

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA



DISSERTAÇÃO DE MESTRADO
Análise de Imagens Digitais em
Patologia utilizando Morfologia Matemática e
Lógica Nebulosa

Wellington Pinheiro dos Santos

UNIVERSIDADE FEDERAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

ANÁLISE DE IMAGENS DIGITAIS EM
PATOLOGIA UTILIZANDO MORFOLOGIA
MATEMÁTICA E LÓGICA NEBULOSA

Dissertação submetida à
Universidade Federal de Pernambuco
como parte dos requisitos para a
obtenção do grau de Mestre em Engenharia Elétrica

WELLINGTON PINHEIRO DOS SANTOS

Recife, Setembro de 2003

Aos meus pais
Orlando e Minervina

Agradecimentos

A Deus.

A minha família e, principalmente, a meus pais Orlando Pinheiro dos Santos e Minervina Ângela Oliveira dos Santos, que tanto me têm apoiado nas minhas decisões, sejam elas acertadas ou não, pela simples vontade de verem realizados meus sonhos e meus ideais.

Ao meu orientador Ascendino Flávio Dias e Silva, que mais do que orientador, converteu-se em verdadeiro amigo, não sendo raras as ocasiões em que conversamos durante horas sobre coisas que, embora fossem importantes, não eram necessariamente relacionadas ao meu trabalho de mestrado.

À minha co-orientadora e amiga Ana Lúcia Bezerra Candeias, que me apresentou ao mundo da pesquisa científica, esse mundo por vezes tão ingrato, mas de um grande fascínio, apesar das vezes em que a falta de recursos nos angustiava e impossibilitava alguns progressos; Agradeço principalmente pela paciência em suportar minha teimosia: não foram poucas as vezes em que lhe tomei tempo precioso com minhas refutações e contra-argumentos, para mais tarde refletir melhor e alterar tudo exatamente como da forma antes sugerida por ela.

A Antonio Fernando de Sousa Bezerra, pelo banco de imagens médicas utilizado neste trabalho, pelo apoio técnico e científico e pelas importantes informações sobre Patologia: se hoje conheço pelo menos uma porção in-

finitesimal dessa área do conhecimento, é ao meu amigo Antonio que devo agradecer.

A Alejandro César Frery Orgambide, por ter me ensinado a ser mais rigoroso e organizado ao expor minhas idéias, seja em artigos científicos ou em simples seminários.

Ao amigo Mozart de Siqueira Campos Araújo Filho, pelas agradáveis conversas que tivemos sobre estórias em quadrinhos, jogos, realidade virtual e demais coisas importantes, quando não estávamos passando mais um final de semana na UFPE fazendo projetos ou tirando dúvidas de processamento de imagens durante as madrugadas pela Internet.

Aos amigos Antonio José de Barros Neto, Pablo Viana da Silva e Cledja Karina Rolim da Silva pela atenção com que ouviam minhas opiniões, as quais geralmente multiplicavam seus trabalhos, e pelos finais de semana que passamos juntos trabalhando para entregar algum projeto a tempo; obrigado, pois vocês foram a equipe mais esforçada e, certamente, a melhor em que já trabalhei.

Ao professor Mauricy Motta, do Departamento de Biofísica, pelas tardes em que conversamos sobre os avanços da Engenharia Biomédica e sobre as coisas importantes da vida; agradeço por ter me aproximado mais de meus objetivos e abrir minha mente para um verdadeiro universo de problemas onde a engenharia pode ajudar na manutenção e no incremento da qualidade da vida humana.

Aos amigos Leonardo Rezende, Fernando José Capeleiro, Roberval de Souza Lima e Maurício Maia, pelas vezes em que me restabeleceram ao convívio social, em especial à sadia vida noturna pernambucana de festas e espetáculos.

Ao amigo Marcílio Feitosa, pelas importantes sugestões e pelas vezes em

que dedicou parte de seu tempo disponível a discutir comigo sobre novos avanços da engenharia aplicados à área médica e biológica.

A todos aqueles que me ajudaram de alguma forma, mas que, no momento em que escrevo estes agradecimentos, não me vieram à mente. Não é por má vontade que os deixo de fora, mas simplesmente pela minha limitadíssima memória.

E finalmente ao CNPq, pela bolsa de mestrado que, apesar de todas as dificuldades e limitações, foi de grande ajuda durante todo este período.

Resumo

Este trabalho apresenta um conjunto de métodos e ferramentas para análise de imagens em Patologia utilizando Morfologia Matemática e Lógica Nebulosa. Uma nova técnica de classificação de imagens baseada na geração de bandas espectrais sintéticas pelo emprego de transformações morfológicas na extração e expansão do espaço de atributos e de Lógica Nebulosa na classificação final é proposta. São apresentadas também as bibliotecas de Morfologia Matemática **MorphoMat** e de classificação de imagens **ImageIO**, desenvolvidas na linguagem de programação **Ox**, e o sistema de visualização **ANIMED**, construído utilizando a linguagem **Object Pascal**, todos desenvolvidos ao longo deste trabalho. Como estudo de caso, realizou-se a análise de imagens de imuno-histoquímica de amostras de pulmão de neomortos com doença da membrana hialina.

Abstract

This work presents a set of tools and methods for image analysis in Pathology using Mathematical Morphology and Fuzzy Logic. A new method for image classification based on synthetic bands generation by the use of morphological transformations in feature extraction and spacial expansion and Fuzzy Logic in the final classification is proposed. Also, the library of Mathematical Morphology operators **MorphoMat** and the library for image classification **ImageIO**, both of which developed in the programming language **Ox**, are presented, as well as the image visualization system **ANIMED**, built using **Object Pascal**. The case study approaches image analysis in lung sample imuno-histochemical images from dead babies with the hyaline membrane disease.

Conteúdo

1	Introdução	1
1.1	Motivação e Objetivos	1
1.2	Materiais e Métodos	2
1.3	Organização do Trabalho	4
2	Estado da Arte da Análise de Imagens em Patologia	6
2.1	Introdução	6
2.2	Aquisição de Imagens	8
2.3	Extração de Atributos em Patologia	11
2.3.1	Morfometria	11
2.3.2	Fotomicrometria	18
2.4	Classificação de Imagens em Patologia	24
2.4.1	Métodos Empíricos	24
2.4.2	Métodos Estatísticos	25
2.4.3	Métodos Não Estatísticos	27
2.5	Conclusão	28
3	Introdução à Lógica Nebulosa	30
3.1	Introdução	30
3.2	Funções de Pertinência	31

3.3	Álgebra dos Conjuntos	36
3.4	Álgebra dos Conjuntos Nebulosos	37
3.5	Uso da Lógica Nebulosa em Reconhecimento de Padrões	38
3.5.1	Fundamentos Teóricos	39
3.5.2	Classificação de Imagens	42
3.6	Conclusão	48
4	Introdução à Morfologia Matemática	50
4.1	Introdução	50
4.2	Conceitos Preliminares	53
4.3	Operadores Básicos da Morfologia Matemática	56
4.3.1	Dilatação e Erosão	57
4.3.2	Dilatação e Erosão Condicionais	66
4.3.3	Gradiente Morfológico	69
4.3.4	Abertura e Fechamento	72
4.3.5	Abertura e Fechamento por Reconstrução	77
4.4	Granulometria	82
4.5	A Biblioteca MorphoMat	84
4.6	Conclusão	89
5	O Problema da Extração de Atributos na Classificação	90
5.1	Introdução	90
5.2	Análise Morfométrica	91
5.3	Análise Fotomicrométrica	95
5.4	Conclusão	98
6	Incremento da Classificação de Imagens Utilizando Geração de Bandas Sintéticas	100
6.1	Introdução	100

6.2	Método Proposto	101
6.2.1	Extração de Atributos	102
6.2.2	Classificação	103
6.3	Resultados	103
6.4	A Biblioteca ImageIO	117
6.5	O Ambiente ANIMED	120
6.6	Conclusão	129
7	Estudo de Caso: Apoio ao Diagnóstico da Doença da Membrana Hialina	131
7.1	Introdução	131
7.2	A Doença da Membrana Hialina (DMH)	132
7.3	Motivação do Estudo de Caso	135
7.4	Análise de Imagens de DMH utilizando o ANIMED	136
7.5	Conclusão	149
8	Conclusão	150
	Bibliografia	154

Lista de Figuras

2.1	Exemplo de videofotômetro (extraído de [dSBCR99])	9
2.2	Grade de pseudo senóides para morfometria	13
2.3	Diagrama em blocos do processamento envolvido em um sistema de análise morfométrica	14
2.4	Imagem de uma amostra histológica de uma metástase de câncer de mama na placenta, onde se percebem os núcleos tumorais em cores mais escuras	22
2.5	Versão em níveis de cinza da figura 2.4, onde são percebidos os núcleos tumorais em níveis de cinza próximos do preto (um conjunto deles está destacado pelo retângulo branco)	22
3.1	Função de pertinência μ_H da altura h do indivíduo x ao conjunto solução das alturas aceitáveis H	34
3.2	Função de pertinência μ_P do peso p do indivíduo x ao conjunto solução dos pesos aceitáveis P	34
3.3	Imagem de amostra histológica de carcinoma de mama. As regiões mais escuras da imagem são os núcleos celulares, onde a região onde eles estão maiores e mais concentrados (a direita) é a região afetada pelo câncer.	44

3.4	Resultado da classificação da imagem da figura 3.3 pelo Método do Trapézio Simétrico utilizando os <i>pixels</i> como vetores de atributos (ver tabela 3.1)	45
3.5	Resultado da classificação da imagem da figura 3.3 pelo Método do Trapézio Assimétrico utilizando os <i>pixels</i> como vetores de atributos (ver tabela 3.2)	46
4.1	Imagem de amostra histológica de carcinoma de mama, estando os núcleos celulares afetados pelo câncer à esquerda e ao centro	62
4.2	Imagem intensidade da imagem da figura 4.1	62
4.3	Binarização da imagem da figura 4.2 utilizando um limiar igual a 0,4	63
4.4	Dilatação da imagem da figura 4.2 pelo quadrado 3×3	63
4.5	Erosão da imagem da figura 4.2 pelo quadrado 3×3	64
4.6	Anti-dilatação da imagem da figura 4.2 pela cruz 3×3	64
4.7	Anti-erosão da imagem da figura 4.2 pela cruz 3×3	65
4.8	3-dilatação da imagem da figura 4.2 pela cruz 3×3	65
4.9	3-erosão da imagem da figura 4.2 pela cruz 3×3	66
4.10	Marcador para a dilatação condicional	67
4.11	Resultado da dilatação condicional do marcador da figura 4.10, dada a imagem da figura 4.2, pelo elemento estruturante quadrado 3×3	68
4.12	Marcador para a erosão condicional	68
4.13	Resultado da erosão condicional do marcador da figura 4.12, dada a imagem da figura 4.2, pelo elemento estruturante quadrado 3×3	69

4.14	Resultado da aplicação do gradiente morfológico à imagem da figura 4.2 pelo elemento estruturante losango 5×5	70
4.15	Resultado da extração da borda externa da imagem da figura 4.2 pelo elemento estruturante losango 5×5	70
4.16	Resultado da extração da borda interna da imagem da figura 4.2 pelo elemento estruturante losango 5×5	71
4.17	Abertura da imagem da figura 4.2 pela quadrado 3×3	73
4.18	Fechamento da imagem da figura 4.2 pela quadrado 3×3	75
4.19	4-abertura da imagem da figura 4.2 pelo quadrado 3×3	75
4.20	4-fechamento da imagem da figura 4.2 pelo quadrado 3×3	76
4.21	Filtragem $3\gamma\phi$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3	77
4.22	Filtragem $3\phi\gamma$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3	78
4.23	Filtragem $3\gamma\phi\gamma$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3	78
4.24	Filtragem $3\phi\gamma\phi$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3	79
4.25	Abertura por reconstrução da imagem da figura 4.3 pelo elemento estruturante quadrado 3×3 , dado o marcador mostrado na figura 4.10 e utilizando-se 150 iterações (idempotência)	81
4.26	Fechamento por reconstrução da imagem da figura 4.3 pelo elemento estruturante quadrado 3×3 , dado o marcador mostrado na figura 4.12 e utilizando-se 150 iterações (idempotência)	82
4.27	Função de distribuição acumulada discreta $\Xi[k]$ da imagem da figura 4.2 para $0 \leq k \leq 20$	85

4.28	Espectro de padrões $\xi[k]$ associado à imagem da figura 4.2, onde $0 \leq k \leq 20$, obtido pela derivada discreta da função de distribuição acumulada plotada no gráfico da figura 4.27 . . .	86
5.1	Macrófagos CD68 ⁺ em amostra de placenta; note as diferenças entre seus tamanhos e formatos.	97
5.2	Macrófagos CD68 ⁺ em amostra de placenta; note que, apesar das diferenças de tamanho, as fronteiras são menos rugosas que as dos macrófagos da figura 5.1.	97
5.3	Macrófagos CD68 ⁺ em amostra de placenta; note o nível de deformação do macrófago ao centro.	98
6.1	Gráfico do coeficiente κ obtido pela avaliação do Método do Paralelepípedo <i>versus</i> o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3 . . .	105
6.2	Gráfico da taxa de acerto obtida pela avaliação do Método do Paralelepípedo <i>versus</i> o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3 . . .	106
6.3	Gráfico do coeficiente κ obtido pela avaliação da MVG <i>versus</i> o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	107
6.4	Gráfico da taxa de acerto obtida pela avaliação da MVG <i>versus</i> o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	108

6.5	Gráfico do coeficiente κ obtido pela avaliação do Método do Trapézio Simétrico <i>versus</i> o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	109
6.6	Gráfico da taxa de acerto obtida pela avaliação do Método do Trapézio Simétrico <i>versus</i> o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	110
6.7	Gráfico do coeficiente κ obtido pela avaliação do Método do Paralelepípedo <i>versus</i> o número de bandas sintéticas geradas por meio de aberturas da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	113
6.8	Gráfico do coeficiente κ obtido pela avaliação da MVG <i>versus</i> o número de bandas sintéticas geradas por meio de aberturas da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	114
6.9	Gráfico do coeficiente κ obtido pela avaliação do Método do Trapézio Simétrico <i>versus</i> o número de bandas sintéticas geradas por meio de aberturas da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3	115
6.10	Tela de abertura do ambiente ANIMED	121
6.11	Formulário principal do ambiente ANIMED	121
6.12	Conversor de imagens Bitmap (.bmp) para BSQ ou BIP	122
6.13	Tela de seleção de bandas a visualizar no ambiente ANIMED	123
6.14	Determinação do número de classes existentes na imagem no ambiente ANIMED	124

6.15	Montagem da tabela de descrição de classes e associação de cores. A direita tem-se a seleção da cor a ser associada à classe.	125
6.16	Janela para adionamento de região de interesse. A direita tem-se a lista das classes definidas.	125
6.17	Regiões de interesse retangulares selecionadas da imagem da figura 3.3	126
6.18	Janela com o resultado da pós-classificação no ANIMED	129
7.1	Alvéolo e, a sua direita, estruturas relacionadas em ampliação (baseado em [Hen00])	133
7.2	Imagem de amostra histológica de pulmão com DMH, destacando a membrana hialina e os espaços alveolares	134
7.3	Amostra histológica de pulmão com DMH expressando a siamolucina CD34 ⁺ com aumento de 200×	137
7.4	Regiões de interesse selecionadas da figura 7.3	140
7.5	Resultado da classificação da imagem da figura 7.3 pelo Método do Trapézio Simétrico	141
7.6	Resultado da classificação da imagem da figura 7.3 pelo Método do Trapézio Assimétrico	142
7.7	Amostra histológica de pulmão com DMH expressando a siamolucina CD34 ⁺ com aumento de 200×	145
7.8	Resultado da classificação da imagem da figura 7.7 pelo Método do Trapézio Assimétrico	146
7.9	Amostra histológica de pulmão com DMH expressando a siamolucina CD34 ⁺ com aumento de 200×	147
7.10	Resultado da classificação da imagem da figura 7.9 pelo Método do Trapézio Assimétrico	148

Lista de Tabelas

3.1	Matriz de confusão da classificação visualizada na figura 3.4	47
3.2	Matriz de confusão da classificação visualizada na figura 3.5	47
4.1	Operações de dilatação, erosão e convolução	59
6.1	Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Paralelepípedo (ver figuras 6.1 e 6.2)	104
6.2	Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pela MVG (ver figuras 6.3 e 6.4)	111
6.3	Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Trapézio Simétrico (ver figuras 6.5 e 6.6)	111
6.4	Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Paralelepípedo (ver figura 6.7)	116
6.5	Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pela MVG (ver figura 6.8)	116

6.6	Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Trapézio Simétrico (ver figura 6.9)	117
6.7	Código C++ de leitura de uma imagem f de grade $m \times n$ e p bandas, armazenada no formato BSQ	118
6.8	Código C++ de leitura de uma imagem f de grade $m \times n$ e p bandas, armazenada no formato BIP	119
6.9	Lista de descrição de classes gerada pelo ANIMED contendo o índice, a cor e o nome associados a cada classe. A cor está no formato RGB normalizado.	126
7.1	Tabela de associação de classes a índices e cores para análise de imagens de pulmão com DMH, com cores no formato RGB normalizado, gerada utilizando o ANIMED	138
7.2	Taxa de acerto, índice κ e matriz de confusão resultantes da avaliação da classificação da imagem da figura 7.3 segundo o Método do Trapézio Simétrico, gerados pelo ANIMED	143
7.3	Taxa de acerto, índice κ e matriz de confusão resultantes da avaliação da classificação da imagem da figura 7.3 segundo o Método do Trapézio Assimétrico, gerados pelo ANIMED	144

Capítulo 1

Introdução

1.1 Motivação e Objetivos

Neste trabalho é proposto um método de classificação de imagens em Patologia que emprega Lógica Nebulosa e Morfologia Matemática. O método consiste em um classificador baseado em Lógica Nebulosa cujos parâmetros são calculados de maneira não iterativa e na geração de bandas sintéticas obtidas pela aplicação de transformações morfológicas às bandas originais, com o objetivo de tentar melhorar o resultado da classificação anterior pelo acréscimo de informação de forma.

Essas bandas sintéticas são adicionadas ao conjunto de bandas originais, fazendo com que o método proposto seja uma espécie de “transformação” de uma imagem colorida (apenas 3 bandas espectrais) em uma imagem multi-espectral (mais de 3 bandas espectrais), objetivando uma melhoria da classificação. Isso torna possível o uso da análise de imagens multiespectrais em Patologia, o que pode trazer potenciais benefícios ao incremento do diagnóstico por imagem.

A maior motivação para a realização desta pesquisa se resume a dois

fatores:

1. Existe uma necessidade latente na Patologia (bem como na Medicina em geral) de métodos objetivos e quantitativos de análise. Torna-se frequente, até mesmo por parte de outros patologistas, a queixa de que, apesar de ser ensinada como uma ciência, a Patologia vem sendo praticada como uma arte [MB94]. Além disso, áreas de pesquisa tais como a pesquisa de câncer e a genômica estão cada vez mais dependentes dos avanços das técnicas de processamento de imagens [MWF⁺02], sejam elas a nível de ferramental matemático, sejam ligadas às tecnologias de aquisição de imagens [vM97].
2. As ferramentas computacionais disponíveis para análise de imagens em Patologia são em geral muito caras, tornando seu uso impraticável onde há poucos recursos financeiros para sua aquisição. Além do mais, os *softwares* comerciais em geral não permitem a inclusão do conhecimento do patologista no processo de apoio ao diagnóstico nem deixam claros os métodos de computação inteligente que estão sendo aplicados. Isto resulta em um problema social, pois limita o acesso a recursos tecnológicos que poderiam melhorar o diagnóstico do patologista, favorecendo a detecção de tumores malignos precocemente e, portanto, aumentando a probabilidade de cura e reduzindo gastos demasiados com tratamentos caros e paliativos, por exemplo.

1.2 Materiais e Métodos

As imagens de amostras histológicas de pulmões e placentas de neomortos, no caso da doença da membrana hialina, e de mama, no caso do câncer, foram obtidas a partir do banco de imagens utilizado no projeto “Implantação

da Unidade Laboratorial de Apoio ao Diagnóstico das Infecções Congênitas Transplacentárias”, financiado pela Fundação de Apoio à Pesquisa do Estado de Alagoas (FAPEAL) de 1999 a 2000 e coordenado pelo Dr. Antonio Fernando de Sousa Bezerra. O autor participou desse projeto na elaboração do programa de análise de imagens IMED [dSBCd⁺01].

Durante o processo de desenvolvimento das ferramentas computacionais utilizadas neste trabalho, optou-se por utilizar *software* livre [Fou03a, Fou03b] e, na medida do possível, gratuito. Por isso foi escolhida a linguagem de programação **Ox** (*Object-Oriented Matrix Language*), uma linguagem aberta e interpretada, multi-plataforma: funciona em Windows, UNIX e GNU/LINUX [Doo02].

Ox é um dialeto da linguagem C++, utilizando praticamente a mesma sintaxe do ANSI C++ [DO01, Mül96] com pequenas, porém consideráveis diferenças em relação à tipagem das variáveis: **Ox** não é tipada, ou seja, existe apenas um único tipo de variável explícita, cabendo ao interpretador reconhecer se a variável é um inteiro, um número de ponto flutuante ou um caracter.

O fato de **Ox** ser uma linguagem matricial traz ainda a vantagem de facilitar as operações que envolvem matrizes: duas matrizes podem ser somadas ou multiplicadas como se fossem variáveis numéricas quaisquer. Além disso, **Ox** possui uma extensa biblioteca de Álgebra Linear, Probabilidade e Estatística, o que a faz uma linguagem muito utilizada entre os estatísticos.

Além disso, **Ox** pode ser controlada ou estendida por outras linguagens, mais particularmente o ANSI C++. **Ox** tem ainda uma vantagem sobre outras linguagens interpretadas, como MATLAB [Inc97], por exemplo: além de ser livre e gratuita, produz em geral código mais rápido (menor tempo de execução) [DO01]. **Ox** pode ainda ser pré-compilada, reduzindo o tempo de execução

do código.

Para a construção da ferramenta computacional baseada no método de classificação proposto neste trabalho, foi utilizada a linguagem `Object Pascal`, junto com os compiladores `DELPHI` [Inc96] e `Free Pascal` [vK02], sendo este último livre e gratuito. `Ox` foi utilizada para a implementação do método de classificação de imagens e das ferramentas de Morfologia Matemática, enquanto que `Object Pascal` foi utilizada para construir o programa `ANIMED`, uma GUI (*Graphic User Interface* - Interface Gráfica para o Usuário) que permite uma maior interatividade entre o usuário e o aplicativo. Os códigos fonte em `Object Pascal` e `Ox` estão disponíveis na *web* [dos03a, dos03b], podendo ser utilizados livremente.

1.3 Organização do Trabalho

Este trabalho se encontra organizado em oito capítulos da maneira que se segue:

O estado da arte das técnicas de análise de imagens empregadas em Patologia é comentado no capítulo 2, onde se aborda apenas brevemente a questão da aquisição de imagens, enquanto se dá maior destaque às técnicas de extração de atributos e de classificação.

A classificação é dividida em duas etapas: extração de atributos - a qual pode ser por morfometria ou por fotomicrometria - e classificação propriamente dita - dividindo-se quanto à natureza dos métodos entre empíricos, estatísticos e não-estatísticos. Cada um destes conceitos é exibido e comentado. Ao final do capítulo são tecidos comentários sobre o conteúdo exposto.

No capítulo 3 introduz-se a Lógica Nebulosa e algumas abordagens possíveis para seu uso em problemas de reconhecimento de padrões.

No capítulo 4 é feita uma introdução à Morfologia Matemática, abordando os operadores básicos de dilatação e erosão, juntamente com alguns operadores secundários derivados desses dois primeiros. São mostrados exemplos práticos para cada operador definido, utilizando para isso uma imagem em níveis de cinza de uma amostra histológica de câncer de mama. Também é apresentada a biblioteca de Morfologia Matemática **MorphoMat**, desenvolvida em **0x** ao longo deste trabalho.

Já no capítulo 5 são discutidos os possíveis problemas e limitações das abordagens de extração de atributos utilizadas em análise de imagens em Patologia.

Um método para geração de bandas sintéticas por meio da aplicação de transformações morfológicas é apresentado no capítulo 6. Resultados práticos da aplicação do método na melhoria da classificação de uma imagem em níveis de cinza de câncer de mama utilizando a Máxima Verossimilhança Gaussiana, o Método do Paralelepípedo e Lógica Nebulosa (ver capítulo 3) são apresentados. As ferramentas computacionais desenvolvidas para utilização e teste do método proposto - como a biblioteca **ImageIO**, desenvolvida em **0x**, e a GUI **ANIMED** - também são apresentadas neste capítulo.

No capítulo 7 um estudo de caso é apresentado. Os métodos de classificação por Lógica Nebulosa propostos são empregados para auxílio ao diagnóstico da doença da membrana hialina utilizando imagens de imunohistoquímica de amostras de pulmão de neomortos.

Por fim, no capítulo 8 são apresentadas as conclusões e comentadas as qualidades, as limitações e as perspectivas de trabalhos futuros relacionados à pesquisa realizada, juntamente com as contribuições teóricas e práticas do autor ao estado da arte da análise de imagens realizadas durante o desenvolvimento deste trabalho.

Capítulo 2

Estado da Arte da Análise de Imagens em Patologia

2.1 Introdução

Com o rápido desenvolvimento das técnicas e tecnologias envolvidas em processamento digital de imagens, a Patologia tem se beneficiado cada vez mais desse poderoso ferramental antes restrito a campos específicos da engenharia, tais como a exploração espacial e a tecnologia de satélites.

A Patologia tem se beneficiado bastante do uso da análise de imagens, a qual tem oferecido à Patologia métodos quantitativos e objetivos para análise de estruturas cito e histológicas.

O uso de métodos quantitativos em Patologia tem dois principais objetivos: trazer formas de medição e objetividade ao diagnóstico e melhorar as capacidades de diagnóstico e de prognóstico do patologista [MB94].

Segundo [MB94], uma crítica frequentemente feita aos patologistas é que a histopatologia diagnóstica (área da Patologia que se preocupa com análises e diagnósticos histológicos) é ensinada como uma disciplina acadêmica, mas

é claramente praticada como uma arte.

Tal crítica procede, se for encarado o fato de que a identificação visual microscópica de uma amostra de tecido biológico é feita baseando-se na experiência própria do patologista e no seu “sentimento” (aprendizado) [MB94].

Muitas empresas de tecnologia biomédica têm se dedicado ao desenvolvimento de tecnologias (*hardware* e *software*) que empreguem ferramentas da inteligência artificial e da estatística, juntamente com o processamento de imagens, para auxílio no diagnóstico por imagem.

Embora muitos profissionais de saúde ainda sejam resistentes à entrada do computador no laboratório de análises, o processamento digital de imagens vem resolvendo uma quantidade cada vez maior de problemas, trazendo benefícios que se estendem da simples automação do processo repetitivo de realizar análises visuais - processo este desgastante e sujeito a inúmeras imprecisões e erros - ao aumento da precisão na detecção de estruturas de interesse em análises cito e histológicas.

Além disso, pode-se afirmar que importantes áreas da pesquisa médica, tais como a pesquisa de câncer, são fortemente dependentes do desenvolvimento das técnicas de processamento de imagens [MWF⁺02]. É na pesquisa de câncer que se observam os maiores avanços.

Porém, um ponto que não deve ser deixado de lado é a aquisição das imagens a serem analisadas. Como os sistemas de auxílio ao diagnóstico histopatológico realizam essa aquisição é uma questão que será explorada na seção seguinte.

Neste capítulo são ainda descritas as duas categorias de métodos de extração de atributos de imagens cito e histológicas, além de também serem citados alguns métodos de classificação utilizados mais comumente em ferramentas comerciais. Também é abordada brevemente uma aplicação que

tem despertado cada vez maior interesse no meio técnico-científico [MB94]: a DNA-ploidia utilizando análise digital de imagens.

2.2 Aquisição de Imagens

A aquisição de imagens para análise digital nos laboratórios biomédicos é usualmente feita por meio de um aparato opto-eletrônico denominado *videofotômetro*.

