

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO


DEPARTAMENTO DE COMPUTAÇÃO E AUTOMAÇÃO

**Técnicas de Processamento e Análise de
Imagens Aplicadas à Avaliação Morfológica e
Morfométrica de Axônios Mielínicos**

Guilherme Augusto Faria de Queiroz

Orientador: **Prof. Dr. Clésio Luis Tozzi** - G.L.

Dissertação de Mestrado



Campinas - SP - Brasil

1997

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

DEPARTAMENTO DE COMPUTAÇÃO E AUTOMAÇÃO

**Técnicas de Processamento e Análise de
Imagens Aplicadas à Avaliação Morfológica e
Morfométrica de Axônios Mielínicos**

Guilherme Augusto Faria de Queiroz

Orientador: Prof. Dr. Clésio Luis Tozzi

Dissertação submetida à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do Título de Mestre em Engenharia Elétrica, Área de concentração: Automação.

Campinas - SP - Brasil

1997



9720210

UNIDADE	BC
N.º CHAMADA:	T/UNICAMP
	Q32t
V.	Ex.
TOMBO BC/	32125
PROC.	281137
C	☐
D	☒
PREÇO	R\$ 11,00
DATA	18/11/97
N.º CPD	

CM-00102279-0

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

Q32t

Queiroz, Guilherme Augusto Faria de

Técnicas de processamento e análise de imagens aplicadas à avaliação morfológica e morfométrica de axônios mielínicos / Guilherme Augusto Faria de Queiroz.--Campinas, SP: [s.n.], 1997.

Orientador: Clésio Luis Tozzi

Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Processamento de imagens. 2. Axônios. 3. Sistemas difusos. 4. Morfologia (Biologia). I. Tozzi, Clésio Luis. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

Aos meus pais, Geraldo e Sônia.

Agradecimentos

A Deus, pela vida e pela capacidade de raciocínio;

A meus pais, Geraldo e Sônia, pelos ensinamentos que têm me passado ao longo da vida, sempre com muita dignidade, caráter e honestidade. Às minhas irmãs, Isabella e Clara, pelo carinho e zelo. E também ao meu cunhado, Juliano, e à minha sobrinha Ana Beatriz, por enriquecerem ainda mais o meu conceito de família;

A Nély, que através do companheirismo, carinho, incentivo e amor, me faz encarar a vida com mais alegria e otimismo;

Ao Prof. Clésio, pela orientação e pela atenção dispensada ao longo do desenvolvimento deste trabalho, como também por me mostrar o caminho para alcançar uma maior maturidade científica;

Ao Prof. Francesco Langone, pelas “consultorias biológicas”, sempre com muita atenção e simpatia, e também pelo material que nos passou ao longo do trabalho;

Ao Prof. Roberto Lotufo, pelo material e idéias fornecidos, demonstrando interesse em ajudar a resolver as dificuldades encontradas durante a fase do desenvolvimento prático do trabalho;

Ao biólogo, Alexandre Oliveira, pelo material fornecido e pela atenção dispensada durante o trabalho;

Aos amigos Agostinho, Marco Antônio, Pedro e Walderson, por todos os momentos de convivência que tivemos na “república”;

A João Matos, pelos “bate-papos ecléticos”, numa relação de amizade e respeito;

A Rogério, Rildecio, Duílio e Thaís, pela solidariedade com que me acolheram em Campinas e, também, por terem me proporcionado um ambiente familiar mesmo estando a “alguns” quilômetros do meu;

Aos familiares que sempre me incentivaram e torceram por mim. Aos avós, Jaime e Mirinha, pela grande contribuição que têm na minha formação. À tia Tânia, por tudo tão agradável que me proporcionou durante este período de convivência mais próxima, sempre com carinho, alegria e amor;

Aos(Às) companheiros(as) do laboratório e da universidade: Maurício Galo, Mauro, Fábio, José, Luís Gonzaga, Jussara, Fernando Nogueira, Júlio Hasegawa, Rosana, Márcio Leandro, Douglas, Cláudio, Adela, Castanho, Olga, Alexandre Falcão, Alencar, Flávio Navarro, Naur, Renato Rocha, Marlus, Marilsa, Everaldo, Edna, e muitos outros, pelos ensinamentos e respeito. Em especial, a Wellington, Affonso e Inês, pois além dos ensinamentos e respeito, pude ter uma convivência mais pessoal;

Aos(Às) amigos(as) que ganhei em Campinas: Jesus, Catharina “A Boya”, Simone, Alcilene, Eliane, Hosi, Jorge, Diego, Robinho, Kléber, Eduardo “Onn”, Huguinho, Aluizio, Raniere, “Zoraide”, pelos bons momentos de alegria e descontração;

Aos bons amigos de Natal que, apesar da distância, sempre estiveram presentes;

Ao CNPq, pelo incentivo financeiro concedido para o desenvolvimento deste trabalho.

