento de imagens voltadas para a caracterização das imagens de úlceras dermatológicas voltadas para a indexação e recuperação por conteúdo. Espera-se que a pesquisa desenvolvida possa subsidiar o desenvolvimento de métodos quantitativos para apoio à tomada de decisão

diagnóstica e acompanhamento da evolução do tratamento das úlceras dermatológicas.

1.2 Objetivo

O objetivo geral desse trabalho foi o estudo de técnicas de segmentação e caracterização de imagens de úlceras dermatológicas por meio de algoritmos computacionais. A proposta consiste no estudo de técnicas de reconhecimento de padrões que possibilitem a classificação e recuperação por conteúdo de imagens similares.

Para isto, foram estudadas técnicas de segmentação de imagens coloridas, recuperação de imagens em diferentes espaços de cores e utilizando diferentes métricas de distâncias, classificação das imagens por meio de técnicas de Aprendizado de Máquina e métodos de seleção de atributos para tentar obter uma otimização nos resultados.

1.3 Organização da Dissertação

O restante deste trabalho está organizado da seguinte forma: no Capítulo 2 são apresentados conceitos relacionados a ciência das cores e aos espaços de cores estudados. No Capítulo 3 são apresentados conceitos de processamento de imagens. No Capítulo 4 são apresentados os conceitos a respeito da recuperação de imagens. No Capítulo 5 são mostradas as técnicas de Aprendizado de Máquina utilizadas. No Capítulo 6 é apresentada a metodologia adotada. No Capítulo 7 são apresentados os resultados obtidos e a discussão. E, por fim, no Capítulo 8 são feitas as conclusões referentes a este estudo.

2 *Ciência das Cores*

Embora o processo seguido pelo cérebro humano na percepção de cores seja um fenômeno fisiológico ainda não entendido em sua totalidade, a natureza física das cores pode ser expressa em uma base formal suportada por resultados experimentais e teóricos.

Em 1666, Sir Isaac Newton fundamentou a ciência das cores quando observou que a luz do sol é composta por uma mistura de todas as cores de um espectro. Ele descobriu que ao passar através de um prisma de vidro, o feixe de luz solar emergente não é branco, mas, ao contrário, consiste de um espectro de cores contínuo variando do violeta ao vermelho. O espectro de cores pode ser dividido em sete regiões amplas: violeta, anil, azul, verde, amarelo, laranja, e vermelho (HUNT, 2004). Um objeto terá determinada cor se não absorver justamente os raios correspondentes à frequência daquela cor (TRUSSELL; SABER; VRHEL, 2005).

As cores primárias são as cores básicas e não podem ser criadas a partir da mistura de outras. As cores secundárias são obtidas pela mistura de duas cores primárias. As cores complementares são as cores colocadas na posição oposta no círculo cromático (Figura 2). As cores análogas são as cores que estão em posição próxima no círculo cromático.

2.1 Modelos de Cores

Modelos de cor especificam sistemas de coordenadas que cobrem completamente um determinado gamut.

A experiência de pessoas com misturas de pigmentos não pode ser transportada para o caso de mistura de luzes coloridas. A mistura de luzes coloridas tem um comportamento completamente diferente da mistura de pigmentos. No caso de luzes, a tendência da mistura é “clarear” na direção da luz branca (comportamento aditivo), enquanto que no caso de pigmentos a tendência é “escurecer” na direção do preto (comportamento subtrativo).

Figura 2: Círculo Cromático

2.1.1 Modelo RGB

Primeiramente, o modelo RGB é composto pelas cores primárias *Red-Green-Blue* que definem um sistema de coordenadas cartesianas de valores entre 0 e 1. O conjunto de cores definidas por este modelo é chamado de cubo RGB (Figura 3). O RGB é um modelo aditivo, isto é, as cores complementares (*ciano*, *magenta* e *yellow*) são obtidas pela adição das cores primárias. O modelo RGB é utilizado nos monitores coloridos.

Figura 3: Modelo de representação de cores no espaço RGB

2.1.2 Modelo HSV

O modelo de cores HSV (*Hue-Saturation-Value* ou Matiz-Saturação-Brilho) foi inventado por Alvy Ray Smith em 1974 e é caracterizado por ser uma transformação linear do sistema de cores RGB (GONZALEZ; WOODS, 2008). O espaço de cor HSV é baseada no apelo intuitivo dos termos usados pelos artistas para descrever a cor em seus termos de sombra e tonalidade, como é mostrado na Figura 4. O tom é aumentado pela adição de um pigmento branco puro, o que corresponde à diminuição S sem alterar V ou H. Sombra é aumentada acrescentando preto a um pigmento puro, o que corresponde à diminuição V. Vários tons são obtidos por adição de branco e preto a um pigmento puro, o que corresponde a mudança V e S juntos. O sistema HSV é modelado como um cone invertido.

Figura 4: Modelo de representação de cores no espaço HSV

A conversão entre os espaços de cores RGB e HSV é dada pelas fórmulas 2.1, 2.2 e 2.3:

$$H = \begin{cases} 60 \times \frac{G-B}{MAX-MIN}, & se MAX = R \\ & e G \geq B \\ 60 \times \frac{G-B}{MAX-MIN} + 360, & se MAX = R \\ & e G < B \\ 60 \times \frac{B-R}{MAX-MIN} + 120, & se MAX = G \\ 60 \times \frac{R-G}{MAX-MIN} + 240, & se MAX = B \end{cases} \quad (2.1)$$

$$S = \frac{MAX - MIN}{MAX} \quad (2.2)$$

$$V = MAX \quad (2.3)$$

2.1.3 Modelo XYZ

Uma vez que o olho humano possui três tipos de sensores de cor que respondem a diferentes faixas de comprimentos de onda, uma trama cheia de todas as cores visíveis é uma figura tridimensional. No entanto, o conceito de cor pode ser dividido em duas partes: brilho e cromaticidade. Por exemplo, a cor branca é uma cor brilhante, enquanto a cor cinza é considerada como uma versão menos brilhante do que o mesmo branco. Em outras palavras, a cromaticidade de branco e cinza é a mesma, enquanto o seu brilho é diferente.

O espaço de cores CIE XYZ foi concebido para que o parâmetro Y seja uma medida do brilho ou luminância de uma cor. A cromaticidade da cor foi, então, especificada por dois parâmetros derivados de X e Y, dois dos três valores normalizados que são funções de todos os três valores tristimulares X, Y e Z. Os valores tristimulares de uma cor são as quantidades de três cores primárias em um modelo de cor de três componentes aditivos necessários para combinar a cor do teste. Os valores tristimulares são freqüentemente administrados no espaço de cores CIE 1931, em que são indicados X, Y e Z (HUNT; POINTER, 2011). Na Figura 5 são exibidas as cores saturadas mais brilhantes que podem ser exibidas por um monitor de computador ou televisor.

2.1.4 Modelos CIE (1976) $L^*u^*v^*$ e $L^*a^*b^*$

O espaço de cores $L^*u^*v^*$, conhecido também por CIE $L^*u^*v^*$, é baseado no CIE 1960 UCS. O espaço $L^*u^*v^*$ foi desenvolvido em 1976 para atingir um espaço de cores uniforme, no qual o termo uniforme significa que a diferença de cor medida no espaço de cores corresponde a diferença perceptual. Espaços de cores previamente definidos, tais como a CIE XYZ ou RGB, não são uniformes e, por este motivo, a CIE decidiu desenvolver novos sistemas em que as diferenças na cor é correlacionada com a percepção humana. O espaço $L^*u^*v^*$ representa uma nova tentativa de linearizar a perceptibilidade das diferenças de cor vetor unitário (FORD; ROBERTS, 2010). A abordagem depende do ponto de referência branca do sistema, com $D65$ sendo o ponto mais comumente utilizado.

Figura 5: Modelo de representação de cores no espaço XYZ

Como no caso do espaço de cor $L^*u^*v^*$, o espaço CIE $L^*a^*b^*$ (1976) baseia-se no espaço CIE XYZ e em um ponto de referência branco. É uma transformação não-linear de XYZ. A não-linearidade é introduzida ao imitar a resposta logarítmica do olho humano. O espaço descreve todas as cores visíveis ao olho humano e foi criado para servir como um modelo independente de dispositivo para ser usado como referência.

3 *Processamento de Imagens Coloridas*

Soluções específicas caracterizam o processamento de imagens. Desse modo, técnicas que funcionam bem em uma área podem mostrar-se totalmente inadequadas em outra. Na Figura 6 é mostrado, no entanto, o objetivo global de um sistema de processamento de imagens, isto é, a produção de um resultado a partir de um domínio do problema. Nos sistemas de reconhecimento de imagens das lesões ulceradas, o domínio do problema seria a lesão ulcerada, e o resultado, as imagens reconhecidas e recuperadas a partir da base de imagens.

Figura 6: Módulos fundamentais em processamento de imagens digitais, adaptado de (GONZALEZ; WOODS, 2008)

A seguir, serão discutidas as etapas de aquisição, segmentação e caracterização (representação) das imagens.

3.1 Aquisição das Imagens

O processo de aquisição das imagens difere dos métodos médicos tradicionais (como radiografia, tomografia computadorizada e etc.) por não possuir um protocolo de aquisição e as lesões apresentarem formas variáveis e localizações anatômicas. O meio de obtenção da imagem digital é feito por um instrumento de obtenção de imagem composto por um sensor e um digitalizador de sinal, como uma máquina fotográfica digital.

Para a construção de uma base de dados de imagens de úlceras dermatológicas é necessário obter um conjunto representativo de imagens para diferentes tipos de tecido. A exigência preliminar é a aquisição de imagens de boa qualidade abrangendo todos os tipos de lesões. A aquisição das imagens das lesões depende de diversos fatores, especialmente se o local onde foram obtidas as imagens não possuir luz controlada.

A distância entre a obtenção da foto e a lesão em questão é outro fator a ser levado em consideração, pois à curta distância, a profundidade de campo fica limitada e a luz ambiente pode se tornar insuficiente, resultando em uma imagem distorcida. Além disso, pode existir o caso no qual o paciente é incapaz de manter uma postura conveniente para ser fotografado.

As condições de iluminação do local onde será obtida a imagem são incontrolláveis e durante o processo de cicatrização a lesão reage de forma diferente à luz. Mesmo quando o flash é usado, a influência da iluminação não é eliminada, pois o ângulo da câmera, via de regra, é diferente em cada sessão de fotos (WANNOUS; TREUILLET; LUCAS, 2007).

3.2 Segmentação das Imagens

A segmentação tem como objetivo encontrar uma região de interesse (ROI- *Region of Interest*). Em termos gerais, a segmentação divide uma imagem de entrada em partes ou objetos constituintes. Segundo Gonzales (GONZALEZ; WOODS, 2008), a segmentação automática é uma das tarefas mais difíceis no processamento de imagens digitais. O procedimento robusto de segmentação favorece substancialmente a solução bem sucedida de um problema de imageamento. Por outro lado, algoritmos de segmentação fracos ou erráticos quase sempre conduzem a falhas no processamento. Em um sistema de segmentação de lesões ulceradas, o papel básico da segmentação é extrair a região dos tecidos ulcerados do fundo da imagem e do tecido saudável.

O resultado da segmentação de imagens é um conjunto de regiões ou um conjunto de

contornos extraídos da imagem. Na Figura 7 é mostrado um exemplo de segmentação utilizando a técnica proposta por (DENG; MANJUNATH, 2001). A saída da segmentação é constituída basicamente por dados em forma de pixels, correspondendo à fronteira de uma região e os pontos dentro da mesma. Segundo especialistas da área, no caso das lesões ulceradas, a região da pele circundante à lesão traz também informações valiosas para a avaliação da mesma, como por exemplo, as margens calosas das úlceras neuropáticas, constituindo-se em uma informação típica do domínio do problema.

Figura 7: Imagem original e o resultado da segmentação utilizando o algoritmo JSEG (DENG; MANJUNATH, 2001)

3.3 Caracterização das Imagens

A caracterização das imagens pode ser feita de diversas maneiras. Uma delas é a extração de características (ou atributos) das imagens que possam descrever e diferenciar a imagem de forma adequada. A extração de características é uma das partes constituintes fundamentais no processo de reconhecimento de padrões e recuperação por conteúdo. Seu objetivo é capturar o que há de mais representativo nas imagens (ASLANDOGAN; YU, 1999).

O processo de extração de características de imagens usualmente envolve alguns aspectos principais, como a distribuição de cores na imagem (histograma) (GUPTA; SANTINI et al., 2000) e elementos de textura (HUANG, 2003).

3.3.1 Características de Cor

A cor é uma característica muito significativa em sistemas de consulta em imagens, com grande representatividade tanto na indexação como na recuperação das mesmas. A extração dos atributos de cor do conteúdo da imagem envolve a determinação de um espaço ou modelo de cor e um descritor efetivo.

As diferentes representações de cores envolvem desde o tradicional RGB, o modelo mais simples e que mapeia as características físicas do dispositivo de exibição, até o HSV, que reflete mais precisamente o modelo de cores para a percepção humana.

A distribuição de cores dos pixels de uma imagem pode ser representada por um histograma de cor. Este tipo de abordagem é amplamente utilizado por ser simples e computacionalmente barato. No entanto, o histograma de cor não considera as informações espaciais dos pixels. A seguir serão apresentados alguns atributos que podem ser extraídos dos histogramas como características de cor.

3.3.1.1 Média

Média é o valor que aponta para onde mais se concentram os dados de uma distribuição. Pode ser considerada o ponto de equilíbrio das frequências em um histograma. A média é calculada através da combinação de valores de um conjunto de um modo específico e gerando um valor, a média do conjunto.

3.3.1.2 Desvio Padrão

Em probabilidade e estatística, o desvio padrão é a medida mais comum da dispersão estatística. O desvio padrão define-se como a raiz quadrada da variância. É definido desta forma de maneira a fornecer uma medida da dispersão da distribuição.

3.3.1.3 Skewness

Skewness é uma medida da assimetria da distribuição de probabilidade de uma variável aleatória real. O valor da assimetria pode ser positivo ou negativo, ou mesmo indefinido. Qualitativamente, uma inclinação negativa indica que a cauda no lado esquerdo da função densidade de probabilidade é maior que o lado direito e a maior parte dos valores (incluindo possivelmente a mediana) estão à direita da média. A inclinação positiva indica que a cauda do lado direito é maior que o lado esquerdo e a maior parte dos valores

se encontram à esquerda da média. Um valor zero indica que os valores são relativamente distribuídos uniformemente em ambos os lados da média, mas normalmente não implicando necessariamente uma distribuição simétrica.

3.3.1.4 Kurtosis

A medida kurtosis é uma mensuração da amplitude da distribuição de probabilidade de uma variável aleatória real. Uma distribuição de kurtosis elevada tem um pico agudo e longo, a cauda “gorda”, enquanto uma distribuição kurtosis baixa tem um pico mais arredondado e mais curto e caudas “finas”.

3.3.2 Características de Textura

Textura é a característica visual onde há um grande número de elementos densamente visíveis e uniformemente dispostos. Diferentemente da cor, a textura não é medida por pixels unitários, mas por regiões caracterizadas por serem intensamente uniformes. Na Figura 8 são mostrados alguns exemplos de textura¹.