O videofotômetro consiste na junção de um microscópio óptico com uma câmera de vídeo e um sistema computacional. Geralmente é utilizado um microscópio de pesquisa comum adicionado a uma câmera CCD de baixo custo.

A aquisição é feita por meio de placas de aquisição de vídeo comuns, tendo sua resolução escolhida de acordo com o tipo de análise ao qual o videofotômetro será dedicado.

A análise é feita pelo sistema computacional, o qual pode ser desde uma estação de trabalho dotada de tecnologia de ponta a um simples microcomputador doméstico.

Podem também ser utilizados sistemas computacionais de arquitetura dedicada. Porém, a relação custo-benefício deve ser levada em conta antes de se optar por um sistema dedicado, uma vez que pode vir a ser mais barato concentrar o custo computacional da análise no *software* empregado.

Todavia, esta é apenas uma verdade circunstancial, uma vez que podem surgir aplicações que, por razões específicas, demandem mais recursos de *hardware*, podendo até exigir que a tarefa de classificação seja executada numa arquitetura específica, sacrificando flexibilidade em favor de um melhor desempenho na classificação.



Figura 2.1: Exemplo de videofotômetro (extraído de [dSBCR99])

A figura 2.1 exibe um exemplo de videofotômetro (extraída de [dSBCR99]). Nos dois quadros superiores e no quadro do centro à esquerda podem-se notar os conjuntos de lentes. No quadro central à direita é exibido o sistema como um todo, tendo um microcomputador como sistema computacional de análise.

No quadro inferior é exibido o sistema de aquisição propriamente dito, tendo além da câmera CCD, a qual está ligada ao microscópio óptico a direita, um monitor analógico. Esse monitor analógico permite a visualização em tempo real da amostra histológica sem desgastar a visão do patologista nem consumir processamento do microcomputador.

As câmeras CCD tem sido preferidas para a aquisição das imagens devido às atuais câmeras digitais ainda não permitirem altas resoluções a um baixo custo. As câmeras CCD constituem uma alternativa de aquisição a um custo mediano, o qual é compensado pelo uso de placas de aquisição de vídeo profissionais, que permitem conversão analógico-digital a altas taxas e resoluções razoáveis.

Entretanto, o panorama tem mudado devido aos investimentos cada vez maiores da indústria eletrônica no desenvolvimento de *web-cams* de alta resolução, o que possibilitará a possível eliminação das placas de aquisição de vídeo, uma vez que a aquisição será puramente digital.

Além disso, será possível a construção de *laboratórios virtuais*, permitindo uma maior troca de informações e imagens entre patologistas, melhorando a capacidade de diagnóstico e prognóstico desses profissionais [LMC⁺01]. Tais laboratórios virtuais consistirão em bancos de dados de imagens classificadas e diagnósticos disponíveis na *web*, além de permitirem a visualização de lâminas em tempo real através da automatização de videofotômetros e seu controle via *web*.

A instrumentação virtual distribuída em rede aplicada aos laboratórios biomédicos se mostra como uma possibilidade cada vez mais real, exigindo cada vez mais atualização tecnológica por parte dos patologistas e biomédicos, no que tange ao domínio das ferramentas computacionais de análise e ao uso racional da *web* como meio de distribuição do conhecimento técnico-científico.

Uma vez escolhido o videofotômetro - cujos detalhes técnicos a respeito da suas partes constituintes, tais como resolução de câmeras e de taxas de aquisição de sistemas comerciais foge ao escopo deste trabalho - o próximo passo é a escolha de um bom sistema de análise.

Na maioria das vezes tais sistemas se limitam a um *software*, mas sistemas computacionais dedicados podem ser exigidos, tal como salientado anteriormente. Porém, o que realmente importa agora é como tais sistemas realizam a análise das imagens.

Tal análise consiste basicamente em um sistema de reconhecimento de padrões (RP), sendo portanto fortemente dependente da forma como os atributos são extraídos das imagens.

A seção seguinte trata dos métodos de extração de atributos comumente utilizados na classificação de imagens biomédicas e histológicas.

2.3 Extração de Atributos em Patologia

A extração de atributos em Patologia é realizada de acordo com o que será considerado para a montagem dos vetores de atributos, ou seja, o que será definido como elemento de interesse.

Existem basicamente duas abordagens para extração de atributos em Patologia: extração por *morfometria* e por *fotomicrometria* [MB94], sendo a primeira mais utilizada quando se deseja fazer classificação utilizando critérios de forma ou textura.

Já a fotomicrometria é preferida quando a classificação é feita utilizando vetores de atributos cujas dimensões são relacionadas com a absorção espectral do amostra histológica.

2.3.1 Morfometria

O termo *morfometria* é usado freqüentemente denotando quantificação de estruturas visíveis numa lâmina histológica [MB94].

Em geral, morfometria é o nome dado aos vários métodos quantitativos

utilizados para análise de tecidos e células; entretanto, o mais correto é dizer que a morfometria diz respeito aos métodos quantitativos que envolvem medidas geométricas (área, perímetro etc.) e de textura [MB94].

A análise de imagens por morfometria vem sendo utilizada em Patologia desde muito antes da popularização do uso de microcomputadores no laboratório biomédico e patológico.

A análise morfométrica não computadorizada era (e ainda o é, em muitos laboratórios carentes de recursos tecnológicos) realizada utilizando uma *grade de apoio*. Essa grade consiste numa transparência com marcações e uma escala em nanômetros. Essas marcações podem ser simples linhas paralelas, uma grade cartesiana ou mesmo pseudo senóides. Os atributos são extraídos da imagem de acordo com a relação entre as estruturas de interesse e os elementos da grade [MB94].

No caso de uma grade com linhas paralelas, um atributo a ser extraído pode ser a distância do centro da estrutura de interesse (uma célula, por exemplo) ao centro da linha paralela mais próxima. Outro pode ser ainda a quantidade de linhas paralelas horizontais que cabem dentro da estrutura de interesse (largura em função das linhas paralelas).

Para uma grade com pseudo senóides (ver figura 2.2), o número de intersecções entre a fronteira da estrutura de interesse e a quantidade de pseudo senóides que cabem dentro da referida estrutura também são atributos que a caracterizam e são largamente utilizados em análises [dSB02].

Já as grades cartesianas são utilizadas para fazer estimativas de área e perímetro das estruturas de interesse. Nota-se que uma grande quantidade de imprecisões e subjetividade está presente em tais processos.

Os sistemas computacionais foram utilizados inicialmente para substituir as grades de análise. Logo, é comum encontrar *softwares* de análises médicas




Figura 2.2: Grade de pseudo senóides para morfometria

dotados de grades do tipo citado, permitindo ao patologista ou biomédico realizar as análises extraindo atributos da maneira tradicional.

Atualmente, os atributos são extraídos automaticamente e muitos desses atributos não tem necessariamente uma interpretação tangível do ponto de vista biológico ao patologista ou biomédico.

Um diagrama em blocos genérico de um sistema de análise morfométrica (extração de atributos por morfometria) é exibido na figura 2.3.

Após realizar a *aquisição da imagem* (transformação T1, ver figura 2.3), obtém-se uma imagem colorida, que no caso da figura 2.3 é uma amostra histológica de carcinoma de mama. Gera-se então uma *imagem em níveis de cinza*, que pode ser simplesmente a seleção de uma das bandas presentes na imagem original ou sua intensidade (transformação T2). No exemplo da figura extrai-se a intensidade da imagem original. Depois realiza-se a *binarização* segundo o método mais adequado (transformação T3). No exemplo




Figura 2.3: Diagrama em blocos do processamento envolvido em um sistema de análise morfométrica

da figura 2.3 foi realizada uma binarização utilizando um limiar fixo de 0,4, considerando imagens normalizadas. É realizada então uma *segmentação*, a qual consiste na geração de uma outra imagem contendo apenas os elementos de interesse para a análise (transformação T4). No caso do exemplo da figura 2.3, a segmentação foi feita utilizando a *abertura morfológica por reconstrução*, utilizando marcadores nas estruturas de interesse. Também é comum que seja feita a segmentação antes da binarização. A seguir é feito o *janelamento* (transformação T5), o qual busca as componentes conectadas (estruturas ligadas na imagem), separa-as em janelas para depois serem medidas (transformação T6), gerando um vetor de atributos. Esse último processo é a *extração de atributos* propriamente dita. Esses atributos podem ser *geométricos* (obtidos de medidas simplesmente geométricas, como perímetro, área etc.) ou *granulométricos* (obtidos de granulometrias). A classificação é então realizada utilizando o método mais adequado à aplicação.

Um exemplo de aplicação de análise morfométrica por *atributos geométricos* é o diagnóstico da filariose [PeS93], onde foram utilizados 22 atributos geométricos clássicos, gerando conseqüentemente um vetor de atributos de 22 dimensões, o qual é depois classificado utilizando o classificador linear de Fisher [DH72]. O objetivo é detectar microfírias, vermes microscópicos responsáveis por deformações físicas em certas partes do corpo humano e transmitidos pela muriçoca [PeS93].

Os atributos geométricos mais comuns são:

Área A

Perímetro P

Diâmetro Equivalente 1 $(4A/\pi)^{1/2}$

Diâmetro Equivalente 2 $(6A/\pi)^{1/3}$

Diâmetro Equivalente $3 P/\pi$

Espessura $\frac{1}{4}[P - (P^2 - 16A)^{1/2}]$

Comprimento $\frac{1}{4}[P + (P^2 - 16A)^{1/2}]$

Fator de Forma $F_f = 4\pi A/P^2$

Numa imagem binária $f : S \rightarrow \{0, 1\}$, onde S é o *suporte* (grade) da imagem, a *área* A será determinada pela quantidade de *pixels* iguais a 1, enquanto o *perímetro* P será determinado pela área resultante da aplicação do operador *gradiente* à imagem. É importante realçar que os atributos são extraídos não da imagem inteira, mas das suas regiões conectadas obtidas do processo de janelamento. As regiões conectadas são separadas em pequenas imagens e os atributos são extraídos delas.

Existem ainda os *momentos*, os quais são bastante utilizados. Os momentos são baseados nos momentos físicos, tais como o momento de inércia, sendo definidos matematicamente de forma semelhante. No entanto, um maior detalhamento a respeito dos momentos foge ao escopo do presente trabalho.

Já os *atributos granulométricos* são obtidos a partir da aplicação de aberturas morfológicas e posterior medição das áreas e perímetros resultantes [DG87, Fac96].

Portanto, a geração de um vetor de atributos seria feita da seguinte forma: seja $\mathbf{X}_p = (x_1, x_2, \dots, x_m)$ o vetor de atributos a descrever a estrutura de interesse p , já devidamente obtida do janelamento (ver figura 2.3); sejam B_k elementos estruturantes, onde $1 \leq k \leq m$; seja $f_W : W \rightarrow [0, 1]$ uma imagem resultante do janelamento de uma estrutura de interesse na imagem original normalizada $f : S \rightarrow [0, 1]$ pela janela W , onde S é o suporte da imagem f

e $W \subseteq S$; os atributos x_k serão obtidos da forma:

$$x_k = \begin{cases} \Gamma_A(\psi_{B_k}(f_W)), & (k \bmod 2) = 1 \\ \Gamma_P(\psi_{B_k}(f_W)), & (k \bmod 2) = 0 \end{cases},$$

onde $1 \leq k \leq m$. Os operadores Γ_A e Γ_P retornam a área e o perímetro, respectivamente. Já o operador ψ_{B_k} pode ser a erosão (ϵ_{B_k}) ou a abertura (γ_{B_k}) morfológicas pelo elemento estruturante B_k .

A *extração de atributos granulométricos* também tem sido utilizada com sucesso na identificação de assinaturas manuscritas [EL96]. Porém, tal abordagem é altamente dependente da boa escolha dos elementos estruturantes e da quantidade de atributos a ser utilizada. Isso sem contar com o método de classificação a ser escolhido. Apesar disso, tais escolhas não são difíceis, sendo bastante intuitivas.

Entretanto, é comum utilizar-se não somente atributos geométricos ou granulométricos, mas também atributos específicos para o tipo de aplicação a qual se destina a análise.

Um exemplo disso é a identificação de tecidos cancerosos em [TM02], onde os atributos são *critérios objetivos de malignância*¹, os quais são mais *intuitivos* para os patologistas. A segmentação é feita utilizando a *abertura morfológica* seguida de uma *reconstrução* e de uma *limiarização* (ou binarização por limiar fixo). Em seguida, na etapa de *extração de atributos*, os raios dos núcleos e suas estatísticas são computados e, a partir deles, os *critérios de malignância* são quantificados.

Em outras aplicações, tais como a detecção de microcalcificações em mamogramas digitalizados, a extração de atributos estatísticos pode ser mais

¹ *Critérios objetivos de malignância* são grandezas relacionadas às características morfométricas dos núcleos celulares e cujos valores numéricos expressam o quão maligno é um tumor.

adequada [KP99].

Outras técnicas de extração de atributos mais sofisticadas também têm sido bastante utilizadas, tais como a análise fractal [ENS⁺02]. Porém, os aplicativos comerciais ainda são um tanto pobres no que se refere à extração de atributos, limitando-se aos atributos geométricos e, quando muito, granulométricos.

Muitas vezes os *pixels* se bastam como vetores de atributos. Este é o caso de análises baseadas na *cor* ou no *nível de cinza*, tais como na *imuno-histoquímica quantitativa* e na *DNA-ploidia*. Tais análises são ditas *microfotométricas*, sendo assunto da próxima seção.

2.3.2 Fotomicrometria

A fotomicrometria é uma poderosa ferramenta para quantificação de substâncias cromogênicas em imagens de amostras microscópicas. Atualmente, a maior aplicação da fotomicrometria tem sido no apoio a *análise de imagens de imuno-histoquímica* [MB94].

A imuno-histoquímica é um processo bastante utilizado na prática diária da Patologia. As técnicas da imuno-histoquímica detectam moléculas (antígenos) teciduais, sendo de grande valor nos diagnósticos e na investigação científica.

Entretanto, métodos quantitativos são necessários, uma vez que a distinção entre certas cores presentes na imagem resultante pode ser difícil, o que pode resultar em diagnósticos errôneos. Além disso, uma maior quantidade de informação pode ser obtida através da correta diferenciação entre níveis de cinza numericamente próximos, além de facilitar o trabalho do patologista.

A fotomicrometria pode ser *baseada em vídeo*, ou seja, fazendo uso do

videofotômetro, ou feita a partir de *citômetros*. Os citômetros são aparelhos que emitem feixes de luz e medem a potência absorvida em várias partes do espectro visível (vermelho, verde e azul, por exemplo).

A partir da análise do espectro de saída, ou seja, verificando as relações entre potência absorvida e potência emitida nas referidas partes do espectro visível, obtém-se uma estimativa da presença de determinadas proteínas ou tipos de células e sua quantidade.

Apesar da utilização de citômetros apresentar “uma certa pobreza” no que tange aos atributos gerados, tal problema pode ser contornado utilizando-se um maior refinamento da ferramenta de classificação, tal qual o uso de aprendizagem estatística e redes neurais [PCB02]. Esta seção se deterá apenas à fotomicrometria baseada em *análise digital de imagens*.

A fotomicrometria aplicada à análise de imagens biomédicas e de patologia é praticamente uma transposição da análise de imagens multi e hiperespectrais do Sensoriamento Remoto para a Patologia, pois o vetor de atributos é também o *pixel*.

Matematicamente, seja $f : S \rightarrow [0, 1]^k$ uma imagem normalizada com k bandas, a fotomicrometria extrai o vetor de atributos $\mathbf{X}_u = (x_1, x_2, \dots, x_k)$ do pixel da posição $u \in S$. Assim, cada atributo será dado por $x_j = f_j(u)$, onde $1 \leq j \leq k$ e $f(u) = \{f_1(u), f_2(u), \dots, f_k(u)\}$. Ou seja, $f_j(u)$ é o *pixel* da posição $u \in S$ na j -ésima banda de f , representado pelo vetor de atributos $\mathbf{X}_u = (f_1(u), f_2(u), \dots, f_k(u))$.

As aplicações mais importantes da fotomicrometria em Patologia são a *DNA-Ploidia* e a *imuno-histoquímica quantitativa*.

DNA-ploidia

Consiste na quantificação do DNA presente em cada célula por meio da contagem dos *pixels* próximos de 0 contidos na imagem do núcleo celular. Conseqüentemente, a DNA-ploidia desempenha papel fundamental na análise de anormalidades cromossômicas, sendo bastante utilizada na pesquisa de câncer em Patologia.

A DNA-ploidia pode ser realizada por meio da *análise de imagens microfotométrica* ou utilizando *citometria de fluxo* (análise com uso do citômetro). A DNA-ploidia é capaz de detectar anormalidades genéticas correspondentes à perda ou ganho de cerca de três cromossomos [MB94].

A DNA-ploidia é baseada na medida fotomicroométrica da coloração dos núcleos celulares em preparações cito e histológicas coloridas por corantes fluorescentes ou histoquímicos que reagem especificamente com a molécula de DNA. A informação do ciclo celular é mostrada como uma freqüência de valores fotomicroométricos no formato de histograma. Assim, tomando-se uma imagem de uma amostra histológica à qual foi aplicado o corante adequado, obtém-se uma versão em níveis de cinza e monta-se o histograma da intensidade (média dos níveis de cinza) dos núcleos celulares. Quanto maior a intensidade, mais avançada a fase do núcleo no ciclo celular. As fases do ciclo celular são, da primeira a última:

- Repouso: G_0
- Pré-síntese de DNA: G_1
- Síntese de DNA: S
- Pós-síntese de DNA: G_2
- Mitose (divisão celular): M

Depois da divisão celular (M), a célula prossegue o ciclo a partir da fase de pré-síntese de DNA (G_1).

Desta forma, através da análise de histograma gerado, o patologista pode observar as fases do ciclo celular pelas quais passam as células e assim observar se existem anormalidades. Um pico do histograma numa faixa de cinza correspondente à mitose pode indicar uma anormalidade na divisão celular, por exemplo, o que poderia indicar a presença de uma neoplasia (câncer) [MB94].

Na figura 2.4 tem-se uma imagem de uma amostra histológica de uma metástase de câncer de mama na placenta. A figura 2.5 é a versão em níveis de cinza da figura 2.4, onde se pode notar os núcleos tumorais da mama (mais escuros e deformados).

A metástase é a transferência de uma afecção de uma parte do organismo para outra por meio de germes ou de células anormais (doentes) transportadas pelo sangue ou pela linfa (líquido do sistema linfático semelhante ao plasma sanguíneo). As células cancerosas são especialmente propensas a produzir metástases. Essas células se desprendem do tumor primário e são transportadas para outras partes do organismo, dando origem a tumores secundários [Mil76].

Neste caso, devido aos núcleos de células tumorais possuírem uma maior quantidade de DNA do que os núcleos normais, a análise por parte do patologista será baseada na avaliação dos picos do histograma para as intensidades dos núcleos mais próximas do preto.

Imuno-Histoquímica Quantitativa

A imuno-histoquímica tem se tornado uma rotina na prática em Patologia numa grande variedade de situações, como a avaliação de tumores de difícil




Figura 2.4: Imagem de uma amostra histológica de uma metástase de câncer de mama na placenta, onde se percebem os núcleos tumorais em cores mais escuras




Figura 2.5: Versão em níveis de cinza da figura 2.4, onde são percebidos os núcleos tumorais em níveis de cinza próximos do preto (um conjunto deles está destacado pelo retângulo branco)

diferenciação, por exemplo [MB94].

A imuno-histoquímica consiste na detecção de moléculas (antígenos) teciduais. Essa detecção é feita por meio de um anticorpo que, ao entrar em contato com um determinado antígeno, libera uma substância cromógena, ou seja, uma substância que marca o antígeno com uma determinada cor [MB94]. Assim, uma determinada célula ou tecido pode ser realçado com uma cor específica sabendo-se qual antígeno está expresso de forma mais abundante e que anticorpo é capaz de detectar esse antígeno.

Na verdade pode-se interpretar a imuno-histoquímica como uma *pré-classificação pela cor*. A análise de imagens serviria neste caso para fazer uma classificação final das estruturas presentes nas lâminas às quais já foi aplicada a imuno-histoquímica. Vê-se que a cor é bastante importante na análise de imagens em Patologia. Desta forma, a *morfologia matemática em níveis de cinza* pode vir a desempenhar um papel importante nesta especialidade médica.

Atualmente, uma das mais importantes aplicações da imuno-histoquímica quantitativa em diagnóstico patológico é a *avaliação de receptores de hormônio no câncer de mama* [MB94].

O mecanismo básico de detecção de um antígeno por um anticorpo na imuno-histoquímica pode ser de forma:

Direta: É utilizado um anticorpo marcado - ou seja, adicionado a um cromógeno, que geralmente é uma substância fosforescente ou uma enzima - para detectar o antígeno desejado e, assim, realçar a célula ou tecido de interesse com a cor gerada pelo cromógeno.

Indireta: Um anticorpo não marcado - ou seja, não adicionado a um cromógeno - é utilizado como antígeno para um segundo anticorpo (anticorpo secundário) marcado.

Entretanto, esses métodos fornecem uma marcação fraca devido à pequena quantidade de cromógeno depositado. Para “amplificar” a visualização da marcação são utilizados outros métodos, todos eles baseados em mecanismos indiretos mais complexos. A descrição de tais métodos foge ao escopo deste trabalho.

2.4 Classificação de Imagens em Patologia

Uma vez definidos os atributos a serem utilizados, passa-se a escolha do classificador propriamente dito. Diversos tipos de classificadores podem ser utilizados. Segundo [MB94], existem basicamente três tipos de métodos de classificação: os métodos *empíricos*, os *estatísticos* e os *não estatísticos*.

2.4.1 Métodos Empíricos

Os métodos empíricos podem ser *objetivos* ou *subjetivos*. Os métodos objetivos são baseados em *fórmulas matemáticas obtidas empiricamente*, enquanto que os subjetivos utilizam *heurísticas baseadas na experiência do especialista* (no caso, o patologista ou o biomédico).

Os métodos empíricos são caracterizados por sua imprecisão intrínseca, pois geralmente levam em consideração poucos atributos.

Um exemplo disso é o caso da procura de núcleos de células cancerosas: o patologista poderia apenas utilizar como atributo o fator de forma F_f , utilizando como critério o fato de que os núcleos de células cancerosas são mais irregulares, ou seja, menos próximos a um círculo. Portanto, um primeiro critério seria $F_f \gg 1$ ou $F_f \ll 1$.

Neste caso, o patologista deixa de extrair outras informações que poderiam também ser importantes, ao assumir apenas um único atributo como

suficiente para caracterizar as estruturas de interesse.

Em geral, os métodos empíricos estão mais ligados ao diagnóstico e prognósticos sem auxílio computacional. Portanto, o avanço tecnológico tende a extinguir a curto prazo os métodos empíricos não objetivos e a absorver os métodos objetivos utilizando abordagens da inteligência artificial.

2.4.2 Métodos Estatísticos

Os métodos estatísticos de classificação surgiram naturalmente com a busca por métodos quantitativos na Patologia.

Os primeiros patologistas a utilizar os métodos estatísticos na classificação de imagens o fizeram empregando as ferramentas computacionais utilizadas em Epidemiologia, uma área da Medicina que utiliza a Estatística e a Cartografia para, dentre outras aplicações, estimar as regiões geográficas onde uma epidemia surge e para onde tende a se alastrar.

Em resumo, os patologistas que utilizam as ferramentas computacionais da Epidemiologia as empregam para visualizar os histogramas dos diversos atributos obtidos da imagem em análise, extraíndo-lhes a *média*, o *desvio padrão* e a *curtose*. Essas estatísticas são utilizadas para caracterizar padrões de estruturas de interesse [MB94].

Também é comum comparar-se os histogramas extraídos com os histogramas dos padrões, classificando a estrutura como pertencente àquela classe cujos histogramas dos atributos sejam mais próximos aos histogramas extraídos da estrutura de interesse [MB94].

Entretanto, as atuais ferramentas computacionais comerciais dispõem também de diversos métodos estatísticos baseados em inteligência artificial. Esses métodos procuram modelar as amostras extraídas (os vetores de atributos) por uma função densidade de probabilidade de múltiplas variáveis.

Ou seja, a função densidade de probabilidade é utilizada como *função discriminante* [DH72, SW81].

Tais métodos fazem uso da *Teoria da Decisão de Bayes* [DHS01], e são chamados de *métodos de máxima verossimilhança*, sendo o mais empregado o método da *máxima verossimilhança gaussiana* (MVG), o qual utiliza uma função densidade de probabilidade gaussiana [SW81].

Existem ainda os métodos clássicos de reconhecimento de padrões: os *classificadores lineares* [DH72, SW81]. Dentre estes, os mais conhecidos são os *classificadores lineares estatísticos*, tais como o de Fisher [DH72], os quais consistem no uso de funções discriminantes lineares cujos parâmetros são estatisticamente obtidos.

Um método que tem sido aplicado cada vez mais na análise histológica de imagens em Patologia é a *Análise Markoviana*, dada a sua eficiência em classificar texturas [MB94].

A análise markoviana extrai dos dados de treinamento matrizes de transição de probabilidade, montando um modelo de *cadeias de Markov escondidas* [DHS01]. Tal método de classificação têm sido utilizado com sucesso na discriminação de núcleos celulares e detecção de células tumorais utilizando apenas atributos microfotométricos [MB94].

A análise markoviana se mostra adequada aos casos de classificação onde as classes são difíceis de modelar com uma baixa quantidade de atributos, tais como nas aplicações de reconhecimento de fala [DHS01, San96, VKM96, NV96].

Um maior aprofundamento matemático a respeito dos métodos estatísticos de classificação citados foge ao escopo deste capítulo. Sugere-se [DHS01] como uma boa referência.

2.4.3 Métodos Não Estatísticos

Os métodos não estatísticos tem estado cada vez mais presentes nos aplicativos comerciais de análise de imagens médicas, sendo os mais utilizados os baseados em redes neurais.

O mais comum é encontrar num aplicativo comercial um classificador baseado em *rede neural de três camadas*: a *camada de entrada*, a *intermediária* (escondida) e a de *saída*.

Entretanto, modelos mais complexos, como o das *redes auto-organizáveis de Kohonen* [DHS01], também têm sido utilizados [PCB02], apesar de não serem considerados adequados para análise em Patologia, pelo menos como classificador final, pelo fato de serem baseados em *apredizado não-supervisionado*, o que praticamente desconsidera o conhecimento do especialista.

Em Patologia, assim como em outras áreas da Medicina onde são encontrados problemas de reconhecimento de padrões, as ferramentas de classificação baseadas em treinamento não-supervisionado são utilizadas apenas como um auxílio na tarefa de seleção das regiões de interesse para treinamento supervisionado, dado que, por uma questão ética, o patologista ou o biomédico nunca devem abdicar de sua responsabilidade pela tomada de decisão. Esta é a razão pela qual no presente texto se evita o termo “diagnóstico automático” e suas variantes.

Outra abordagem de classificação de bastante interesse é a *Lógica Nebulosa*. Pode-se dizer que os classificadores nebulosos ainda não têm recebido a devida atenção, pois existe uma crença de que a abordagem de *classificação por regras* não se mostra adequada à classificação de imagens. Daí ser comum utilizar-se a *Lógica Nebulosa* no meio médico apenas em sistemas de apoio ao diagnóstico por sintomas [vM97].

Porém, tal crença é baseada na observação, por vezes equivocada, feita por

alguns especialistas de que as regras nebulosas devem ser fixas, utilizando-se abordagens híbridas, tais como as neuro-nebulosas (associação de pesos às funções de pertinência), quando se deseja expandir o poder de classificação. Mesmo em textos consagrados de reconhecimento de padrões pode se encontrar tal afirmação, como em [DHS01].

Em [ddN⁺03] é proposta uma nova técnica de classificação de imagens de sensoriamento remoto utilizando Lógica Nebulosa. Logo, com algumas modificações devidas à diferente natureza da aplicação, é possível utilizar a mesma técnica em análise de imagens médicas, como será visto nos capítulos seguintes.