"A fisionomia de cada civilização dificilmente dependerá de uma determinada cultura componencial. Pode a mesma atividade repetir-se noutras entidades independentes sem impor a coincidência morfológica. Todos têm coração, mas o ritmo cardíaco não é o mesmo. Cada pianista tem o seu Bach, o seu Beethoven, o seu Mozart. A técnica determina o esplendor da execução. A interpretação, presença do artista na obra do mestre, é soma de sensibilidade, inteligência, intuição (...), fatores eminentes da civilização que nele vive".

Luís da Câmara Cascudo
In: Civilização e Cultura

Sumário

Lista de Figuras	x
Lista de Tabelas	xvi
Resumo	xviii
Abstract	xix
1. Introdução	1
1.1. Motivação e Objetivos	1
1.2. Organização do Trabalho	4
2. Limiarização de Imagens	5
2.1. Introdução	5
2.2. Evolução dos Métodos de Limiarização	5
2.3. Classificação dos Métodos de Limiarização.....	6
2.3.1. Métodos Globais	7

2.3.1.1. <i>Determinação do Limiar Ótimo a Partir do Histograma da Imagem</i>	8
2.3.1.1.1. <i>Método Proposto por KAPUR et al. (1985)</i>	8
2.3.1.1.2. <i>Método Proposto por SHANBHAG (1994)</i>	10
2.3.1.1.3. <i>Método Proposto por HUANG & WANG (1995)</i> ..	11
2.3.1.2. <i>Determinação do Limiar Ótimo a Partir da Informação da Distribuição Espacial dos Pixels</i>	13
2.3.1.2.1. <i>Método Proposto por ABUTALEB (1989)</i>	13
2.3.1.2.2. <i>Extensão do Método Proposto por SHANBHAG (1994)</i>	14
2.3.1.2.3. <i>Método Proposto por BRINK (1995)</i>	15
2.3.1.3. <i>Determinação do Limiar Ótimo a Partir da Entropia Relativa</i>	16
2.3.1.3.1. <i>Método Proposto por LI & LEE (1993)</i>	17
2.3.1.3.2. <i>Método Proposto por CHANG et al. (1994)</i>	17
2.3.1.3.3. <i>Método Proposto por BRINK & PENDOCK (1996)</i>	18
2.3.1.3.4. <i>Método Proposto por PAL (1996)</i>	18
2.3.2. <i>Métodos Locais</i>	19
3. Transformações Baseadas na Morfologia Matemática	24
3.1. <i>Introdução</i>	24
3.2. <i>Reticulado Completo e Elemento Estruturante</i>	25
3.3. <i>Dilatação e Erosão</i>	25
3.3.1. <i>Propriedades da Dilatação e da Erosão</i>	27
3.4. <i>Abertura e Fechamento</i>	29
3.4.1. <i>Propriedades da Abertura e do Fechamento</i>	30
3.5. <i>Reconstrução</i>	31
3.6. <i>Fechamento de Buracos</i>	33
3.7. <i>Esqueletização por Afinamento</i>	34

4. Classificador <i>Fuzzy</i>	37
4.1. Introdução	37
4.2. Noções da Teoria de Conjuntos <i>Fuzzy</i>	38
4.2.1. Lógica <i>Fuzzy</i>	38
4.2.2. Conjunto <i>Fuzzy</i>	38
4.2.2.1. Suporte de um Conjunto <i>Fuzzy</i>	39
4.2.2.2. Número <i>Fuzzy</i>	39
4.3. Algumas Operações com Conjuntos <i>Fuzzy</i>	40
4.4. Variáveis Linguísticas	41
4.5. Mecanismos de Inferência <i>Fuzzy</i>	42
4.5.1. Regra Composicional sup-* de Inferência	42
4.6. Sistema <i>Fuzzy</i>	43
4.6.1. Interface de <i>Fuzzificação</i>	44
4.6.2. Base de Conhecimento	45
4.6.2.1. Base de Dados	45
4.6.2.2. Base de Regras	46
4.6.3. Lógica de Tomada de Decisão	47
4.6.3.1. Exemplo Ilustrativo do Processo de Inferência <i>Fuzzy</i>	48
4.6.4. Interface de <i>Defuzzificação</i>	50
 5. Avaliação Morfológica e Morfométrica de Axônios Mielínicos	 52
5.1. Introdução	52
5.2. Uma Visão Geral do Sistema	52
5.3. Aquisição da Imagem	53
5.4. Binarização da Imagem de Entrada	54
5.5. Fechamento de Regiões e Eliminação de Pequenos Artefatos	56
5.6. Eliminação do Espaço Endoneural	57
5.7. Eliminação das Regiões que Tocam as Bordas da Imagem	61
5.8. Classificação <i>Fuzzy</i> das Regiões	62