Figura 8: Exemplos de textura

Para (GONZALEZ; WOODS, 2008), a textura é uma abordagem importante para a descrição de regiões que fornecem intuitivamente medidas de propriedades como suavidade, rugosidade e regularidade. A textura pode ser analisada a partir dos pixels ou a partir de elementos de textura. A análise estatística caracteriza a variação de intensidade, incluindo contraste, granulação e direção. A análise estrutural, por sua vez, captura elementos na imagem, determina sua forma e descreve a posição em relação a outros elementos da imagem estimando o número de elementos vizinhos (conectividade), número de elementos em

¹Imagem de: http://www.memorialsbydesign.com/images/texture_samples.jpg

uma região (densidade) e se eles estão em camadas ou representados homogeneamente (regularidade).

A captura de textura a partir do uso das matrizes de coocorrência (CoM) (HARALICK; SHANMUGAM; DINSTEIN, 1973) é um método muito popular para sua caracterização.

3.3.2.1 Matrizes de Coocorrência e Descritores de Haralick

O pixel é a primitiva básica em uma imagem digital em níveis de cinza. Sua propriedade é o seu nível de cinza. Assim, a distribuição dos níveis de cinza dos pixels pode ser descrita por estatísticas.

Segundo (MARQUES, 2006), as matrizes de coocorrência bidimensionais resumem em tabulações a probabilidade de dois pixels de um determinado nível de cinza ocorrendo em diferentes distâncias e orientações. Cada distância d e ângulo a geram uma matriz P em que seus elementos $P(i, j)$ representam a frequência com que dois pixels vizinhos ocorrem na imagem, um com o nível de cinza i e o outro com o nível de cinza j . As matrizes de coocorrência são quadradas e simétricas em relação à diagonal principal.

A partir da matriz de coocorrência, vários descritores podem ser extraídos, como os propostos (HARALICK; SHANMUGAM; DINSTEIN, 1973): contraste, correlação, homogeneidade, homogeneidade local, variância, entropia e outros. Cada descritor tem por objetivo expor uma característica da imagem de forma mensurável.

A dimensão da matriz é definida pelo número de tons de cinza distintos na imagem. Para a obtenção de matrizes de dimensões reduzidas, é comum a utilização de algoritmos que reduzem a quantidade de tons de cinza das imagens.

3.4 Operadores Morfológicos

Os operadores morfológicos são técnicas de morfologia digital ou matemática (DOUGHERTY; LOTUFO, 2003) destinadas à descrição ou análise da forma de um objeto digital. Os operadores morfológicos destinam-se a extração de informações a partir de transformações morfológicas nos conceitos da álgebra booleana. O princípio morfológico é dado ao fato de uma imagem ser constituída por pixels que formam um mapa bi-dimensional dos seus subconjuntos. Os subconjuntos e a interrelação entre eles formam estruturalmente a morfologia da imagem. Operadores morfológicos são comumente utilizados no processamento de imagens para delinear elementos e auxiliar determinadas fases do processo.

Os operadores morfológicos básicos são: erosão (MATHERON, 1975), na qual elementos que não pertencem a região da máscara do operador morfológico são retirados da imagem; e a dilatação (SERRA, 1986), na qual elementos que não se encontram na imagem, porém estão relacionados ao padrão da região da máscara do operador morfológico são adicionados a imagem. Pode-se definir estas operações, dilatação e erosão, a partir das fórmulas 3.1 e 3.2, respectivamente.

$$D(A, B) = A \oplus B = \{z \in E | B_z \cap A \neq \emptyset\} \quad (3.1)$$

$$E(A, B) = A \ominus B = \{z \in E | B_z \subseteq A\} \quad (3.2)$$

onde A é dado originalmente como a imagem e B o elemento estruturante (ou máscara) e E um espaço Euclidiano.

A operação de dilatação faz com que o elemento cresça e “buracos” menores do que a máscara sejam preenchidos. Por outro lado, a erosão reduz o tamanho do elemento e objetos menores ao que a máscara aplicada são removidos. A magnitude e modo do elemento dependem diretamente da máscara aplicada a este.

3.5 *Convex Hull*

O *convex hull* é uma técnica de processamento de imagens que auxilia na identificação de ROIs de objetos convexos. Um objeto é convexo se quaisquer dois pontos dentro do objeto conectados por uma linha reta tem todos os pontos do segmento de linha também inclusos no objeto. Por exemplo, um cubo é um objeto convexo.

O *convex hull* de um conjunto de pontos é o menor conjunto convexo que contém todos os pontos (DEGLINT; RANGAYYAN, 2005). O *convex hull* é uma construção fundamental para a matemática e geometria computacional.

Um *convex hull* é representado como um conjunto de facetas e um conjunto de listas adjacentes dados os vizinhos e vértices de cada faceta. Os elementos de contorno de uma faceta são chamados de arestas. Cada aresta significa a adjacência de duas facetas (BARBER; DOBKIN; HUHDANPAA, 1996).

4 *Recuperação de Imagens por Conteúdo*

Sistemas que utilizam Recuperação de Imagens Baseada em Conteúdo (CBIR-*Content-Based Image Retrieval*) têm como principal característica o reconhecimento de imagens similares em uma base de imagens, a partir de uma dada imagem de consulta, considerando apenas informações intrinsecamente relacionadas às mesmas. Assim, as informações são obtidas a partir da análise dos pixels de cada imagem, sem considerar, por exemplo, índices de textos associados ou anotações externas (WEI; LI; WILSON, 2006).

A proposta desses sistemas é suplantiar as dificuldades relativas aos registros de anotações textuais em grandes bancos de dados de imagens (EL-NAQA et al., 2004). Assim, ao invés de utilizar uma palavra ou frase como referência em uma consulta - como ocorre na maioria dos sistemas de recuperação de documentos - a informação relevante (ou similar) para cada consulta do usuário é recuperada utilizando como referência apenas a imagem. O sucesso na utilização desta metodologia está na seleção de descritores apropriados para a extração de características, assim como, no desenvolvimento de métricas de similaridade para classificar a relevância de uma imagem a partir do contexto ao qual ela pertence (EL-NAQA et al., 2004).

Os descritores são importantes para o cálculo automático de características quantitativas das imagens. A partir da extração dessas características, as métricas de similaridade podem ser utilizadas para a comparação da imagem de consulta com as demais imagens do banco de imagens. O sistema retorna e exibe para o usuário as imagens com maior similaridade com relação à imagem de consulta.

4.1 Consulta por Similaridade

A recuperação de imagens por conteúdo é baseada nos seus atributos de imagens extraídos e sua representação cartesiana no espaço. Cada atributo adiciona uma dimensão

ao espaço e cada ponto é determinado pelos dados indexados de cada imagem. A busca por pontos (ou imagens) mais próximos a um específico é denominado como busca por similaridade.

A similaridade entre dados complexos e imagens é definida por uma função de distância, ou função de “dissimilaridade” $d(O_i, O_j)$, que retorna zero se ambos os objetos O_i e O_j forem idênticos, e um valor positivo que aumenta quanto maior for a distância (ou dissimilaridade) entre os objetos.

A seguir, serão abordados alguns tópicos principais relacionados aos espaços métricos, funções de distância, tipos e avaliação das consultas.

4.1.1 Espaços Métricos

Formalmente, um espaço métrico é um par $M=(D, d(O_i, O_j))$, onde D é o domínio do vetor de característica ou chave da indexação, e $d(O_i, O_j)$ é uma de distância que satisfaz as seguintes propriedades:

1. Simetria: $d(O_i, O_j) = d(O_j, O_i)$;
2. Não negatividade: $0 \leq d(O_i, O_j) < \infty$, $O_i \neq O_j$ e $d(O_i, O_i)=0$;
3. Desigualdade triangular: $d(O_i, O_j) \leq d(O_i, O_y) + d(O_y, O_j)$, onde: O_i , O_j e O_y são objetos pertencentes ao espaço D .

A função de distância utilizada no processo de consulta por similaridade tem influência direta na sua precisão. Ela deve ser escolhida, portanto, considerando as características utilizadas (MARQUES, 2006). Existem várias funções de distância estudadas e propostas. A seguir serão apresentadas diversas funções de distância amplamente utilizadas em sistemas de recuperação de imagens.

As funções de distância Minkowsk (SMITH, 1997) trabalham com objetos compostos por n -atributos de valores numéricos. Cada atributo é considerado como um eixo de coordenadas cartesianas, permitindo a visualização do objeto como um ponto no espaço de n -dimensões (espaço vetorial), dado pela fórmula:

$$d_{(x,y)} = \sqrt[p]{\sum_{j=1}^n |x_j - y_j|^p} \quad (4.1)$$

na qual s e t são as imagens comparadas e n é o tamanho do espaço (no caso o número de características).

Variando o atributo p é possível obter outras funções de distância, como: a Euclidiana (Eq. 4.2), na qual o p vale 2; *City Block* (Eq. 4.3), na qual o p vale 1; e *Chebychev* (Eq. 4.4), na qual o p tem valor infinito.

$$d_{(x,y)} = \sqrt{\sum_{j=1}^n (x_j - y_j)^2} \quad (4.2)$$

$$d_{(x,y)} = \sum_{j=1}^n |x_j - y_j| \quad (4.3)$$

$$d_{(x,y)} = \max_{j=1}^n \{|x_j - y_j|\} \quad (4.4)$$

Outras funções de distância foram estudadas e testadas de modo a comparar seus resultados. Tais distâncias foram Cosseno (Eq. 4.5) e Correlação (Eq. 4.6):

$$d_{(x,y)} = 1 - \frac{\sum_{j=1}^n x_j y_j}{\sqrt{\sum_{j=1}^n x_j^2 \sum_{j=1}^n y_j^2}} \quad (4.5)$$

$$d_{(x,y)} = 1 - \frac{\sum_{j=1}^n (x_j - x_a)(y_j - y_a)}{\sqrt{\sum_{j=1}^n (x_j - x_a)^2 \sum_{j=1}^n (y_j - y_a)^2}} \quad (4.6)$$

onde

$$x_a = \frac{1}{n} \sum_{j=1}^n x_j \quad (4.7)$$

e

$$y_a = \frac{1}{n} \sum_{j=1}^n y_j \quad (4.8)$$

Uma outra métrica utilizada é a CIEDE2000, proposta pelo *CIE Technical Committee 1-47* (SHARMA; WU; DALAL, 2005). Ela foi destinada à avaliação de pequenas médias diferenças de cores (LUO; CUI; RIGG, 2001; CUI; LUO, 2009) nos espaços $L^*a^*b^*$ e $L^*u^*v^*$, pois distâncias como a Euclidiana, não são completamente correlacionadas com as diferenças de cores percebidas nestes espaços de cores.

4.1.2 Tipos de Consultas

Consultas por similaridade são importantes em sistemas que manipulam imagens por permitirem o reconhecimento e a recuperação de imagens similares a uma dada imagem de busca baseando-se nas características extraídas das imagens e utilizadas para representá-las. Existem pelo menos dois tipos básicos de consultas por similaridade: consultas por abrangência (*range queries*) e consulta aos vizinhos mais próximos (*K-nearest neighbor query* ou K-NN).

Consultas por abrangência são dadas por, considerando um conjunto de objetos $O = O_1, O_2, \dots, O_n$ pertencentes a um domínio D , uma função de distância métrica $d()$, um objeto de consulta $Q \in D$ e uma distância de busca máxima $r(Q)$, a consulta por abrangência seleciona todos os objetos O_i do conjunto de dados tal que eles estejam dentro da distância $r(Q)$ do objeto de busca.

$$range(Q, r(Q)) = \{O_i | O_i \in D \text{ e } d(O_i, Q) \leq r(Q)\} \quad (4.9)$$

Consulta aos K vizinhos mais próximos (K-NN) é dada por, tendo um conjunto de objetos $O = O_1, O_2, \dots, O_n$ em um domínio D , uma função métrica $d()$, um objeto de consulta O_i e um número inteiro $K \geq 1$, a consulta K-NN seleciona os K objetos do conjunto de dados que estão mais próximos de Q . Isto é:

$$K-NN(Q) = \{A_i | A_i \in A, A \subseteq D, |A| = K \text{ \& } \forall A_i \in A, d(Q, A_i) \leq d(Q, Q_i)\} \quad (4.10)$$

Em caso de empate de distâncias na maior distância obtida, pode-se selecionar apenas o número necessário de objetos que satisfazem a regra, ou criar uma lista de empates.

Estas consultas são ilustradas na Figura 9 (MARQUES, 2006), com o objeto centro da consulta representado em vermelho e os objetos em verde representando os objetos retornados pela consulta.

4.1.3 Avaliação das Consultas

As medidas mais tradicionais para se avaliar consultas por similaridade e mensurar a efetividade da recuperação são as medidas de precisão (*precision*) e revocação (*recall*) (BAEZA-YATES; RIBEIRO-NETO et al., 1999).

Figura 9: Tipos de consulta: em (a) consulta por abrangência Q com raio r . (b) Consulta por vizinhos mais próximos com $K=5$

A precisão da recuperação pode ser computada como a razão do número de imagens relevantes pelo número total de imagens recuperadas. Nessa computação, cada imagem recuperada recebe um peso binário de valor unitário ou zero, indicando relevância ou não da imagem. O valor da somatória dos pesos de todas as imagens recuperadas é dividido pelo número total de imagens recuperadas. A imagem é considerada relevante se sua classe pertence à mesma classe da imagem de busca.

A revocação da recuperação, por sua vez, é computada como a razão do número de imagens relevantes pelo número total de imagens relevantes na base.

5 *Aprendizado de Máquina*

Uma outra abordagem na caracterização das imagens de úlceras dermatológicas é a visão do problema pelo paradigma de aprendizado de máquinas (AM). Por este meio é possível realizar a classificação das imagens utilizando seus atributos extraídos anteriormente.

AM é uma área de Inteligência Artificial (IA) que visa o desenvolvimento de técnicas computacionais capazes de adquirir conhecimento de forma automática. Um sistema de aprendizado é um algoritmo que toma decisões baseado em experiências acumuladas por meio da solução bem sucedida de problemas anteriores. O aprendizado de máquina pode ser dividido em supervisionado e não-supervisionado.

No aprendizado supervisionado, a classe associada é conhecida. Assim, o algoritmo aprende por meio de um conjunto de entradas e saídas desejadas (classes associadas). Em geral, cada exemplo é descrito por um vetor de atributos e o rótulo da classe a qual este exemplo pertence.

No processo de aprendizado, há três etapas elementares (BARANAUSKAS, 2001): pré-processamento, mineração e pós-processamento. Na etapa de pré-processamento, preparam-se os dados para o processo de mineração. Na etapa de preparação, os dados são coletados e transformados para o início do processo de mineração. A etapa de mineração procura por soluções que podem ter diferentes objetivos e complexidade. Por fim, a etapa de pós-processamento ou análise das soluções obtidas é efetuada, consolidando os resultados obtidos em uma solução final.

A seguir, serão apresentados alguns algoritmos de AM que foram utilizadas no desenvolvimento do presente projeto: Árvores de Decisão, Redes Neurais Artificiais, Aprendizado por Memorização e classificador Bayesiano.