2.5 Conclusão

O presente capítulo apresentou um panorama geral do estado da arte da análise de imagens em Patologia, desde os métodos de classificação e extração de atributos usualmente empregados às abordagens de inteligência artificial e aplicações mais importantes da análise de imagens.

Pode-se afirmar que, apesar da existência de diversos resultados interessantes de pesquisas na área, tanto da parte da proposta de novas técnicas para classificação de imagens quanto da descoberta de importantes aplicações onde a análise de imagens facilitaria o diagnóstico e o prognóstico patológicos, existe ainda uma grande distensão entre o conhecimento gerado pela engenharia e a prática real dos patologistas, distensão esta que se deve muito mais à falta de uma linguagem comum a ambos do que às dificuldades relacionadas à adoção de novas tecnologias nos laboratórios de patologia.

Além disso, ainda existe forte resistência por parte dos profissionais de saúde em relação a um maior emprego de ferramentas computacionais no

laboratório de análises, uma vez que há uma confusão entre diagnóstico auxiliado por computador (o que é necessário) e diagnóstico automático.

O capítulo 5 trata dos problemas inerentes a cada estratégia de extração de atributos (morfometria e fotomicrometria), procurando dar exemplos da utilização correta de cada uma dessas abordagens, bem como demonstrar a necessidade de uma abordagem unificada para a extração de atributos em certos casos que uma morfometria e fotomicrometria.

No capítulo 7 é feito um estudo de caso baseado na análise fotomicrométrica de imagens de imuno-histoquímica de pulmão com DMH e expressando o antígeno CD34⁺, utilizando Lógica Nebulosa, mais especificamente funções de pertinência trapezoidais. São exibidos resultados visuais e quantitativos das classificações realizadas - como imagens classificadas e matrizes de confusão, por exemplo -, mostrando como a análise de imagens em Patologia se beneficia das técnicas de Inteligência Artificial, em particular da Lógica Nebulosa, e dos métodos objetivos e quantitativos em geral.

Capítulo 3

Introdução à Lógica Nebulosa

3.1 Introdução

A Teoria dos Conjuntos Nebulosos é uma extensão natural da Teoria dos Conjuntos, tendo sido inicialmente concebida para modelar classes definidas com imprecisão, ou seja, classes que, se modeladas como conjuntos, esses conjuntos não apresentariam fronteiras bem definidas.

Embora a necessidade de se conceituar conjuntos de fronteira indefinida tenha aparecido com frequência nos problemas de reconhecimento de padrões, somente no começo da década de 1970 é que começam a surgir os primeiros trabalhos, os quais inicialmente abordavam problemas de agrupamento (ou *clusterização*, como alguns autores assim definem) [Bez81].

Entretanto, no princípio da década de 1970 ainda não estava definida formalmente a diferença entre o conceito de *grau de pertinência* - presente na Teoria dos Conjuntos Nebulosos e servindo para expressar a idéia de *incerteza não estatística* - e o conceito de probabilidade.

Enquanto a Teoria dos Conjuntos clássica engloba a Álgebra Booleana, a Teoria dos Conjuntos Nebulosos incorpora a Lógica Nebulosa como extensão

natural da Álgebra de Boole.

A Lógica Nebulosa tem sido utilizada em inúmeras aplicações que necessitam de Inteligência Artificial, sendo uma das mais importantes o auxílio ao diagnóstico médico, dada a facilidade de definir quantitativamente conceitos que na linguagem humana expressam imprecisão, tais como “muito”, “pouco”, “razoável” etc.

Também tem tido um êxito razoável o uso da Lógica Nebulosa em processamento e análise de imagens para diversas aplicações, tais como a análise computadorizada de imagens de cromossomos [MWF⁺02] para diagnóstico de doenças genéticas (cariotipagem), a análise de imagens de ressonância magnética [YLK⁺03] e a classificação de regiões em imagens de sensoriamento remoto [ddN⁺03].

Particularmente no caso da análise de imagens de sensoriamento remoto, a Lógica Nebulosa tem demonstrado ser capaz de realizar classificação de regiões a uma performance aceitável e a um baixo custo computacional, podendo este custo ser ainda mais reduzido pela utilização de arquiteturas computacionais dedicadas [dddF03, Fdd⁺03].

3.2 Funções de Pertinência

Um conceito de fundamental importância dentro da Teoria dos Conjuntos Nebulosos é o de *função de pertinência*, chegando alguns autores a frequentemente confundi-lo com o de conjunto nebuloso.

As funções de pertinência devem sua existência à ausência de ferramentas capazes de modelar conjuntos de fronteira indefinida (ou “nebulosa”, daí o nome da teoria). Para melhor conceituá-los faz-se necessário um exemplo prático.

Considere-se o problema de selecionar pessoas cujas alturas sejam de *aproximadamente* 1,75m e pesem *mais ou menos* 74kg. Note que os termos que estão em itálico definem o caráter impreciso do problema.

Uma primeira possível solução seria definir os conjuntos H_1 e P_1 como sendo altura e peso *aceitáveis*, respectivamente. Logo, H_1 e P_1 seriam definidos como sendo, omitindo as unidades:

$$H_1 = \{x \in X : h(x) = 1,75\},$$

$$P_1 = \{x \in X : p(x) = 74\},$$

onde X é a amostra, ou seja, o conjunto de indivíduos a terem altura e peso medidos, x é um elemento da amostra (um indivíduo), $h(x)$ é a altura medida do indivíduo x e $p(x)$ o peso medido.

Note que os conjuntos H_1 e P_1 não são verdadeiras soluções do problema, pois excluem casos tais como um indivíduo x com $h(x) = 1,751$ e $p(x) = 74,003$, por exemplo. Isso porque H_1 e P_1 carecem de *tolerância*, a qual é expressa como uma necessidade dada a imprecisão explícita no problema.

Além do mais, mesmo que tal imprecisão não estivesse tão evidente, um tal problema real deveria considerar as imprecisões intrínsecas dos instrumentos de medição.

Se for considerada uma tolerância de $\pm 0,02$ para a altura e $\pm 0,5$ para o peso, ter-se-á novas possíveis soluções, H_2 e P_2 , definidas como segue:

$$H_2 = \{x \in X : 1,73 \leq h(x) \leq 1,77\},$$

$$P_2 = \{x \in X : 73,5 \leq p(x) \leq 74,5\}.$$

Entretanto, observe que ainda não faz muito sentido rejeitar o indivíduo x cujo peso seja $p(x) = 74,51$, por exemplo. É em casos assim que se faz necessário definir *funções de pertinência*.

Pode-se definir as funções de pertinência μ_H e μ_P - relacionadas respectivamente com o conjunto “altura aceitável” H e “peso aceitável” P - como sendo:

$$\mu_H(h(x)) = \begin{cases} (h(x) - 1,71)/0,02, & 1,71 \leq h(x) \leq 1,73 \\ 1, & 1,73 \leq h(x) \leq 1,77 \\ (1,79 - h(x))/0,02, & 1,77 \leq h(x) \leq 1,79 \\ 0, & \text{c.c.} \end{cases},$$

$$\mu_P(p(x)) = \begin{cases} (p(x) - 73,0)/0,5, & 73,0 \leq p(x) \leq 73,5 \\ 1, & 73,5 \leq p(x) \leq 74,5 \\ (75,0 - p(x))/0,5, & 74,5 \leq h(x) \leq 75,0 \\ 0, & \text{c.c.} \end{cases},$$

onde $\mu_H(h(x))$ e $\mu_P(p(x))$ expressam os *graus de pertinência* de $h(x)$ e de $p(x)$ aos conjuntos H e P , respectivamente. Observe que $\mu_P(p)$ e $\mu_H(h)$ são funções trapezoidais, um tipo de função bem adequado a este tipo de problema (ver figuras 3.1 e 3.2).

Portanto, o grau de pertinência $\mu_A(x)$ é um número entre 0 e 1 inclusive que expressa quantitativamente “o quanto” de x pertence ao conjunto A .

Observe que a definição de grau de pertinência é *puramente determinística*, não cabendo, portanto, confusão entre o conceito de grau de pertinência e o de probabilidade.

Porém, para muitos, o grau de pertinência é um conceito difícil de absorver. Para facilitar as coisas, pode-se utilizar o seguinte exemplo:

Se o leitor tivesse que obrigatoriamente escolher um entre dois frascos, sendo que em um dos frascos o rótulo diz “20% de chances de conter veneno” e o outro “grau de pertinência de veneno de 20%”, qual frasco escolheria?

Certamente se o leitor estivesse em tal situação hipotética indesejável, somente teria chance de escapar vivo se escolhesse o frasco com 20% de




Figura 3.1: Função de pertinência μ_H da altura h do indivíduo x ao conjunto solução das alturas aceitáveis H

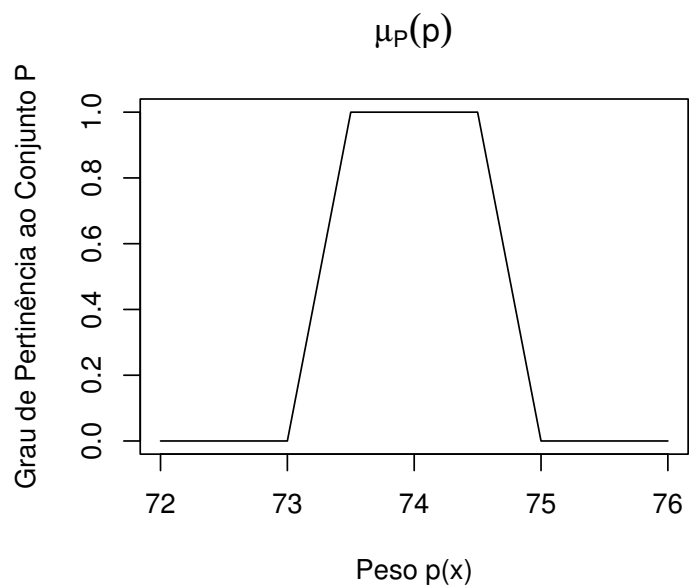


Figura 3.2: Função de pertinência μ_P do peso p do indivíduo x ao conjunto solução dos pesos aceitáveis P

chances de conter veneno, pois o outro frasco contém certamente veneno em 20% da mistura, uma vez que, como dito, grau de pertinência é uma definição determinística.

Seja A um conjunto classicamente definido. Seja Ω o conjunto universo ($A \subseteq \Omega$). A função de pertinência $\mu_A : \Omega \rightarrow [0, 1]$ é definida como sendo:

$$\mu_A(x) = \begin{cases} 1, & x \in A \\ 0, & x \notin A \end{cases} .$$

A partir da definição acima pode-se entender a Teoria dos Conjuntos Nebulosos como uma extensão da Teoria dos Conjuntos classicamente definida.

As funções de pertinência podem assumir vários formatos. Entretanto, as funções triangulares, trapezoidais, gaussianas, sigmoidais, retangulares e impulso discreto são as mais comumente empregadas.

As funções retangulares e impulso discreto são utilizadas quando os conjuntos a modelar têm fronteiras bem definidas, ou seja, não são nebulosos. Os outros formatos anteriormente citados são empregados de acordo com a distribuição dos dados.

Para os casos de conjuntos mais concentrados numa determinada região, sugere-se o emprego das funções de pertinência trapezoidais. Para casos onde os conjuntos são mais dispersos, as gaussianas são preferidas.

Entretanto, pode-se substituir uma gaussiana por uma função trapezoidal ou triangular quando se deseja um menor custo computacional e o problema em estudo assim o permite.

Contudo, tudo isto são apenas heurísticas, não consistindo um conjunto de regras exatas, mas apenas conclusões empíricas e informalmente seguidas por diversos autores, embora nem sempre citadas.

A forma de obtenção dos parâmetros que definem uma função de pertinência varia de acordo com a aplicação, não havendo, portanto, uma metodologia

formal para a montagem de tais funções, pelo simples motivo de haver forte dependência com a distribuição dos dados e a natureza do problema.

3.3 Álgebra dos Conjuntos

Sejam A, B conjuntos. Seja Ω o conjunto universo ($A, B \subseteq \Omega$). A álgebra do *conjunto potência* $P(X) \subseteq \Omega$, onde X é um conjunto qualquer e x um elemento de X , é definida em termos de operações e relações familiares como segue, onde $A, B \in P(X)$ [Bez81]:

Subconjuntos $A \subseteq B \Leftrightarrow x \in A \Rightarrow x \in B$

Igualdade $A = B \Leftrightarrow (A \subseteq B) \wedge (B \subseteq A)$

Complemento $\bar{A} = \Omega - A$

Intersecção $A \cap B = \{x \in X : (x \in A) \wedge (x \in B)\}$

União $A \cup B = \{x \in X : (x \in A) \vee (x \in B)\}$

Os símbolos \vee e \wedge denotam as operações lógicas “ou” e “e”, nesta ordem. Esta notação é muito empregada no contexto da Lógica Nebulosa, uma vez que evita o uso de termos próprios de outras línguas, substituindo as conjunções “e” e “ou” por símbolos matemáticos. Portanto, esta será também a notação empregada ao longo deste texto.

É importante notar que $P(X)$ é um conjunto de conjuntos em Ω . Ou seja, se $A \subseteq X$, então $A \in P(X)$. A quintupla de operadores primitivos apresentados é indicada por $(\subseteq, =, \bar{\cdot}, \cup, \cap)$. O conjunto vazio é indicado pelo símbolo \emptyset .

O par $(X, P(X))$ é chamado uma σ -álgebra quando segue as seguintes propriedades:

$$\emptyset \subseteq P(X), \quad (3.1)$$

$$A \in P(X) \Rightarrow \overline{A} \in P(X), \quad (3.2)$$

$$A, B \in P(X) \Rightarrow A \cup B \in P(X). \quad (3.3)$$

De (3.1), (3.2) e (3.3) são derivadas as leis de De Morgan:

$$\overline{A \cup B} = \overline{A} \cap \overline{B}, \quad (3.4)$$

$$\overline{A \cap B} = \overline{A} \cup \overline{B}, \quad (3.5)$$

para todo $A, B \in P(X)$ [Bez81]. Por indução matemática, pode-se generalizar as leis de De Morgan da forma que segue, para um número n de termos A_i tal que $n < \infty$:

$$\overline{\bigcup_{i=1}^n A_i} = \bigcap_{i=1}^n \overline{A_i}, \quad (3.6)$$

$$\overline{\bigcap_{i=1}^n A_i} = \bigcup_{i=1}^n \overline{A_i}. \quad (3.7)$$

A seção seguinte trata das definições, operações e relações da Álgebra dos Conjuntos Nebulosos, explorando o conceito de função de pertinência.

3.4 Álgebra dos Conjuntos Nebulosos

Uma vez que os conjuntos nebulosos são definidos matematicamente por funções, é de se esperar que exista o dual nebuloso das relações entre conjuntos definido para as funções de pertinência.

Seja a σ -álgebra $(X, P(X))$ definida anteriormente. Cada conjunto X é associado a uma função de pertinência $\mu_X : \Omega \rightarrow [0, 1]$. Conseqüentemente,

um conjunto $A \subseteq X$ está associado a uma função de pertinência $\mu_A : X \rightarrow [0, 1]$. Mais formalmente, tem-se:

$$X \leftrightarrow \mu_X : \Omega \rightarrow [0, 1]$$

$$A \subseteq X \Rightarrow A \leftrightarrow \mu_A : X \rightarrow [0, 1]$$

Logo, a Álgebra dos Conjuntos Nebulosos (ou simplesmente Álgebra Nebulosa) é definida de forma semelhante à da Álgebra dos Conjuntos clássica pelas seguintes relações e operações lógicas:

Subconjuntos $\mu_A \leq \mu_B \Leftrightarrow \mu_A(x) \leq \mu_B(x)$

Igualdade $\mu_A = \mu_B \Leftrightarrow \mu_A(x) = \mu_B(x)$

Complemento $\overline{\mu}_A(x) = \mu_{\overline{A}}(x) = 1 - \mu_A(x)$

Intersecção $\mu_{A \cap B}(x) = (\mu_A \wedge \mu_B)(x) := \min(\mu_A(x), \mu_B(x))$

União $\mu_{A \cup B}(x) = (\mu_A \vee \mu_B)(x) := \max(\mu_A(x), \mu_B(x))$

Na Álgebra Nebulosa também são definidos dois conjuntos importantes: **1** e **0** [Bez81]. Dada a σ -álgebra $(X, P(X))$, tem-se:

$$\mathbf{1}(x) := 1, \quad \forall x \in X,$$

$$\mathbf{0}(x) := 0, \quad \forall x \in X,$$

onde $\mathbf{1} \leftrightarrow X$ e $\mathbf{0} \leftrightarrow \emptyset$, ou seja, **1** está relacionado com o conjunto domínio da σ -álgebra e **0** com o conjunto vazio.

3.5 Uso da Lógica Nebulosa em Reconhecimento de Padrões

A Lógica Nebulosa está ligada ao Reconhecimento de Padrões (RP) desde o seu início. Na verdade, a Lógica Nebulosa foi concebida em resposta aos

problemas de RP dentro de classes imprecisamente definidas, apresentando muitas vantagens em relação a outras abordagens de computação inteligente, tais como as redes neurais e os classificadores estatísticos.

Tais vantagens vêm principalmente da facilidade oferecida pela Lógica Nebulosa para modelar classes caracterizadas por conjuntos com fronteiras mal definidas (nebulosas). Estas vantagens podem se estender também à diminuição do custo computacional e à melhora do desempenho da classificação desde que as funções de pertinência sejam adequadamente escolhidas e seus parâmetros adequadamente calculados.

Uma heurística muito utilizada no começo da década de 1980 é que as qualidades e defeitos das abordagens em Lógica Nebulosa estão entre as das abordagens estatísticas e as redes neurais [Bez81]. Porém, tal afirmação não é mais válida, pois as abordagens híbridas vem conseguindo resultados melhores em muitos casos, mostrando-se mais promissoras do que as técnicas baseadas puramente em redes neurais, estatística ou lógica nebulosa. Entretanto, tal discussão foge ao escopo deste trabalho.

3.5.1 Fundamentos Teóricos

Os classificadores baseados em Lógica Nebulosa são formados por regras do tipo “se... então”. Estes classificadores utilizam as definições clássicas de *vetor de atributos* e de *classe*, que podem ser intuitivamente definidas por meio de um exemplo: considerando a tarefa de se classificar meios de transporte terrestre urbanos, por exemplo, existiriam diversas *classes*, tais como carro, moto, trimoto, quadrimoto, caminhão etc.; cada objeto a ser classificado seria representado por um *vetor de atributos*, onde cada coordenada corresponde a um determinado *atributo* do objeto, tal como o número de rodas, o tamanho do veículo ou a quantidade de lugares, por exemplo.

Matematicamente, seja um *vetor de atributos* \mathbf{X} de dimensão m dado por $\mathbf{X} = (x_1, x_2, \dots, x_m)$. Seja Ω o *conjunto universo* das n classes existentes tal que $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$.

Cada classe ω_k é representada por uma *função discriminante* $f_k : \mathbb{R}^m \rightarrow \mathbb{R}$. Por sua vez, cada classe ω_k é definida como sendo:

$$\omega_k = A_{k1} \cap A_{k2} \cap \dots \cap A_{km}, \quad (3.8)$$

onde cada conjunto A_{kj} define a condição necessária da classe ω_k a ser satisfeita pela j -ésima dimensão x_j do padrão \mathbf{X} para que $\mathbf{X} \in \omega_k$, onde $1 \leq j \leq m$. Assim, a k -ésima classe ω_k será então definida pela seguinte regra:

$$(x_1 \in A_{k1}) \wedge (x_2 \in A_{k2}) \wedge \dots \wedge (x_m \in A_{km}) \Rightarrow \mathbf{X} \in \omega_k. \quad (3.9)$$

Ou seja, para que $\mathbf{X} \in \omega_k$, cada dimensão x_j deve satisfazer a A_{kj} . A regra pode então ser expressa de forma equivalente a 3.9 como segue:

$$\mathbf{X} \in \omega_k \Rightarrow x_j \in A_{kj}, \quad 1 \leq j \leq m \quad (3.10)$$

Como, pela Lógica Nebulosa, a cada conjunto A_{kj} está associada uma função de pertinência $\mu_{A_{kj}} : \mathbb{R} \rightarrow [0, 1]$, a qual, para simplificar a notação, será denominada simplesmente $\mu_{kj} : \mathbb{R} \rightarrow [0, 1]$, o conjunto ω_k será associado à sua função de pertinência f_k (a qual, na teoria de RP, faria o papel de função discriminante, como anteriormente foi afirmado) da forma que segue:

$$f_k(\mathbf{X}) = \bigwedge_{j=1}^m \mu_{kj}(x_j). \quad (3.11)$$

A decisão será então tomada pela regra da classe vencedora [DHS01, SW81], derivada da *Teoria da Decisão de Bayes* [DHS01]:

$$f_k(\mathbf{X}) = \bigvee_{i=1}^n f_i(\mathbf{X}) \Rightarrow \mathbf{X} \in \omega_k. \quad (3.12)$$

Obviamente, regras diferentes do tipo em (3.9) podem ser montadas, caso se opte por utilizar expressões lógicas mais complexas. Porém, o modelo apresentado em (3.9) é o mais intuitivo para a maioria dos casos em RP [ddN⁺03].

Nota-se que é possível achar relações mais simples desde que sejam encontradas semelhanças entre os subconjuntos das classes. Um exemplo seria o caso de $\mu_{uq}(x_q) \approx \mu_{vq}(x_q)$, por exemplo, o que indica que a condição A_{uq} da classe ω_u é aproximadamente a mesma q -ésima condição A_{vq} da classe ω_v . Neste caso, o desempenho da classificação poderia ser melhorado evitando a repetição dos cálculos das funções de pertinência nesta condição [AR00].

Porém, embora neste caso o classificador tenha sua performance melhorada e seu custo computacional diminuído [AR00, RSA01], o modelo se tornaria pouco genérico, o que dificultaria a geração de uma arquitetura computacional dedicada, tal como em [dddF03] e [Fdd⁺03].

Uma arquitetura computacional dedicada para a tarefa de classificação poderia ser necessária em aplicações onde fosse necessário menor tempo de execução [Fdd⁺03] ou onde não fosse adequado do ponto de vista econômico utilizar-se um computador ou qualquer outra arquitetura genérica, tais como em aparelhos médicos inteligentes ou sistemas de reconhecimento de voz.

Muitos trabalhos propõem sistemas híbridos chamados sistemas *neuro-nebulosos*, tentando combinar uma abordagem genérica a um baixo custo computacional, usando uma combinação de Lógica Nebulosa com Redes Neurais [AR00, RSA01].

Portanto, a opção entre um classificador nebuloso baseado em regras simples e um outro com um desempenho mais alto, tal como um classificador estatístico, dependerá da aplicação, optando-se pelo primeiro quando se deseja combinar baixo custo computacional e um desempenho razoável.

3.5.2 Classificação de Imagens

A *abordagem por regras* também pode ser utilizada com sucesso na classificação de imagens. [ddN⁺03] apresenta uma nova técnica para classificação de imagens de sensoriamento remoto. Contudo, tal técnica pode ser utilizada também na classificação de imagens médicas utilizando a cor como atributo.

Matematicamente, dada uma imagem $f : S \rightarrow [0, 1]^m$, ou seja uma imagem f modelada como uma função que mapeia cada posição da grade $S \subseteq \mathbb{Z}^2$ a um vetor \mathbf{X} de m dimensões (*pixel* da imagem de m bandas) cujas coordenadas estão no intervalo $[0, 1]$. Seja o conjunto Ω das n classes tal que $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$. Cada classe ω_k está associada a uma função discriminante $g_k : [0, 1]^m \rightarrow [0, 1]$ definida como:

$$g_k(\mathbf{X}) = \bigwedge_{j=1}^m \mu_{kj}(x_j), \quad 1 \leq k \leq n, \quad (3.13)$$

onde $\mathbf{X} = (x_1, x_2, \dots, x_m)$ é o vetor de atributos que corresponde a um *pixel* $u \in S$. Cada coordenada x_j de \mathbf{X} corresponde ao *nível de cinza* do *pixel* u na j -ésima banda espectral. Já as funções $\mu_{kj} : [0, 1] \rightarrow [0, 1]$ são as *funções de pertinência* da coordenada x_j à classe ω_k na j -ésima banda.

Em [ddN⁺03] as funções de pertinência $\mu_{kj} : [0, 1] \rightarrow [0, 1]$ são trapezoidais e determinadas da forma que segue:

$$\mu_{kj}(x_j) = \begin{cases} 0, & (x_j < a_{kj}) \vee (x_j > d_{kj}) \\ (x_j - a_{kj}) / (b_{kj} - a_{kj}), & a_{kj} \leq x_j < b_{kj} \\ 1, & b_{kj} \leq x_j < c_{kj} \\ (x_j - d_{kj}) / (c_{kj} - d_{kj}), & c_{kj} \leq x_j \leq d_{kj} \end{cases}. \quad (3.14)$$

Os parâmetros a_{kj} , b_{kj} , c_{kj} e d_{kj} podem ser calculados por diversos métodos. Seja $x_j^k(i) : 1 \leq i \leq N_k$ a amostra de tamanho N_k da j -ésima banda da região de interesse R_k correspondente à classe ω_k . Para o *Método do Trapézio*

Simétrico [ddN⁺03] as estatísticas de interesse são a *média amostral* \bar{u}_{kj} e o *desvio padrão amostral* s_{kj} . Assim, os parâmetros são calculados da forma que segue:

$$a_{kj} = \bar{u}_{kj} - 2s_{kj}, \quad (3.15)$$

$$b_{kj} = \bar{u}_{kj} - s_{kj}, \quad (3.16)$$

$$c_{kj} = \bar{u}_{kj} + s_{kj}, \quad (3.17)$$

$$d_{kj} = \bar{u}_{kj} + 2s_{kj}. \quad (3.18)$$

Já o *Método do Trapézio Assimétrico* (desenvolvido ao longo deste trabalho) utiliza a *moda amostral* η_{kj} , sendo os parâmetros das funções de pertinência determinados da forma que segue:

$$a_{kj} = 0, \quad (3.19)$$

$$b_{kj} = \eta_{kj}, \quad (3.20)$$

$$c_{kj} = b_{kj}, \quad (3.21)$$

$$d_{kj} = 1. \quad (3.22)$$

Na verdade, o Método do Trapézio Assimétrico forma funções de pertinência triangulares, as quais na verdade são trapézios degenerados.

Um exemplo de aplicação é a classificação da imagem na figura 3.3, a qual consiste numa amostra histológica de carcinoma de mama. Dois conjuntos foram gerados utilizando o conhecimento de um patologista para seleção das regiões de interesses: um *conjunto de treinamento* e um *conjunto de teste*.

Pode-se notar nas regiões mais escuras da figura 3.3 os núcleos celulares, onde a região onde eles estão maiores e mais concentrados (a direita) é a região afetada pelo câncer.

Na figura 3.4 tem-se o mapeamento colorido da classificação pelo Método do Trapézio Simétrico, a qual resultou numa taxa de acerto de 91,84% com




Figura 3.3: Imagem de amostra histológica de carcinoma de mama. As regiões mais escuras da imagem são os núcleos celulares, onde a região onde eles estão maiores e mais concentrados (a direita) é a região afetada pelo câncer.

um índice $\kappa \approx 0,88$. Tanto melhor é a classificação quanto mais próximo da unidade está o índice κ .

Na figura 3.5 tem-se o mapeamento colorido da classificação pelo Método do Trapézio Assimétrico, a qual resultou numa taxa de acerto de 87,89% com um índice $\kappa \approx 0,81$. Nota-se que a classificação pelo método anterior foi melhor devido ao fato do primeiro ser mais adequado a conjuntos simetricamente distribuídos, enquanto o segundo foi desenvolvido para casos com uma maior assimetria dos dados.

Nos mapeamentos coloridos das classificações resultantes, nas figuras 3.4 e 3.5, as regiões *amarelas* correspondem ao fundo da lâmina; em *vermelho* estão as *hemácias*; em *cinza*, o *tecido saudável*, enquanto que em *preto* estão




Figura 3.4: Resultado da classificação da imagem da figura 3.3 pelo Método do Trapézio Simétrico utilizando os *pixels* como vetores de atributos (ver tabela 3.1)

destacadas os *núcleos celulares* (ver tabelas 3.1 e 3.2).