5.8.1. Classificador que Utiliza Área e Distância como Variáveis de Entrada	63
5.8.2. Classificador que Utiliza Área e Fator de Forma como Variáveis de Entrada	69
5.9. Reclassificação das Regiões Duvidosas	75
5.10. Agrupamento das Regiões Classificadas como Axônios.....	75
5.11. Quantificação e Qualificação de Axônios.....	77
 6. Resultados e Discussões	 78
6.1. Introdução	78
6.2. Considerações de Implementação.....	79
6.3. Configuração 1 (Área e Distância como Variáveis de Entrada do Classificador <i>Fuzzy</i>).....	80
6.4. Configuração 2 (Área e Fator de Forma como Variáveis de Entrada do Classificador <i>Fuzzy</i>)	84
6.5. Comparação dos Erros de Contagem do Sistema com o Erro Obtido pela Aplicação do Método de BLIGHT (1983)	87
6.6. Análise do Comportamento do Classificador <i>Fuzzy</i>	88
6.7. Erro de Classificação e Percentual de Interação do Usuário.....	90
 7. Conclusões	 92
 Referências Bibliográficas	 94
 Apêndice 1	 100

Lista de Figuras

Figura 1.1: Imagem de corte transversal de fibras mielínicas.	3
Figura 2.1: Binarização pelo método proposto por KAPUR et al., (1985): (a) Imagem original; (b) Resultado da binarização da imagem da Figura 2.1-a.	9
Figura 2.2: Histograma da imagem da Figura 2.1-a.....	9
Figura 2.3: Binarização da imagem da Figura 2.1-a pelo método proposto por SHANBHAG (1994).....	11
Figura 2.4: Imagens resultantes da aplicação da extensão do método proposto por SHANBHAG (1994) à imagem da Figura 2.1-a, quando consideradas as vizinhanças: (a) 7×7 ; (b) 9×9 ; e (c) 11×11	15
Figura 2.5: Região assimétrica (pintada) considerada por BRINK (1995) para corrigir a redundância no cálculo do valor médio da entropia espacial.	16
Figura 2.6: Imagens resultantes da aplicação do método de KAPUR et al. (1985) à imagem da Figura 2.1-a, em uma abordagem local, quando consideradas janelas de dimensões: (a) 3×3 ; (b) 5×5 ; (c) 7×7 ; (d) 9×9	22
Figura 2.7: Imagens resultantes da aplicação do método de SHANBHAG (1994) à imagem da Figura 2.1-a, em uma abordagem local, quando consideradas janelas de dimensões: (a) 3×3 ; (b) 5×5 ; (c) 7×7 ; (d) 9×9	23

Figura 3.1:	Processo de dilatação morfológica: (a) Imagem original; (b) Ilustração da transformação; (c) Imagem resultante da dilatação da Figura 3.1-a utilizando um elemento estruturante do tipo disco de diâmetro 20.	26
Figura 3.2:	Processo de erosão morfológica: (a) Imagem original; (b) Visualização da transformação; (c) Imagem resultante da erosão da imagem da Figura 3.2-a quando utilizado um elemento estruturante do tipo disco de diâmetro 20.	27
Figura 3.3:	Processo de abertura morfológica: (a) Imagem original; (b) Ilustração da transformação; (c) Imagem resultante da abertura da imagem da Figura 3.3-a quando utilizado um elemento estruturante do tipo disco de diâmetro 10.	29
Figura 3.4:	Fechamento morfológico: (a) Imagem original; (b) Ilustração da transformação; (c) Imagem resultante do fechamento da imagem da Figura 3.4-a, quando utilizado um elemento estruturante disco de diâmetro 10.	30
Figura 3.5:	Processo de reconstrução: (a) Imagem original; (b) Imagem dos marcadores (obtidos manualmente); (c) Imagem resultante da reconstrução da imagem na Figura 3.5-b, condicional à imagem da Figura 3.5-a, utilizando um elemento estruturante de conectividade 4.	33
Figura 3.6:	Exemplo do processo de fechamento de buracos.	34
Figura 3.7:	Elementos estruturantes utilizados para a obtenção do esqueleto homotópico: (a) B_1 ; (b) B_2	35
Figura 3.8:	Esqueletização homotópica: (a) Imagem original; (b) Imagem resultante da esqueletização, quando utilizados os elementos estruturantes apresentados na Figura 3.7.	35
Figura 3.9:	Elementos estruturantes utilizados para a obtenção dos contornos dos objetos de uma imagem no processo de esqueletização por afinamento: (a) B_1 ; (b) B_2	36