5.1 Árvores de Decisão

Árvores de Decisão pertencem à família de algoritmos de AM indutivo *Top Down Induction of Decision Trees*. Uma árvore de decisão utiliza uma estratégia de dividir-para-conquistar, decompondo um problema maior em subproblemas mais simples, de forma recursiva (QUINLAN, 1990). A construção de uma árvore de decisão baseia-se na escolha de um atributo que servirá para particionar os exemplos em subconjuntos correspondentes a cada valor do atributo. Passa-se então os exemplos para os subconjuntos de acordo com o valor do atributo escolhido e para cada subconjunto, observa-se se todos os exemplos pertencem a uma mesma classe. Se isso ocorrer, associa-se essa classe à um nó folha contendo todos os exemplos desse subconjunto. Caso contrário, é escolhido um novo atributo para particionar os exemplos e o processo é repetido até que haja uma homogeneidade das classes dos exemplos de um determinado subconjunto. Porém, uma árvore pode crescer muito, tornando-se específica para um determinado conjunto de exemplos, e causando assim um *overfitting*. A poda é uma técnica que evita o problema de *overfitting* por meio da geração de uma hipótese mais genérica a partir do conjunto de treinamento. Como consequência da poda, as folhas não necessariamente conterão exemplos de uma única classe, e assim, a poda pode causar a classificação incorreta de exemplos de treinamento. Há basicamente dois métodos de poda (BARANAUSKAS, 2001):

1. pré-poda: durante a geração da hipótese, alguns exemplos de treinamento são deliberadamente ignorados, de forma que a hipótese final não classifique todos os exemplos de treinamento corretamente;
2. pós-poda: inicialmente, uma hipótese que explica os exemplos de treinamento é gerada. Após isso, a hipótese é generalizada por meio da eliminação de algumas partes, tais como o corte de alguns ramos em uma árvore de decisão.

Uma árvore de decisão pode ser usada para classificar novos exemplos. Assim, quando se deseja classificar um novo exemplo, percorre-se a árvore a partir da raiz e desvia-se em cada nó de decisão, segundo o atributo correspondente até que se atinja um nó folha, e então, associa-se a esse novo exemplo a classe correspondente a esse nó folha.

Na Figura 10 é ilustrada a estrutura da árvore de decisão do exemplo para classificar um novo paciente em saudável ou doente.

Figura 10: Estrutura de uma árvore de decisão

5.2 Redes Neurais Artificiais - RNAs

Segundo (HAYKIN, 2001), uma rede neural é um processador maciçamente e paralelamente distribuído, constituído de unidades de processamento simples e que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente por meio de um processo de aprendizagem e forças de conexão entre neurônios, conhecidas como pesos sinápticos que são utilizadas para armazenar o conhecimento adquirido. Cada representação computacional de um nó, que se assemelha a um neurônio, é chamada de *perceptron*.

Uma RNA com mais de uma camada de *perceptrons* é denominada por *Perceptron Multicamadas* (MLP). O MLP consiste em um conjunto de nós sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas ou intermediárias de nós computacionais (neurônio) e uma camada de saída de nós computacionais. O sinal de entrada se propaga para a frente, passando pelas camadas ocultas em direção à camada de saída.

Há dois tipos de algoritmos de treinamento do MLP, os estáticos e os construtivos. Os construtivos alteram a estrutura da rede, já os estáticos não. No treinamento estático, o algoritmo mais utilizado é o algoritmo de retropropagação do erro (*Backpropagation*) o qual utiliza regra de aprendizado por correção de erro. O treinamento consiste em duas fases, cada uma percorre a rede em um sentido, a fase *forward* e a fase *backward*.

Na fase *forward*, a entrada é apresentada à primeira camada da rede (camada de entrada). Os neurônios de uma camada calculam seus valores de saída, que são utilizados pelos neurônios da camada posterior para definir suas saídas. As saídas produzidas pelos neurônios da última camada são comparadas às saídas desejadas e o erro para cada neurônio da camada de saída é calculado. Na fase *backward*, cada nó ajusta seu peso de modo a reduzir seu erro e cada nó das camadas anteriores tem seu erro definido pelos erros da camada seguinte conectados a ele, ponderados pelos pesos das conexões entre ele e estes nós.

Na Figura 11 é ilustrada a estrutura de um MLP, onde as entradas são os atributos de cada exemplo e as saídas seriam as classes previstas pelo MLP.

Figura 11: Estrutura do MLP

5.3 Aprendizado por Memorização

Algoritmos de aprendizado por memorização utilizam uma função de distância ou similaridade para determinar o quão próximo o novo exemplo encontra-se de um exemplo já armazenado e utiliza este exemplo mais próximo para determinar a classe do novo exemplo. Este método assemelha-se a consulta por K vizinhos mais próximos, porém sob um paradigma de aprendizado de máquinas e não de recuperação de informação.

Pode-se utilizar também os K exemplos mais próximos para classificar um novo exemplo. O algoritmo K-NN (*K-Nearest-Neighbors*) encontra os K vizinhos mais próximos do novo exemplo a ser classificado e normalmente utiliza distância Euclidiana (Eq. 4.2) entre dois exemplos A e B.

A classe do novo exemplo é determinada pela maioria dos vizinhos encontrados. Assim, se a maioria dos K vizinhos pertencerem a uma mesma classe, essa classe será associada ao novo exemplo.

5.4 Classificador Bayesiano

Fundamentados no teorema de Bayes da probabilidade condicional, conforme Equação 6.4, os classificadores Bayesianos, dentre eles o Naive Bayes, calculam a probabilidade de um exemplo pertencer a cada uma das classes pré-determinadas, assumindo que há independência entre os atributos que descrevem o exemplo (DOMINGOS; PAZZANI, 1997). Tal probabilidade é usada para gerar um modelo com uma regra de decisão que sempre fornece como resposta a classe que, após a aplicação do teorema de Bayes, obteve a maior probabilidade.

$$P(C|A) = \frac{P(A|C) \cdot P(C)}{P(A)} \quad (5.1)$$

Suponha que A é um novo exemplo a ser classificado, ou seja, não está no conjunto de treinamento. O classificador Naive Bayes classifica A como pertencente a uma classe C para a qual a probabilidade condicional $P(C | A)$ é a mais alta possível. Ou seja, A será classificada na classe C se a probabilidade condicional de C acontecer dado que A acontece é maior do que a probabilidade de qualquer outra classe C' acontecer dado que A acontece. Portanto, o exemplo A será classificado na classe C_i se:

$$P(C_i|A) > P(C_j|A) \quad (5.2)$$

para todas as outras classes C_j , $C_j \neq C_i$. Esta probabilidade $P(C_i | A)$ também é chamada de probabilidade posterior.

5.5 Validação Cruzada

A validação cruzada (*r-fold cross validation*) é um método de amostragem para a análise do desempenho de um classificador que divide aleatoriamente as amostras em r partições (*folds*) mutuamente exclusivas de tamanho aproximadamente igual a n/r amostras, onde n é o número total de amostras disponíveis. O classificador é treinado com os $r - 1$ *folds* induzidos de amostras e a regra de classificação ou metodologia derivada é

testada no *fold* restante. Este processo é repetido r vezes, de modo que cada *fold* é usado uma vez como o conjunto de teste, conforme ilustrado na Figura 12.

Figura 12: Validação cruzada utilizando r folds

5.6 Seleção de Atributos

A seleção de atributos úteis é um dos problemas relacionados à ciência de Aprendizado de Máquinas. Embora a maioria dos algoritmos de aprendizado tente selecionar atributos, ou então atribuir graus de importância a eles, análises teóricas e estudos experimentais indicam que muitos algoritmos apresentam um comportamento ruim com a presença de um grande número de atributos irrelevantes. Por exemplo, o número de exemplos necessário para o algoritmo K-NN atingir um dado nível de precisão parece crescer exponencialmente com o número de atributos irrelevantes, independente do conceito a ser aprendido. Mesmo os indutores de árvores de decisão, que explicitamente selecionam alguns atributos em detrimento de outros, exibem este comportamento para alguns conceitos. Outros algoritmos, tais como Naive Bayes (DOMINGOS; PAZZANI, 1997), são robustos com relação à presença de atributos irrelevantes, mas podem ser extremamente sensíveis em domínios contendo atributos fortemente correlacionados, mesmo se os atributos são relevantes. Isto pode ser explicado pelo fato que esses algoritmos assumem independência entre os atributos. Assim, isso sugere a necessidade de métodos adicionais para selecionar um subconjunto

útil de atributos quando muitos deles encontram-se disponíveis (LANGLEY, 1996).

Existem três abordagens de seleção de atributos: embutida, filtro e *Wrapper* (LIU; MOTODA, 2008). Nas estratégias do tipo embutida os indutores realizam sua própria seleção de atributos de maneira dinâmica durante a fase de treinamento (GUYON; ELISSEEFF, 2003). Na abordagem do tipo filtro um subconjunto de atributos é selecionado de forma independente do classificador. Os filtros utilizam as informações da própria base para escolher os atributos mais relevantes a serem selecionados (GUYON; ELISSEEFF, 2003). Por fim, a seleção de atributos utilizando a abordagem tipo *Wrapper* utiliza o próprio indutor como um modelo não simbólico para predizer o melhor subconjunto de atributos (GUYON; ELISSEEFF, 2003).

5.6.1 *Wrapper*

O algoritmo *Wrapper* gera subconjuntos de atributos candidatos e avalia-os usando um sistema de aprendizado (KOHAVI, 1995). Este processo é repetido com cada conjunto candidato até que o critério de parada seja atingido. Validação cruzada é usada para estimar a precisão do sistema de aprendizado para um determinado conjunto de atributos (KOHAVI, 1995).

5.6.2 Mecanismo de Busca

O algoritmo *Wrapper* precisa de um mecanismo de busca para selecionar os atributos no espaço de atributos. Dentre os algoritmos de busca existem: busca genética (GOLDBERG, 1989), busca gulosa (*hill-climbing*) (KOHAVI, 1995) e *linear forward selection search* (GÜTLEIN et al., 2009).

Algoritmos de busca genética são implementados como uma simulação computacional na qual uma população de representações abstratas de solução é selecionada em busca de melhores soluções (GOLDBERG, 1989). A evolução geralmente começa a partir de um conjunto de soluções criadas aleatoriamente, e é levada através de gerações. Em cada geração, a adaptação de cada solução é avaliada com a população; alguns indivíduos são selecionados para a próxima geração, e mutados ou recombinados para formar uma nova população. A nova população é então usada como entrada para a iteração seguinte.

A técnica de busca *hill-climbing*, também conhecida como busca gulosa ou *steepest ascent*, é um algoritmo que expande o nó atual e move-se para o nó filho que apresenta a maior precisão, terminando quando nenhum nó filho proporciona melhoria em relação ao

nó atual (KOHAVI, 1995).

A busca *Linear forward selection* leva um número restrito de l atributos em conta. A busca utiliza ou a ordem inicial dos atributos ou um *ranking*, o qual é realizado para selecionar os l melhores atributos. A direção da busca pode ser *forward* (para frente), ou uma abordagem de seleção flutuante para frente também pode ser usada, e o processo pára em um tamanho ótimo précalculado do subconjunto (GÜTLEIN et al., 2009).

5.7 Clusters

A ação de criar *Cluster*, ou aglomerações, deve-se ao ato de agrupar objetos a uma mesma classe de acordo com alguma característica semelhante entre eles. O objetivo de um *cluster* é maximizar a homogeneidade dentro de um *cluster* enquanto maximiza-se a heterogeneidade entre diferentes *clusters* (MICHALSKI; STEPP, 1992). Existem três técnicas de agrupamento de *clusters*: otimização, distribuição e hierárquicas. Na Figura 13 são mostrados os três métodos de clusterização.

Figura 13: Os três métodos de clusterização: (a) otimização, (b) distribuição e (c) hierárquicas

As técnicas de otimização formam h partições no espaço de atributos, sendo que para cada espaço um centróide é definido e cada elemento no espaço é relacionado como

pertencente ao cluster de centróide mais próximo (JAIN; MURTY; FLYNN, 1999).

Os modelos de distribuição são baseados em modelos de distribuições estatísticas e sua probabilidade de estar em cada *cluster* (FRALEY; RAFTERY, 1998). Dentre os modelos de distribuição, o método mais conhecido é o *Expectation-maximization* (*EM-clustering*) (DEMPSTER; LAIRD; RUBIN, 1977) que será descrito na seção seguinte.

O modelo hierárquico cria árvores de dendogramas, nos quais as folhas representam os exemplos individuais e os nós internos representam os *clusters*. A profundidade da aglomeração define o *cluster* (ZHAO; KARYPIS; FAYYAD, 2005).

5.7.1 *Expectation Maximization*

O algoritmo *EM-clustering* utiliza a distribuição dos dados para tomar uma decisão probabilística sobre qual exemplo deve pertencer a qual *cluster* baseando-se na máxima verossimelhança estimada por parâmetros do modelo estatístico utilizado. O algoritmo baseia-se em um modelo estatístico de “misturas finitas” (MCLACHLAN; PEEL, 2000), que é a probabilidade de em cada distribuição um exemplo possuir um determinado conjunto de atributos para pertencer a um determinado *cluster*.

O procedimento do algoritmo *EM-clustering* é realizar uma tentativa inicial de estimação dos parâmetros para o modelo estatístico utilizado e, com os parâmetros mensurados, são calculadas as probabilidades de cada um dos exemplos pertencerem a um *cluster* (*expectation*). De forma iterativa, o algoritmo reestima os parâmetros com base nas probabilidades calculadas (*maximization*). Por fim, é esperado uma convergência nos valores estimados até que o aumento na probabilidade geral seja desprezível (GOGGINS et al., 1998).

6 *Materiais e Métodos*

Neste capítulo serão descritos os materiais e métodos utilizados nos processos de montagem da base de dados, préprocessamento das imagens, segmentação das imagens, quantificação da composição de cores da lesão, recuperação por conteúdo e classificação das imagens. Na Figura 14 é exemplificada a funcionalidade e conexões entre as etapas.

Figura 14: Visão geral do fluxo da metodologia adotada

As etapas de segmentação, quantização e extração de características das imagens foi feita utilizando o pacote de software comercial MatLab (MATLAB 2009a, The MathWorks Inc., Natick, MA, 2010).

6.1 Base de Imagens

Este trabalho faz um estudo retrospectivo, utilizando uma base de imagens préexistente do trabalho (DORILEO et al., 2008), aprovado pelo Comitê de Ética e Pesquisa do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, ofício 2981/2011.

Todas as imagens foram fotografadas com uma câmera digital do mesmo modelo (Canon EOS 5D0, 2 Mega pixels), com uma lente de macro de 50 mm e filtro de polarização, segundo protocolo estabelecido para esse propósito. Tipicamente, as imagens obtidas possuem matriz de 1747 x 1165 pixels e 24 bits/pixel. A composição do tecido de cada lesão foi posteriormente classificada por um dermatologista experiente, que é colaborador também neste estudo, com base nas cores, como sendo granulação (vermelho), fibrina (amarelo), necrótica (preto), calosa (branca) e misto. As 172 imagens da base incluem 51 imagens com predominância de tecido com granulação, 31 com predominância de fibrina, 3 com tecido necrótico, 3 com tecido caloso e 87 mistas, as quais são lesões compostas por dois tecidos ou mais. Um fundo azul foi utilizado na aquisição das imagens para facilitar o processamento posterior, uma vez que essa componente de cor não existe na lesão. Uma régua de calibração também foi utilizada, como é ilustrado na Figura 15. O especialista supervisionou a segmentação manual e classificação das imagens das lesões, para fins de obtenção dos padrões de referência para posterior comparação com os resultados.

Figura 15: Régua criada para a normalização das cores das imagens usadas no estudo

6.2 Préprocessamento das Imagens

Previamente à segmentação, cada imagem da base de dados passou por um préprocessamento com a requantização de suas cores, utilizando o modelo de cores HSV. O objetivo do préprocessamento é diminuir o número de cores das imagens deixando somente as relevantes ao contexto, sendo elas as tonalidades branca, preta, amarela e vermelha.