Os dois métodos de avaliação de classificação mais utilizados em RP são o *índice κ* e a *matriz de confusão* (ver tabelas 3.1 e 3.2). Por esta razão serão os empregados ao longo deste trabalho.

Comparando as matrizes de confusão resultantes da classificação da imagem da figura 3.3 pelos dois métodos apresentados (tabelas 3.1 e 3.2), pode-se perceber que o Método do Trapézio Simétrico apresentou melhor classificação de hemácias (69,60% contra 46,12%) e núcleos celulares (95,90% contra 78,43%), enquanto o Método do Trapézio Assimétrico foi o que melhor reconheceu tecido normal (97,87% contra 76,07%).

Já em relação ao fundo da imagem, ambos os métodos conseguiram uma acurácia de 100%, devido ao fato dessa classe ser bastante homogênea e sua




Figura 3.5: Resultado da classificação da imagem da figura 3.3 pelo Método do Trapézio Assimétrico utilizando os *pixels* como vetores de atributos (ver tabela 3.2)

cor se diferenciar bastante das cores das outras classes de interesse.

A matriz de confusão é montada da seguinte forma: todos os elementos t_{ij} da matriz de confusão $T = [t_{ij}]_{n \times n}$ são inicialmente iguais a zero; se um vetor de atributos $\mathbf{X}(k) \in \omega_j$ tal que $1 \leq k \leq N_{\mathbf{X}}$, for classificado como pertencente à classe ω_i , considerando o universo de classes $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$, o elemento t_{ij} de T é incrementado; este processo continua até finalizar o conjunto de teste, ou seja, até $k = N_{\mathbf{X}}$ (tamanho do conjunto de teste).

Nota-se que, conseqüentemente, as colunas da matriz de confusão indicam as verdadeiras classes, enquanto que as linhas indicam as classes reconhecidas pelo classificador.

Já o índice κ é obtido a partir da matriz de confusão $T = [t_{ij}]_{n \times n}$, sendo

Tabela 3.1: Matriz de confusão da classificação visualizada na figura 3.4

(%)	FN	HM	TN	NC
FN	100,00	29,39	19,56	1,51
HM	0,00	69,60	0,00	0,00
TN	0,00	0,25	76,07	2,59
NC	0,00	0,76	4,37	95,90

FN: *Fundo (amarelo)*

HM: *Hemácias (vermelho)*

TN: *Tecido normal (cinza)*

NC: *Núcleos celulares (preto)*

Tabela 3.2: Matriz de confusão da classificação visualizada na figura 3.5

(%)	FN	HM	TN	NC
FN	100,00	53,46	0,24	14,05
HM	0,00	46,12	1,48	1,24
TN	0,00	0,25	97,87	6,28
NC	0,00	0,17	0,41	78,43

FN: *Fundo (amarelo)*

HM: *Hemácias (vermelho)*

TN: *Tecido normal (cinza)*

NC: *Núcleos celulares (preto)*

um tipo de *correlação estatística*. O índice κ é definido da seguinte forma:

$$\kappa = \frac{n \sum_{i=1}^n t_{ii} - \sum_{k=1}^n \left[\left(\sum_{i=1}^n t_{ik} \right) \left(\sum_{j=1}^n t_{kj} \right) \right]}{n^2 - \sum_{k=1}^n \left[\left(\sum_{i=1}^n t_{ik} \right) \left(\sum_{j=1}^n t_{kj} \right) \right]}. \quad (3.23)$$

Todos os resultados, desde os mapeamentos coloridos resultantes das classificações às matrizes de confusão e os índices κ , foram obtidos utilizando a biblioteca `ImageIO`, desenvolvida em `0x`, uma linguagem de programação matricial baseada na linguagem `C++`. `0x` é multi-plataforma - roda nos sistemas operacionais `Windows`, `UNIX` e `GNU/Linux` - e interpretada (utiliza um interpretador, à semelhança de outras linguagens *script*), podendo ainda ser pré-compilada para reduzir seu tempo de execução [DO01, Doo02].

A partir dos resultados expressos pelas figuras 3.4, 3.5 e pelas tabelas 3.1 e 3.2, percebe-se que a Lógica Nebulosa consiste em uma poderosa ferramenta para a classificação de imagens, podendo ser aplicada com sucesso tanto na classificação de imagens de sensoriamento remoto [ddN⁺03, Fdd⁺03] quanto na análise de imagens de Patologia, sendo esta última a ênfase deste trabalho.

3.6 Conclusão

Do que foi exposto pode-se concluir que a Lógica Nebulosa mostra ser uma interessante alternativa às outras abordagens de classificação, particularmente as abordagens estatísticas, dada a facilidade de modelar categorias imprecisamente definidas por meio de conjuntos dotados de fronteira nebulosa.

Foi visto também que a Lógica Nebulosa é na verdade uma extensão natural da Lógica Booleana e por conseguinte, a Teoria dos Conjuntos Nebulosos é uma extensão da Teoria Clássica dos Conjuntos, dotando essa última de um ferramental matemático mais poderoso e abrangente.

O capítulo 4 trata de princípios de Morfologia Matemática. São apresentados e definidos os principais e comuns operadores morfológicos. Diversos exemplos e imagens são apresentados junto a cada definição matemática, visando facilitar a compreensão dos aspectos qualitativos de cada operador.

Capítulo 4

Introdução à Morfologia

Matemática

4.1 Introdução

Apesar da importância das técnicas de processamento linear, como os filtros de convolução, têm-se constatado que o processamento linear de sinais não é eficiente para resolver certos problemas de processamento de imagens, apesar de sua grande importância na modelagem e filtragem de sinais acústicos, eletrônicos, ópticos e outros.

Esta afirmação se apóia no fato de que as ferramentas de processamento linear se baseiam na preservação das relações de soma (linearidade), e não as de inclusão. Na prática isto limita o uso do processamento linear a problemas onde não ocorrem objetos que se sobreponham a outros [Bra94], o que exige o uso de abordagens auxiliares, aumentando a complexidade da solução.

No entanto, as técnicas baseadas em Morfologia Matemática lidam naturalmente com problemas de sobreposição, pois preservam as relações de inclusão de objetos, ao invés das relações de soma [Bra94].

A Morfologia Matemática é uma teoria de processamento não linear bastante utilizada em processamento digital de imagens (PDI). Ela é baseada em transformações de forma que preservam a relação de inclusão de objetos, empregando operadores não lineares. Dentre esses operadores, os fundamentais são a *erosão* e a *dilatação*.

Além disso, a Morfologia Matemática pode ser considerada uma teoria “construtiva”, pois os demais operadores são construídos baseados na erosão e na dilatação, o que torna possível a construção de inúmeros outros operadores dedicados a funções específicas tais como filtragens e extrações de formas de interesse [Can97].

A Morfologia Matemática surgiu por volta de 1964, na *École Nationale Supérieure des Mines de Paris*, em Fontainebleau, criada por George Matheron e Jean Serra. Eles desejavam experimentar uma nova abordagem para resolver problemas de análise de imagens. Essa abordagem consistia na extração de informação de imagens a partir de transformações de formas (daí o nome *morfologia*), as quais eram realizadas por dois operadores que depois seriam batizados de *dilatação* e *erosão*.

Entre os anos de 1964 e 1968, Matheron e Serra, juntamente com o engenheiro Jean Claude Klein, resolveram transformar sua idéia em tecnologia, construindo o primeiro analisador morfológico de imagens em *hardware*: o *Texture Analyzer*, um computador com *hardware* dedicado otimizado para as operações lógicas e de dilatação e erosão para imagens binárias. Posteriormente esta tecnologia foi industrializada, tendo sido útil para a resolução de diversos problemas em análise de imagens.

Pode-se dizer que as operações fundamentais da Morfologia Matemática consistem em investigar uma imagem através de um *elemento estruturante* [Bra94]. O elemento estruturante tem a mesma importância para a Morfologia

gia Matemática que uma máscara tem para o Processamento Linear. Ele é uma imagem de dimensões menores do que as da imagem a ser aplicada a transformação morfológica. As diversas transformações morfológicas são baseadas em comparações entre o elemento estruturante e a imagem em questão.

Enquanto na filtragem linear uma máscara é utilizada para gerar “médias ponderadas” por regiões, na dilatação o elemento estruturante, que desempenha aqui papel semelhante ao da máscara na filtragem linear, é utilizado para “maximizar” regiões, gerando imagens resultantes mais claras. De forma análoga, na erosão o elemento estruturante é empregado na “minimização” de regiões, gerando imagens mais escuras. Estas operações de “minimização” e “maximização” estão relacionadas às operações de intersecção e união, o que nos remete à idéia de ter o elemento estruturante como um elemento de “encaixe” nas regiões da imagem. Assim, [Can97] faz um paralelo interessante entre estes operadores - dilatação e erosão - e o jogo de montar LEGO.

Este capítulo tem como objetivo apresentar brevemente os principais conceitos da Morfologia Matemática, bem como os conceitos básicos a ela atrelados, como o de imagem, o qual é apresentado na seção seguinte. Os operadores básicos também são apresentados.

Na penúltima seção deste capítulo é apresentada a biblioteca **MorphoMat**, implementada na linguagem de programação **Ox** e utilizada neste trabalho. Finaliza-se com a conclusão, onde são tecidos comentários a respeito do conteúdo exposto.

4.2 Conceitos Preliminares

Antes de dar prosseguimento a esta apresentação teórica da Morfologia Matemática é importante definir matematicamente uma *imagem digital*.

Uma *imagem* $f : S \rightarrow K$ é definida como sendo a função que mapeia um vetor bidimensional $u \in S$ no ponto $f(u) \in K$, onde S é a *grade* ou *suporte* da imagem, u é o *pixel* da grade S ; $f(u) \in K$ é o *valor* do *pixel* $u \in S$.

De forma mais rigorosa, [Can97] define *pixel* como sendo o par $(u, f(u))$, ou seja, o vetor formado pela sua posição u na grade S e seu valor associado $f(u)$. Já K é o conjunto dos valores possíveis de $f(u)$. Denota-se K^S o *conjunto de todas as imagens possíveis* na grade S em K [Can97].

Quando a grade S é *discreta*, isto é, $S \subseteq \mathbb{Z}^2$, diz-se que $f : S \rightarrow K$ é uma *imagem discreta*.

K é definido como sendo da forma $K = V^p$, onde $V \in \mathbb{R}$ é o *conjunto dos níveis de cinza* e $p \in \mathbb{N}^*$ é o *número de bandas* presentes na imagem f .

Assim, seja f uma imagem de p bandas $f : S \rightarrow V^p$, f pode ser denotada de forma equivalente por

$$f(u) = \{f_1(u), f_2(u), \dots, f_p(u)\}, \quad u \in S,$$

onde $f_j(u)$ é a j -ésima banda de $f : S \rightarrow V^p$, para $f_j : S \rightarrow V$ e $1 \leq j \leq p$.

Quando $p = 1$ diz-se que a imagem é uma imagem em *níveis de cinza* ou *monocromática*. Uma imagem é dita ser uma *imagem colorida* quando $p = 3$ e *multiespectral* quando $4 \leq p \leq 100$ [Lan02]. Já uma imagem é dita *hiperespectral* quando $p > 100$ [Lan02].

Uma imagem $f : S \rightarrow K$ é dita ser uma *imagem digital* quando, além de ser discreta, ela é *quantizada*, ou seja, seus *pixels* assumem apenas vetores discretos. Matematicamente, $f : S \rightarrow K$ é uma imagem digital quando $K = \{0, 1, \dots, k\}^p$ e $S \in \mathbb{Z}$, onde $p \in \mathbb{N}^*$.

Quando uma imagem digital é representada com N bits, $k = 2^N - 1$. Assim, uma imagem digital $f : S \rightarrow K$ de 8 bits tem $K = \{0, 1, \dots, 255\}^p$, enquanto que imagens digitais de 16 bits tem $K = \{0, 1, \dots, 65535\}^p$. Conseqüentemente, uma *imagem binária de banda única* $f : S \rightarrow K$ é uma imagem digital com $K = \{0, 1\}$.

Por uma questão de conveniência, é comum representar as imagens digitais como imagens discretas normalizadas, substituindo $K = \{0, 1, \dots, k\}^p$ por $\overline{K} = [0, 1]^p$. Desta forma não é preciso explicitar quantos bits são utilizados na representação dos valores possíveis dos *pixels*. Assim, uma imagem $f : S \rightarrow \{0, 1, \dots, k\}^p$ passa a ser representada por $\tilde{f} : S \rightarrow [0, 1]^p$.

É importante realçar que as imagens binárias são apenas casos particulares das imagens em níveis de cinza. Assim, uma imagem binária $f : S \rightarrow \{0, k\}^p$ passa a ser denotada utilizando a notação normalizada por $\tilde{f} : S \rightarrow \{0, 1\}^p$.

Salvo indicação em contrário, neste texto uma imagem $f : S \rightarrow K$ sempre será representada por sua versão normalizada, sendo K^S o conjunto de todas as imagens normalizadas, onde $K = [0, 1]^p$, para p bandas.

Usualmente S é uma região *retangular* de \mathbb{Z}^2 , podendo-se representar as imagens digitais em nível de cinza $f : S \rightarrow \{0, 1, \dots, k\}$ como *matrizes* [KZ95, DG87]. [DG87] representaria uma imagem $f : S \rightarrow V$ da seguinte forma, para S sendo uma grade $m \times n$ centrada em (r, s) :

$$f = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}_{(r,s)},$$

onde $a_{ij} \in V$, para $1 \leq i \leq m$ e $1 \leq j \leq n$. Isto implica dizer que, segundo

esta notação:

$$f(u) = a_{ij} \Rightarrow u = (i - r, j - s), \quad u \in S.$$

Note que, neste caso, a grade S é uma região retangular de \mathbb{Z}^2 do tipo:

$$S = \{(1 - r), (2 - r), \dots, (m - r)\} \times \{(1 - s), (2 - s), \dots, (n - s)\}.$$

Esta será a notação utilizada ao longo deste texto sempre que for conveniente representar uma imagem como uma matriz.

As operações básicas entre imagens em Morfologia Matemática são a *comparação*, a *subtração*, a *intersecção* e a *união*.

É importante afirmar que as operações básicas da Morfologia Matemática só podem ser aplicadas a imagens que mantenham uma *relação de ordem* entre os *pixels*, ou seja, que tenham bem definidas as operações de intersecção (mínimo) e união (máximo) [BB94].

Somente as imagens em níveis de cinza e as imagens binárias mantêm a relação de ordem, já que nas imagens com mais de uma banda os *pixels* são *vetores* e, portanto, já não faz mais sentido definir as operações de mínimo e máximo. No caso destas imagens é necessário trabalhar banda a banda ou supor algum artifício para manter a relação de ordem. A relação de ordem é a base da Morfologia Matemática [Can97].

Dadas duas imagens $f_1 : S \rightarrow [0, 1]$ e $f_2 : S \rightarrow [0, 1]$, a *comparação* \leq é a operação de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$ definida como segue [Can97]:

$$(f_1 \leq f_2)(u) = \begin{cases} 1, & f_1(u) \leq f_2(u) \\ 0, & c.c. \end{cases}, \quad \forall u \in S. \quad (4.1)$$

Dada uma imagem $f : S \rightarrow [0, 1]$, o *negativo* de f , denotado por \bar{f} ou $\sim f$, é o operador de $[0, 1]^S$ em $[0, 1]^S$ definido como sendo [BB94]:

$$\bar{f}(u) = 1 - f(u), \quad \forall u \in S. \quad (4.2)$$

A *união* entre $f_1 : S \rightarrow [0, 1]$ e $f_2 : S \rightarrow [0, 1]$ é o operador de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$, denotado $f_1 \vee f_2$, definido como segue [Can97]:

$$(f_1 \vee f_2)(u) = \max\{f_1(u), f_2(u)\}, \quad \forall u \in S. \quad (4.3)$$

A *intersecção* entre $f_1 : S \rightarrow [0, 1]$ e $f_2 : S \rightarrow [0, 1]$ é o operador de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$, denotado $f_1 \wedge f_2$, definido como [Can97]:

$$(f_1 \wedge f_2)(u) = \min\{f_1(u), f_2(u)\}, \quad \forall u \in S. \quad (4.4)$$

Pode-se notar que as operações de união e intersecção entre imagens se assemelham às operações de mesmo nome entre conjuntos nebulosos. A semelhança entre estas operações da Morfologia Matemática e da Lógica Nebulosa cresce com a adoção da notação de imagem normalizada, o que faz com que, de certa forma, as imagens normalizadas se assemelhem a conjuntos nebulosos.

A *subtração* ou *diferença* entre $f_1 : S \rightarrow [0, 1]$ e $f_2 : S \rightarrow [0, 1]$ é operação de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$ dada por [BB94]:

$$(f_1 \sim f_2)(u) = (f_1 \wedge \overline{f_2})(u), \quad \forall u \in S. \quad (4.5)$$

A partir destas operações é possível definir os *operadores básicos* da Morfologia Matemática: a *dilatação*, a *erosão*, o *gradiente morfológico*, a *abertura*, o *fechamento*, as *aberturas e fechamentos por reconstrução* e as *dilatações e erosões condicionais*.

4.3 Operadores Básicos da Morfologia Matemática

Pode-se dizer que a Morfologia Matemática é uma teoria *construtiva*, devido ao fato de que operadores mais complexos podem ser construídos a partir dos

mais simples. Destes, os operadores fundamentais são a *dilatação* e a *erosão*, originando-se todos os outros a partir de combinações destes.

4.3.1 Dilatação e Erosão

A *dilatação* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada $\delta_g(f)$ ou $f \oplus g$ (soma de Minkowsky, no caso binário [Can97]), é um operador de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$ definido como:

$$\delta_g(f)(u) = (f \oplus g)(u) := \bigvee_{v \in S} f(v) \wedge g(u - v), \quad \forall u \in S, \quad (4.6)$$

onde g é denominado *elemento estruturante*. Na prática, a dilatação transforma a imagem original de forma a fazer o elemento estruturante se “encaixar” na imagem, ou seja, a imagem original f será modificada de modo a fazer as áreas semelhantes a g “crescerem”, “encaixando” g (ver exemplo 4.3.1).

Exemplo 4.3.1 *Seja uma imagem f definida como segue:*

$$f = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 & 0 \end{bmatrix}, \quad (4.4)$$

e o elemento estruturante g definido como:

$$g = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \quad (2,2)$$

o resultado da dilatação de f por g será a imagem $h_1 = f \oplus g$ dada por:

$$h_1 = \begin{bmatrix} 0 & 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 & 1 & 1 & 0 \end{bmatrix}_{(4,4)} .$$

Visualmente, a dilatação resulta no *crescimento das áreas claras* e na *eliminação nas áreas escuras menores do que o elemento estruturante*, considerando o fato de que, usualmente, os *pixels* mais claros são representados por valores mais próximos de 1, enquanto os mais escuros, por valores mais próximos de 0.

A *erosão* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada $\epsilon_g(f)$ ou $f \ominus g$ (subtração de Minkowsky, no caso binário [Can97]), é um operador de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$ definido como:

$$\epsilon_g(f)(u) = (f \ominus g)(u) := \bigwedge_{v \in S} f(v) \vee \bar{g}(v - u), \quad \forall u \in S. \quad (4.7)$$

Na prática, a erosão transforma a imagem original f de modo a fazer as áreas semelhantes a g “diminuirem”, “encaixando” \bar{g} (ver exemplo 4.3.2).

Exemplo 4.3.2 Considerando a imagem f e o elemento estruturante g do

Tabela 4.1: Operações de dilatação, erosão e convolução

<i>Operação</i>	<i>Expressão</i>
Dilatação	$(f \oplus g)(u) = \bigvee_{v \in S} f(v) \wedge g(u - v)$
Erosão	$(f \ominus g)(u) = \bigwedge_{v \in S} f(v) \vee \bar{g}(v - u)$
Convolução	$(f * g)(u) = \sum_{v \in S} f(v)g(u - v)$

exemplo 4.3.1, a erosão de f por g será uma imagem $h_2 = f \ominus g$ dada por:

$$h_2 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}_{(4,4)} .$$

Visualmente, a erosão resulta no *crescimento das áreas escuras* e na *eliminação nas áreas claras menores do que o elemento estruturante*, considerando o fato de que, usualmente, os *pixels* mais claros são representados por valores mais próximos de 1, enquanto os mais escuros, mais próximos de 0.

Em [BB94] a dilatação e a erosão são mostrados esquematicamente por meio de exemplos e ilustrações, que mostram o elemento estruturante percorrendo uma imagem binária. É uma abordagem bastante ilustrativa, que dá ao leitor uma idéia de como são implementadas de forma algorítmica a dilatação e a erosão.

A tabela 4.1 mostra as expressões das operações de *dilatação*, *erosão* e *convolução*, podendo-se perceber a semelhança entre estas três operações.

Um resultado interessante pode ser obtido aplicando-se o *Teorema de De Morgan* à expressão 4.6:

$$\delta_g(f)(u) = \overline{\bigwedge_{v \in S} \bar{f}(v) \vee \bar{g}(u - v)}, \quad \forall u \in S. \quad (4.8)$$

Caso o elemento estruturante g seja *simétrico*, ou seja, $g(u) = g(-u)$, $\forall u \in S$, a expressão 4.8 torna-se:

$$\overline{\delta_g(f)}(u) = \bigwedge_{v \in S} \bar{f}(v) \vee \bar{g}(v - u), \quad \forall u \in S. \quad (4.9)$$

Da definição da erosão (ver equação 4.7) e trocando f por \bar{f} , resulta a importante relação:

$$\epsilon_g(f)(u) = \overline{\delta_g(\bar{f})}(u), \quad \forall u \in S, \quad (4.10)$$

para todo $g : S \rightarrow [0, 1]$ simétrico. Esta relação é de fundamental importância, pois expressa quantitativamente a *dualidade* entre dilatação e erosão.

Quanto às suas propriedades, a *dilatação* é uma *operação extensiva* devido ao fato de $\delta_g(f)(u) \geq f(u)$, $\forall u \in S$, enquanto que a *erosão* é uma *operação anti-extensiva*, pois $\epsilon_g(f)(u) \leq f(u)$, $\forall u \in S$ [Bra94].

A *anti-dilatação* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada por $\delta_g^a(f)$, é dada por:

$$\delta_g^a(f)(u) := \overline{\delta_g(f)}(u), \quad \forall u \in S. \quad (4.11)$$

A *anti-erosão* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada por $\epsilon_g^a(f)$, é dada por:

$$\epsilon_g^a(f)(u) := \overline{\epsilon_g(f)}(u), \quad \forall u \in S. \quad (4.12)$$

A *n-dilatação* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada por $\delta_g^n(f)$, é dada por, para $n > 1$:

$$\delta_g^n(f)(u) := \underbrace{\delta_g \delta_g \cdots \delta_g}_{n} (f)(u), \quad \forall u \in S. \quad (4.13)$$

De forma semelhante, a n -erosão de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada por $\epsilon_g^n(f)$, é dada por, para $n > 1$:

$$\epsilon_g^n(f)(u) := \underbrace{\epsilon_g \epsilon_g \cdots \epsilon_g}_n(f)(u), \quad \forall u \in S. \quad (4.14)$$

Na figura 4.1 tem-se uma imagem de amostra histológica de carcinoma de mama com os núcleos celulares afetados pelo câncer à esquerda e ao centro. Na figura 4.2 é exibida a imagem intensidade dessa amostra histológica.

Na figura 4.3 tem-se o resultado da binarização da imagem da figura 4.2. O processo de binarização consistiu, neste caso, na operação comparação da imagem $f_1 : S \rightarrow [0, 1]$ (a imagem da figura 4.2) com uma imagem $f_2 : S \rightarrow [0, 1]$ tal que $f_2(u) = \lambda$, $\forall u \in S$, onde $\lambda = 0,4$ é o *limiar*.

Na figura 4.4 tem-se o resultado da aplicação da dilatação da imagem da figura 4.2 por um elemento estruturante b , enquanto na figura 4.5 é exibida a erosão da imagem da figura 4.2 pelo mesmo elemento estruturante b , denominado *quadrado* 3×3 dado por:

$$b = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}_{(2,2)}.$$

Outro elemento estruturante importante e muito utilizado é a *cruz* 3×3 :

$$b = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{bmatrix}_{(2,2)}.$$

Nas figuras 4.6, 4.7, 4.8 e 4.9 tem-se os resultados da aplicação da anti-dilatação, da anti-erosão, da 3-dilatação e da 3-erosão, respectivamente, da imagem da figura 4.2 pelo elemento estruturante cruz 3×3 .




Figura 4.1: Imagem de amostra histológica de carcinoma de mama, estando os núcleos celulares afetados pelo câncer à esquerda e ao centro



Figura 4.2: Imagem intensidade da imagem da figura 4.1



Figura 4.3: Binarização da imagem da figura 4.2 utilizando um limiar igual a 0,4




Figura 4.4: Dilatação da imagem da figura 4.2 pelo quadrado 3×3




Figura 4.5: Erosão da imagem da figura 4.2 pelo quadrado 3×3




Figura 4.6: Anti-dilatação da imagem da figura 4.2 pela cruz 3×3




Figura 4.7: Anti-erosão da imagem da figura 4.2 pela cruz 3×3




Figura 4.8: 3-dilatação da imagem da figura 4.2 pela cruz 3×3




Figura 4.9: 3-erosão da imagem da figura 4.2 pela cruz 3×3

Em [BB94] é demonstrado que qualquer elemento estruturante de dimensões maiores que 3×3 pode ser decomposto em vários 3×3 . Isto quer dizer que uma dilatação por um elemento estruturante h de dimensões $m \times n$, tal que $m > 3$ e $n > 3$, pode ser executada por meio de um certo número de dilatações por b_k de dimensões 3×3 , onde cada b_k é um elemento estruturante que constitui h [BB94].

4.3.2 Dilatação e Erosão Condicionais

A *dilatação condicional* ou *geodésica* é um tipo de “dilatação parcial” que permite a “extração” de determinadas áreas de uma imagem f através da dilatação de um *marcador* h pelo elemento estruturante b .

Assim, a *dilatação condicional* do marcador $h : S \rightarrow \{0, 1\}$ pelo elemento estruturante $g : S \rightarrow [0, 1]$ dada a imagem $f : S \rightarrow [0, 1]$, denotada $\delta_{g,f}(h)$, é definida por [Fac96]:

$$\delta_{g,f}(h)(u) := (\delta_g(h) \wedge f)(u), \quad \forall u \in S. \quad (4.15)$$




Figura 4.10: Marcador para a dilatação condicional

Analogamente, a *erosão condicional* ou *geodésica do marcador* $h : S \rightarrow \{0, 1\}$ pelo *elemento estruturante* $g : S \rightarrow [0, 1]$ dada a imagem $f : S \rightarrow [0, 1]$, denotada $\epsilon_{g,f}(h)$, é definida por [BB94]:

$$\epsilon_{g,f}(h)(u) := (\epsilon_g(h) \vee f)(u), \quad \forall u \in S. \quad (4.16)$$

É importante realçar que o conjunto dos marcadores h é uma *imagem binária* cujas regiões com *pixels* de valor igual a 1 representam as *regiões marcadas*, no caso da *dilatação condicional*, enquanto as regiões marcadas na *erosão condicional* são representadas com 0.

Na figura 4.10 tem-se um exemplo de marcador e na figura 4.11 tem-se o resultado da dilatação condicional do referido marcador pelo elemento estruturante quadrado 3×3 dada a imagem da figura 4.2 após 10 iterações.

Nas figuras 4.12 e 4.13 tem-se o marcador e o resultado da erosão condicional, respectivamente, pelo elemento estruturante quadrado 3×3 , depois de 10 iterações, ou seja, após 10 erosões condicionais seguidas.




Figura 4.11: Resultado da dilatação condicional do marcador da figura 4.10, dada a imagem da figura 4.2, pelo elemento estruturante quadrado 3×3



Figura 4.12: Marcador para a erosão condicional




Figura 4.13: Resultado da erosão condicional do marcador da figura 4.12, dada a imagem da figura 4.2, pelo elemento estruturante quadrado 3×3

4.3.3 Gradiente Morfológico

Em muitas aplicações de processamento de imagens é desejável extrair as bordas de uma imagem, ou seja, gerar uma outra imagem composta pelos contornos dos objetos presentes na imagem original. O operador que realiza tal operação é chamado de *gradiente*.