Figura 3.10: Esqueletização da imagem da Figura 3.8-a, quando utilizados os elementos estruturantes apresentados na Figura 3.9.	36
Figura 4.1: Exemplo de número <i>fuzzy</i>	40
Figura 4.2: Exemplo de conjunto <i>fuzzy</i> não-convexo.	40
Figura 4.3: Configuração básica de um sistema <i>fuzzy</i>	44
Figura 4.4: Exemplos de funções de pertinência: (a) triangular; (b) trapezoidal. .	46
Figura 4.5: Diagrama representativo da relação <i>fuzzy</i> de Mamdani.	49
Figura 4.6: Diagrama representativo da relação <i>fuzzy</i> de Larsen.	50
Figura 4.7: Representação esquemática das técnicas de <i>defuzzificação</i> : máximo (MAX), centro de área (CDA) e média dos máximos (MDM).	51
Figura 5.1: Visão Geral do Sistema de Avaliação Morfológica e Morfométrica de Axônios Mielínicos.	53
Figura 5.2: Imagem típica processada pelo método de avaliação morfológica e morfométrica de axônios mielínicos proposto neste trabalho	54
Figura 5.3: Processo de binarização: (a) Imagem de entrada; (b) Resultado da binarização.	55
Figura 5.4: Pós-Processamento da imagem binarizada (Figura 5.3-b): (a) Fechamento de buracos; (b) Artefatos eliminados da imagem da Figura 5.4-a; (c) Imagem resultante da eliminação de pequenos artefatos aplicada à imagem da Figura 5.4-a.	57
Figura 5.5: Esqueletização homotópica para a imagem da Figura 5.4-b: (a) Esqueletos das regiões; (b) Tamanho do esqueleto $\times$ Região.	60
Figura 5.6: (a) Esqueletos eliminados após a limiarização dos tamanhos dos esqueletos da Figura 5.5-a; (b) Imagem obtida após a reconstrução da imagem da Figura 5.6-a.	60
Figura 5.7: Eliminação do espaço endoneural da imagem da Figura 5.4-b.	61
Figura 5.8: Eliminação das regiões que tocam as bordas da imagem da Figura 5.7.	61

Figura 5.9: Dois exemplos de regiões não-axônios (em branco), dentre as regiões da imagem apresentada na Figura 5.8.	62
Figura 5.10: Funções de pertinência para a variável distância (d).	64
Figura 5.11: Funções de pertinência para a variável área (a).	64
Figura 5.12: Funções de pertinência para a variável forma ($form$): (a) Para as Abordagens 2 e 3; (b) Para a Abordagem 1.	65
Figura 5.13: Imagem processada pelo sistema baseado em regras <i>fuzzy</i> para a classificação de regiões.....	67
Figura 5.14: Classificação <i>fuzzy</i> pela configuração 1. Segundo a abordagem 1: (a1) Axônios; (b1) Não-Axônios. Segundo a abordagem 2: (a2) Axônios; (b2) Não-axônios; (c2) Duvidosos. Segundo a abordagem 3: (a3) Axônios; (b3) Não-axônios; (c3) Duvidosos.....	68
Figura 5.15: Funções de pertinência para a variável fator de forma (fa_f).	70
Figura 5.16: Funções de pertinência para a variável área (a).	70
Figura 5.17: Funções de pertinência para a variável forma ($form$): (a) Para as abordagens 2 e 3; (b) Para a abordagem 1.	71
Figura 5.18: Imagem processada pelo sistema baseado em regras <i>fuzzy</i> para a classificação de regiões.....	73
Figura 5.19: Classificação <i>fuzzy</i> pela configuração 2. Segundo a abordagem 1: (a1) Axônios; (b1) Não-Axônios. Segundo a abordagem 2: (a2) Axônios; (b2) Não-axônios; (c2) Duvidosos. Segundo a abordagem 3: (a3) Axônios; (b3) Não-axônios; (c3) Duvidosos.....	74
Figura 5.20: Imagens resultantes da reclassificação de regiões duvidosas, quando considerada a abordagem 2: (a) Para a configuração 1; (b) Para a configuração 2.	75
Figura 5.21: Agrupamento das regiões classificadas como axônios, segundo a abordagem 2, para: (a) Configuração 1; (b) Configuração 2.....	76
Figura 5.22: (a) Regiões da imagem da Figura 5.21-a sobrepostas na imagem original em níveis de cinza; (b) Regiões da imagem da Figura 5.21-b sobrepostas na imagem original em níveis de cinza.	76