A imagem foi requantizada para 150 cores (mais branco e preto) utilizando sua matiz e saturação. Foram apenas consideradas as matizes compreendidas entre os ângulos de

330 e 90 graus, que são as cores encontradas nas úlceras. A cor branca foi definida pela saturação inferior a 0.2 e brilho maior que 0.5, enquanto que a cor preta foi definida pela saturação inferior a 0.2 e brilho inferior a 0.5. As cores restantes pertencentes ao intervalo (330 a 90 graus) foram agrupadas por determinadas faixas de saturação e matiz, como é mostrado na Figura 16.

Figura 16: Distribuição das cores na matiz e saturação após a requantização. As cores compreendidas na faixa escura não foram consideradas e as com saturação inferior a 0.2 foram definidas como preto ou branco. Cada segmento determinado pelas faixas de saturação e matiz corresponde então a apenas uma cor

6.3 Segmentação de Imagens

Segmentação é o processo de divisão da imagem em regiões que não sejam interseccionadas. Espera-se de uma boa segmentação que os pontos da imagem de uma mesma região tenham propriedades similares e delimitem uma área de interesse (*Region of Interest* - ROI). A segmentação de imagens coloridas adiciona uma informação que por vezes está ausente nas imagens em escala de cinza, aumentando com isso o grau de complexidade das técnicas de segmentação. A informação adicional vem da composição da imagem por diversas matrizes. No caso das imagens no espaço de cor RGB (*Red, Green, Blue*), cada pixel da imagem é formado pela composição dos seus valores para cada uma das três cores, como é mostrado na Figura 3.

6.3.1 JSEG

Dentre os métodos de segmentação estudados, foi visto que em (WANNOUS; TREUILLET; LUCAS, 2010), a segmentação utilizando o algoritmo JSEG (DENG; MANJUNATH, 2001) apresentava bons resultados. Portanto, foi estudado um meio de otimizá-los realizando uma requantização prévia das cores e uma posterior avaliação da segmentação realizada comparada com a segmentação manual feita pelo dermatologista. A técnica de avaliação utilizada foi o coeficiente de Jaccard dado pela fórmula 6.1:

$$Jaccard(A, B) = \frac{A \cap B}{A \cup B} \quad (6.1)$$

sendo A a imagem com a segmentação realizada e B a imagem segmentada manualmente.

O JSEG é um algoritmo para a segmentação não supervisionada de regiões de textura de cores em imagens. Este é um método robusto para segmentar as imagens e pode ser adaptado para as imagens de úlceras dermatológicas. Ele consiste em duas etapas independentes: quantização da cor e segmentação espacial.

Na primeira etapa, o objetivo é definir as regiões da imagem utilizando um mínimo de cores e cada cor é associada a uma classe. A imagem original tem os pixels substituídos pelas classes, o que dá origem ao mapa de classes que será usado na próxima etapa.

Para a etapa da segmentação espacial é necessário criar a *J-image* a partir do mapa de classes. As *J-images* correspondem às medições da homogeneidade local em diferentes escalas e podem indicar possíveis regiões de bordas. Os valores dos pixels da *J-image* são chamados de valores J e são calculados a partir de uma janela posicionada sobre a imagem quantizada, em que o valor J a ser calculado é o do pixel no centro da janela.

Para calcular o valor J , primeiro define-se Z como o conjunto de todos os pontos da imagem quantizada por $z = (x, y)$, com $z \in Z$ e m sendo a média de todos os elementos em Z . O conjunto C é definido pelas classes obtidas na quantização. Então, Z é classificado em C classes, sendo que Z_i são os elementos de Z que pertencem à classe i , em que $i = 1, \dots, C$; m_i são as médias dos elementos em Z_i . O valor J é dado por:

$$J(A, B) = \frac{(S_t - S_w)}{S_w} \quad (6.2)$$

na qual:

$$S_t = \sum_{z \in Z} |z - m|^2 \quad (6.3)$$

e

$$S_w = \sum_{i=1}^C \sum_{z \in Z} |z - m|^2 \quad (6.4)$$

São usados diversos tamanhos de janelas em ordem decrescente: as maiores detectam as fronteiras de regiões com texturas e as menores detectam mudanças de cores e/ou de intensidade da luz. Cada tamanho de janela está associado a uma escala de análise da imagem. O conceito de *J-image*, juntamente com as diversas escalas, viabiliza a segmentação de regiões com texturas. Após o uso da menor janela, o algoritmo agrupa as regiões com variâncias semelhantes por meio do crescimento de regiões, resultando assim na imagem segmentada.

Após o processo de requantização, como ilustrado na Figura 17, a imagem passa então pelo algoritmo JSEG, como é mostrado na Figura 18, que realiza a segmentação da imagem. A escolha dos segmentos que compõem a lesão é feita de modo manual pelo clique do mouse do usuário. Depois é então calculado o coeficiente de Jaccard tendo como base a imagem segmentada manualmente. Para a análise qualitativa, cada segmento foi identificado como pertencente à lesão ou não pela utilização da imagem de referência segmentada manualmente pelo especialista.

Figura 17: Requantização das imagens. Em (a) a imagem original e em (b) a imagem requantizada. Os pixels em azul referem-se aos pontos aos quais a matiz está fora da faixa de cores selecionada

Figura 18: (a) Resultado da imagem após o algoritmo de segmentação JSEG. (b) Resultado da escolha das regiões pertencentes à úlcera pelo clique do usuário nelas

6.3.2 Segmentação utilizando algoritmo JSEG e técnicas de Aprendizado de Máquinas

Na tentativa de automatizar o processo de segmentação com o método JSEG que necessitava da interação com o usuário, foi agregado ao método técnicas de aprendizado de máquinas para prever a classe de cada segmento. Portanto para cada segmento encontrado pelo algoritmo JSEG foram extraídos os atributos para caracterização das imagens citados na Seção 6.5. Por fim, cada segmento foi classificado como pertencente ou não a lesão.

Este método foi aplicado de forma experimental em 35 imagens da base de dados escolhidas aleatoriamente. Foram extraídos X segmentos, sendo Y contendo lesão e Z não contendo lesão. Para cada segmento foram extraídos as características descritas a seguir, na Seção 6.5, e utilizadas para os testes de classificação utilizando o método de validação cruzada com 20 *folds*. Uma vez que existem mais exemplos de X do que de Y , foram removidos $Y - X$ exemplos aleatoriamente da classe Y para não comprometer a classificação devido a existência de mais da metade de exemplos de uma classe quando comparada com a outra.

A base de dados então foi passada pelos classificadores K-NN ($K = 10$), MLP, Naive Bayes e Árvores de decisão. As métricas porcentagem de acerto e área média embaixo da curva ROC foram obtidas como parâmetros para análise.

6.3.3 Segmentação utilizando histogramas de cores e *Clusters*

Um histograma de cores fornece a frequência de cada valor de pixel que aparece em uma imagem (PITAS; KINIKLIS, 1996). Os histogramas no modelo de cores HSV, fornecem para cada uma de suas componentes a informação da frequência em que um valor de matiz, saturação e brilho apareceram em uma imagem. É possível obter um histograma em duas dimensões com as informações de frequência apenas das componentes matiz (H) e saturação (S). Na Figura 19 um exemplo de histograma HS é apresentado, na qual o anel de cores externo serve como orientação para identificar o ângulo da matiz da frequência daquela cor e a saturação é o valor do raio relativo àquele ponto. Quanto mais clara a cor no pixel, maior é a frequência desta cor na imagem.

Figura 19: Exemplo de uma imagem de úlcera dermatológica (a) e seu histograma HS (b)

O agrupamento de pixels em determinada região do histograma pode ser devido a uma aglomeração individual ou difusão de pixels na imagem (CHENG; SUN, 2000).

Para realizar a segmentação baseada nos histogramas HS foi então necessária a adoção de técnicas de clusterização, como descritas na Seção 5.7, nas quais cada *cluster* é rotulado por uma classe. Foi utilizada a técnica *EM-clustering*, com uma distribuição Gaussiana (PERNKOPF; BOUCHAFFRA, 2005) no procedimento realizado.

Após esta fase, foram gerados n *clusters* para cada uma das 172 imagens da base de dados. Na Figura 20 são apresentados os *clusters* criados para uma imagem da base de dados. Em decorrência, os *clusters* que continham pelo menos uma região pertencente a lesão foram selecionados para a composição da máscara de segmentação e operadores morfológicos foram utilizados para retirar possíveis ruídos e preencher buracos da máscara.

No entanto, em alguns casos, a região segmentada não preenche todo o domínio da lesão, porém a maioria dos elementos presentes aparecem na lesão, portanto a técnica de *Convex Hull* foi utilizada para criar o menor polígono convexo que englobe todos os elementos da segmentação, com isso finalizando o processo.

Figura 20: Segmentação utilizando um método de clusterização com $N=5$. Em (a) a imagem original; (b) o histograma HS com os *clusters* formados representando cada um uma tonalidade de cor; e (c) o *cluster* aplicado à imagem

Para a análise do processo foi calculado o coeficiente de Jaccard (Eq.6.1) entre a imagem segmentada automaticamente e a segmentada manualmente. Além disso foi feita uma quantificação da composição de cores da lesão como descrito na Seção 6.4 para determinar o quanto a composição da imagem segmentada automaticamente se relaciona com a segmentada manualmente.

6.4 Quantificação da Composição de Cores da Lesão

A análise do problema pela quantificação dos seus componentes fornece pistas importantes para o diagnóstico e para o prognóstico (ODUNCU et al., 2004), portanto a quantificação da distribuição de cores da lesão, por meio de técnicas de processamento de imagens pode auxiliar na caracterização e análise da dinâmica do processo patológico (PEREIRA et al., 2010). Neste contexto, foi estudada uma técnica para a caracterização automática dos componentes de tecido das úlceras por meio de métodos de processamento de imagens utilizando o modelo de cores HSV.

Foram definidas faixas de valores para a saturação, brilho e matiz de modo a separar cada abrangência das cores estudadas. Portanto, tendo em vista que as cores que compõem uma lesão são a vermelha, amarela, branca e preta, como descrito anteriormente, é possível determinar intervalos para cada uma. Na Figura 21 é demonstrado um intervalo de matiz entre 0 e 90 graus e saturação entre 0,2 e 0,7.

Como parâmetros da quantificação, foram definidas condições para o procedimento de segregação das cores por meio de segmentos determinados pela matiz (H), saturação (S) e brilho (V). A cor branca foi considerada pelos parâmetros de $S < 0,2$ e $V > 0,75$; a cor preta foi dada por $S < 0,2$ e $V > 0,2$; a cor vermelha como $S \geq 0,2$ e matiz entre $330^\circ \leq H \leq 30^\circ$; e por fim a cor amarela como $S \geq 0,2$ e matiz entre $30^\circ \leq H \leq 90^\circ$. Os resultados foram então comparados com a quantificação realizada por um dermatologista (MACF) e então calculado o erro médio quadrático (RMS - *Root Mean Square*) para cada imagem para determinar a taxa de dissimilaridade entre ambas as quantificações.

6.5 Extração de Características

Cada imagem foi manualmente segmentada por um dermatologista especialista em duas regiões: a lesão e o plano de fundo. Para cada região representando a lesão, em adição à representação básica de cor RGB, foram geradas imagens nas representações de cores $L^*a^*b^*$, $L^*u^*v^*$ e HSV (GONZALEZ; WOODS, 2008), sendo que nesses três espaços de cor, a componente de brilho ou luminosidade foi desconsiderada (L para $L^*a^*b^*$ e $L^*u^*v^*$ e H para HSV). Foram extraídas um total de 111 características de cada imagem, descritas a seguir:

- Média, desvio padrão, skewness e kurtosis dos histogramas das componentes das imagens RGB, HS, a^*b^* e u^*v^* .

Figura 21: Exemplificação da segregação de cores no modelo HSV com matiz entre 0 e 90 graus e saturação entre 20% e 70%. A região selecionada encontra-se em destaque

- Cinco dos quatorze atributos propostos por (HARALICK; SHANMUGAM; DINSTEIN, 1973) retirados da matriz de co-ocorrência média, computada a partir de quatro matrizes de co-ocorrência para distância de 1 pixel e ângulos de 0, 45, 90 e 135 graus. Os atributos extraídos são homogeneidade (Eq. 6.5), contraste (Eq. 6.6), correlação (Eq. 6.7), entropia (Eq. 6.12) e homogeneidade local (Eq. 6.13), como sugerido por (CONNERS; HARLOW, 1980).
- Os cinco atributos mencionados acima foram obtidos a partir de matrizes de co-ocorrência multi-espectral ou coloridas (CCMs), obtidas das componentes RGB, HS, a^*b^* e u^*v^* , utilizando e estendendo o método proposto por (ARVIS et al., 2004). O método é uma extensão do método proposto por (HARALICK; SHANMUGAM; DINSTEIN, 1973) e foi desenvolvido para aplicação em imagens coloridas para levar em conta a correlação existente entre as componentes de cor, como é exemplificado na Figura 22.

$$Homogeneidade = \sum_i \sum_j \frac{M(i, j)}{1 + |i - j|} \quad (6.5)$$

$$Contraste = \sum_i \sum_j (i - j)^2 \cdot M(i, j) \quad (6.6)$$

$$Correlacao = \sum_i \sum_j \frac{(j - m_x) \cdot (i - m_y) \cdot M(i, j)}{\sqrt{s_x \cdot s_y}} \quad (6.7)$$

na qual:

$$m_x = \sum_i \sum_j j \cdot M(i, j) \quad (6.8)$$

$$m_y = \sum_i \sum_j i \cdot M(i, j) \quad (6.9)$$

$$s_x = \sum_i \sum_j (j - m_x)^2 \cdot M(i, j) \quad (6.10)$$

$$s_y = \sum_i \sum_j (i - m_y)^2 \cdot M(i, j) \quad (6.11)$$

$$Entropia = - \sum_i \sum_j \log(M(i, j)) \quad (6.12)$$

$$HomogeneidadeLocal = \sum_i \sum_j \frac{M(i, j)}{1 + (i - j)^2} \quad (6.13)$$

6.5.1 Recuperação por Conteúdo

O processo de recuperação de imagens por conteúdo foi feito utilizando diferentes métricas de distância e imagens recuperadas. Em cada recuperação foi calculada a precisão (Eq. 6.14) e posteriormente feita a média e desvio padrão para a base toda e para cada tipo de lesão. A precisão não foi calculada para as classes de necrose e calosa por apresentarem apenas 3 exemplos cada uma na base de imagens.

$$precisao = \frac{|\{documentos\ recuperados\} \cap \{documentos\ relevantes\}|}{|\{documentos\ recuperados\}|} \quad (6.14)$$

Portanto, foram realizadas combinações entre as métricas Euclidiana, *City Block*,

Figura 22: Método proposto para correlação existente entre as componentes de cor com as combinações das matrizes de co-ocorrência

Chebychev, Cosseno e Correlação e o número de exemplos recuperados utilizando o K-NN. O K variou inicialmente de 5 a 30, com passo 5. Ao final, cada métrica foi utilizada para 6 recuperações com diferentes valores de K , totalizando 30 testes de recuperação por conteúdo.

Além disso, outro experimento de recuperação foi feito com o valor de K variando de 1 até 7 com passo 2. Para cada valor de K , todas as imagens da base de dados foram usadas, uma a uma, como a imagem de consulta. O valor médio da precisão de recuperação foi calculado para cada experimento de recuperação e para cada distância ou métrica.