Usualmente o conceito de gradiente está relacionado ao de derivada [KZ95]. O *gradiente morfológico* é o operador da Morfologia Matemática cuja função é extrair as bordas de uma imagem, semelhantemente ao gradiente definido no processamento linear de imagens.

Matematicamente, o *gradiente morfológico* de uma imagem $f : S \rightarrow [0, 1]$ dado um elemento estruturante $g : S \rightarrow [0, 1]$, denotado $\psi_g(f)$, é uma transformação de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$ dada por:

$$\psi_g(f)(u) := (\delta_g(f) \sim \epsilon_g(f))(u), \quad \forall u \in S. \quad (4.17)$$

Em geral escolhe-se o elemento estruturante g simétrico, para evitar de-




Figura 4.14: Resultado da aplicação do gradiente morfológico à imagem da figura 4.2 pelo elemento estruturante losango 5×5




Figura 4.15: Resultado da extração da borda externa da imagem da figura 4.2 pelo elemento estruturante losango 5×5




Figura 4.16: Resultado da extração da borda interna da imagem da figura 4.2 pelo elemento estruturante losango 5×5

formações na extração das bordas. Em [Can97] também são citadas duas transformações com efeitos visuais ao gradiente morfológico: a *borda externa* e a *borda interna*. A *borda externa*, aqui denotada por ψ_g^{ex} , é dada por:

$$\psi_g^{\text{ex}}(f)(u) := (\delta_g(f) \sim f)(u), \quad \forall u \in S. \quad (4.18)$$

A *borda interna* de $f : S \rightarrow [0, 1]$ dado o elemento estruturante $g : S \rightarrow [0, 1]$, aqui denotada ψ_g^{in} , é uma transformação de $[0, 1]^S \times [0, 1]^S$ em $[0, 1]^S$ definida como segue:

$$\psi_g^{\text{in}}(f)(u) := (f \sim \epsilon_g(f))(u), \quad \forall u \in S. \quad (4.19)$$

Nas figuras 4.14, 4.15 e 4.16 tem-se o resultado da aplicação do *gradiente morfológico*, da *borda externa* e da *borda interna* à imagem da figura 4.2 pelo elemento estruturante *losango* 5×5 , nesta ordem, onde o losango 5×5 é

definido como sendo:

$$b = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}_{(3,3)} .$$

Note que as bordas externas e internas são menos espessas que os contornos visualizados na imagem do gradiente morfológico (figura 4.14).

4.3.4 Abertura e Fechamento

Uma das aplicações mais importantes da Morfologia Matemática é a implementação de *filtros morfológicos*, os quais consistem em filtros não-lineares baseados em operações morfológicas. Os filtros morfológicos mais comuns são a *abertura*, o *fechamento*, a *n-abertura*, o *n-fechamento* e os *filtros alternados*.

Segundo [Can97], uma transformação ξ é um *filtro morfológico* se for ao mesmo tempo *idempotente* e *crescente*.

A transformação ξ é *crescente* se, dadas duas imagens $f : S \rightarrow K$ e $g : S \rightarrow K$, a seguinte condição é satisfeita [Can97]:

$$f(u) \leq g(u) \Rightarrow \xi(f)(u) \leq \xi(g)(u), \quad \forall u \in S. \quad (4.20)$$

Por sua vez, a transformação ξ é *idempotente* se [Can97]:

$$\xi\xi(f)(u) = \xi(f)(u), \quad \forall u \in S, \quad (4.21)$$

ou seja, se ξ é idempotente, a imagem f não é alterada por aplicações sucessivas da mesma transformação ξ .

O filtro morfológico de *abertura* é utilizado para “eliminar” regiões claras na imagem que não possam estar contidas no elemento estruturante. Assim,




Figura 4.17: Abertura da imagem da figura 4.2 pela quadrado 3×3

a abertura realiza na imagem uma espécie de “peneiramento” dos pontos claros. Como resultado, fazendo uma analogia entre uma imagem em níveis de cinza e um relevo topográfico, os picos (pontos de máximo ou regiões mais claras) inferiores em tamanho ao elemento estruturante são “eliminados”.

Matematicamente, a *abertura* de $f : S \rightarrow [0, 1]$ pelo elemento estruturante $g : S \rightarrow [0, 1]$, denotada $\gamma_g(f)$, é a transformação de $[0, 1]^S$ em $[0, 1]^S$ definida por [Can97]:

$$\gamma_g(f) := \delta_g \epsilon_g(f). \quad (4.22)$$

A abertura $\gamma_g(f)$ é uma transformação *anti-extensiva*, pois:

$$\gamma_g(f)(u) \leq f(u), \quad \forall u \in S. \quad (4.23)$$

Na figura 4.17 é exibida a abertura da imagem da figura 4.2 pelo quadrado 3×3 . Note a suavização da imagem e a eliminação de pequenas regiões mais claras.

O filtro morfológico de *fechamento* é utilizado para “eliminar” regiões escuras na imagem que não possam estar contidas no elemento estruturante.

Assim, o fechamento realiza na imagem uma espécie de “peneiramento” dos pontos escuros. Como resultado, novamente utilizando uma analogia entre uma imagem em níveis de cinza e um relevo topográfico, os vales (pontos de mínimo ou regiões mais escuras) inferiores em tamanho ao elemento estruturante são “eliminados”.

Matematicamente, o *fechamento* de $f : S \rightarrow [0, 1]$ pelo elemento estruturante $g : S \rightarrow [0, 1]$, denotado $\phi_g(f)$, é a transformação de $[0, 1]^S$ em $[0, 1]^S$ definida da forma que segue [Can97]:

$$\phi_g(f) := \epsilon_g \delta_g(f). \quad (4.24)$$

O fechamento $\phi_g(f)$ é uma transformação *extensiva*, pois:

$$f(u) \leq \phi_g(f)(u), \quad \forall u \in S. \quad (4.25)$$

Na figura 4.18 é exibido o fechamento da imagem da figura 4.2 pelo quadrado 3×3 . Note a suavização da imagem e a eliminação de pequenas regiões mais escuras.

A *n-abertura* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotada $\gamma_g^n(f)$, é definida da forma que segue [Can97]:

$$\gamma_g^n(f) := \delta_g^n \epsilon_g^n(f). \quad (4.26)$$

O *n-fechamento* de $f : S \rightarrow [0, 1]$ por $g : S \rightarrow [0, 1]$, denotado $\phi_g^n(f)$, é definido como segue [Can97]:

$$\phi_g^n(f) := \epsilon_g^n \delta_g^n(f). \quad (4.27)$$

Nas figuras 4.19 e 4.20 tem-se os resultados da 4-abertura e do 4-fechamento da imagem da figura 4.2, respectivamente, pelo quadrado 3×3 .

Os *filtros alternados* são do tipo $\phi\gamma$, $\gamma\phi$, $\phi\gamma\phi$ ou $\gamma\phi\gamma$ [Can97], correspondendo respectivamente às transformações $\phi_g\gamma_g(f)$, $\gamma_g\phi_g(f)$, $\phi_g\gamma_g\phi_g(f)$ e




Figura 4.18: Fechamento da imagem da figura 4.2 pelo quadrado 3×3




Figura 4.19: 4-abertura da imagem da figura 4.2 pelo quadrado 3×3




Figura 4.20: 4-fechamento da imagem da figura 4.2 pelo quadrado 3×3

$\gamma_g \phi_g \gamma_g(f)$ da imagem f dado o elemento estruturante g . A função dos filtros alternados é eliminar elementos de dimensão menor do que a do elemento estruturante.

Também são muito utilizadas as versões de filtros baseadas nas n -aberturas e nos n -fechamentos [Can97]: $n\phi\gamma$, $n\gamma\phi$, $n\phi\gamma\phi$ e $n\gamma\phi\gamma$, correspondendo respectivamente às transformações $\phi_g^n \gamma_g^n(f)$, $\gamma_g^n \phi_g^n(f)$, $\phi_g^n \gamma_g^n \phi_g^n(f)$ e $\gamma_g^n \phi_g^n \gamma_g^n(f)$ da imagem f pelo elemento estruturante g . Estes filtros são denominados genericamente por φ_g^n [Can97].

Segundo [Can97], a composição de mais de três filtros (abertura e fechamento) será igual a uma das composições de filtros de menor composição. Por exemplo:

$$\gamma_g \phi_g \gamma_g \phi_g(f) = \gamma_g \phi_g(f),$$

$$\phi_g \gamma_g \phi_g \gamma_g(f) = \phi_g \gamma_g(f).$$

Nas figuras 4.21, 4.22, 4.23 e 4.24 são exibidos os resultados da aplicação da filtragem $3\gamma\phi$, da $3\phi\gamma$, da $3\gamma\phi\gamma$ e da $3\phi\gamma\phi$, respectivamente, à imagem




Figura 4.21: Filtragem $3\gamma\phi$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3

da figura 4.2 pelo elemento estruturante quadrado 3×3 .

Ao contrário das aberturas e fechamentos usuais, as aberturas e fechamentos por reconstrução não são construídos por dilatações e erosões alternadas, como definido nas equações 4.22 e 4.24, mas são assim nomeados por seguirem certas propriedades, como será visto na próxima seção.

4.3.5 Abertura e Fechamento por Reconstrução

Em muitas aplicações de processamento de imagens deseja-se eliminar certos objetos, podendo estes serem frutos de ruídos ou simplesmente objetos que não expressam importância da extração de informação da imagem. Isto pode ser feito utilizando um filtro, o qual não precisa necessariamente ser morfológico. O problema é que a aplicação de um filtro adequado não apenas elimina os objetos desejados, mas pode afetar negativamente os elementos de interesse na imagem. Uma solução para este tipo de problema é o uso de




Figura 4.22: Filtragem $3\phi\gamma$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3




Figura 4.23: Filtragem $3\gamma\phi$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3




Figura 4.24: Filtragem $3\phi\gamma\phi$ da imagem da figura 4.2 pelo elemento estruturante quadrado 3×3

aberturas e fechamentos por reconstrução.

Matematicamente, a *abertura por reconstrução* da imagem $f : S \rightarrow [0, 1]$ pelo elemento estruturante $g : S \rightarrow [0, 1]$, dado o marcador $h : S \rightarrow \{0, 1\}$, denotada $\gamma_{g,h}(f)$, é uma transformação de $[0, 1]^S$ em $[0, 1]^S$ definida por [Can97]:

$$\gamma_{g,h}(f) := \bigvee_{k=1}^m \delta_{g,f}^k(h), \quad (4.28)$$

onde:

$$m = k \Rightarrow \delta_{g,f}^k(h)(u) = \delta_{g,f}^{k-1}(h)(u), \quad \forall u \in S$$

e $\delta_{g,f}^k(h)$ é a *k-dilatação condicional* do marcador h por g dado f definida por [BB94]:

$$\delta_{g,f}^k(h) := \underbrace{\delta_{g,f} \delta_{g,f} \cdots \delta_{g,f}}_{k \geq 1}(h). \quad (4.29)$$

Assim, a *abertura por reconstrução* $\gamma_{g,h}(f)$ é um processo *iterativo* cujo critério de parada é a dilatação condicional $\delta_{g,f}(h)$ atingir a *idempotência*.

A *abertura por reconstrução* é uma *abertura* por ser *idempotente*, *crescente* e *anti-extensiva*. Toda e qualquer transformação morfológica é considerada uma *abertura* se obedecer a estes três critérios: ser *idempotente*, *crescente* e *anti-extensiva* [Can97].

O *fechamento por reconstrução* de $f : S \rightarrow [0, 1]$ pelo elemento estruturante $g : S \rightarrow [0, 1]$, dado o marcador $h : S \rightarrow \{0, 1\}$, denotado $\phi_{g,h}(f)$, é uma transformação de $[0, 1]^S$ em $[0, 1]$ definida como segue [Can97]:

$$\phi_{g,h}(f) := \bigwedge_{k=1}^m \epsilon_{g,f}^k(h), \quad (4.30)$$

onde:

$$m = k \Rightarrow \epsilon_{g,f}^k(h)(u) = \epsilon_{g,f}^{k-1}(h)(u), \quad \forall u \in S$$

e $\epsilon_{g,f}^k(h)$ é a *k-erosão condicional* do marcador h por g dado f definida como segue [BB94]:

$$\epsilon_{g,f}^k(h) := \underbrace{\epsilon_{g,f} \epsilon_{g,f} \cdots \epsilon_{g,f}}_{k \geq 1}(h). \quad (4.31)$$

Assim, o *fechamento por reconstrução* $\phi_{g,h}(f)$ é um processo *iterativo* cujo critério de parada é a *erosão condicional* $\epsilon_{g,f}(h)$ atingir a *idempotência*.

O *fechamento por reconstrução* é um *fechamento* por ser *idempotente*, *crescente* e *extensivo*. Toda e qualquer transformação morfológica é considerada um *fechamento* se obedecer a estes três critérios: ser *idempotente*, *crescente* e *anti-extensiva* [Can97].

As *aberturas* e *fechamentos* por *reconstrução* têm a função de reconstruir as componentes conexas que possuem marcadores [Can97], sendo bastante utilizadas em aplicações como, por exemplo, a extração de elementos que tocam as bordas da imagem [BB94]. Um exemplo mais prático seria a eliminação das estruturas que tocam as bordas numa imagem de Patologia, evitando que sua presença implique num erro no diagnóstico devido à sua inclusão do cálculo das áreas das células.




Figura 4.25: Abertura por reconstrução da imagem da figura 4.3 pelo elemento estruturante quadrado 3×3 , dado o marcador mostrado na figura 4.10 e utilizando-se 150 iterações (idempotência)

Na figura 4.25 é exibido o resultado da abertura por reconstrução da imagem da figura 4.3 pelo elemento estruturante quadrado 3×3 , dado o marcador mostrado na figura 4.10. Já na figura 4.26 mostra-se o fechamento por reconstrução da imagem da figura 4.3 pelo mesmo elemento estruturante, dado o marcador mostrado na figura 4.12.

Nota-se que, tanto na abertura por reconstrução quanto no fechamento por reconstrução, as regiões não conectadas foram simplesmente suprimidas, ficando intactas as estruturas marcadas, as quais são as mesmas, pois os marcadores dos dois casos são semelhantes, sendo na verdade um o negativo do outro (comparar as imagens 4.10 e 4.12).

Os resultados foram gerados utilizando 150 iterações, para evitar utilizar-se comparações entre imagens inteiras como critério de parada e assim reduzir o custo computacional.




Figura 4.26: Fechamento por reconstrução da imagem da figura 4.3 pelo elemento estruturante quadrado 3×3 , dado o marcador mostrado na figura 4.12 e utilizando-se 150 iterações (idempotência)

4.4 Granulometria

Dentre as ferramentas da Morfologia Matemática para a descrição de tamanho e forma em análise de imagens, as *granulometrias* constituem algumas das mais poderosas.

A idéia básica de uma granulometria é realizar diversas *crivagens* (ou *peneiramentos*) seguidas de medições quantitativas dos resíduos, tais como medição de área ou perímetro. Ou seja, realiza-se um *peneiramento* da imagem original utilizando uma certa *peneira* e depois medem-se os *grãos* que passaram; em seguida, utiliza-se uma *peneira* com *furos menores* e novamente se medem os resíduos, e assim por diante. No caso, o *tamanho dos furos da peneira* é determinado pela dimensão do elemento estruturante utilizado na transformação granulométrica.

A família de transformações $\{\psi_j\}$, parametrizadas com um parâmetro

$j \geq 0$, onde $\psi_0(f)(u) = f(u)$, $\forall u \in S$, $f : S \rightarrow [0, 1]$, é chamada de uma *granulometria* se constituir um *critério de forma* [Bra94], ou seja:

$$\psi_j(f)(u) \leq f(u), \quad (4.32)$$

$$f(u) \leq g(u) \Rightarrow \psi_j(f)(u) \leq \psi_j(g)(u), \quad (4.33)$$

$$\psi_j[\psi_k(f)](u) = \psi_k[\psi_j(f)](u) = \psi_{\max(j,k)}(f)(u), \quad \forall j, k \geq 0, \quad (4.34)$$

$\forall u \in S$, onde $g : S \rightarrow [0, 1]$.

A última condição expressa a idéia intuitiva de que dois *peneiramentos* seguidos são equivalentes a um só *peneiramento* com a *peneira de buracos menores* ($\max(j, k)$), já que o índice j da transformação ψ_j expressa o rigor do *peneiramento*: quanto maior o j , mais rigoroso o *peneiramento*, ou seja, menores os *grãos* passantes.

É possível demonstrar que o conjunto de transformações morfológicas que constitui um *critério de forma* é o *conjunto das j -aberturas* por um elemento estruturante *disco digital* [Bra94]. Os discos digitais mais elementares são o quadrado 3×3 e a cruz 3×3 [Bra94]. Assim, $\{\gamma_g^j\}$ é uma *granulometria*, onde $j \geq 0$ e g é um disco digital.

Logo, uma granulometria passa a ser expressa da forma $\{\psi_j = \gamma_g^j\}$, $r \geq 0$, onde g é um disco digital [Bra94].

Analogamente, define-se uma *anti-granulometria* como sendo o conjunto dos j -fechamentos $\{\phi_g^j\}$, onde $j \geq 0$ e g é um disco digital [Bra94].

Seja uma imagem $f : S \rightarrow [0, 1]$. A função $V : \mathbb{Z}_+ \rightarrow \mathbb{R}$ é definida como sendo [Bra94]:

$$V(k) = \sum_{u \in S} \gamma_g^k(f)(u), \quad (4.35)$$

onde g é a cruz ou o quadrado 3×3 . Assim, a função $\Xi : \mathbb{Z}_+ \rightarrow [0, 1]$ é definida da forma que segue:

$$\Xi[k] = 1 - \frac{V(k)}{V(0)}, \quad k \geq 0. \quad (4.36)$$

Se considerarmos a imagem f um *conjunto aleatório* e observarmos que Ξ é uma função monotônica, crescente e limitada em $[0, 1]$, pois $V(k + 1) < V(k)$, $\forall k \geq 0$, podemos afirmar que Ξ é uma *função de distribuição acumulada discreta* associada à imagem f [Bra94]. Assim, pode-se definir uma *função densidade de probabilidade discreta* $\xi : \mathbb{Z}_+ \rightarrow \mathbb{R}_+$ por meio da diferença:

$$\xi[k] = \Xi[k + 1] - \Xi[k], \quad k \geq 0. \quad (4.37)$$

A função densidade de probabilidade definida na equação 4.37 é denominada *espectro de padrões* [Bra94]. O espectro de padrões é uma espécie de *histograma de tamanho e forma*, sendo *único* para uma imagem específica f e um determinado elemento estruturante g [Bra94].

Nas figuras 4.27 e 4.28 tem-se os gráficos da *função de distribuição acumulada discreta* $\Xi[k]$ e do *espectro de padrões* $\xi[k]$, onde $0 \leq k \leq 20$, obtidos da imagem da figura 4.2.

Uma vez que as transformações granulométricas têm a propriedade de “espalhar” informações de tamanho e forma nas imagens resíduo, muitas outras representações diferentes do histograma de padrões dos objetos de interesse podem ser geradas, desde que uma quantidade adequada de transformações seja utilizada. Como é de se esperar, o número de transformações (ou *peneiramentos*) necessário, ou seja, o maior valor de k , varia de acordo com a aplicação, pois está diretamente associado à dimensão do vetor de atributos a ser utilizado na aplicação de reconhecimento de padrões.

4.5 A Biblioteca MorphoMat

Existem diversos aplicativos de computação gráfica capazes de realizar erosões, dilatações e filtragens morfológicas, além de haver vários ambientes de

Função de distribuição acumulada




Figura 4.27: Função de distribuição acumulada discreta $\Xi[k]$ da imagem da figura 4.2 para $0 \leq k \leq 20$




Figura 4.28: Espectro de padrões $\xi[k]$ associado à imagem da figura 4.2, onde $0 \leq k \leq 20$, obtido pela derivada discreta da função de distribuição acumulada plotada no gráfico da figura 4.27

programação com implementações dos principais operadores da Morfologia Matemática, como IDL [Inc02] e MATLAB [Inc97].

Entretanto, a maioria desses ambientes de programação possui um conjunto muito limitado de ferramentas morfológicas em suas bibliotecas padrão, além de serem limitadas a imagens binárias. Existem bibliotecas mais completas em IDL e MATLAB capazes de operar com imagens em níveis de cinza, mas devem ser adquiridas a parte e custam relativamente alto.

Portanto, uma biblioteca com ferramentas da Morfologia Matemática foi desenvolvida, utilizando a linguagem interpretada `Ox`. Essa biblioteca recebeu o nome de `MorphoMat` e está disponível na Internet [dos03b]. Todos os resultados exibidos neste capítulo foram gerados utilizando a `MorphoMat`.

A biblioteca `MorphoMat` é dedicada a Morfologia Matemática para imagens binárias e em níveis de cinza, contendo os seguintes operadores:

- “E” lógico;
- “OU” lógico;
- Dilatação genérica;
- Dilatação otimizada para elementos estruturantes 3×3 ;
- Erosão genérica;
- Erosão otimizada para elementos estruturantes 3×3 ;
- n -dilatação;
- n -erosão;
- Dilatação condicional;
- Erosão condicional;

- Abertura;
- Fechamento;
- n -abertura;
- n -fechamento;
- Abertura por reconstrução;
- Fechamento por reconstrução;
- n -filtragem morfológica;
- Subtração morfológica;
- Gradiente morfológico;
- Extração da borda interna;
- Extração da borda externa;
- Geração da função de distribuição acumulada;
- Geração do espectro de padrões.

A biblioteca **MorphoMat** funciona junto com uma outra biblioteca também construída ao longo deste trabalho, a **ImageIO**, responsável por abrir e salvar imagens num formato genérico, onde as imagens são armazenadas em dois arquivos, sendo um de cabeçalho e o outro com os valores dos *pixels*. Mais detalhes podem ser obtidos da nota técnica [dos03a].

4.6 Conclusão

Do que foi exposto pode-se perceber que a Morfologia Matemática é uma abordagem bastante interessante para processamento de imagens. Além disso, a Morfologia Matemática segue uma lógica construtiva, pois a maioria das suas ferramentas são construídas utilizando combinações de erosões e dilatações, o que torna possível a geração de diversos outros operadores específicos empregando esses dois operadores básicos.

A Morfologia Matemática também pode ser utilizada com sucesso na extração de atributos em aplicações de reconhecimento de padrões, o que torna a granulometria uma abordagem bastante interessante.

Também foi visto que uma biblioteca de ferramentas da Morfologia Matemática, a **MorphoMat**, foi implementada utilizando a linguagem **Ox**, uma linguagem matricial e interpretada, dialeto da linguagem **C++**, disponível gratuitamente para fins acadêmicos e mais rápida do que muitas outras linguagens interpretadas [Doo02]. A biblioteca **MorphoMat** é livre sob a licença **LGPL** [Fou03b].

Capítulo 5

O Problema da Extração de Atributos na Classificação

5.1 Introdução

No capítulo 2 foi visto um panorama geral sobre a análise de imagens em Patologia, onde foram citados diversos métodos de análise: uns empíricos, outros mais científicos. Também foram citadas diversas estratégias de Inteligência Artificial para classificação de imagens biomédicas.

Além disso, foi visto que existem basicamente duas abordagens para extração de atributos: a morfometria e a fotomicrometria; a primeira consiste em montar vetores que representem as estruturas de interesse a partir de suas características de forma. A segunda considera estruturas caracterizadas unicamente pela cor.

Neste capítulo serão citadas as limitações de cada uma destas abordagens, bem como exemplos onde uma abordagem híbrida (ao mesmo tempo morfométrica e fotomicrométrica) poderia ser de maior utilidade clínica.

5.2 Análise Morfométrica

Como visto, a análise morfométrica se caracteriza pela extração de atributos relacionados com a forma da estrutura de interesse. Esses atributos podem ser simplesmente geométricos (*área, perímetro, fator de forma* etc.), baseados em *momentos* ou obtidos por *granulometria* (medição de área ou perímetro de cada uma das imagens obtidas por filtragem morfológica da imagem original).

Além disso, a análise morfométrica é caracterizada pela necessidade de janelamento e segmentação prévios. Pode-se dizer que tais características são os principais pontos fracos da morfometria.

O primeiro e mais complicado problema é a *segmentação*. A segmentação se faz necessária porque os atributos morfométricos são extraídos de imagens binárias, as quais são obtidas da extração da estrutura de interesse da cena.

A etapa de segmentação é um grande obstáculo à geração de algoritmos genéricos para classificação de imagens biomédicas, pois é altamente dependente da aplicação. Entretanto, isto pode ser melhorado caso sejam estudadas maneiras de permitir uma maior interatividade entre o processo de segmentação e o especialista por meio da entrada de parâmetros para auxiliar no processo.

A estratégia mais empregada nos problemas de segmentação e também a mais rudimentar é a *limiarização* por *limiar fixo*. Ela consiste na busca de um nível de cinza que permita a extração da estrutura de interesse da cena. O problema é que isso nem sempre é possível, pois existem casos em que a fronteira da estrutura de interesse não está bem definida.

Em [PeS93] é abordado o problema do diagnóstico automático da filariose a partir de imagens digitais de amostras sanquíneas. Tal diagnóstico é feito pela contagem das microfilárias. Para tanto, foi necessário segmentá-las.

O algoritmo de [PeS93] é simples e se baseia em dois limiares fixos, t_1

e t_2 . Matematicamente, o problema de segmentação e binarização consistiu em obter uma imagem $g : W \rightarrow \{0, 1\}$ a partir da janela $f_W : W \rightarrow \{0, 1, \dots, 255\}$, extraída de $f : S \rightarrow \{0, 1, \dots, 255\}$ (imagem de 8 bits), onde $W \subseteq S$, tal que:

$$g(u) = \begin{cases} 1, & t_1 \leq f_W(u) \leq t_2 \\ 0, & \text{c.c.} \end{cases},$$

onde $u \in W$.

Note que, apesar da simplicidade do critério adotado, o problema é altamente dependente dos valores de t_1 e t_2 , os quais são determinados por inspeção, sem critérios objetivos que não a análise visual. No caso de [PeS93], o problema da classificação das microfilárias, os limiares encontrados foram $t_1 = 7$ e $t_2 = 37$, para imagens de 8 bits não normalizadas.

Conseqüentemente, o uso de limiares fixos é altamente dependente da aplicação. Logo, mesmo que sejam empregados os mesmos métodos usados em [PeS93] para identificação de outras estruturas que não microfilárias em outras imagens, o biomédico ou o patologista terão que encontrar os melhores limiares para cada aplicação, o que se mostra pouco prático.

Além disso, as condições de reprodutibilidade da obtenção da imagem (iluminação, brilho etc.) devem ser garantidas, pois este método é pouco flexível, dado que usa um limiar fixo.

Em [TM02] é proposto um método de segmentação e binarização bem mais eficaz, o qual é utilizado para classificação de tecidos cancerosos. A imagem $g_1 : W \rightarrow \{0, 1, \dots, 255\}$ é obtida a partir da janela $f_W : W \rightarrow \{0, 1, \dots, 255\}$ de $f : S \rightarrow \{0, 1, \dots, 255\}$ da forma que segue:

$$g_1(u) = \rho_{k, f_W}(\gamma_k(f_W))(u),$$

onde $u \in W \subseteq S$ e k é o elemento estruturante quadrado 3×3 . $\gamma_k(f_W)$ é a abertura de f_W por k e $\rho_{k, f_W}(g)$ é a reconstrução de g por k condicional a

f_W , onde $g = \gamma_k(f_W)$. O elemento estruturante k foi escolhido para permitir a eliminação de estruturas menores que os núcleos celulares presentes em f_W .

O objetivo do método descrito anteriormente é encontrar a imagem binarizada $g_2 : W \rightarrow \{0, 255\}$. Segundo [TM02], g_1 é uma imagem onde os núcleos celulares se apresentam uniformemente escuros, se comparada a f_W . Logo, um método simples de análise do histograma permite a extração do limiar ótimo [TM02].