Figura 5.23: Histograma do tamanho dos axônios: (a) Para a imagem da Figura 5.21-a; (b) Para a imagem da Figura 5.21-b.	77
Figura 6.1: Valores dos erros de contagem e de classificação obtidos pela abordagem 1 da primeira configuração para cada uma das 10 imagens processadas pelo método.	82
Figura 6.2: Valores dos erros de contagem e de classificação obtidos pela abordagem 2 da primeira configuração para cada uma das 10 imagens processadas pelo método.	82
Figura 6.3: Valores dos erros de contagem e de classificação obtidos pela abordagem 3 da primeira configuração para cada uma das 10 imagens processadas pelo método.	83
Figura 6.4: Valores dos percentuais de interação do usuário para as abordagens 2 e 3 da primeira configuração, para cada uma das 10 imagens processadas pelo método.	83
Figura 6.5: Valores dos erros de contagem e de classificação obtidos pela abordagem 1 da segunda configuração para cada uma das 10 imagens processadas pelo método.	85
Figura 6.6: Valores dos erros de contagem e de classificação obtidos pela abordagem 2 da segunda configuração para cada uma das 10 imagens processadas pelo método.	85
Figura 6.7: Valores dos erros de contagem e de classificação obtidos pela abordagem 3 da segunda configuração para cada uma das 10 imagens processadas pelo método.	86
Figura 6.8: Valores dos percentuais de interação do usuário para as abordagens 2 e 3 da segunda configuração, para cada uma das 10 imagens processadas pelo método.	86
Figura 6.9: Distribuição das classes axônios e não-axônios considerando o fator de forma e a área como atributos, para uma amostra de 5 imagens...	89
Figura 6.10: Resposta da abordagem 2 do classificador <i>fuzzy</i> que utiliza a área e o fator de forma das regiões como variáveis de entrada, quando	

aplicadas todas as combinações possíveis dos valores destas
variáveis..... 89

Lista de Tabelas

TABELA 4-I: Base de regras utilizada para o exemplo ilustrativo do processo de inferência <i>fuzzy</i>	48
TABELA 5-I: Base de regras <i>fuzzy</i> para a abordagem 1 da configuração 1	66
TABELA 5-II: Base de regras <i>fuzzy</i> para a abordagem 2 da configuração 1	66
TABELA 5-III: Base de regras <i>fuzzy</i> para a abordagem 3 da configuração 1	66
TABELA 5-IV: Base de regras <i>fuzzy</i> para a abordagem 1 da configuração 2	72
TABELA 5-V: Base de regras <i>fuzzy</i> para a abordagem 2 da configuração 2	72
TABELA 5-VI: Base de regras <i>fuzzy</i> para a abordagem 3 da configuração 2	72
TABELA 6-I: Erros médios percentuais de contagem e de classificação de axônios e o percentual médio de interação para as três abordagens do sistema <i>fuzzy</i> que utiliza a área e a distância mínima para classificar as regiões.....	81
TABELA 6-II: Erros médios percentuais de contagem e de classificação de axônios e o percentual médio de interação para as três abordagens do sistema <i>fuzzy</i> que utiliza a área e o fator de forma para classificar as regiões.....	84
TABELA 6-III: Erros médios de contagem obtidos pelo método de BLIGHT (1983) e pelas três abordagens das duas configurações do sistema proposto neste trabalho.	87

TABELA 6-IV: Erros médios de classificação obtidos pelas três abordagens das
duas configurações do sistema proposto neste trabalho. 90

TABELA 6-V: Percentual de interação do usuário quanto à classificação de
axônios. 90

Resumo

QUEIROZ, G. A. F. **Técnicas de processamento e análise de imagens aplicadas à avaliação morfológica e morfométrica de axônios mielínicos.** Campinas: DCA/FEEC/UNICAMP, 1997. (Dissertação de Mestrado).