Empregando outra abordagem, foi calculada a distância das imagens no espaço de cor $L^*a^*b^*$ utilizando a métrica CIEDE2000, citada na Seção 4.1.1, para tanto, utilizou-se o algoritmo implementado por (SHARMA; WU; DALAL, 2005) em linguagem Matlab. Utilizou-se como parâmetro de recuperação a média dos histogramas das três componentes de cada imagem no espaço de cores $L^*a^*b^*$. Foram então realizados testes de recuperação variando o número de imagens recuperadas entre 5 e 30, com passo 5.

Os testes de recuperação foram feitos de dois modos. Primeiramente com as imagens segmentadas manualmente pelo médico especialista (MACF) e posteriormente com as imagens segmentadas utilizando a metodologia proposta na Seção 6.3.3. Em ambos

experimentos foram utilizadas as 172 imagens da base de dados, as mesmas métricas de distância e os mesmos números de imagens recuperadas. Deste modo, foi possível avaliar o real impacto da segmentação automática no processo de recuperação.

6.5.2 Classificação das Imagens

A classificação das imagens foi feita com os indutores Árvore de Decisão, K-NN, Naive Bayes e MLP, implementados pela biblioteca Weka (HALL et al., 2009) e utilizando validação cruzada com 20 *folds*. Para avaliar os resultados de classificação, métricas como especificidade (Eq. 6.16), sensibilidade (Eq. 6.15) e a área embaixo da curva ROC (*receiver operating characteristic*) foram obtidas para cada experimento. A especificidade da classificação foi calculada em cada experimento como a razão entre os verdadeiros positivos e o número de amostras positivas. A sensibilidade da classificação é a razão entre os verdadeiros negativos e o número de amostras negativas. O desempenho dos classificadores foi avaliado por meio da plotagem de um gráfico de sensibilidade versus (1-especificidade), isto é, a curva ROC, e calculando a área embaixo da curva (AUC) (HAND; TILL, 2001). Um grande valor de AUC indica bom desempenho na classificação.

No contexto deste trabalho, cada imagem é um exemplo que possui um vetor de atributos e cada uma delas possui uma classe associada que é o tipo de lesão do paciente, granulação fibrina, necrótico, cicatrização ou misto. Utilizando esses dados, almeja-se o desenvolvimento de um indutor que seja capaz de classificar corretamente novos exemplos.

$$\text{sensibilidade} = \frac{\text{exemplos positivos classificados corretamente}}{\text{todas amostras positivas}} \quad (6.15)$$

$$\text{especificidade} = \frac{\text{exemplos negativos classificados corretamente}}{\text{todas amostras negativas}} \quad (6.16)$$

A base de dados de imagens foi dividida em três conjuntos diferentes: o primeiro contendo todas as imagens e as suas características extraídas; o segundo sem as classes necrótica e calosa; e o terceiro somente com as classes fibrina e granulação (PEREIRA et al., 2011).

O motivo para a exclusão das classes necrótica e calosa na segunda base de dados é devido ao pequeno número de amostras (somente seis, sendo três de cada classe). Por esta razão, a classificação destas classes é comprometida devido a memorização de pe-

culiaridades do conjunto de treinamento ao invés de encontrar regras preditivas gerais, resultando em um fenômeno denominado *overfitting* (DIETTERICH, 1995). Estas classes podem ser consideradas como ruído ou fora de contexto (*outliers*) na base de dados.

Na terceira base de dados, foram levadas em consideração apenas as imagens da classe de granulação e fibrina, pois é interessante verificar a separabilidade entre os mais importantes tipos de lesões da base de dados que contenham um número razoável de imagens, com base no processo de acompanhamento da cura. Desta maneira, pode-se verificar se as características extraídas podem caracterizar uma classe pura de lesão, como é o caso da granulação e fibrina.

Para o terceiro subconjunto, a razão de manter somente as classes fibrina e granulação foi que estes tipos de tecidos representam diferentes situações no processo de cura; é importante ser capaz de classificá-los corretamente. Além disso, a classe mista é formada principalmente pela mistura destes dois tipos de tecidos.

6.5.3 Seleção de Atributos

No processo de classificação entre os diferentes tipos de úlceras de pele, as características extraídas devem ser avaliadas para determinar quais são as mais relevantes para a solução do problema (KOHAVI, 1995). A existência de atributos correlacionados no conjunto de características utilizado pode alterar drasticamente a precisão de alguns classificadores. Por outro lado, alguns classificadores perdem precisão devido à existência de mais atributos do que o conjunto ideal desejável (MITCHELL, 1997). Assim, é importante verificar a adequação e relevância das características disponíveis no contexto do presente problema (BLUM; LANGLEY, 1997). Os experimentos descritos no presente trabalho foram realizados usando o *software* de código aberto Weka 3.6.4 (HALL et al., 2009).

Dentre os algoritmos disponíveis para realizar a seleção de atributos ou características, foi escolhido o algoritmo *Wrapper*. A validação cruzada é usada para estimar a precisão do sistema de aprendizado para um determinado conjunto de atributos (KOHAVI, 1995). Os classificadores escolhidos para executar o algoritmo *Wrapper* são Naive Bayes (DOMINGOS; PAZZANI, 1997), *multilayer perceptron* (MLP) (VAZIRI et al., 2007), árvores de decisão (QUINLAN, 1990), e *K-nearest-neighbor* (K-NN) (BEYER et al., 1999).

Os mecanismos de busca utilizados foram a busca genética (GOLDBERG, 1989), busca gulosa (*hill-climbing*) (KOHAVI, 1995), e *linear forward selection search* (GÜTLEIN et al., 2009).

Doze testes de seleção de atributos foram realizados, utilizando as 111 características extraídas para cada imagem, com os quatro classificadores e os três mecanismos de busca mencionados na Seção 5.6.2 e o algoritmo *Wrapper*. Os atributos selecionados foram armazenados e comparados para verificar quais foram selecionados mais vezes.

Foi analisada a frequência de seleção de cada atributo nos doze testes. Um teste de avaliação foi realizado com os classificadores utilizados (naive Bayes, MLP, K-NN, e árvores de decisão) e os atributos selecionados uma vez ou mais, duas vezes ou mais, e assim por diante até oito vezes, que foi a frequência mais alta obtida. A porcentagem de imagens classificadas corretamente e a área embaixo da curva ROC (*receiver operating characteristic*) foram obtidas para a análise comparativa. No presente trabalho, devido à existência de cinco classes de úlceras, a análise da curva ROC foi realizada em cinco etapas, tratando cada classe como positivo e as quatro classes restantes como negativo. Uma média ponderada foi então calculada utilizando os cinco valores de AUC obtidos.

7 *Resultados e Discussão*

Neste capítulo serão apresentados os resultados obtidos a partir da metodologia adotada. Os resultados serão exibidos a partir de tabelas e gráficos para avaliar o desempenho dos processos de segmentação, quantificação, recuperação e classificação.

7.1 Segmentação das Imagens

O processo de segmentação foi realizado de forma semi-automática pela seleção dos segmentos pertencentes à lesão após a segmentação pelo método JSEG nas 172 imagens da base de dados. O processo foi comparado entre a utilização ou não do pré-processamento proposto, como é mostrado na Tabela 1. Pode-se observar um alto coeficiente de Jaccard para as segmentações com e sem a utilização do préprocessamento proposto, no entanto pode-se notar que a adição do préprocessamento trouxe uma melhora ao processo.

A seguir, foram introduzidos métodos de AM para tentar automatizar a segmentação do algoritmo JSEG. Os valores de AUC e taxa de acerto foram obtidos para a análise da classificação dos segmentos das 35 imagens escolhidas para este teste. Na Tabela 2 são apresentados estes valores extraídos para os quatro classificadores utilizados.

Apesar dos resultados serem preliminares, é possível dizer que a taxa de acerto é aceitável e pode segregar bem as regiões entre contendo e não contendo lesão. Além disso, o valor obtido de AUC foi alto, o que demonstra que esta solução para segmentação

Tabela 1: Comparação do coeficiente de Jaccard entre os métodos de segmentação propostos

	Tempo de Processamento (s)	Número Médio de Regiões	Coeficiente de Jaccard Médio
Sem pré-processamento	41,9	77,2	0,78
Com pré-processamento	47,2	62,2	0,81

Tabela 2: Taxa de acerto e valores de AUC para os quatros classificadores utilizados na segmentação utilizando JSEG e AM

Classificador	Taxa de acerto	AUC
Naive Bayes	67,5%	0,7
MLP	72%	0,79
K-NN	72,18%	0,79
Árvores de Decisão	73,21%	0,78

de imagens de úlceras dermatológicas pode ser aplicada a base de imagens.

Com a segmentação utilizando a abordagem de definição de *cluster* no histograma HS, foram extraídos dados do coeficiente de Jaccard e quantificação da composição de cores entre as imagens segmentadas manualmente e automaticamente nas 172 imagens da base de dados. Na Figura 23 é apresentada a distribuição dos valores dos coeficientes de Jaccard extraídos no formato de um gráfico boxplot. O coeficiente de Jaccard médio foi de 0,56, com desvio padrão de 0,22. Na Figura 24 são apresentados alguns exemplos de imagens segmentadas pelo método proposto.

Uma tentativa de quantificação da composição de cores da imagem segmentada automaticamente foi realizada para observar se, apesar do baixo valor médio de coeficiente de Jaccard, a composição de cores da imagem segmentada automaticamente era próxima da segmentada manualmente. O valor do RMS médio das 172 imagens foi de 4%, com desvio padrão de 5%. Isto foi feito para justificar que mesmo que a segmentação não seja tão precisa, não acarretará em um comprometimento nos processos de classificação e recuperação, uma vez que a composição de cores das duas imagens serão muito próximas.

7.2 Quantificação da Composição de Cores da Lesão

Em relação à quantificação, foi calculada a porcentagem de composição das cores vermelha, amarela, branca e preta na imagem, utilizando a metodologia proposta. O valor de RMS médio obtido foi de 32,8% com desvio padrão de 19,9%. Este valor de erro é pouco aceitável, entretanto ele pode estar correlacionado com um viés na quantificação, uma vez que ele foi realizado de forma qualitativa em estudo realizado anteriormente utilizando a mesma base de imagens. Na Tabela 3 são mostrados os valores de RMS separados por classes.

Figura 23: Boxplot mostrando o coeficiente de Jaccard para as 172 imagens da base de dados

Tabela 3: Erro médio quadrático da quantificação por tipos de lesão

	RMS (%)	Desvio Padrão
Granulação	15,3	15,01
Fibrina	51,94	14,67
Necrose	44,97	11,86
Cicatrização	41,14	5,63
Mista	35,65	16,17

7.3 Recuperação por Conteúdo

Baseando-se nos experimentos conduzidos para as 172 imagens, das quais foi realizada a extração de 111 atributos, descritos na Seção 6.5. Foram executados diversos testes de recuperação variando o número de imagens recuperadas por requisição e variando a métrica de distância utilizada. Nos testes calculou-se a precisão média para os tipos de lesão de granulação, fibrina e mista, uma vez que as classes de cicatrização e necrótica apresentavam apenas 3 exemplos cada, consideradas então como ruído no conjunto de dados. Os resultados são apresentados nas Figuras 25 a 29, separados pelas métricas de distâncias utilizadas. Os valores das precisões médias obtidas nos testes para cada uma das métricas de distância utilizadas são apresentados na Figura 30.

É possível observar que os valores de precisão foram muito próximos quando as métricas utilizadas foram variações da função de distância Minkowski (Eq. 4.1) que são

Figura 24: Quatro exemplos de segmentação utilizando um método de clusterização. Para cada imagem são apresentados a imagem original, a segmentada e a imagem com o *Convex Hull* aplicado

Figura 25: Precisão obtida usando a distância Euclidiana, com K variando entre 5 e 30 nos experimentos CBIR

Figura 26: Precisão obtida usando a distância *City Block*, com K variando entre 5 e 30 nos experimentos CBIR

Figura 27: Precisão obtida utilizando a distância *Chebychev*, com K variando entre 5 e 30 nos experimentos CBIR

Figura 28: Precisão obtida utilizando a métrica cosseno, com K variando entre 5 e 30 nos experimentos CBIR

Figura 29: Precisão obtida utilizando a métrica correlação, com K variando entre 5 e 30 nos experimentos CBIR

Figura 30: Precisão média obtida utilizando diferentes métricas de distância nos testes de recuperação com K variando entre 5 e 30

Euclidiana, *City Block* e *Chebyshev*. No caso das distâncias Cosseno (Eq. 4.5) e Correlação (Eq. 4.6), nota-se uma melhora nos resultados.

Em relação a recuperação utilizando a função de distância CIEDE2000, os resultados de precisão são apresentados na Tabela 4. É possível verificar que os resultados deste teste não se enquadram como solução do problema de recuperação das imagens de úlceras dermatológicas, pois os valores de precisão média foram muito baixos.

Foi realizado um outro experimento, recuperando imagens variando o valor de K de 1 até 7. Baseado nos experimentos de recuperação utilizando as diferentes métricas mencionadas, o valor da precisão de cada recuperação foi calculado para cada classe de imagens e um valor médio da precisão foi derivado. Em uma aplicação médica, um pequeno número de casos altamente relevantes, tais como 3 ou 5 casos, recuperados de uma grande base de dados juntamente com os relatórios clínicos relacionados, auxiliaria no diagnóstico do caso de consulta atual, como é ilustrado na Figura 31, portanto não seria de interesse recuperar todos os casos relevantes que existem na base de dados. Assim, em uma aplicação clínica de CBIR com imagens médicas, a precisão seria, em geral, a medida mais importante, quando comparada a outras medidas de desempenho do CBIR, tais como a revocação ou a área embaixo da curva de precisão-versus-revocação.

A distância Euclidiana apresentou uma precisão média entre 63% (com $K=1$, uma imagem recuperada em cada experimento CBIR) e 49% (com $K=7$, sete imagens recuperadas), como é mostrado na Figura 32. O melhor resultado individual foi obtido quando as imagens de consulta pertenciam à classe fibrina e uma imagem era recuperada em cada experimento ($K=1$), resultando em um valor de precisão de 67%.

Utilizando a distância *city-block*, a precisão média ficou entre 65% ($K=1$) e 47% ($K=7$), como é ilustrado na Figura 33. O melhor resultado individual foi obtido quando as imagens de consulta pertenciam à classe fibrina e uma imagem era recuperada em cada experimento ($K=1$), com uma precisão de 71%. Pode-se observar um pequeno ganho no processo de recuperação com esta métrica quando comparado à distância Euclidiana.

Quando os experimentos CBIR foram realizados com a distância *Chebyshev*, os piores resultados de precisão foram obtidos com $K=1$ ou 3. Em contrapartida, com $K=5$ ou 7, houve uma melhora no valor da precisão quando comparado com os resultados obtidos utilizando as distâncias Euclidiana e *city-block* (Figura 34).