Apesar das qualidades apresentadas, o método de extração de atributos apresentado em [TM02] não é genérico, pois é altamente dependente da escolha do elemento estruturante k , o que pode não ser tão complicado para um engenheiro, mas não talvez não facilite muito o trabalho do patologista.

Em [MWF⁺02] é apresentado um método para segmentação de cromossomos humanos utilizando um algoritmo nebuloso iterativo. O algoritmo se baseia na montagem de uma função de pertinência para representar o centrômero. Essa função é ajustada segundo um método baseado em gradiente descendente, resultando na imagem segmentada.

Matematicamente, seja $f : S \rightarrow [0, 1]$ a imagem original normalizada e $f_W : W \rightarrow [0, 1]$ a imagem extraída de f pela janela W , onde $W \subseteq S$, a imagem segmentada $g : W \rightarrow [0, 1]$ será obtida pelo seguinte processo iterativo:

$$g^{(k+1)}(u) = g^{(k)}(u) + \Delta g^{(k)}(u),$$

onde o ajuste $\Delta g^{(k)}(u)$ é dado por:

$$\Delta g^{(k)}(u) = \begin{cases} 2\eta[h(u) * (g^{(k)}(u) - 0,5)], & 0,15 \leq g^{(k)}(u) \leq 0,90 \\ 0, & c.c. \end{cases},$$

para $u \in W$; h é uma máscara passa baixas 3×3 e η é a taxa de aprendizado. O valor inicial $g^{(0)}$ é escolhido como igual a função de pertinência μ_A associada ao conjunto A dos *pixels* que pertencem aos centrômeros presentes em f

(imagem original). No caso, $g^{(0)}$ é uma sigmóide centrada em T , onde T é o limiar estimado a partir do qual os *pixels* passam a estar contidos em centrômeros.

Apesar de apresentar resultados razoáveis para a segmentação de *centrômeros*¹, segundo um critério de validação puramente biológico (experiência de um especialista), o algoritmo de segmentação apresentado em [MWF⁺02] tem baixíssimo poder de generalização, pois as funções de pertinência que representam os centrômeros na imagem são sigmoidais com limiares obtidos do histograma da imagem, o que é basicamente uma reutilização do limiar fixo (T).

Note que o trabalho de segmentação é bastante difícil, indicando a inexistência de uma abordagem generalizada de classificação de imagens que faça uso da segmentação: cada problema necessita de uma técnica de segmentação diferente.

Outro problema é o *janelamento*. Esse também se caracteriza por ser altamente dependente da aplicação, pois o tamanho da janela W depende do tamanho da maior estrutura de interesse, o que também pode ser influenciado pela qualidade da aquisição da imagem. Nota-se que tudo isso limita a tarefa de generalização, pois existe o problema de incluir artefatos ou outras estruturas menores dentro de uma mesma janela, invalidando os atributos assim extraídos.

¹*Centrômeros* são as partes centrais dos cromossomos. Quando os cromossomos estão na fase de *metáfase* eles apresentam a forma de X . O centro do X é o *centrômero*, os quatro “membros” do X são os dois pares de *cromátidas*, unidas pelo centrômero, enquanto que as suas extremidades são os *telômeros*. A *metáfase* é uma das fases do ciclo de vida celular, sendo a terceira fase da *mitose*. A mitose corresponde ao ciclo reprodutivo da célula, quando os cromossomos começam a se duplicar para formar um novo núcleo. A mitose ocorre na regeneração celular e na reprodução [Lop02].

Uma solução para tal problema seria o uso de *aberturas e fechamentos* morfológicos. Dado que tais filtros podem eliminar objetos menores que o elemento estruturante, o analista (o patologista ou o biomédico) teria que definir os diferentes tamanhos de estruturas presentes na imagem e assim classificar a imagem “por partes”, ou seja, fazer uma classificação para cada etapa de segmentação, onde cada uma dessas etapas faz uma segmentação utilizando um elemento estruturante diferente. Nota-se a dificuldade de realização intrínseca a tal solução para o patologista.

Além disso, percebe-se que a morfometria está bastante limitada à *análise citológica*, a qual consiste basicamente na identificação e contagem de células, pois não há como caracterizar tecidos por meio de atributos geométricos, dado que, neste caso, a variação dos níveis de cinza é o tipo de informação mais importante a extrair. É por isso que a fotomicrometria é utilizada para *análise histológica* (tecidos) [MB94].

5.3 Análise Fotomicrométrica

A análise fotomicrométrica toma como atributos os componentes relacionados com a cor ou com o nível de cinza, sendo bastante utilizada em análises de imagens de imuno-histoquímica e de imuno-citoquímica.

Logo, uma conclusão óbvia é que, através da análise fotomicrométrica, não é possível diferenciar possíveis estruturas cito e histológicas morfometricamente diferentes cujos atributos de cor sejam semelhantes.

Um bom exemplo onde a análise fotomicrométrica se mostra incompleta é a *análise de macrófagos em placentas*. Tal análise necessita da extração de atributos morfométricos para uma maior eficiência do diagnóstico.

Os macrófagos (figuras 5.1, 5.2 e 5.3) são células do sistema imunológico

responsáveis pela defesa do organismo contra elementos estranhos, “fagocitando”² tais corpos estranhos e “comunicando” aos outros macrófagos informações sobre a estrutura bioquímica dos corpos estranhos. Os macrófagos estão presentes tanto nos pulmões quanto na placenta, uma vez que a última desempenha a função respiratória no feto enquanto os pulmões ainda estão imaturos.

Informações importantes podem ser extraídas a partir das características morfométricas dos macrófagos: o *tamanho*, a *quantidade de fagolisossomos*³ e a *rugosidade* da fronteira estão diretamente relacionados com a *quantidade de corpos estranhos* (intensidade do “ataque”). Quanto maior a rugosidade da fronteira, maior a quantidade de *pseudópodes*⁴ e portanto maior o número de estruturas estranhas presentes. O mesmo para o tamanho e a quantidade de fagolisossomos.

Na figuras 5.1, 5.2 e 5.3 são exibidas imagens de imuno-histoquímica de amostras da placenta com macrófagos CD68⁺.

Observe que a classificação das estruturas é bastante fácil, pois os macrófagos são bastante diferenciáveis devido à ação do anticorpo utilizado para detectar o antígeno CD68⁺. Entretanto, não é possível diferenciar os diversos “tipos” de macrófagos, pois alguns estão sendo mais atacados que outros, o que se caracteriza por maior rugosidade e tamanho.

Logo, o patologista deixa de obter importantes informações a respeito

²*Fagocitose* é o processo pelo qual uma célula se alimenta. Este processo consiste em sua primeira etapa na emissão de *pseudópodes* (falsos pés) para envolver o alimento. Assim, a célula cerca o alimento e o envolve, para depois “ingeri-lo” [Lop02]. Neste caso, o alimento em questão são os corpos estranhos.

³*Fagolisossomos* são sáculos presentes no interior dos macrófagos, responsáveis por “quebrar” e “decodificar” os corpos estranhos [Lop02].

⁴*Pseudópodes* são *falsos pés* emitidos para que a célula possa capturar o alimento, envolvendo-o por meio deles [Lop02].




Figura 5.1: Macrófagos CD68⁺ em amostra de placenta; note as diferenças entre seus tamanhos e formatos.



Figura 5.2: Macrófagos CD68⁺ em amostra de placenta; note que, apesar das diferenças de tamanho, as fronteiras são menos rugosas que as dos macrófagos da figura 5.1.



Figura 5.3: Macrófagos CD68⁺ em amostra de placenta; note o nível de deformação do macrófago ao centro.

da dinâmica do ataque dos elementos estranhos e do comportamento dos macrófagos ao realizar a defesa.

Conseqüentemente, uma abordagem que permitisse uma espécie de união entre morfometria e fotomicrometria seria desejável, desde que a extração de atributos fosse simples o suficiente a ponto de não ser necessário fazer duas análises, a morfométrica e a fotomicrométrica, o que seria a solução mais natural para problemas como o apresentado.

5.4 Conclusão

Do que foi exposto pode-se perceber que a extração de atributos por morfometria ainda tem necessidade de ser aprimorada, caso se deseje uma abordagem genérica, a qual possa ser utilizada na maioria das situações de análises histo e citológicas em Patologia.

Já a extração de atributos por fotomicrometria tem a vantagem de ser

bastante simples, pois os vetores de atributos são os próprios *pixels*. Não é necessário, portanto, nenhum tipo de segmentação, binarização ou janelamento, diferentemente das análises morfométricas.

Entretanto, a fotomicrometria está limitada à análise pela cor, podendo-se extrair mais informações de interesse caso fosse feita uma análise morfométrica junto com a fotomicrométrica. Contudo, *a utilização de dois tipos de análise diferentes traz um prejuízo à generalização.*

O capítulo 6 propõe uma tentativa de incremento da análise fotomicrométrica: a introdução de informações morfométricas por meio da geração de bandas espectrais sintéticas para melhorar a classificação de imagens utilizando apenas abordagens fotomicrométricas (o *pixel* como vetor de atributos). Isto tornaria a análise semelhante à análise de imagens multi e hiperespectrais, como as obtidas de sensores imageadores e satélites.

Ao final do capítulo 6 são apresentados a biblioteca em `0x` de classificação de imagens `ImageIO` e o ambiente de visualização e análise de imagens médicas `ANIMED`, desenvolvidos ao longo deste trabalho para implementação e teste das técnicas propostas.

Capítulo 6

Incremento da Classificação de Imagens Utilizando Geração de Bandas Sintéticas

6.1 Introdução

No capítulo 5 foram exibidos alguns problemas pertinentes às técnicas de classificação de imagens digitais de Patologia, particularmente no que se refere às abordagens em morfometria e fotomicrometria.

Neste capítulo é proposta uma técnica para incremento da classificação de imagens utilizando expansão de atributos pela geração de bandas espectrais sintéticas. Também são mostradas as ferramentas computacionais desenvolvidas ao longo deste trabalho para implementação das técnicas propostas: a biblioteca `Ox` de classificação de imagens `ImageIO` e o ambiente de análise de imagens médicas `ANIMED`.

A abordagem proposta consiste basicamente em empregar ferramentas de classificação fotomicroométricas nas imagens expandidas pelo acréscimo de

bandas sintéticas, sendo que essas bandas sintéticas conteriam uma certa quantidade de informação de forma, pois seriam obtidas através de transformações morfológicas adequadas de uma composição das bandas da imagem original.

A vantagem de se utilizar análise fotomicrométrica nessas imagens expandidas por bandas sintéticas reside no fato de que as ferramentas de classificação de imagens multi e hiperespectrais se encontram hoje muito desenvolvidas, o que traria um grande benefício para a melhoria da classificação de imagens médicas em Patologia.

6.2 Método Proposto

Seja $f : S \rightarrow [0, 1]^m$ uma imagem digital normalizada de grade $S \subseteq \mathbb{Z}^2$ e m bandas espectrais. Pode-se representar f também por meio do conjunto $\{f_1, f_2, \dots, f_m\}$, onde $f_k : S \rightarrow [0, 1]$ é a k -ésima banda de $f : S \rightarrow [0, 1]^m$. Uma nova imagem $p : S \rightarrow [0, 1]$ é obtida da forma que segue:

$$p(u) = \frac{1}{m} \sum_{k=1}^m f_k(u), \quad \forall u \in S. \quad (6.1)$$

A imagem p expressa a *intensidade* da imagem f . Pode-se obter uma nova imagem $q : S \rightarrow [0, 1]^n$ por meio de n transformações morfológicas de p segundo um elemento estruturante $g : S \rightarrow [0, 1]$, as quais serão denotadas φ_g^k , onde $1 \leq k \leq n$. Assim:

$$q_k(u) = \varphi_g^k(p)(u), \quad \forall u \in S, \quad (6.2)$$

onde $q = \{q_1, q_2, \dots, q_n\}$ e $1 \leq k \leq n$.

O método proposto consiste na geração de uma imagem $\check{f} : S \rightarrow [0, 1]^{m+n}$ a partir da imagem original $f : S \rightarrow [0, 1]^m$ utilizando o conjunto de bandas

sintéticas $q : S \rightarrow [0, 1]^n$ gerado como na equação 6.2. Assim:

$$\check{f} = \{\check{f}_1, \check{f}_2, \dots, \check{f}_{m+n}\}, \quad (6.3)$$

onde,

$$\check{f}_k(u) = \begin{cases} f_k(u), & 1 \leq k \leq m \\ q_{k-m}(u), & m+1 \leq k \leq m+n \end{cases}, \quad \forall u \in S. \quad (6.4)$$

Ou seja, $\check{f} : S \rightarrow [0, 1]^{m+n}$ é obtida pelo simples acréscimo da imagem de bandas sintéticas $q : S \rightarrow [0, 1]^n$ à imagem original $f : S \rightarrow [0, 1]^m$.

6.2.1 Extração de Atributos

Através da geração de bandas sintéticas, a imagem original f de m bandas é transformada em \check{f} com $m+n$ bandas pelo acréscimo de $n > 0$ bandas sintéticas geradas a partir de transformações morfológicas aplicadas à intensidade $p : S \rightarrow [0, 1]$ definida na expressão 6.1.

Portanto, abstraindo o sentido físico, \check{f} é na verdade uma *imagem multiespectral*. Para análise de imagens multiespectrais, os *vetores de atributos* são seus próprios *pixels* [Lan02].

Logo, para cada posição $u \in S$ está associado um vetor de atributos \mathbf{X}_u de dimensão $m+n$, tal que:

$$\mathbf{X}_u = (x_1, x_2, \dots, x_{m+n}),$$

onde $x_k = \check{f}_k(u)$, $1 \leq k \leq m+n$.

Assim, a abordagem de análise acaba por se tornar efetivamente morfométrica, tendo a vantagem de, por meio de transformações morfológicas adequadas, acrescentar à cor informação de forma. Logo, os m primeiros atributos do vetor \mathbf{X}_u trazem os níveis de cinza nas respectivas bandas espectrais, enquanto os n últimos carregam informação de forma distribuída por meio de transformações morfológicas como as aberturas, por exemplo.

6.2.2 Classificação

Uma vez que efetivamente \check{f} é uma imagem multiespectral, qualquer ferramenta matemática para classificação de imagens multiespectrais pode ser utilizada.

Na seção seguinte são apresentados alguns resultados de classificação utilizando os métodos da *Máxima Verossimilhança Gaussiana* (MVG), do *Paralelepípedo* e do *Trapézio Simétrico* - sendo este último baseado em Lógica Nebulosa não iterativa e desenvolvido ao longo deste trabalho [ddN⁺03] - para várias bandas sintéticas, procurando detectar uma relação entre a quantidade de bandas sintéticas e o crescimento ou decréscimo dos índices de avaliação de classificação (*taxa de acerto* e *coeficiente* κ), bem como a escolha entre a transformação morfológica adequada para a geração das bandas sintéticas.

6.3 Resultados

Para avaliar a validade do acréscimo de bandas sintéticas para melhoria da classificação de imagens médicas foi realizada a classificação da imagem da figura 3.3 utilizando o conjunto de treino e as classes definidas no capítulo 2. Foram experimentados três métodos, como citado anteriormente, o Método do Paralelepípedo, a MVG e o Método do Trapézio Simétrico. A avaliação foi realizada empregando-se o mesmo conjunto de teste utilizado no capítulo 2 deste texto.

Na figura 6.1 tem-se o gráfico do coeficiente κ obtido da avaliação do Método do Paralelepípedo *versus* o número de bandas sintéticas geradas fazendo $q_k(u) = \epsilon_g^k(p)(u)$, $\forall u \in S$, onde g é a cruz 3×3 , na expressão 6.2, enquanto que na figura 6.2 tem-se o gráfico da taxa de acerto para o método citados pelo número de bandas sintéticas geradas.

Tabela 6.1: Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Paralelepípedo (ver figuras 6.1 e 6.2)

#B.F.	0	1	2	3	4	5
κ	0,9656	0,9657	0,9683	0,9697	0,9673	0,9671
T.A. (%)	97,6496	97,6591	97,8384	97,9328	97,7629	97,7534
#B.F.	6	7	8	9	10	
κ	0,9666	0,9666	0,9666	0,9637	0,9636	
T.A. (%)	97,7157	97,7157	97,7157	97,5175	97,5080	

#B.F.: Número de bandas sintéticas

T.A.: Taxa de acerto

Nota-se dos dois gráficos que a classificação vai melhorando até a geração de 3 bandas sintéticas (ver também tabela 6.1); depois disso, os resultados vão piorando, estabilizando-se para 6, 7 e 8 bandas sintéticas; a partir da utilização de 9 bandas sintéticas a classificação se torna pior do que se não fosse utilizada nenhuma banda sintética.

Os gráficos das figuras 6.3 e 6.4 exibem o comportamento do coeficiente κ e da taxa de acerto, nesta ordem, em função do número de bandas sintéticas geradas, para a classificação pelo método da MVG. Novamente os melhores resultados se verificam para 3 bandas sintéticas; embora isto esteja quase imperceptível nos gráficos citados, pode ser percebido na tabela 6.2.

Já para o Método do Trapézio Simétrico, os resultados de classificação com acréscimo de bandas sintéticas pioraram, atingindo uma queda brusca a partir de nona banda sintética.

Portanto, é possível já prever que o número de bandas sintéticas a acrescentar de forma a melhorar os resultados de classificação deve ser igual ao




Figura 6.1: Gráfico do coeficiente κ obtido pela avaliação do Método do Paralelepípedo *versus* o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3




Figura 6.2: Gráfico da taxa de acerto obtida pela avaliação do Método do Paralelepípedo *versus* o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3




Figura 6.3: Gráfico do coeficiente κ obtido pela avaliação da MVG *versus* o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3




Figura 6.4: Gráfico da taxa de acerto obtida pela avaliação da MVG *versus* o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3




Figura 6.5: Gráfico do coeficiente κ obtido pela avaliação do Método do Trapézio Simétrico *versus* o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3

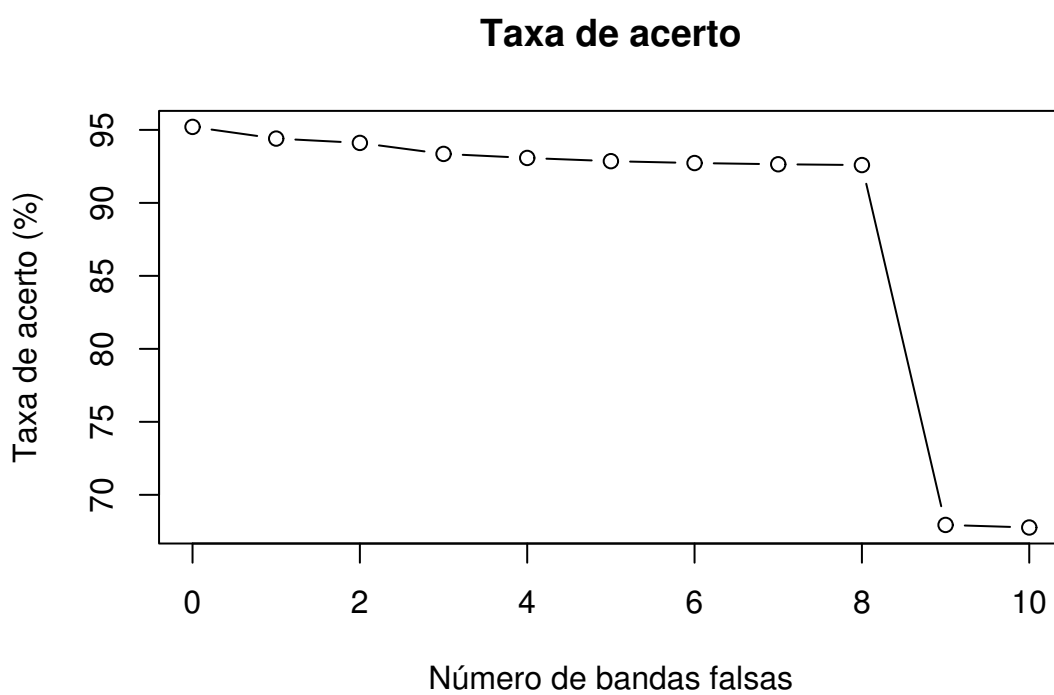


Figura 6.6: Gráfico da taxa de acerto obtida pela avaliação do Método do Trapézio Simétrico *versus* o número de bandas sintéticas geradas por meio de erosões da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3

Tabela 6.2: Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pela MVG (ver figuras 6.3 e 6.4)

#B.F.	0	1	2	3	4	5
κ	0,9965	0,9967	0,9968	0,9969	0,9969	0,9954
T.A. (%)	99,7640	99,7735	99,7846	99,7923	99,7923	99,6885
#B.F.	6	7	8	9	10	
κ	0,9951	0,9951	0,9949	0,6195	0,6194	
T.A. (%)	99,6696	99,6696	99,6507	72,9658	72,9658	

#B.F.: Número de bandas sintéticas

T.A.: Taxa de acerto

Tabela 6.3: Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Trapézio Simétrico (ver figuras 6.5 e 6.6)

#B.F.	0	1	2	3	4	5
κ	0,9279	0,9155	0,9109	0,8990	0,8947	0,8911
T.A. (%)	95,2052	94,4046	94,1101	93,5454	93,0793	92,8585
#B.F.	6	7	8	9	10	
κ	0,8892	0,8879	0,8870	0,4735	0,4702	
T.A. (%)	92,7296	92,6468	92,5916	67,9367	67,7618	

#B.F.: Número de bandas sintéticas

T.A.: Taxa de acerto

número de bandas originais da imagem quando são utilizadas erosões para geração de bandas sintéticas.

Fazendo $q_k(u) = \gamma_g^k(p)(u)$, $\forall u \in S$, onde g é a cruz 3×3 , na expressão 6.2 tem-se os resultados das avaliações das classificações nos gráficos nas figuras 6.7, 6.8 e 6.9 para os métodos do Paralelepípedo, da MVG e do Trapézio Simétrico, respectivamente.

Pode-se perceber que, neste caso, é bastante difícil estabelecer uma relação entre o número de bandas sintéticas geradas e a máxima melhora na classificação, pois a melhora na classificação da MVG só veio a acontecer na banda 8 (ver figura 6.8 e tabela 6.5), enquanto que nos métodos do Paralelepípedo e do Trapézio Simétrico a classificação apenas piorou, apesar desta piora ter sido significativamente menor do que se as bandas sintéticas tivessem sido geradas utilizando erosões (ver figuras 6.7, 6.9 e tabelas 6.4 e 6.6).

Além do mais, o emprego de aberturas traz um crescimento do custo computacional pois, para a geração de bandas sintéticas por erosões:

$$q_k(u) = \epsilon_g^k(p)(u) \Rightarrow q_k(p)(u) = \epsilon_g(q_{k-1})(u), \quad \forall u \in S,$$

$2 \leq k \leq m$, enquanto que utilizando aberturas não é possível utilizar tal recursividade, pois $q_k(u) = \gamma_g^k(p)(u) \neq \gamma_g(q_{k-1})(u)$, $\forall u \in S$. Além disso, cada k -abertura exige k erosões seguidas de k dilatações.

Portanto, considerando que uma erosão consome um tempo τ e que uma dilatação consome o mesmo tempo τ , para gerar m bandas sintéticas utilizando erosões consome-se um tempo igual a $m\tau$, enquanto utilizando aberturas consome-se um tempo igual a $m(m+1)\tau$, ou seja, um tempo $(m+1)$ vezes maior.

Logo, tanto do ponto de vista do custo computacional quanto da eficácia do método, a expansão de atributos por geração de bandas sintéticas geradas




Figura 6.7: Gráfico do coeficiente κ obtido pela avaliação do Método do Paralelepípedo *versus* o número de bandas sintéticas geradas por meio de aberturas da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3

por erosões sucessivas se mostrou mais adequada do que a geração por aberturas, embora se esperasse inicialmente o contrário, dado que as erosões não constituem granulometrias.

Outra conclusão interessante é que a simples aplicação de transformações morfológicas à uma imagem intensidade - obtida pela média das imagens das bandas originais - não acrescenta informação de forma suficiente a ponto de permitir o abandono das abordagens por janelamento, apesar de melhorar a classificação pela MVG.

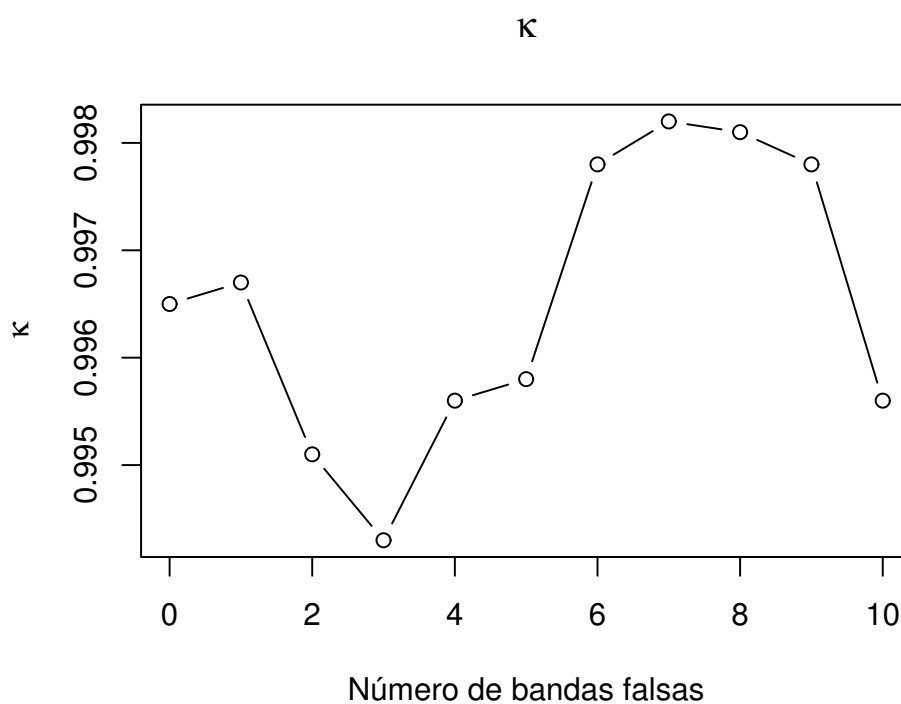


Figura 6.8: Gráfico do coeficiente κ obtido pela avaliação da MVG *versus* o número de bandas sintéticas geradas por meio de aberturas da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3




Figura 6.9: Gráfico do coeficiente κ obtido pela avaliação do Método do Trapézio Simétrico *versus* o número de bandas sintéticas geradas por meio de aberturas da imagem intensidade p , definida na expressão 6.1, utilizando o elemento estruturante cruz 3×3

Tabela 6.4: Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Paralelepípedo (ver figura 6.7)

#B.F.	0	1	2	3	4	5
κ	0,9656	0,9636	0,9383	0,9398	0,9430	0,9438
T.A. (%)	97,6496	97,5175	95,7429	95,8467	96,0638	96,1110
#B.F.	6	7	8	9	10	
κ	0,9393	0,9329	0,9265	0,9245	0,9225	
T.A. (%)	95,7901	95,3370	94,8839	94,7423	94,6007	

#B.F.: Número de bandas sintéticas

T.A.: Taxa de acerto

Tabela 6.5: Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pela MVG (ver figura 6.8)

#B.F.	0	1	2	3	4	5
κ	0,9965	0,9967	0,9951	0,9943	0,9956	0,9958
T.A. (%)	99,7640	99,7735	99,6696	99,6130	99,6979	99,7168
#B.F.	6	7	8	9	10	
κ	0,9978	0,9982	0,9981	0,9978	0,9956	
T.A. (%)	99,8490	99,8773	99,8678	99,8490	99,6979	

#B.F.: Número de bandas sintéticas

T.A.: Taxa de acerto

Tabela 6.6: Variação do coeficiente κ e da taxa de acerto com o número de bandas sintéticas para classificação pelo Método do Trapézio Simétrico (ver figura 6.9)

#B.F.	0	1	2	3	4	5
κ	0,9279	0,9272	0,9194	0,9148	0,9081	0,8990
T.A. (%)	95,2052	95,1592	94,6530	94,3585	93,9260	93,3462
#B.F.	6	7	8	9	10	
κ	0,8875	0,8852	0,8830	0,8781	0,8743	
T.A. (%)	92,6008	92,4535	92,3155	92,0026	91,7633	

#B.F.: Número de bandas sintéticas

T.A.: Taxa de acerto

6.4 A Biblioteca ImageIO

A biblioteca `ImageIO` [dos03a] foi desenvolvida ao longo deste trabalho para operações de entrada e saída com imagens (abrir e salvar arquivos) utilizando a linguagem interpretada `Ox`. `ImageIO` consiste num conjunto de duas classes: `NormImage` e `ModImage`, sendo a última descendente da primeira, contendo ainda métodos para classificação de imagens.