Os melhores resultados deste estudo foram obtidos utilizando as métricas cosseno e correlação, com precisão média entre 75% ($K=1$) e 61% ($K=7$) em ambos os casos. Na

Imagem Referência	Imagens Recuperadas					Precisão
	1	2	3	4	5	
						80%
						60%
						80%
						60%
						60%

Classe das Imagens

- Granulação
- Fibrina
- Misto

Figura 31: Experimentos CBIR mostrando os cinco casos mais relevantes (com $K=5$) para cada imagem de consulta e a precisão correspondente, usando a medida de distância Euclidiana

Figura 32: Precisão obtida usando a distância Euclidiana nos experimentos CBIR

Tabela 4: Valores de precisão em porcentagem para diferentes valores de K utilizando a distância CIEDE2000

k	Precisão Granulação	D.P. Granulação	Precisão Fibrina	D.P. Fibrina	Precisão Mista	D.P. Mista	Precisão Média	D.P. Média
5	27,84	20,03	26,45	24,43	49,05	23,93	34,45	22,80
10	27,65	15,31	26,13	20,28	49,76	16,28	34,51	17,29
15	28,50	10,92	27,10	18,93	48,89	15,12	34,83	14,99
20	30,29	10,32	25,81	17,42	47,56	12,67	34,55	13,47
25	29,57	9,64	26,45	18,03	49,05	10,22	35,02	12,63
30	29,93	8,21	24,9	15,29	49,21	8,19	34,41	10,56

Figura 33: Precisão obtida usando a distância *City Block* nos experimentos CBIR

Figura 34: Precisão obtida utilizando a distância *Chebychev* nos experimentos CBIR

Figura 35 são mostrados os resultados para a métrica cosseno e na Figura 36 são fornecidos os resultados da métrica correlação. Como pode ser observado a partir dos resultados, estas duas métricas proporcionam um desempenho similar. A principal diferença é que, na correlação, a média dos valores de um vetor é subtraída de cada característica antes do cálculo seguinte.

Na Figura 37 é mostrado uma comparação da precisão média obtida com as diferentes métricas avaliadas. As métricas cosseno e correlação apresentam o melhor desempenho em todos os estudos CBIR, com valores de precisão substancialmente mais altos em comparação com as outras métricas testadas.

7.3.1 Recuperação Utilizando Imagens Segmentadas Automaticamente

O processo de recuperação de imagens baseado em seu conteúdo foi aplicado também nas imagens segmentadas utilizando a metodologia proposta na Seção 6.3.3. Nos testes calculou-se a precisão média para os tipos de lesão de granulação, fibrina e mista para cada uma das métricas de distância utilizadas. Os resultados são apresentados nas Figuras 38 a 42. Os valores das precisões médias obtidas nos testes são apresentados na Figura 43.

De modo geral, os resultados de recuperação obtiveram valores menores de precisão quando o número de imagens variou entre cinco e 30. Em especial, pode-se ressaltar os resultados com as distâncias Correlação (Figura 42) e Cosseno (Figura 41), que obtive-

Figura 35: Precisão obtida utilizando a métrica Cosseno nos experimentos CBIR

Figura 36: Precisão obtida utilizando a métrica Correlação nos experimentos CBIR

Figura 37: Comparação da precisão média para as diferentes medidas ou métricas de distância utilizadas

Figura 38: Precisão obtida usando a distância Euclidiana, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 39: Precisão obtida usando a distância *City Block*, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 40: Precisão obtida utilizando a distância *Chebychev*, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 41: Precisão obtida utilizando a métrica cosseno, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 42: Precisão obtida utilizando a métrica correlação, com K variando entre 5 e 30 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 43: Comparação da precisão média para as diferentes medidas ou métricas de distância utilizando imagens segmentadas automaticamente

ram os melhores resultados com as imagens segmentadas manualmente, porém, quando utilizadas as imagens segmentadas automaticamente, obtiveram desempenho inferior e semelhante às demais métricas utilizadas no mesmo experimento com precisões médias variando aproximadamente entre 51% ($K=5$) e 37% ($K=30$), como é possível observar na Figura 43.

Os valores de precisão média referentes ao segundo experimento foram obtidos para as classes granulação, fibrina e mista, bem como a média de cada uma delas como é mostrado na Figura 44. Os resultados de precisão média para cada uma das distâncias são exibidos nas Figuras 45 a 49. Como pode ser observado foram recuperadas poucas imagens, com K variando entre 1 e 7.

Pode-se observar que os resultados das precisões da recuperação foram melhores quando recuperadas menos de três imagens, no entanto, quando recuperadas três ou mais imagens, os resultados foram inferiores aos resultados com as imagens segmentadas manualmente. Além disso, nos testes de recuperação com as imagens segmentadas automaticamente, foi possível observar que os valores de precisão das métricas Cosseno (Figura 48) e Correlação (Figura 49) foram muito próximos dos obtidos utilizando as demais métricas de distância, o que não aconteceu quando foram utilizadas as imagens segmentadas manualmente, uma vez que os valores de precisão obtidos para as métricas de Cosseno e Correlação foram muito maiores quando comparados com as outras métricas

Figura 44: Comparação da precisão média para as diferentes medidas ou métricas de distância utilizando imagens segmentadas automaticamente

utilizadas no experimento.

De modo geral, os testes de recuperação utilizando as imagens segmentadas automaticamente apresentaram desempenho inferior quando comparados com os testes utilizando as imagens segmentadas manualmente. Deste modo, pode-se afirmar que o método de segmentação proposto influenciou de maneira negativa na precisão da recuperação das imagens.

Outro ponto importante para ser ressaltado é que, apesar dos resultados serem inferiores, quando recuperadas menos de três imagens, os valores de precisão foram superiores aos valores obtidos nas imagens segmentadas manualmente, no entanto, quando o número de imagens recuperadas foi maior, entre três e 30, os valores de precisão para as imagens segmentadas manualmente foram muito maiores, principalmente com as métricas de Correlação e Cosseno.

7.4 Classificação das Imagens

7.4.1 Utilizando toda base de dados

Em relação à classificação das imagens, calculou-se os valores de AUC das curvas ROC geradas a partir da classificação de cada indutor. Na Tabela 5 são mostrados os valores

Figura 45: Precisão obtida usando a distância Euclidiana, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 46: Precisão obtida usando a distância *City Block*, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 47: Precisão obtida utilizando a distância *Chebychev*, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 48: Precisão obtida utilizando a métrica cosseno, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR

Figura 49: Precisão obtida utilizando a métrica correlação, com K variando entre 1 e 7 e imagens segmentadas automaticamente nos experimentos CBIR

de AUC para cada classe, bem como a média ponderada de todas.

É possível observar um alto valor de AUC em todos os casos, uma vez que ele varia de 0 a 1. O classificador MLP foi o que obteve melhor desempenho e, em contrapartida, a árvore de decisão obteve o pior, porém aceitável.

Nas Figuras 50 a 53 são mostradas as curvas ROC médias para cada um dos indutores. É possível pelos gráficos ratificar a informação dada pela AUC de cada classificador. Novamente denotando que os melhores resultados foram para os indutores MLP seguido do K-NN.

7.4.2 Base de dados somente com as classes Granulação, Fibrina e Mista

Em outro experimento foi utilizado o subconjunto com as classes granulação, fibrina e mista. Na Tabela 6 são mostrados os valores de AUC obtidos e na Figura 54 são ilustradas as curvas ROC para o classificador MLP que também apresentou o melhor desempenho neste experimento.

Tabela 5: AUC para cada classe dos classificadores testados

Tipos de Lesão (número de amostras)	Classificador			
	Naive Bayes	MLP	Árvores de Decisão	K-NN
Granulação (51)	0,81	0,85	0,84	0,75
Fibrina (31)	0,91	0,93	0,93	0,77
Necrótico (3)	0,33	0,94	0,66	0,81
Calosa (3)	0,67	0,94	0,88	0,64
Mista (84)	0,68	0,80	0,75	0,70
Média Ponderada	0,76	0,89	0,81	0,73

Figura 50: Curva ROC para cada uma das classes utilizando o indutor Naive Bayes

Figura 51: Curva ROC para cada uma das classes utilizando o indutor MLP

Figura 52: Curva ROC para cada uma das classes utilizando o indutor K-NN

Figura 53: Curva ROC para cada uma das classes utilizando o indutor Árvore de Decisão

Tabela 6: Valor AUC considerando somente os tipos de lesão granulação, fibrina e mista (segundo subconjunto de imagens)

Tipos de Lesão (número de amostras)	Classificador			
	Naive Bayes	MLP	Árvores de Decisão	K-NN
Granulação (51)	0,79	0,85	0,70	0,85
Fibrina (31)	0,91	0,96	0,79	0,94
Mista (84)	0,71	0,80	0,65	0,76
Média Ponderada	0,78	0,85	0,69	0,82

7.4.3 Base de dados somente com as classes Granulação e Fibrina

Finalmente, o terceiro experimento foi realizado para verificar a separabilidade entre os mais importantes tipos de lesões na base de dados, com base no processo de acompanhamento da cura. Desta maneira, pode-se verificar se as características extraídas podem caracterizar uma classe pura de lesão, como é o caso da granulação e fibrina. Na Tabela 7 são mostrados os valores de AUC para o experimento e na Figura 55 são ilustradas as curvas ROC para o melhor classificador, o MLP. Pode-se observar que os resultados melhoraram ainda mais e demonstraram uma boa segregação entre as duas classes puras de tecidos.

Figura 54: Curva ROC para cada classe de úlcera obtida utilizando o classificador MLP com o segundo subconjunto de imagens

7.5 CBIR versus reconhecimento de padrões

A avaliação da composição do tecido fornece informações de extrema importância no monitoramento dos efeitos do tratamento de pacientes com úlceras crônicas. As medidas quantitativas podem fornecer contribuições significativas para a avaliação objetiva do processo de cura e podem ser aplicadas tanto para o reconhecimento de padrões como para o CBIR. No contexto da presente aplicação, reconhecimento de padrões seria focado na classificação de uma úlcera com base na sua composição do tecido a fim de facilitar o diagnóstico de um paciente e o acompanhamento dos efeitos do tratamento. CBIR é uma abordagem de recuperação de informação e é mais provável ser útil em tomada de decisão médica baseada em casos.

Normalmente, as duas aplicações podem compartilhar a mesma estrutura de processamento básico de imagem, tais como pré-processamento, segmentação, extração de características, seleção de características e categorização. Em um trabalho anterior focado em CBIR para dermatologia (DORILEO et al., 2008), o qual utilizava a mesma base de dados deste presente trabalho, características baseadas somente nos componentes RGB, CCMs de pares dos componentes RGB e a distância Euclidiana. No entanto, o melhor valor obtido para a precisão foi de 70% para a classe tecido misto. A inclusão de características e métricas adicionais no estudo está sendo capaz de aumentar a precisão média

Figura 55: Curva ROC para cada classe de úlcera obtida utilizando o classificador MLP com o terceiro subconjunto de imagens

para até 75%.

Apesar desta melhora na precisão média, é interessante notar que, em outro trabalho focado no reconhecimento de padrões aplicado na classificação de úlceras com base nas suas composições de tecido (PEREIRA et al., 2011), usando a mesma base de dados e características do presente trabalho, os resultados foram muito melhores em termos de área embaixo da curva ROC, atingindo um valor de até 0,93 para a classe fibrina utilizando o classificador K-NN. Tendo em vista os altos níveis de eficiência obtidos na classificação de padrões, seria esperado valores similarmente altos para a precisão da recuperação nos experimentos CBIR com a mesma base de dados e características. No entanto, uma diferença parece existir entre o alto desempenho em uma tarefa de classificação e a precisão em um processo CBIR. No trabalho de Davis e Goadrich (DAVIS; GOADRIC, 2006), foi mostrado que um algoritmo que otimiza a área embaixo da curva ROC em um experimento de classificação de padrões não é garantido otimizar a área embaixo da curva de precisão-versus-revocação em um estudo CBIR. Este problema deve ser investigado em mais detalhes no futuro.

Tabela 7: Valor AUC considerando somente os tipos de lesão granulação e fibrina (terceiro subconjunto de imagens)

Tipos de Lesão (número de amostras)	Classificador			
	Naive Bayes	MLP	Árvores de Decisão	K-NN
Granulação (51)	0,97	0,98	0,90	0,97
Fibrina (31)	0,98	0,98	0,90	0,97
Média Ponderada	0,97	0,98	0,90	0,97

7.6 Seleção de atributos

Foram realizados 12 testes de seleção de atributos utilizando o algoritmo *Wrapper* com os indutores Naive Bayes, MLP, K-NN ($K=10$) e árvores de decisão, com os algoritmos de busca genética, *hill-climbing* e *linear forward selection*.

A frequência de seleção de cada característica é mostrada nas Tabelas 8 a 11, separadas pelo espaço de cores. A maior frequência de seleção obtida nos experimentos conduzidos foi oito. Somente 22 das 111 características foram selecionadas pelo menos quatro vezes (metade do maior valor); entre estas características, 18 foram derivadas de CCMs. Além disso, somente as características dos espaços de cores $L^*a^*b^*$ e $L^*u^*v^*$ foram selecionadas mais do que quatro vezes, e todas elas eram características derivadas de CCMs.

Os experimentos de classificação foram realizados com todos os conjuntos de atributos selecionados nenhuma vez até oito vezes. Na Figura 56 é mostrada a porcentagem de imagens classificadas corretamente para cada limiar da frequência de seleção dos atributos; a abscissa mostra o número de características em cada conjunto. Na Figura 57 é mostrada a média ponderada dos valores de AUC para cada experimento como descrito anteriormente.

Quando todas as 111 características foram utilizadas, o classificador MLP obteve a melhor precisão de classificação, 70,35%, e $AUC = 0,75$. Na Tabela 12 é mostrada a matriz de confusão para este caso. Pode-se observar um alto desempenho na classificação das categorias fibrina e mista, com uma precisão de até 76%.

A melhor classificação utilizando o classificador naive Bayes foi obtida com apenas duas características que foram selecionadas oito vezes cada, com uma taxa de classificação correta de 73,26%. Os dois atributos selecionados oito vezes são o contraste entre as componentes u^* e v^* , e a entropia entre as componentes a^* e b^* .

A melhor classificação com o MLP foi obtida utilizando quatro atributos, os quais

Tabela 8: Frequência de seleção de cada atributo no espaço de cores HSV

Atributos	
Não selecionados	• Média em saturação.
Uma vez	• Homogeneidade entre matiz e saturação. • Homogeneidade em matiz. • Homogeneidade em saturação. • Homogeneidade local em saturação. • Kurtosis em saturação. • Média em matiz.
Duas vezes	• Contraste em matiz. • Correlação em matiz. • Entropia em matiz. • Homogeneidade local em matiz. • Entropia em saturação. • Desvio padrão em saturação. • Kurtosis em matiz.
Três vezes	• Contraste entre matiz e saturação. • Correlação entre matiz e saturação. • Entropia entre matiz e saturação. • Contraste em saturação. • Correlação em saturação. • Skewness em saturação. • Desvio padrão em matiz. • Skewness em matiz.
Quatro vezes	• Homogeneidade local entre matiz e saturação.

Tabela 9: Frequência de seleção de cada atributo no espaço de cores $L^*a^*b^*$

Atributos	
Não selecionados	• Contraste em b^*. • Skewness em b^*. • Kurtosis em b^*.
Uma vez	• Correlação entre a^* e b^*. • Contraste em a^*. • Correlação em a^*. • Homogeneidade local em b^*. • Skewness em a^*. • Média em b^*.
Duas vezes	• Homogeneidade local em a^*. • Desvio padrão em a^*. • Kurtosis em a^*. • Desvio padrão em b^*.
Três vezes	• Entropia em a^*. • Correlação em b^*.
Quatro vezes	• Homogeneidade em b^*. • Entropia em b^*. • Média em b^*.
Cinco vezes	• Homogeneidade local entre a^* e b^*. • Homogeneidade em a^*.
Seis vezes	• Contraste entre a^* e b^*.
Sete vezes	• Homogeneidade entre a^* e b^*.
Eight times	• Entropia entre a^* e b^*.