A classe `NormImage` é capaz de abrir e salvar imagens multi e hiperespectrais do tipo *byte* organizadas em arquivos nos formatos de armazenamento `BSQ` e `BIP`.

Considerando uma imagem $f : S \rightarrow K^p$, onde S é uma grade quadrada $m \times n$, como uma matriz tridimensional do tipo $f(x, y, z)$, onde o par $(x, y) \in S$ é a posição do *pixel* e a coordenada z , onde $0 \leq z \leq (p - 1)$, representa a banda, se f está armazenada no formato `BSQ` (Banda Seqüencial) significa que sua leitura será dada pelo código da tabela 6.7 (no caso, em `C++`).


```

for (x=0, x<m, x++) {
    for (y=0, y<n, y++) {
        for (z=0, z<p, z++) {
            fread(file,f[x][y][z]);
        }
    }
}

```

Tabela 6.7: Código C++ de leitura de uma imagem f de grade $m \times n$ e p bandas, armazenada no formato BSQ

Ou seja, cada banda é armazenada seqüencialmente. Já no formato BIP (*Band Interleave by Pixel*), cada *pixel* é armazenado seqüencialmente antes de se passar a próxima banda, como se pode ver no código C++ na tabela 6.8.

A classe `ModImage` contém um conjunto de métodos relacionados às tarefas de classificação e pós classificação de imagens multi e hiperespectrais. A classificação se dá por meio de Lógica Nebulosa não iterativa utilizando funções de pertinência trapezoidais.

Existem dois métodos da classe `ModImage` para treinamento que têm como entrada um arquivo texto com as coordenadas de regiões de interesse retangulares que compõem o conjunto de treino: `TrainingST` e `TrainingAT`. Estes dois métodos retornam os parâmetros das funções de pertinência trapezoidais como definidas no capítulo 2 deste texto.

O método `TrainingST` é a implementação do Método do Trapézio Simétrico, enquanto `TrainingAT` é uma versão desenvolvida ao longo deste trabalho para utilização de funções de pertinência trapezoidais assimétricas como definidas na seção 3.5.2.

A classificação propriamente dita é realizada utilizando o método `Classif`,

```

for (z=0, z<p, z++) {
    for (x=0, x<m, x++) {
        for (y=0, y<n, y++) {
            fread(file,f[x][y][z]);
        }
    }
}

```

Tabela 6.8: Código C++ de leitura de uma imagem f de grade $m \times n$ e p bandas, armazenada no formato BIP

o qual recebe um arquivo texto com os parâmetros das funções de pertinência trapezoidais e retorna o resultado da classificação num arquivo de imagem em banda única, contendo nas posições dos *pixels* os índices numéricos da classe correspondente.

Caso seja necessário gerar um mapeamento colorido da classificação resultante, utiliza-se o método `ThematicMap`, o qual recebe um arquivo texto com a tabela de associação do índice da classe a sua cor correspondente no mapa temático a ser gerado e retorna o mapa temático como uma imagem colorida RGB no formato BIP.

Para realizar a avaliação da classificação utiliza-se o método `PostClassif`, o qual recebe um arquivo texto contendo o conjunto de teste - estruturado da mesma forma que o arquivo contendo o conjunto de treino utilizado nos métodos de treinamento - e retorna um arquivo texto contendo as informações da imagem original, tais como o número de bandas presentes e o tamanho da imagem, e a matriz de confusão, a taxa de acerto e o coeficiente κ .

Existem ainda dois métodos para geração de bandas sintéticas: `GenNewBands` e `GenNewBandsOpen`; o primeiro utiliza erosões e o segundo, aberturas.

Os dois métodos recebem como entrada a quantidade de bandas sintéticas desejadas. A biblioteca `ImageIO` utiliza a biblioteca de funções e transformações morfológicas `MorphoMat`, descrita sucintamente no capítulo 3.

A biblioteca `ImageIO` foi utilizada para gerar todos resultados que aparecem neste capítulo. Para realizar a classificação pelos métodos da MVG e do Paralelepípedo foi utilizado o ENVI [Inc02], embora a expansão de atributos pelo acréscimo de bandas sintéticas tenha sido realizada utilizando `ImageIO`. A biblioteca `ImageIO` é livre e está disponível na Internet [dos03a]. Mais detalhes desta biblioteca podem ser encontrados na nota técnica [dos03a].

6.5 O Ambiente ANIMED

Ao longo deste trabalho foi desenvolvido um sistema de visualização e manipulação que recebeu o nome de `ANIMED`, que na verdade é um sistema para classificação de imagens médicas por fotomicrometria implementado em `Object Pascal` utilizando a versão de estudante do ambiente `DELPHI 4` [Inc96].

`ANIMED` nada mais é do que uma interface gráfica para a execução de programas desenvolvidos em `Ox` para classificação de imagens médicas que fazem uso das bibliotecas `ImageIO` e `MorphoMat`. Por meio do ambiente `ANIMED` o patologista pode classificar imagens e utilizar o resultado para auxílio ao diagnóstico sem necessitar nenhum conhecimento da linguagem `Ox`. Na figura 6.10 é exibida a tela de abertura do ambiente, enquanto na figura 6.11 é mostrado o programa propriamente dito.

Uma vez que o ambiente `ANIMED` utiliza as bibliotecas `Ox MorphoMat` e `ImageIO`, as imagens de entrada devem estar armazenadas em arquivos de dados no formato `BIP` ou `BSQ` e ser do tipo *byte*, além de terem o cabeçalho



Figura 6.10: Tela de abertura do ambiente ANIMED




Figura 6.11: Formulário principal do ambiente ANIMED

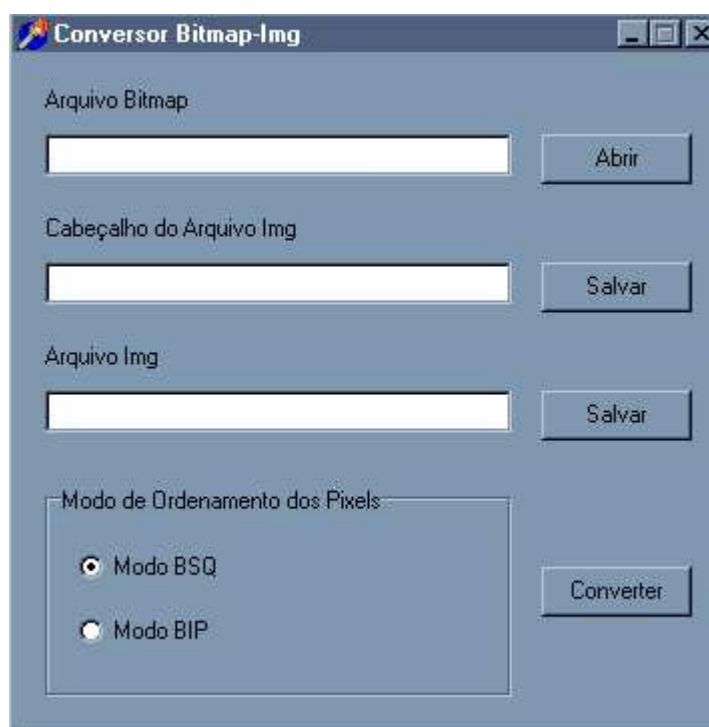


Figura 6.12: Conversor de imagens Bitmap (.bmp) para BSQ ou BIP

como o utilizado pela biblioteca `ImageIO` [dos03a]. Não há limitação de bandas para a imagem de entrada, sendo possível a análise de imagens médicas multiespectrais.

O ambiente construído também é acompanhado por um aplicativo, também construído em `Object Pascal`, que converte imagens do formato Bitmap (.bmp) para um dos formatos acima citados: `ConvBmpImg` (ver figura 6.12), devendo-se escolher os nomes do arquivo de cabeçalho e de dados.

O ambiente `ANIMED` também possibilita tanto a visualização de bandas específicas da imagem de entrada quanto a montagem de composições coloridas com 3 das bandas existentes, associando cada uma dessas 3 bandas escolhidas ao vermelho, verde ou ao azul. A seleção é visual, sendo a tela de seleção de bandas a serem visualizadas exibida na figura 6.13.

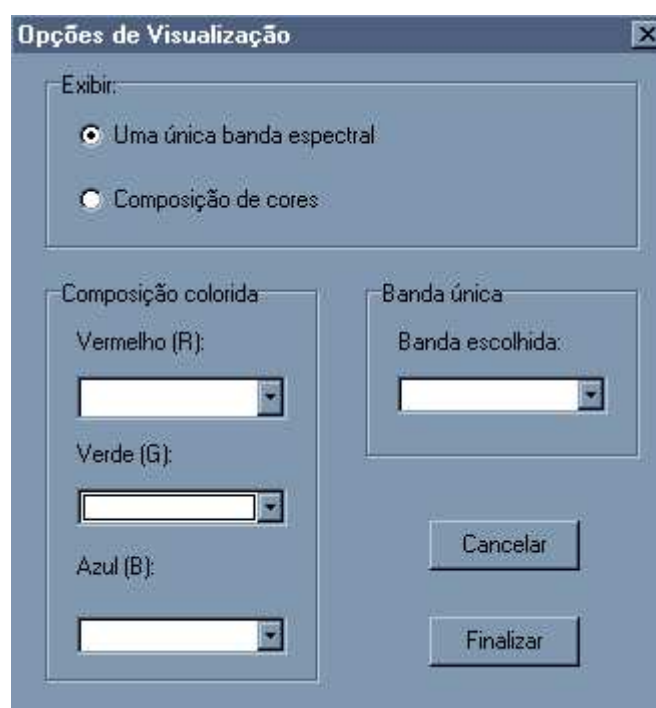


Figura 6.13: Tela de seleção de bandas a visualizar no ambiente ANIMED




Figura 6.14: Determinação do número de classes existentes na imagem no ambiente ANIMED

Por meio do ambiente construído, o patologista pode selecionar visualmente regiões de interesse na imagem e armazenar em arquivo essas regiões; mas antes de selecioná-las, o patologista deve construir uma lista de descrição de classes, definindo quantas classes existem na imagem (ver figura 6.14), o nome de cada uma delas e a cor que será associada a cada classe quando da montagem do mapa temático, sendo cada classe associada a um índice durante o processo de construção dessa lista de descrição de classes (ver figura 6.15).

Depois de ter montado a lista de descrição de classes, o patologista deve selecionar na imagem de entrada as regiões de interesse. Para isso, ele deve adicionar nova região de interesse e selecionar o índice da classe à qual a região a ser marcada pertence; no lado direito é exibida a lista de todas as classes presentes na imagem e seus respectivos índices (ver figura 6.16). Em seguida, o patologista utiliza o *mouse* para selecionar regiões de interesse retangulares. Depois deve-se salvar em arquivo as regiões de interesse.

Como exemplo de geração de regiões de interesse tem-se a imagem da figura 6.17, que corresponde às regiões de interesse selecionadas da imagem da figura 3.3. Na tabela 6.9 tem-se a lista de descrição de classes gerada pelo ANIMED.

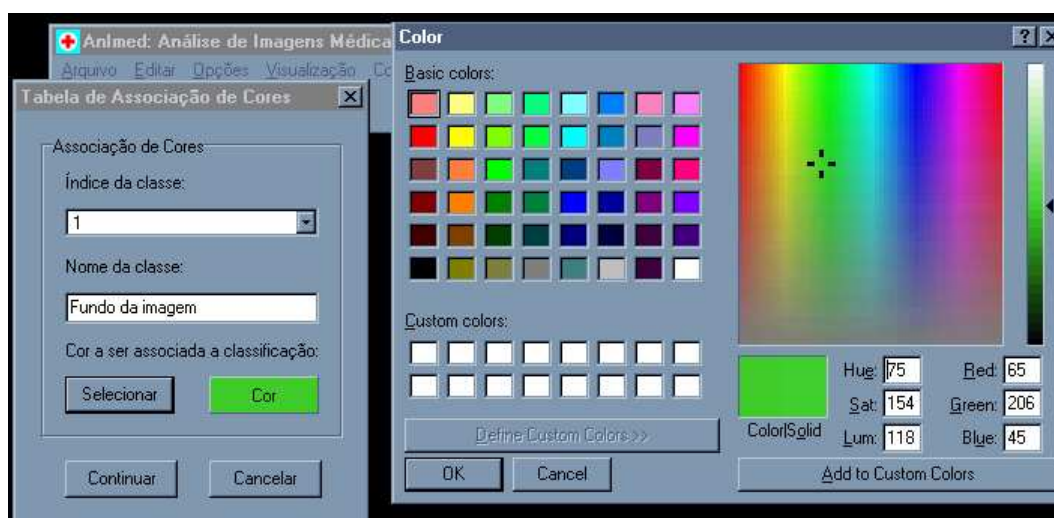


Figura 6.15: Montagem da tabela de descrição de classes e associação de cores. A direita tem-se a seleção da cor a ser associada à classe.

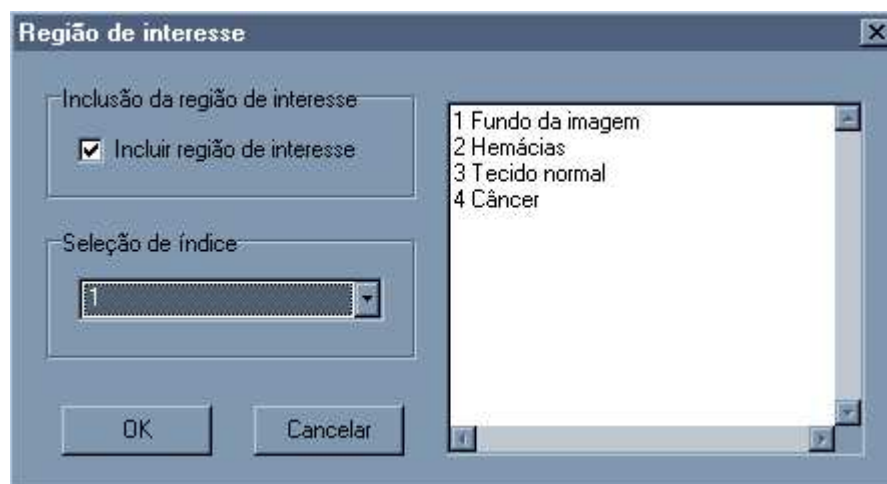


Figura 6.16: Janela para adição de região de interesse. A direita tem-se a lista das classes definidas.


```
<Index> <Color (normalized RGB)> <Class name>
1 1.000 1.000 0.000 Fundo da imagem
2 1.000 0.000 0.000 Hemácias
3 0.753 0.753 0.753 Tecido normal
4 0.251 0.000 0.251 Câncer
```

Tabela 6.9: Lista de descrição de classes gerada pelo ANIMED contendo o índice, a cor e o nome associados a cada classe. A cor está no formato RGB normalizado.




Figura 6.17: Regiões de interesse retangulares selecionadas da imagem da figura 3.3

Uma vez tendo gerado os arquivos com a lista de classes e as regiões de interesse, o patologista pode prosseguir com o trabalho de treinamento do classificador nebuloso. Para isso, o patologista deve entrar com o arquivo que contém as regiões de interesse de treinamento e com o nome do arquivo que receberá os parâmetros de classificação, que nada mais são do que os parâmetros das funções de pertinência trapezoidais como definidos no capítulo 2 deste trabalho.

O treinamento propriamente dito é feito em `0x`: os nomes dos arquivos de regiões de interesse e de parâmetros de classificação, junto com o da imagem de entrada, são utilizados para que o ANIMED gere o programa `0x` de treinamento - `TreinoTS.ox` ou `TreinoAS.ox`, dependendo do método de classificação nebulosa selecionado - o qual irá gerar os parâmetros das funções de pertinência e os armazenará no arquivo de parâmetros como arquivo texto. O programa `0x` é executado numa janela a parte no *prompt* do sistema operacional.

Caso o arquivo com as regiões de interesse já exista, não é necessário gerar a lista descrição de classes novamente. Isso permite que possa haver um maior compartilhamento de informação entre os patologistas quando do estudo de uma determinada imagem, pois aqueles mais experientes podem contribuir com regiões de interesse melhor selecionadas.

A classificação também é feita em `0x`. O patologista deve entrar com o arquivo que contém os parâmetros de classificação, com o mapa de cores - o qual contém a associação das cores aos respectivos índices das classes - e com os nomes dos arquivos que receberão a classificação e o mapa temático resultantes. A partir dessas informações e do nome do arquivo da imagem de entrada, o ANIMED gera um programa `0x` - `Classif.ox` - o qual também é executado em modo *prompt*. Dessa forma, `Classif.ox` gera o resultado da

classificação e seu mapeamento colorido.

Caso o arquivo com os parâmetros de classificação e o mapa de cores já existam, o treinamento anterior é desnecessário. Isso permite que ocorra uma “distribuição” de conhecimento conhecimento especialista, já que um patologista mais experiente pode realizar um treinamento num determinado tipo de imagem de amostra histológica submetida a um certo corante e, posteriormente, passar o arquivo com os parâmetros para ser utilizado na classificação de imagens do mesmo tipo, proporcionando não só uma maior automatização do processo, mas também a distribuição de conhecimento especialista.

Posteriormente poderia ser montado um banco de dados aberto de parâmetros de classificação otimizados para cada tipo de análise, o que facilitaria o trabalho dos patologistas, além contribuir para a melhora global do diagnóstico por imagem em Patologia.

Utilizando o ANIMED também é possível fazer uma avaliação da classificação realizada. Basta que o patologista entre com o arquivo que contém a classificação resultante, a tabela de descrição de classes e o arquivo contendo as regiões de interesse de teste; deve-se entrar também com o nome do arquivo texto que receberá o resultado da pós-classificação. O ANIMED então cria o programa `Ox PostClassif.ox`, o qual utiliza os arquivos citados e o nome do arquivo da imagem de entrada para gerar a matriz de confusão e o índice κ , armazenando-os, juntamente com o tamanho e o número de bandas da imagem, em arquivo texto. A execução do programa também é via *prompt*. Terminada a pós-classificação, o resultado é exibido numa janela, juntamente com a tabela de descrição de classes (ver figura 6.18).

Dessa forma é possível que o patologista possa avaliar a acurácia da classificação por ele realizada ou mesmo cruzar diagnósticos, utilizando na pós-classificação regiões de interesse selecionadas por outro patologista. Assim,

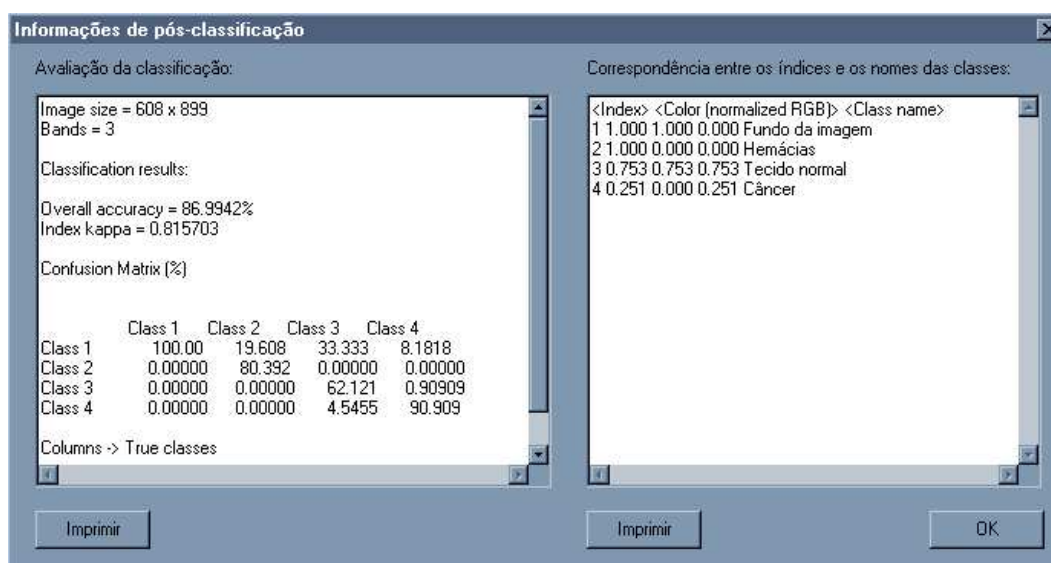


Figura 6.18: Janela com o resultado da pós-classificação no ANIMED

a dúvida em um diagnóstico é cada vez mais minimizada e o trabalho do patologista passa a ser também mais coletivo, o que beneficia a qualidade dos diagnósticos.

6.6 Conclusão

Dentre as duas propostas de métodos para geração de bandas sintéticas - geração por erosões e por aberturas -, a que utiliza geração por erosões se mostrou a mais adequada, embora as erosões não constituam granulometrias.

Além disso, a geração de bandas sintéticas se mostrou particularmente eficaz no incremento da classificação pela Máxima Verossimilhança Gaussiana, podendo ser uma alternativa interessante quando os atributos mais importantes das regiões a serem classificadas são relacionados à cor e se deseja pelo menos um mínimo de informação em relação à forma e à textura.

Foi visto que foi construída uma biblioteca $0x$ de classificação de imagens

utilizando Lógica Nebulosa: `ImageIO`, a qual é livre sob a licença LGPL [Fou03b].

Foi também construído o ambiente de análise de imagens por Lógica Nebulosa `ANIMED`, uma GUI (Interface Gráfica para o Usuário) construída em `Object Pascal` que utiliza a biblioteca `ImageIO`. O `ANIMED` foi construído para ser utilizado no auxílio ao diagnóstico por imagem em Patologia, particularmente na análise de imagens de lâminas, podendo trazer benefícios que englobam desde o auxílio na automação do processo de diagnóstico quanto na distribuição de conhecimento em Patologia. O `ANIMED` é livre sob a licença GPL [Fou03a].

O capítulo 7 mostra um estudo de caso que trata do uso da análise de imagens por Lógica Nebulosa no auxílio ao diagnóstico da doença da membrana hialina utilizando as técnicas de classificação propostas e as ferramentas desenvolvidas ao longo deste trabalho para classificação de imagens de amostras histológicas de imuno-histoquímica de pulmão.

Capítulo 7

Estudo de Caso: Apoio ao Diagnóstico da Doença da Membrana Hialina

7.1 Introdução

A análise de imagens vem tomando uma importância cada vez maior nos diversos ramos da Medicina. Cada vez mais aumenta a diversidade de ferramentas tecnológicas disponíveis para análise, prognóstico e diagnóstico por imagem. Novas tecnologias surgem. Métodos antigos são aperfeiçoados. Multiplicam-se os esforços para reduzir o empirismo e trazer cada vez mais métodos de análise objetivos e quantitativos, reduzindo o caráter subjetivo dos diagnósticos. Entretanto, é na Patologia que se encontra a maior necessidade de métodos objetivos para diagnóstico [MB94].

Freqüentemente o patologista necessita quantificar a informação visual extraída da análise das imagens das lâminas obtidas por microscopia óptica, bem como separar adequadamente os diferentes tipos de informação. Assim,

a classificação e análise digital de imagens se torna uma importante ferramenta no auxílio e no conseqüente incremento do diagnóstico por imagem.

Em [dSBCR99] afirma-se que a combinação da imuno-histoquímica com a análise digital de imagens consiste um método útil na elucidação de eventos patológicos, uma vez que permite gerar tanto informação qualitativa (mapa temático resultante da classificação) quanto quantitativa (índices de avaliação da classificação e matrizes de confusão).

A classificação de imagens por Lógica Nebulosa utilizando o Método do Trapézio Simétrico e o Método do Trapézio Assimétrico (ver seção 3.5.2) mostra ser uma ferramenta adequada para a análise de imagens de imuno-histoquímica, pois combinam informação de cor e de textura nas funções de pertinência, além de apresentarem um desempenho razoável e um custo computacional relativamente baixo, devido à simplicidade das operações matemáticas envolvidas.

Este capítulo apresenta um estudo de caso de aplicação da análise de imagens de Patologia por Lógica Nebulosa no auxílio ao diagnóstico da doença da membrana hialina utilizando análise de imagens histológicas do pulmão, utilizando-se nas análises o ambiente ANIMED.

7.2 A Doença da Membrana Hialina (DMH)

A doença da membrana hialina (DMH), também chamada de síndrome do desconforto respiratório, é um dos problemas mais comuns dos bebês prematuros. Ela pode fazer com que os bebês necessitem de oxigênio extra ou ajuda na respiração. O rumo que a DMH pode tomar depende do tamanho e da idade gestacional do bebê, do grau de avanço da doença, da presença de infecção, se o bebê possui problemas de coração ou se ele necessita de

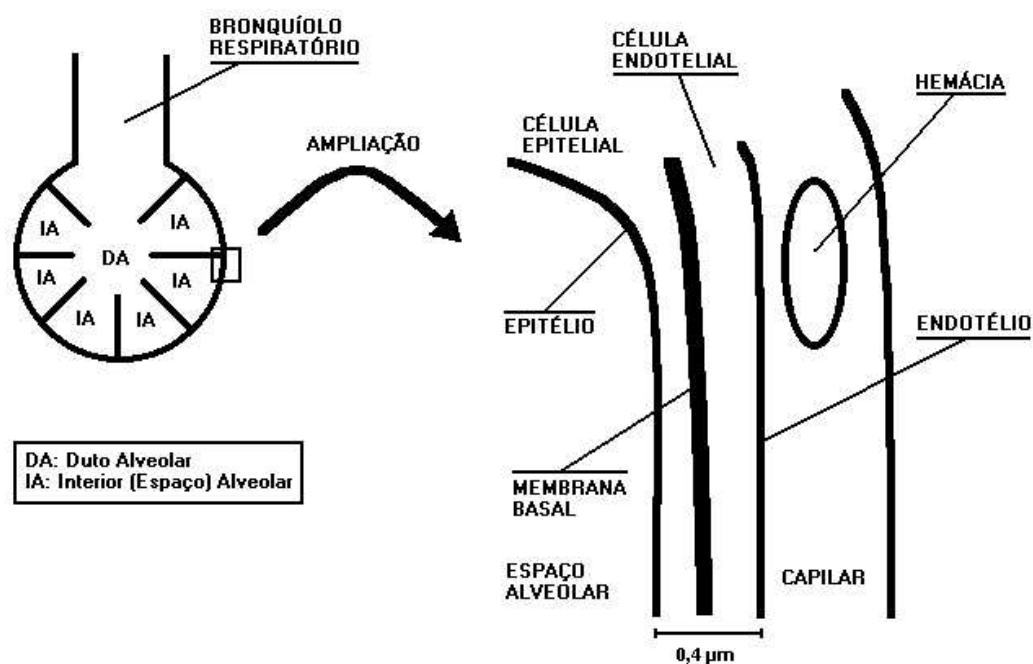


Figura 7.1: Alvéolo e, a sua direita, estruturas relacionadas em ampliação (baseado em [Hen00])

ajuda mecânica para respirar [RAK86]. A DMH tipicamente piora durante as primeiras 48-72 horas, melhorando então com o tratamento [RAK86].

A DMH ocorre quando não existe uma substância chamada *surfactante* em quantidade suficiente nos pulmões. O surfactante é produzido por células, chamadas *pneumócitos*, nas vias aéreas e é composto por fosfolipídios e proteína. Ele começa a ser produzido no feto nas primeiras 24 ou 28 semanas de gravidez. Por volta de 35 semanas de gestação a maioria dos bebês já desenvolveu uma quantidade adequada de surfactante [RAK86].

Nos pulmões, a respiração é efetivamente realizada pelos sacos aéreos, também chamados de *alvéolos* (ver figura 7.1). O surfactante é lançado nos tecidos pulmonares. Sua função é reduzir a tensão superficial nos alvéolos,




Figura 7.2: Imagem de amostra histológica de pulmão com DMH, destacando a membrana hialina e os espaços alveolares

mantendo-os sempre abertos. Obviamente, quando da expiração, os alvéolos reduzem o seu volume, mas o surfactante evita que suas paredes se toquem, pois se isso acontecer o alvéolo entrará em colapso, fechando-se [Hen00].

A DMH se origina da produção insuficiente de surfactante por pneumócitos imaturos [RAK86]. Assim, a cada inspiração realizada pelo bebê, alguns alvéolos colapsam, gerando uma dificuldade cada vez maior na respiração. Ao mesmo tempo, cada vez que um alvéolo colapsa, células endoteliais, epiteliais e a membrana basal são danificados (ver figura 7.1), causando um vazamento de fluido do exterior do alvéolo para o seu interior (espaços aéreos). Esse fluido se acumula e forma no interior do alvéolo uma membrana, a *mem-*

brana hialina (ver figura 7.2), que recebe esse nome por sua tonalidade rósea (*hialino* significa *cor de rosa* [RAK86]).

Os sintomas da DMH são dificuldade respiratória progressiva, respiração difícil e acelerada, cansaço, retrações bruscas ao respirar e pele azulada.

O diagnóstico da DMH pode ser feito observando os sintomas externos citados anteriormente e fazendo testes para medir as taxas de oxigênio, dióxido de carbono e surfactante ou tirando a radiografia dos pulmões.

O tratamento consiste na aplicação de surfactante artificial, de medicamentos e no uso de respiradores mecânicos.

7.3 Motivação do Estudo de Caso

Os bebês mais propensos a terem DMH são bebês prematuros que geralmente são filhos de mães diabéticas, nascidos de cesariana, nascidos de parto múltiplo (gêmeos), filhos de mães que já tiveram bebês com DMH, bebês que tiveram asfixia ou infecção pré-natais. Muito provavelmente existe uma relação entre essas variáveis e outras a serem obtidas pela análise de imagens de amostras histológicas de DMH [dSBCR99].

A medida em que a função respiratória do pulmão do bebê se deteriora, menos oxigênio é inspirado e mais dióxido de carbono é trazido pelo sangue. Isso aumenta a acidez do sangue, afetando outros órgãos [RAK86]. Assim, existe uma correlação entre o estado de avanço da DMH e o deterioramento do funcionamento de outros órgãos.

Poucos trabalhos se dedicaram ao estudo dessas correlações, e a maioria dos poucos que o fizeram não utilizaram análise digital de imagens de lâminas de imuno-histoquímica na extração de informação da DMH [dSBCR99].

Em [dSB02] faz-se um estudo a respeito da correlação entre macrófagos da

placenta e a maturidade dos pulmões utilizando, além das técnicas clássicas de Patologia, análise digital de imagens, morfologia matemática e métodos estatísticos de classificação.

Embora o estabelecimento de tais correlações esteja fora do escopo deste trabalho, a existência desse problema motiva o emprego da análise e classificação de imagens digitais de lâminas de imuno-histoquímica do pulmão e da placenta de bebês com DMH.

Em patologia freqüentemente é necessário obter uma imagem cujas estruturas histológicas de interesse sejam definidas com precisão, ou mais precisamente, tenham suas fronteiras bem definidas, o que nem sempre é conseguido pelo simples uso da imuno-histoquímica. Isto faz com que a classificação *pixel-a-pixel* da imagem de imuno-histoquímica seja de fundamental importância na análise patológica, pois através dela o patologista pode identificar com rapidez as estruturas histológicas e, principalmente, as regiões onde ocorrem grandes concentrações de núcleos celulares [dSB02].

7.4 Análise de Imagens de DMH utilizando o ANIMED

Para avaliar as interações histológicas da DMH com o pulmão utiliza-se imagens de amostras de imuno-histoquímica de pulmões com DMH de neomortos. Neste trabalho foram analisadas imagens de amostras de pulmão com DMH expressando a siamolucina CD34⁺, uma molécula presente nas células endoteliais [dSB02]. O objetivo é classificar imagens desse tipo para destacar as estruturas histológicas de interesse e assim permitir tanto a avaliação qualitativa (visual) quanto a objetiva (numérica, em termos percentuais) das áreas ocupadas pelas estruturas de interesse.




Figura 7.3: Amostra histológica de pulmão com DMH expressando a siamolucina $CD34^+$ com aumento de $200\times$

A metodologia utilizada consistiu em escolher uma imagem que caracterizasse bem as classes presentes nesse tipo de análise: *fundo da imagem*, *núcleos celulares*, *membrana hialina*, e *siamolucina $CD34^+$* . Para isso foi escolhida a imagem da figura 7.3, por possuir todas as classes de interesse ao estudo da DMH numa quantidade bastante representativa.

Feita a escolha, utiliza-se o ANIMED para selecionar as regiões de interesse e armazená-las em arquivo. Com esse arquivo, faz-se o treinamento, obtendo-se um outro arquivo com os parâmetros a serem utilizados na classificação. Esses parâmetros são os parâmetros das funções de pertinência trapezoidais definidas no capítulo 2. Foram utilizados o Método do Trapézio Simétrico e

<Index>	<Color (normalized RGB)>	<Class name>
1	1.000 1.000 1.000	fundo da imagem
2	1.000 0.502 1.000	membrana hialina
3	0.000 0.000 1.000	núcleos celulares
4	1.000 0.502 0.000	siamolucina CD34+

Tabela 7.1: Tabela de associação de classes a índices e cores para análise de imagens de pulmão com DMH, com cores no formato RGB normalizado, gerada utilizando o ANIMED

o Método do Trapézio Assimétrico.

O patologista deve procurar identificar com bastante cuidado as regiões de interesse, para que o erro de classificação seja o menor possível. A figura 7.4 mostra as regiões de interesse selecionadas.

A classe *membrana hialina* foi associada à cor *rosa*; *núcleos celulares* ao *azul*; *siamolucina CD34⁺* ao *laranja* e *fundo da imagem* ao *branco* (ver tabela 7.1 com as cores em RGB normalizado e os índices associados a cada classe).

É bastante importante associar o fundo da imagem ao branco pois, para o patologista, isto ajuda a análise visual, pois esta é a cor esperada para o fundo de uma imagem obtida por microscopia. Muitas vezes os patologistas chegam a descartar imagens de imuno-histoquímica cuja cor de fundo não seja o branco, o que aumenta os custos das análises. Assim, tal escolha também contribui para a redução do custo das análises e para um melhor aproveitamento do material coletado.

Nas figuras 7.5 e 7.6 tem-se os resultados da classificação pelo Método do Trapézio Simétrico e pelo Método do Trapézio Assimétrico, respectivamente. Avaliando os resultados utilizando o mesmo conjunto de regiões de interesse, obtem-se as matrizes de confusão das tabelas 7.2 e 7.3. Devido ao

melhor desempenho do Método do Trapézio Assimétrico ($\kappa = 0,7489$, contra $\kappa = 0,7255$ do Método do Trapézio Simétrico, ver tabelas 7.2 e 7.3), foi escolhido este método para a análise. Portanto, pode-se utilizar o mesmo arquivo de parâmetros para classificar outras imagens de imuno-histoquímica de amostras histológicas de pulmão com DMH expressando a siamolucina CD34⁺.

Nota-se que os *pixels* pertencentes à siamolucina CD34⁺ foram classificados com uma taxa de acerto de 82,906% pelo Método do Trapézio Assimétrico contra 70,940% pelo Método do Trapézio Simétrico. Isto é bastante importante, pois a presença da siamolucina CD34⁺ está relacionada com o progresso da DMH: quanto maior, mais desenvolvida a DMH [dSB02].

Utilizando o arquivo de parâmetros de classificação gerado no exemplo anterior para classificar as imagens das figuras 7.7 e 7.9, obtém-se resultados bastante razoáveis que podem ser visualizados nas figuras 7.8 e 7.10, respectivamente.

Percebe-se que, desta forma, o trabalho de análise do patologista pode ser facilitado, pois ele não precisa selecionar novamente regiões de interesse, o que dá um certo nível de automatização do processo de análise e evita erros.

É importante salientar que em momento algum o ANIMED se coloca no lugar do patologista. Muito pelo contrário: os métodos do Trapézio Simétrico e do Trapézio Assimétrico apenas modelam por funções matemáticas o conhecimento *a priori* e a experiência do patologista. E mesmo ao utilizar a metodologia proposta, a classificação ainda é feita utilizando o conhecimento inicial do patologista. Portanto, a classificação será tão boa quanto o for a escolha das regiões de interesse e a análise visual dos resultados de classificação ao escolher qual dos dois métodos será empregado.




Figura 7.4: Regiões de interesse selecionadas da figura 7.3




Figura 7.5: Resultado da classificação da imagem da figura 7.3 pelo Método do Trapézio Simétrico




Figura 7.6: Resultado da classificação da imagem da figura 7.3 pelo Método do Trapézio Assimétrico

Classification results:

Overall accuracy = 79.3103%

Index kappa = 0.725545

Confusion Matrix (%)

	Class 1	Class 2	Class 3	Class 4
Class 1	100.00	14.286	21.324	29.060
Class 2	0.00000	85.714	10.294	0.00000
Class 3	0.00000	0.00000	63.235	0.00000
Class 4	0.00000	0.00000	5.1471	70.940

Columns -> True classes

Lines -> Recognized classes

Tabela 7.2: Taxa de acerto, índice κ e matriz de confusão resultantes da avaliação da classificação da imagem da figura 7.3 segundo o Método do Trapézio Simétrico, gerados pelo ANIMED

Classification results:

Overall accuracy = 81.1359%

Index kappa = 0.748865

Confusion Matrix (%)

	Class 1	Class 2	Class 3	Class 4
Class 1	100.00	22.222	0.00000	0.00000
Class 2	0.00000	77.778	25.000	5.9829
Class 3	0.00000	0.00000	66.912	11.111
Class 4	0.00000	0.00000	8.0882	82.906

Columns -> True classes

Lines -> Recognized classes

Tabela 7.3: Taxa de acerto, índice κ e matriz de confusão resultantes da avaliação da classificação da imagem da figura 7.3 segundo o Método do Trapézio Assimétrico, gerados pelo ANIMED



Figura 7.7: Amostra histológica de pulmão com DMH expressando a siamolucina CD34⁺ com aumento de 200×




Figura 7.8: Resultado da classificação da imagem da figura 7.7 pelo Método do Trapézio Assimétrico



Figura 7.9: Amostra histológica de pulmão com DMH expressando a siamolina CD34⁺ com aumento de 200×




Figura 7.10: Resultado da classificação da imagem da figura 7.9 pelo Método do Trapézio Assimétrico

7.5 Conclusão

Apesar da classificação pelo Método do Trapézio Simétrico ter apresentado um resultado melhor do que pelo Método do Trapézio Assimétrico na análise de imagens de imuno-histoquímica de carcinoma de mama (ver seção 3.5.2), no caso da análise de imagens de imuno-histoquímica de pulmão com DMH expressando a siamolucina CD34⁺ os resultados foram melhor obtidos utilizando o Método do Trapézio Assimétrico.

Isso se explica pelo fato de que o Método do Trapézio Simétrico utiliza funções de pertinência trapezoidais simétricas centradas nas médias amostrais, o que é mais adequado à classificação de dados simetricamente distribuídos, enquanto que o Método do Trapézio Assimétrico é mais indicado à classificação de dados assimetricamente distribuídos, pois neste método as funções de pertinência são trapézios degenerados em triângulos centrados nas modas amostrais e cujas bases compreendem toda a faixa de níveis de cinza (ver seção 3.5.2), o que modela melhor as fronteiras de conjuntos de dados com baixa simetria.

Entretanto, o patologista não necessita esboçar os histogramas para escolher o melhor método de classificação dentre os dois citados. Basta fazer a análise visual dos resultados obtidos pelo emprego de ambos ou, para utilizar um método mais objetivo, realizar a pós-classificação e comparar os índices κ , as taxas de acerto ou as matrizes de confusão.

O ANIMED, que inclui os métodos de classificação de imagens por lógica nebulosa propostos neste trabalho, mostrou-se uma ferramenta importante no auxílio à análise de imagens de imuno-histoquímica, permitindo automatizar o processo de análise sem retirar do patologista o processo de tomada de decisão.

Capítulo 8

Conclusão

Este trabalho apresentou dois novos métodos não-iterativos para classificação de imagens utilizando Lógica Nebulosa: o Método do Trapézio Simétrico e o Método do Trapézio Assimétrico.

Foi construída a biblioteca `ImageIO` na linguagem `Ox` para manipular imagens e realizar a classificação segundo os dois métodos propostos. Como exemplo, foi utilizada uma imagem de uma amostra histológica de carcinoma de mama para realizar a classificação pela cor das estruturas de interesse presentes na imagem - núcleos celulares, hemácias, tecido normal e o fundo da imagem - realçando a região afetada pelo câncer.

Também foi feita uma revisão bibliográfica da Lógica Nebulosa e da Morfologia Matemática nos capítulos 3 e 4, respectivamente. Os diversos operadores da Morfologia Matemática para imagens em níveis de cinza e binárias foram apresentados acompanhados de exemplos, gerados pela biblioteca `MorphoMat`, utilizando versões em níveis de cinza e binárias de uma imagem de amostra histológica de mama. A biblioteca `MorphoMat` foi construída ao longo deste trabalho utilizando a linguagem `Ox`.

Também foi abordado na revisão bibliográfica da Morfologia Matemática

o conceito de espectro de padrões, muito útil como alternativa à extração de atributos convencional por utilizar granulometrias.

Uma revisão bibliográfica das técnicas de classificação de imagens em Patologia foi realizada no capítulo 2, tendo sido apresentados no texto alguns procedimentos comuns em patologia. Os diversos métodos de classificação foram apresentadas tal como são classificados na literatura médica: métodos empíricos, métodos estatísticos e não estatísticos.

Foram contempladas ainda as abordagens básicas de extração de atributos em Patologia: a morfometria e a fotomicrometria, sendo a primeira aplicada quando se deseja extrair atributos baseados na forma ou na textura, enquanto a segunda se aplica à classificação pela cor. Definiu-se também os conceitos de imuno-histoquímica e DNA-ploidia.

As limitações das abordagens morfométricas e fotomicrométricas foram expostas no capítulo 5, procurando-se indicar para trabalhos futuros a busca de uma abordagem híbrida, por meio da qual pudessem ser extraídos atributos morfométricos e fotomicrométricos ao mesmo tempo, de forma a maximizar a extração de informação na análise de imagens em Patologia.

Uma nova técnica para incremento da classificação de imagens pelo acréscimo de bandas sintéticas geradas por operadores da Morfologia Matemática foi proposta no capítulo 6, resultando no melhoramento da classificação quando se utiliza o Método da Máxima Verossimilhança Gaussiana, melhoramento esse que não se verificou quando da utilização do Método do Trapézio Simétrico à classificação da imagem acrescida de bandas sintéticas.

Chegou-se a conclusão de que o incremento da classificação é ótimo quando é gerada uma quantidade de bandas sintéticas igual ao número de bandas originais da imagem, utilizando seguidas erosões da imagem em níveis de cinza obtida da média aritmética das bandas originais.

Entretanto, tais resultados não podem ser generalizados para todos os tipos de imagens, o que motiva a experimentação desse método em imagens multiespectrais, as quais não necessariamente devem ser imagens médicas. Uma boa opção seria utilizar imagens de sensoriamento remoto e verificar se o incremento na classificação justifica o aumento no consumo de memória de armazenamento.

Neste trabalho foi construído o ambiente de classificação de imagens médicas ANIMED, com o fim de testar os métodos de classificação propostos. O ambiente ANIMED foi implementado utilizando a linguagem `Object Pascal` e consiste na verdade em uma interface amigável para classificação de imagens de Patologia. O ANIMED realiza a classificação executando programas em `0x` baseados na biblioteca de classificação e manipulação de imagens `ImageIO` e de Morfologia Matemática `MorphoMat`.

É possível utilizar as bibliotecas `ImageIO` e `MorphoMat` em futuros trabalhos na área de processamento e análise de imagens, pois suas aplicações não se limitam a imagens médicas: por meio da biblioteca `ImageIO` pode-se manipular imagens de uma quantidade ilimitada de bandas espectrais, o que as torna bibliotecas atraentes para lidar com diversos ramos do conhecimento: desde Patologia e Biologia até Sensoriamento Remoto.

O estudo de caso feito com imagens de imuno-histoquímica de amostras histológicas de pulmão com a doença da membrana hialina (capítulo 7) mostrou que o ambiente ANIMED pode vir a ser utilizado no dia-a-dia da Patologia Clínica, resultando um grande benefício para o patologista, pois o processo de análise pode ser automatizado sem que a decisão seja subtraída do patologista, pois na verdade é o emprego do conhecimento *a priori* do patologista que é otimizado e aproveitado nas análises subsequentes, pois a classificação será tão boa quanto o for a experiência do patologista na iden-

tificação das classes presentes na imagem e na seleção visual das regiões de interesse.

Este trabalho resultou em contribuições teóricas para as áreas de Engenharia Biomédica [dCdSBeS03] e Sensoriamento Remoto, envolvendo desde a proposição de técnicas de classificação de imagens multiespectrais por Lógica Nebulosa [ddN⁺03] ao desenvolvimento de arquiteturas computacionais para a execução em alto desempenho dessas técnicas [dddF03, Fdd⁺03].

Bibliografia

- [AR00] J. Abonyi and J. A. Roubos. Structure identifications of fuzzy classifiers. In *The 5th Online World Conference on Soft Computing in Industrial Applications*, 2000.
- [BB94] G. J. F. Banon and J. Barrera. *Bases da Morfologia Matemática para Análise de Imagens Binárias*. UFPE-DI, 1994.
- [Bez81] J. C. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press, New York, 1981.
- [Bra94] U. M. Braga Neto. Reconstrução volumétrica e análise de imagens tridimensionais por morfologia matemática. Master's thesis, Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas, Campinas, Brasil, 1994.
- [Can97] A. L. B. Candeias. *Aplicação da Morfologia Matemática à Análise de Imagens de Sensoriamento Remoto*. PhD thesis, Departamento de Computação Aplicada do Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Brasil, 1997.
- [dCdSBeS03] W. P. dos Santos, A. L. B. Candeias, A. F. de S. Bezerra, and A. F. D. e Silva. Analysis of immuno-histochemical lung sam-

ple images with hyaline membrane disease using non-interactive fuzzy functions. *International Journal of Medical Informatics*, xx(x):xxx–xxx, 2003. (submetido).

- [dddF03] P. V. da Silva, W. P. dos Santos, M. E. de Lima, and A. C. Frery. A fuzzy vlsi architecture for multispectral image classification. In *XI Simpósio Brasileiro de Sensoriamento Remoto*, pages 1107–1114, Belo Horizonte, Brasil, 2003. Sociedade Brasileira de Sensoriamento Remoto.
- [ddN⁺03] W. P. dos Santos, M. S. C. de Araújo Filho, A. J. B. Neto, C. K. R. da Silva, P. V. da Silva, J. D. da Silva, and A. C. Frery. Uma nova técnica de classificação de imagens baseada em lógica nebulosa não iterativa. In *XI Simpósio Brasileiro de Sensoriamento Remoto*, pages 1091–1098, Belo Horizonte, Brasil, 2003. Sociedade Brasileira de Sensoriamento Remoto.
- [DG87] E. R. Dougherty and C. R. Giardina. *Matrix Structured Image Processing*. Prentice Hall Inc., 1987.
- [DH72] R. Duda and P. Hart. *Pattern Classification and Scene Analysis*. John Wiley and Sons Inc., 1972.
- [DHS01] R. Duda, P. Hart, and D. G. Stork. *Pattern Classification*. John Wiley and Sons Inc., 2001.
- [DO01] J. A. Doornik and M. Ooms. *Introduction to \mathcal{Ox}* . 2001. Disponível em <http://www.nuff.ox.ac.uk/Users/Doornik/>.
- [Doo02] J. A. Doornik. *\mathcal{Ox} Appendices*. 2002. Disponível em <http://www.nuff.ox.ac.uk/Users/Doornik/>.

- [dos03a] W. P. dos Santos. *ImageIO*: Biblioteca de entrada-saída e classificação de imagens utilizando lógica nebulosa em *Ox*. Maio 2003. Nota técnica do DES/UFPE disponível em <http://www.eb.ufpe.br/~wellington>.
- [dos03b] W. P. dos Santos. *MorphoMat*: Biblioteca de morfologia matemática em *Ox*. Maio 2003. Nota técnica do DES/UFPE disponível em <http://www.eb.ufpe.br/~wellington>.
- [dSB02] A. F. de S. Bezerra. *Estudo da Interação das Alterações Histológicas da Placenta com a Doença da Membrana Hialina Utilizando Imuno-Histoquímica, Histomorfometria e Análise de Imagens*. PhD thesis, Programa de Pós-Graduação em Patologia da Universidade Federal Fluminense, Niterói, Brasil, 2002.
- [dSBCd⁺01] A. F. de S. Bezerra, A. L. B. Candeias, W. P. dos Santos, C. T. Nakamura, and C. P. Ramos. Overexpression of the cd34⁺ sialomucin in hyaline membrane disease (hmd): An immunohistochemical and histomorphometric study with image analysis. In *III Simpósio Temático sobre Citoesqueleto e Diferenciação Celular*, São Paulo, SP, 2001. Sociedade Brasileira de Biologia Celular.
- [dSBCR99] A. F. de S. Bezerra, A. L. B. Candeias, and C. P. Ramos. Avaliação das interações das alterações histológicas da placenta com a doença da membrana hialina usando técnicas da fotogrametria e processamento de imagens. In *XIX Congresso Brasileiro de Cartografia*. Sociedade Brasileira de Cartografia, 1999.

- [EL96] M. G. L. Espinosa and L. L. Ling. Um sistema de verificação de assinaturas que utiliza morfologia matemática na extração de características das imagens. In *XIV Simpósio Brasileiro de Telecomunicações*, pages 79–84, Curitiba, Brasil, 1996. Sociedade Brasileira de Telecomunicações.
- [ENS⁺02] A. N. Esgiar, R. N. G. Naguib, B. S. Sharif, M. K. Bennet, and A. Murray. Fractal analysis in the detection of colonic cancer images. *IEEE Transactions on Information Technology in Biomedicine*, 6(1):54–58, 2002.
- [Fac96] J. Facon. *Morfologia Matemática: Teoria e Exemplos*. Editora Universitária Champagnat da Pontifícia Universidade Católica do Paraná, 1996.
- [Fdd⁺03] A. C. Frery, W. P. dos Santos, P. V. da Silva, M. S. C. de Araújo Filho, C. K. R. da Silva, A. J. B. Neto, and M. E. de Lima. A fuzzy architecture for classification of multi- and hyperspectral images. In *Nonlinear Signal and Image Processing*, pages 1–5, Grado-Trieste, Italy, 2003. IEEE - Eurasip. CD-ROM.
- [Fou03a] Free Software Foundation. General public license. 2003. Disponível em <http://www.gnu.org>.
- [Fou03b] Free Software Foundation. Library general public license. 2003. Disponível em <http://www.gnu.org>.
- [Hen00] I. F. Heneine. *Biofísica Básica*. Editora Atheneu, São Paulo, Brasil, 2000.

- [Inc96] Borland International Inc. *Borland DELPHI for Windows User's Guide*. Borland Press, 1996.
- [Inc97] The Math Works Inc. *MATLAB Version 5 User's Guide*. Prentice Hall, 1997.
- [Inc02] Research Systems Inc. *IDL Manual*. 2002. Disponível em <http://www.researchsystems.com>.
- [KP99] J. K. Kim and H. W. Park. Statistical textural features for detection of microcalcification in digitized mammograms. *IEEE Transactions on Biomedical Engineering*, 18(3):231–238, 1999.
- [KZ95] R. Klette and P. Zamperoni. *Handbook of Image Processing Operators*. John Wiley & Sons, 1st edition, 1995.
- [Lan02] D. Landgrebe. Hyperspectral image analysis. *IEEE Signal Processing Magazine*, Jan 2002.
- [LMC⁺01] N. H. Lovell, F. Magrabi, B. G. Celler, K. Huynh, and H. Garsden. Web-based acquisition, storage and retrieval of biomedical signals. *IEEE Engineering in Medicine and Biology*, pages 38–44, June 2001.
- [Lop02] S. Lopes. *Bio: Introdução à Biologia e Origem da Vida, Citologia, Reprodução e Embriologia*, volume 1. Ed. Saraiva, 2002.
- [MB94] A. M. Marchevsky and P. H. Bartels, editors. *Image Analysis: A Primer to Pathologists*. Raven Press, New York, 1994.
- [Mil76] B. F. Miller, editor. *O Livro da Saúde - Enciclopédia Médica Familiar*. Reader's Digest, Lisboa, 1st edition, 1976.

- [Mül96] P. Müller. *Introduction to Object-Oriented Programming Using C++*. Nov. 1996. Disponível em <http://www.gnacadey.org>.
- [MWF⁺02] P. Mousavi, R. K. Ward, S. S. Fels, M. Sameti, and P. M. Lansdorp. Feature analysis and centromere segmentation of human chromosome images using an iterative fuzzy algorithm. *IEEE Transactions on Biomedical Engineering*, 49(4):363–371, 2002.
- [NV96] H. F. Nunes and F. Violaro. Reconhecimento de fala com vocabulário flexível para português brasileiro utilizando hmm. In *XIV Simpósio Brasileiro de Telecomunicações*, pages 539–544, Curitiba, Brasil, 1996. Sociedade Brasileira de Telecomunicações.
- [PCB02] C. E. Pedreira, E. S. Costa, and A. Bonomo. Citokohonen - aprendizado estatístico e redes neurais em citometria de fluxo. In *XIV Congresso Brasileiro de Automática*, pages 3101–3107, Natal, Brasil, 2002. Sociedade Brasileira de Automática.
- [PeS93] L. F. C. Pessoa and A. F. D. e Silva. Uma metodologia para diagnóstico automático da filariose utilizando imagens microscópicas digitalizadas. In *Anais do SIBGRAPI VI*, pages 333–342. Sociedade Brasileira de Computação, 1993.
- [RAK86] S. L. Robbins, M. Angell, and V. Kumar. *Patologia Básica*. Atheneu Editora, São Paulo, SP, 3rd edition, 1986.
- [RSA01] J. A. Roubos, M. Setnes, and J. Abonyi. Learning fuzzy classification rules from labeled data. *International Journal of Information Sciences*, 2001.

- [San96] I. Sanches. Aplicação da relação sinal-ruído intra-palavra no reconhecimento automático de fala em ruído. In *XIV Simpósio Brasileiro de Telecomunicações*, pages 527–531, Curitiba, Brasil, 1996. Sociedade Brasileira de Telecomunicações.
- [SW81] J. Sklansky and G. N. Wassel. *Pattern Classifiers and Trainable Machines*. Springer-Verlag, 1st edition, 1981.
- [TM02] J. P. Thiran and B. Macq. Morphological feature extraction for the classification of digital images of cancerous tissues. *IEEE Transactions on Biomedical Engineering*, 43(10):1011–1020, 2002.
- [vK02] M. van Canneyt and F. Klämpfl. *Free Pascal User's Manual*. Free Pascal Org., 2002. Disponível em <http://www.freepascal.org>.
- [VKM96] F. Violaro, B. Kaspar, and J. A. Martins. Isolated word recognition using hidden markov models. In *XIV Simpósio Brasileiro de Telecomunicações*, pages 533–538, Curitiba, Brasil, 1996. Sociedade Brasileira de Telecomunicações.
- [vM97] J. H. van Bommel and M. A. Musen, editors. *Handbook of Medical Informatics*. Springer, 1st edition, 1997.
- [YLK⁺03] U. Yoon, J. M. Lee, J. J. Kim, S. M. Lee, I. Y. Kim, J. S. Kwon, and S. I. Kim. Modified magnetic resonance image based parcellation method for cerebral cortex using successive fuzzy clustering and boundary detection. *Annals of Biomedical Engineering*, 31(4):441–447, 2003.