Tabela 10: Frequência de seleção de cada atributo no espaço de cores $L^*u^*v^*$

Atributos	
Não selecionados	• Correlação em v^*.
Uma vez	• Correlação em u^*. • Entropia em u^* e u^*. • Homogeneidade local em v^* e v^*. • Média em u^*. • Kurtosis em u^*. • Skewness em v^*. • Kurtosis em v^*.
Duas vezes	• Correlação entre u^* e v^*. • Entropia entre u^* e v^*. • Homogeneidade em u^*. • Contraste em u^*. • Homogeneidade local em u^*. • Contraste em v^*. • Desvio padrão em u^*.
Três vezes	• Média em v^*. • Desvio padrão em v^*.
Quatro vezes	• Homogeneidade local entre u^* e v^*. • Homogeneidade em v^*. • Skewness em u^*.
Cinco vezes	• Homogeneidade entre u^* e v^*. • Entropia em v^*.
Oito vezes	• Contraste entre u^* e v^*.

Tabela 11: Frequência de seleção de cada atributo no espaço de cores RGB

Atributos	
Não selecionados	• Homogeneidade em vermelho. • Homogeneidade em verde. • Homogeneidade local em verde. • Contraste em azul. • Correlação em azul. • Homogeneidade local entre vermelho e verde. • Entropia entre verde e azul.
Uma vez	• Entropia em verde. • Entropia em azul. • Homogeneidade local em azul. • Homogeneidade entre vermelho e azul. • Contraste entre vermelho e azul. • Homogeneidade local entre verde e azul. • Média em verde. • Kurtosis em verde. • Média em azul.
Duas vezes	• Contraste em vermelho. • Correlação em vermelho. • Homogeneidade em azul. • Homogeneidade entre vermelho e verde. • Entropia entre vermelho e verde. • Entropia entre vermelho e azul. • Homogeneidade entre verde e azul. • Desvio padrão em vermelho. • Kurtosis em vermelho. • Skewness em azul. • Kurtosis em azul.
Três vezes	• Correlação em vermelho. • Contraste em verde. • Correlação em verde. • Correlação entre vermelho e azul. • Homogeneidade local entre vermelho e azul. • Contraste entre verde e azul. • Skewness em vermelho. • Skewness em verde.
Quatro vezes	• Homogeneidade local em vermelho. • Contraste entre vermelho e verde. • Correlação entre vermelho e verde. • Correlação entre verde e azul. • Média em vermelho. • Desvio padrão em verde. • Desvio padrão em azul.

Figura 56: Porcentagem de imagens classificadas corretamente com cada classificador utilizando diferentes limiares da frequência de seleção dos atributos. O rótulo no eixo horizontal indica os números de características nos diversos subconjuntos de características utilizadas, começando com as 111 características calculadas, as características selecionadas uma vez (99), duas vezes (71), e assim por diante até oito vezes (2)

foram os atributos selecionados seis ou mais vezes, com uma precisão de 73,84% e AUC de 0,82. Esta foi a maior precisão de classificação obtida em todos os experimentos conduzidos. Dentre os quatro atributos utilizados, três são do espaço de cores $L^*a^*b^*$ e um é do espaço de cores $L^*u^*v^*$; todos são atributos calculados utilizando CCMs. Na Tabela 13 é mostrada a matriz de confusão obtida neste experimento, o qual apresenta um bom desempenho com as classes fibrina e mista, com uma precisão de até 80% para estas duas classes.

Os classificadores K-NN e árvores de decisão apresentaram o melhor desempenho utilizando oito características, as quais foram os atributos selecionados cinco vezes ou mais, com uma taxa de classificação correta de 73,63% e 71,51%, e AUC de 0,87 e 0,79, respectivamente. Dentre os oito atributos que foram selecionados cinco vezes ou mais, cinco são do espaço de cores $L^*a^*b^*$ e três são do espaço de cores $L^*u^*v^*$; seis desses atributos são baseados no CCMs e dois são características de cor de componentes individuais.

Pode-se observar que em todos os casos de melhor desempenho de cada classificador, somente características dos espaços de cores $L^*a^*b^*$ e $L^*u^*v^*$ foram utilizados, e a maioria deles são características extraídas de CCMs. Além disso, estas características foram selecionadas mais frequentemente do que as características extraídas de componentes individuais de cor.

Figura 57: Média ponderada dos valores de AUC para cada classificador utilizando diferentes limiares da frequência de seleção dos atributos. O rótulo no eixo horizontal indica os números de características nos diversos subconjuntos de características utilizadas, começando com as 111 características calculadas, as características selecionadas uma vez (99), duas vezes (71), e assim por diante até oito vezes (2).

Tabela 12: Matriz de confusão da classificação utilizando todas as 111 características extraídas e o classificador MLP. Cada linha representa a classe real da imagem e cada coluna, a classificação do MLP

Real \ MLP	Granulação	Fibrina	Necrótica	Calosa	Mista	Total
Granulação	31	3	0	0	17	51
Fibrina	1	24	0	0	6	31
Necrótica	0	0	0	0	3	3
Calosa	0	0	0	2	1	3
Mista	14	2	2	2	64	84

Tabela 13: Matriz de confusão da classificação utilizando os atributos selecionados seis vezes ou mais e o classificador MLP. Cada linha representa a classe real da imagem e cada coluna, a classificação do MLP

Real \ MLP	Granulação	Fibrina	Necrótica	Calosa	Mista	Total
Granulação	31	0	0	0	19	51
Fibrina	0	26	0	0	5	31
Necrótica	0	2	0	0	1	3
Calosa	0	1	0	0	1	3
Mista	8	6	0	2	68	84

Em resumo, pode-se afirmar que, com base nos experimentos conduzidos neste estudo, a melhor abordagem para a classificação de imagens coloridas de úlceras dermatológicas é a utilização do classificador MLP com as seguintes características: homogeneidade entre as componentes a^* e b^* , contraste entre as componentes a^* e b^* , entropia entre a^* e b^* , e contraste entre as componentes u^* e v^* .

8 Conclusão

A partir dos resultados obtidos nos experimentos realizados foi possível um estudo aprofundado de diversas técnicas para quantificação, segmentação, classificação e recuperação das imagens de úlceras dermatológicas.

A quantificação de cores, utilizando o modelo HSV, demonstrou uma melhora no resultado da segmentação do algoritmo JSEG. Além disso, vale ressaltar que o processo de segmentação pode ser considerado como o mais desafiador de todos, uma vez que depende em muito da aquisição padronizada das imagens. No entanto as três técnicas desenvolvidas apresentaram bons resultados, ressaltando a técnica com utilização de *clusters* que apresentou uma quantificação de cores muito próxima da obtida nas imagens segmentadas manualmente, provando que mesmo com uma segmentação não tão precisa, ainda assim é possível manter uma distribuição de cores similares nas duas imagens. E a utilização da segmentação com o algoritmo JSEG, com um coeficiente de Jaccard alto.

Em relação à recuperação das imagens, os resultados recuperando muitas imagens ficaram abaixo do esperado, porém com alguma melhora em relação a outros trabalhos realizados com a mesma base de imagens. No entanto, os testes de recuperação com poucas imagens demonstraram um desempenho bom, o que seria mais aplicável a prática clínica, uma vez que a decisão do médico é baseada em um conjunto pequeno de imagens relevantes.

Além disso, foi avaliado o desempenho de algumas métricas de distância para determinar qual se encaixava melhor na solução do problema. Com isso, foi possível obter uma melhora nos testes em comparação com a métrica Euclidiana, que é usualmente aplicada. No presente trabalho, as métricas de Cosseno e Correlação apresentaram as melhores precisões, quando comparadas com a Euclidiana, *City-block* e *Chebyshev*.

Em se tratando da classificação das imagens de úlceras dermatológicas, foi possível concluir que as características extraídas são relevantes e apropriadas para uma análise quantitativa das imagens e sua classe (granulação, fibrina, calosa, necrótica e mista).

Utilizando como validação dos resultados o AUC, os valores obtidos foram acima do esperado, e demonstraram um bom método de classificação. Outro ponto importante, é que quando comparadas imagens de classes muito distintas, como as imagens da classe de granulação e fibrina, o AUC ficou muito próximo do valor máximo, com isso foi possível demonstrar uma boa segregação das imagens no espaço de características de forma não-simbólica.

Foi provado também o potencial da aplicação de técnicas de aprendizado de máquina em processamento de imagens digitais e reconhecimento de padrões, quando aplicado à seleção de atributos e posteriormente aos testes de classificação, não houve decréscimo nos valores de AUC, mesmo quando utilizados poucos atributos extraídos. Além disso, pode ser observado que atributos baseados na matriz de coocorrência extraídos dos espaços de cores $L^*a^*b^*$ e $L^*u^*v^*$ apresentaram melhor desempenho nos testes quando comparados com atributos dos espaços de cores RGB e HSV. O classificador com melhor desempenho foi o MLP.

A análise objetiva de imagens coloridas de úlceras de pele utilizando os métodos propostos pode levar ao desenvolvimento de melhores protocolos para o tratamento e monitoramento das lesões dermatológicas crônicas. Além disso, tais abordagens podem contribuir para o desenvolvimento de terapia otimizada e personalizada para cada paciente.

8.1 Contribuições do Trabalho

A partir deste trabalho de mestrado, foram feitas quatro publicações em congressos e revistas nacionais e internacionais.

Em 2010, foi feita a primeira publicação no XXII Congresso Brasileiro de Engenharia Biomédica (CBEB 2010), com um artigo dando enfoque apenas na quantificação de cores entre a análise quantitativa do médico especialista e a obtida pela técnica de quantificação (PEREIRA et al., 2010).

Em 2011, foi realizada uma publicação no 4th International Symposium on Applied Sciences in Biomedicine and Communication Technologies (ISABEL 2011), analisando o problema pelo paradigma de classificação das imagens de úlceras dermatológicas utilizando técnicas de AM (PEREIRA et al., 2011).

Além disso, em 2012, dois artigos foram aceitos, porém até o presente momento não

foram publicados. O primeiro no XXIII Congresso Brasileiro de Engenharia Biomédica (CBEB 2012), com o tema de recuperação de imagens dermatológicas e sua análise por diferentes métricas de distância (PEREIRA et al., 2012b). O segundo na revista IEEE Transactions on Information Technology in Biomedicine, com a comparação entre a classificação realizada com e sem as metodologias de seleção de atributos (PEREIRA et al., 2012a).

8.2 Trabalhos Futuros

Algumas limitações foram encontradas no decorrer do estudo realizado, dentre elas a que mais influenciaram negativamente foram as relacionadas ao protocolo de aquisição das imagens e tamanho da base de dados. Portanto deseja-se uma ampliação e atualização da base de imagens, bem como a inserção de um objeto de calibração de cores. Além disso também seria almejado uma maior padronização no protocolo de aquisição das imagens e criação de uma base focada na evolução do tratamento.

Outro aspecto importante para ser pesquisado futuramente é relativo ao processo de segmentação. Pois as metodologias aplicadas até o momento não suprem a uma boa segmentação de forma automática, portanto uma melhoria da segmentação e estudo de técnicas de classificação voltadas para apoiar a evolução do tratamento a partir da quantificação das componentes de tecido e área da lesão seriam essenciais para o objetivo de segmentação automática das imagens de úlceras dermatológicas.

Referências²

- ACHA, B. et al. **Segmentation and classification of burn images by color and texture information.** *Journal of biomedical optics*, v. 10, p. 034014, 2005.
- ARVIS, V. et al. **Generalization of the cooccurrence matrix for colour images: application to colour texture classification.** *Image Analysis and Stereology*, v. 23, n. 1, p. 63–72, 2004.
- ASLANDOGAN, Y.; YU, C. **Techniques and systems for image and video retrieval.** *Knowledge and Data Engineering, IEEE Transactions on*, IEEE, v. 11, n. 1, p. 56–63, 1999.
- AZEVEDO-MARQUES, P. M. **Generalização do conceito de diagnóstico auxiliado por computador no ambiente hospitalar através da integração de função de recuperação por conteúdo no sistema de gerenciamento de imagens.** 115 p. — USP, 2005. Tese de Livre-Docência.
- BAEZA-YATES, R.; RIBEIRO-NETO, B. et al. **Modern information retrieval.** [S.l.]: ACM press New York., 1999.
- BARANAUSKAS, J. A. **Extração automática de conhecimento utilizando múltiplos indutores.** Brasil, 2001.
- BARBER, C.; DOBKIN, D.; HUHDANPAA, H. **The quickhull algorithm for convex hulls.** *ACM Transactions on Mathematical Software (TOMS)*, ACM, v. 22, n. 4, p. 469–483, 1996.
- BERRETTI, S.; BIMBO, A. D.; PALA, P. **Content based retrieval of 3D cellular structures.** In: IEEE. *Multimedia and Expo, 2001. ICME 2001. IEEE International Conference on*. [S.l.], 2001. p. 889–892.
- BEYER, K. et al. **When is nearest neighbor meaningful?** *Database Theory - ICDT'99*, Springer, p. 217–235, 1999.
- BLUM, A. L.; LANGLEY, P. **Selection of relevant features and examples in machine learning.** *Artificial intelligence*, Elsevier Science Publishers Ltd., Essex, UK, v. 97, n. 1-2, p. 245–271, dez. 1997. ISSN 0004-3702. Disponível em: <[http://dx.doi.org/10.1016/S0004-3702\(97\)00063-5](http://dx.doi.org/10.1016/S0004-3702(97)00063-5)>.
- CHENG, H.; SUN, Y. **A hierarchical approach to color image segmentation using homogeneity.** *Image Processing, IEEE Transactions on*, IEEE, v. 9, n. 12, p. 2071–2082, 2000.

---

²De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023

COMANICIU, D. et al. **Bimodal system for interactive indexing and retrieval of pathology images**. Published by the IEEE Computer Society, 1998.

CONNERS, R. W.; HARLOW, C. A. **A Theoretical Comparison of Texture Algorithms**. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-2, n. 3, p. 204–222, 1980. ISSN 0162-8828.

CUI, G.; LUO, M. R. **Testing colour-difference formulae and uniform colour spaces using small colour differences datasets**. 11th Congress of the International Colour Association, v. 1, 2009.

DAVIS, J.; GOADRIC, M. **The relationship between Precision-Recall and ROC curves**. In: *Proceedings of the 23rd International Conference on Machine Learning*. Pittsburgh, PA: ACM, 2006. (ICML '06), p. 233–240. ISBN 1-59593-383-2. Disponível em: <<http://doi.acm.org/10.1145/1143844.1143874>>.

DEGLINT, H.; RANGAYAN, R. **Segmentation of neuroblastoma in CT images using deformable contours, image reconstruction, and convex hulls**. In: *IET. Medical Applications of Signal Processing, 2005. The 3rd IEE International Seminar on* (Ref. No. 2005-1119). [S.l.], 2005. p. 29–34.

DEMPSTER, A.; LAIRD, N.; RUBIN, D. **Maximum likelihood from incomplete data via the EM algorithm**. *Journal of the Royal Statistical Society. Series B (Methodological)*, JSTOR, p. 1–38, 1977.

DENG, Y.; MANJUNATH, B. S. **Unsupervised segmentation of color-texture regions in images and video**. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI '01)*, v. 23, n. 8, p. 800–810, Aug 2001. Disponível em: <<http://vision.ece.ucsb.edu/publications/01PAMIJseg.pdf>>.

DIETTERICH, T. **Overfitting and undercomputing in machine learning**. *ACM Comput. Surv.*, ACM, v. 27, p. 326–327, September 1995. ISSN 0360-0300. Disponível em: <<http://doi.acm.org/10.1145/212094.212114>>.

DOMINGOS, P.; PAZZANI, M. J. **On the optimality of the simple Bayesian classifier under zero-one loss**. *Machine Learning*, v. 29, n. 2, p. 103–130, 1997.

DORILEO, E. et al. **Color image processing and content-based image retrieval techniques for the analysis of dermatological lesions**. In: *IEEE. Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*. Vancouver, BC, Canada, 2008. p. 1230–1233.

DOUGHERTY, E.; LOTUFO, R. **Hands-on morphological image processing**. [S.l.]: Society of Photo Optical, 2003.

EL-NAQA, I. et al. **A similarity learning approach to content-based image retrieval: application to digital mammography**. *Medical Imaging, IEEE Transactions on*, IEEE, v. 23, n. 10, p. 1233–1244, 2004.

ERCAL, F. et al. **Neural network diagnosis of malignant melanoma from color images**. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 41, n. 9, p. 837–845, 1994.

- FORD, A.; ROBERTS, A. **Colour space conversions**. Retrieved in June 2010, 2010. Disponível em: <<http://www.poynton.com/PDFs/coloureq.pdf>>.
- FRALEY, C.; RAFTERY, A. **How many clusters? Which clustering method? Answers via model-based cluster analysis**. *The computer journal*, Br Computer Soc, v. 41, n. 8, p. 578–588, 1998.
- GOGGINS, W. et al. **A Markov chain Monte Carlo EM algorithm for analyzing interval-censored data under the Cox proportional hazards model**. *Biometrics*, JSTOR, p. 1498–1507, 1998.
- GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.
- GONZALEZ, R.; WOODS, R. **Digital Image Processing**. 3rd. ed. [S.l.]: Pearson Prentice Hall, 2008.
- GUPTA, A.; SANTINI, S. et al. **Toward feature algebras in visual databases: The case for a histogram algebra**. In: CITESEER. *Proceedings of the IFIP Working Conference on Visual Databases (VDB5), Fukuoka (Japan)*. [S.l.], 2000.
- GÜTLEIN, M. et al. **Large-scale attribute selection using wrappers**. In: *Proc IEEE Symposium on Computational Intelligence and Data Mining*. [S.l.]: IEEE, 2009. p. 332–339.
- GUYON, I.; ELISSEEFF, A. **An introduction to variable and feature selection**. *The Journal of Machine Learning Research*, JMLR.org, v. 3, p. 1157–1182, 2003.
- HALL, M. et al. **The Weka data mining software: an update**. *ACM Special Interest Group on Knowledge Discovery and Data Mining (SIGKDD) Explorations Newsletter*, ACM, v. 11, n. 1, p. 10–18, 2009.
- HAND, D.; TILL, R. **A simple generalisation of the area under the ROC curve for multiple class classification problems**. *Machine Learning*, Springer, v. 45, n. 2, p. 171–186, 2001.
- HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. **Textural features for image classification**. *Systems, Man, and Cybernetics, IEEE Transactions on*, IEEE, v. 3, n. 6, p. 610–621, 1973.
- HAYKIN, S. **Redes Neurais: Princípios e Práticas**. 2. ed. Brasil: Bookman, 2001.
- HUANG, S. **Dimensionality reduction in automatic knowledge acquisition: A simple greedy search approach**. *IEEE Transactions on Knowledge and Data Engineering*, Published by the IEEE Computer Society, p. 1364–1373, 2003.
- HUNT, R. **The reproduction of colour**. [S.l.]: Wiley, 2004.
- HUNT, R.; POINTER, M. **Measuring colour**. [S.l.]: Wiley, 2011.
- JAIN, A.; MURTY, M.; FLYNN, P. **Data clustering: a review**. *ACM computing surveys (CSUR)*, ACM, v. 31, n. 3, p. 264–323, 1999.

- JAULENT, M. et al. **A property concept frame representation for flexible image-content retrieval in histopathology databases.** In: AMERICAN MEDICAL INFORMATICS ASSOCIATION. *Proceedings of the AMIA Symposium*. [S.l.], 2000. p. 379.
- KITTLER, H. et al. **Diagnostic accuracy of dermoscopy.** *The lancet oncology*, Elsevier, v. 3, n. 3, p. 159–165, 2002.
- KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection.** In: CITESEER. *International Joint Conference on Artificial Intelligence*. [S.l.], 1995. v. 14, p. 1137–1145.
- LANGLEY, P. ***Elements of machine learning***. [S.l.]: Morgan Kaufmann Pub, 1996.
- LIU, H.; MOTODA, H. ***Computational methods of feature selection***. [S.l.]: Chapman & Hall, 2008.
- LUCAS, P. **Enhancement of learning by declarative expert-based models.** In: *Proceedings of the 5th Workshop on Intelligent Data Analysis in Medicine and Pharmacology*. [S.l.: s.n.], 2000.
- LUO, M.; CUI, G.; RIGG, B. **The development of the CIE 2000 colour-difference formula: CIEDE2000.** *Color Research & Application*, Wiley Online Library, v. 26, n. 5, p. 340–350, 2001.
- MAGLOGIANNIS, I.; PAVLOPOULOS, S.; KOUTSOURIS, D. **An integrated computer supported acquisition, handling, and characterization system for pigmented skin lesions in dermatological images.** *Information Technology in Biomedicine, IEEE Transactions on*, IEEE, v. 9, n. 1, p. 86–98, 2005.
- MARQUES, J. ***Realimentação de relevância para recuperação por conteúdo de imagens Médicas visando diminuir a descontinuidade semântica***. [S.l.]: São Carlos, 2006. Tese de Mestrado.
- MATHERON, G. ***Random sets and integral geometry***. [S.l.]: Wiley New York, 1975.
- MATTIE, M. et al. **PathMaster: Content-based cell image retrieval using automated feature extraction.** *Journal of the American Medical Informatics Association*, BMJ Publishing Group Ltd, v. 7, n. 4, p. 404–415, 2000.
- MCLACHLAN, G.; PEEL, D. ***Finite mixture models***. [S.l.]: Wiley-Interscience, 2000.
- MEYER, F. **Automatic screening of cytological specimens.** *Computer vision, graphics, and image processing*, Elsevier, v. 35, n. 3, p. 356–369, 1986.
- MICHALSKI, R.; STEPP, R. **Clustering.** *Encyclopedia of artificial intelligence*, p. 168–176, 1992.
- MITCHELL, T. M. ***Machine Learning***. 1. ed. New York, NY, USA: McGraw-Hill, Inc., 1997. ISBN 0070428077, 9780070428072.

- MULLER, H. et al. **A review of content-based image retrieval systems in medical applications – clinical benefits and future directions.** *International Journal of Medical Informatics*, Elsevier, v. 73, n. 1, p. 1–23, 2004.
- NIBLACK, C. et al. **QBIC project: querying images by content, using color, texture, and shape.** In: *Proceedings of SPIE - Conference on Storage and Retrieval for Image and Video Databases*. [S.l.: s.n.], 1993. v. 1908, p. 173–187.
- ODUNCU, H. et al. **Analysis of skin wound images using digital color image processing: a preliminary communication.** *The International Journal of Lower Extremity Wounds*, SAGE Publications, v. 3, n. 3, p. 151–156, 2004.
- OGIELA, M.; TADEUSIEWICZ, R. **Semantic-oriented syntactic algorithms for content recognition and understanding of images in medical databases.** Published by the IEEE Computer Society, 2001.
- PEREIRA, S. et al. **Quantificação Automática de Componentes de Tecido em Imagens de Úlceras Dermatológicas.** XXII Congresso Brasileiro de Engenharia Biomédica, p. 691, 2010.
- PEREIRA, S. et al. **Classification of color images of dermatological ulcers.** *IEEE Transactions on Information Technology in Biomedicine*, 2012. Aceito.
- PEREIRA, S. et al. **Recuperação de imagens dermatológicas por conteúdo: uma avaliação de desempenho de métricas de distâncias.** XXIII Congresso Brasileiro de Engenharia Biomédica, 2012. Aceito.
- PEREIRA, S. M. et al. **Classification of dermatological ulcers based on tissue composition and color texture features.** In: *Proceedings of the 4th International Symposium on Applied Sciences in Biomedical and Communication Technologies*. Barcelona, Spain: ACM, 2011. (ISABEL '11), p. 68:1–68:6. ISBN 978-1-4503-0913-4. Disponível em: <<http://doi.acm.org/10.1145/2093698.2093766>>.
- PERNKOPF, F.; BOUCHAFFRA, D. **Genetic-based EM algorithm for learning Gaussian mixture models.** *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 27, n. 8, p. 1344–1348, 2005.
- PITAS, I.; KINIKLIS, P. **Multichannel techniques in color image enhancement and modeling.** *Image Processing, IEEE Transactions on*, IEEE, v. 5, n. 1, p. 168–171, 1996.
- QUINLAN, J. **Decision trees and decision-making.** *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, v. 20, n. 2, p. 339–346, 1990.
- SBONER, A. et al. **Clinical validation of an automated system for supporting the early diagnosis of melanoma.** *Skin Research and Technology*, Wiley Online Library, v. 10, n. 3, p. 184–192, 2004.
- SBONER, A. et al. **A multiple classifier system for early melanoma diagnosis.** *Artificial Intelligence in Medicine*, Elsevier, v. 27, n. 1, p. 29–44, 2003.

- SCHMID-SAUGEON, P.; GUILLOD, J.; THIRAN, J. **Towards a computer-aided diagnosis system for pigmented skin lesions.** *Computerized Medical Imaging and Graphics*, Elsevier, v. 27, n. 1, p. 65–78, 2003.
- SERRA, J. **Introduction to mathematical morphology.** *Computer Vision, Graphics, and Image Processing*, Academic Press Professional, Inc., v. 35, n. 3, p. 283–305, 1986.
- SHARMA, G.; WU, W.; DALAL, E. **The CIEDE2000 color-difference formula: Implementation notes, supplementary test data, and mathematical observations.** *Color Research & Application*, Wiley Online Library, v. 30, n. 1, p. 21–30, 2005.
- SMITH, J. **Integrated spatial and feature image systems: retrieval, analysis and compression.** *Doctoral Dissertations, Columbia University*, v. 112, 1997.
- TANG, L. et al. **Extraction of semantic features of histological images for content-based retrieval of images.** In: *Proceedings of SPIE*. [S.l.: s.n.], 1999. v. 3662, p. 360.
- TANG, L. et al. **Automatic semantic labelling of medical images for content-based retrieval.** In: *Proceedings of the International Conference on Artificial Intelligence, Expert Systems and Applications (EXPERTSYS 1998)*, Virginia Beach, VA, USA. [S.l.: s.n.], 1998. p. 77–82.
- TARALLO, A.; GONZAGA, A.; FRADE, M. **Artificial neural networks applied to the segmentation and classification of digital images of cutaneous ulcers.** In: *IEEE 7th International Conference on Bioinformatics and Bioengineering*. [S.l.: s.n.], 2007. p. 1–1.
- TRAINA, A. et al. **How to Cope with the Performance Gap in Content-Based Image Retrieval Systems.** *International Journal of Healthcare Information Systems and Informatics (IJHISI)*, IGI Global, v. 4, n. 1, p. 47–67, 2009.
- TRUSSELL, H.; SABER, E.; VRHEL, M. **Color image processing.** *Signal Processing Magazine, IEEE*, IEEE, v. 22, n. 1, p. 14–22, 2005.
- VAZIRI, N. et al. **Critical heat flux prediction by using radial basis function and multilayer perceptron neural networks: A comparison study.** *Nuclear Engineering and Design*, Elsevier, v. 237, n. 4, p. 377–385, 2007.
- VEREDAS, F.; MESA, H.; MORENTE, L. **Binary tissue classification on wound images with neural networks and Bayesian classifiers.** *Medical Imaging, IEEE Transactions on*, IEEE, v. 29, n. 2, p. 410–427, 2010.
- WANG, J. **Pathfinder: multiresolution region-based searching of pathology images using IRM.** In: AMERICAN MEDICAL INFORMATICS ASSOCIATION. *Proceedings of the AMIA Symposium*. [S.l.], 2000. p. 883–887.
- WANNOUS, H.; TREUILLET, S.; LUCAS, Y. **Supervised tissue classification from color images for a complete wound assessment tool.** In: IEEE. *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*. [S.l.], 2007. p. 6031–6034.

WANNOUS, H.; TREUILLET, S.; LUCAS, Y. **Robust tissue classification for reproducible wound assessment in telemedicine environments.** *Journal of Electronic Imaging*, v. 19, p. 023002, 2010.

WEI, C.; LI, C.; WILSON, R. **A content-based approach to medical image database retrieval.** *Database Modeling for Industrial Data Management: Emerging Technologies and Applications*, p. 258–291, 2006.

WILD, T. et al. **Digital measurement and analysis of wounds based on colour segmentation.** *European Surgery*, Springer, v. 40, n. 1, p. 5–10, 2008.

ZHAO, Y.; KARYPIS, G.; FAYYAD, U. **Hierarchical clustering algorithms for document datasets.** *Data mining and knowledge discovery*, Springer, v. 10, n. 2, p. 141–168, 2005.

*ANEXO A – Ofício de aprovação obtido
pelo Comitê de Ética*

HOSPITAL DAS CLÍNICAS DA FACULDADE DE MEDICINA
DE RIBEIRÃO PRETO DA UNIVERSIDADE DE SÃO PAULO

www.hcrp.usp.br

Ribeirão Preto, 17 de agosto de 2011

Ofício nº 2981/2011
CEP/MGV

Prezados Senhores,

O trabalho intitulado **“AVALIAÇÃO QUANTITATIVA E RECONHECIMENTO DE PADRÕES EM ÚLCERAS DERMATOLÓGICAS”** foi analisado pelo Comitê de Ética em Pesquisa, em sua 330ª Reunião Ordinária realizada em 15/08/2011 e enquadrado na categoria: **APROVADO**, de acordo com o Processo HCRP nº 6397/2011.

Este Comitê segue integralmente a Conferência Internacional de Harmonização de Boas Práticas Clínicas (IGH-GCP), bem como a Resolução nº 196/96 CNS/MS.

Lembramos que devem ser apresentados a este CEP, o Relatório Parcial e o Relatório Final da pesquisa.

De acordo com Carta Circular nº 003/2011/CONEP/CNS datada de 21 de março de 2011, o sujeito de pesquisa ou seu representante, quando for o caso, deverá rubricar todas as folhas do Termo de Consentimento Livre e Esclarecido – TCLE – apondo sua assinatura na última página do referido Termo; o pesquisador responsável deverá da mesma forma, rubricar todas as folhas do Termo de Consentimento Livre e Esclarecido – TCLE – apondo sua assinatura na última página do referido Termo.

Atenciosamente,

DRª MARCIA GUIMARÃES VILLANOVA
Coordenadora do Comitê de Ética em
Pesquisa do HCRP e da FMRP-USP

Ilustríssimos Senhores

PROF. DR. PAULO MAZZONCINI DE AZEVEDO MARQUES

SILVIO MORETO PEREIRA (Orientando)

Depto. de Clínica Médica – Centro de Ciências das Imagens e Física Médica - CCIFM