Este trabalho propõe um método semi-automático para a avaliação morfológica e morfométrica de axônios mielínicos a partir de suas seções transversais, fundamentado em técnicas de processamento e análise de imagens digitais e que inclui um classificador de regiões baseado em regras *fuzzy* e um processo de reclassificação de regiões duvidosas supervisionado pelo usuário. Técnicas para limiarização (*thresholding*) de imagens são analisadas e aspectos da morfologia matemática são descritos. Diferentemente da maioria dos métodos de avaliação morfológica e morfométrica de axônios encontrados na literatura, o processo de limiarização utilizado neste trabalho é realizado de forma local, após verificado que os métodos globais falham para o tipo de imagem utilizada. Para o classificador de regiões baseado em regras *fuzzy*, três abordagens são propostas. Na primeira, as regiões são classificadas apenas como axônios ou não-axônios, tornando o método completamente automático; na segunda, as regiões são classificadas como axônios, não-axônios ou duvidosas; e na terceira, a classificação de regiões axônios ou não-axônios é restringida às regiões de maior certeza, enquanto os parâmetros para a classificação de regiões duvidosas são ampliados. Os resultados obtidos pelo método são comparados com os resultados de uma contagem manual e mostram que o método atende aos requisitos da aplicação. Ainda, o método pode ser estendido a aplicações similares em outras áreas de pesquisa.

Palavras-Chave: Processamento de imagens, Axônios, Sistemas difusos, Morfologia.

Abstract

QUEIROZ, G. A. F. **Image processing and analysis techniques applied to the morphologic and morphometric evaluation of myelinated axons.** Campinas: DCA/FEEC/UNICAMP, 1997. (Dissertação de Mestrado).

This work proposes a semi-automatic method for the morphologic and morphometric evaluation of myelinated axons from images of their cross sections. The method is based on image processing and analysis techniques and includes a region classifier based on fuzzy rules and a supervised classification of doubtful regions. The techniques for image thresholding are analyzed and aspects of mathematical morphology are presented. Differently from the majority of axon morphologic and morphometric evaluation methods found in literature, the thresholding used in this work is done locally, after verifying that global methods fail to this kind of image. Three approaches are proposed for the region classifier based on fuzzy rules. In the first one, the regions are classified only as axon or non-axon, being the method completely automatic; in the second one, the regions are classified as axon, non-axon or doubtful regions; and in the third approach, the parameters for classifying the regions as doubtful are enlarged and consequently the classification of regions as axon and non-axon are restricted to those regions with a high degree of certainty. The results obtained by the method are compared with the results of a manual counting process and show that the method fulfills the application requirements. The method can be extended to similar applications in other areas of research.

Keywords: Image processing, Axons, Fuzzy systems, Morphology.

Capítulo 1

Introdução

1.1. Motivação e Objetivos

A avaliação morfológica e morfométrica de axônios mielínicos fornece informações relevantes às pesquisas sobre desenvolvimento, envelhecimento, regeneração neural, neurotoxicidade e várias condições patológicas (ZIMMERMAN et al., 1980).

O número e as dimensões das fibras nervosas, tais como o diâmetro axonal e a espessura da bainha de mielina, são parâmetros que fornecem indicações sobre o estado funcional dos neurônios e das células associadas, fisiológica e estruturalmente, aos mesmos (FRIEDE & BISCHHAUSEN, 1982). Estas informações são particularmente importantes para a avaliação dos processos degenerativos e regenerativos, decorrentes de estados patológicos ou traumáticos, que podem se estabelecer no sistema nervoso central ou periférico (BEUCHE & FRIEDE, 1985; FIELDS & ELLISMAN, 1986).

Tradicionalmente, a análise qualitativa e quantitativa dos axônios mielínicos tem sido realizada a partir de fotografias ou imagens de cortes transversais de feixes de fibras nervosas (ver Figura 1.1, pág. 3), nas quais o número e parâmetros morfométricos dos axônios são obtidos manualmente (FRYKMAN et al., 1988; LANGONE, 1991). Porém, visto que o número de axônios em cada imagem é grande e que muitas imagens são necessárias para o estabelecimento da relação procurada, esta abordagem se torna extremamente ineficiente.

O desenvolvimento de arranjos eletro-mecânicos (ESPIR & HARDING, 1961) e o desenvolvimento de técnicas estatísticas (BLIGHT, 1983), têm se apresentado como alternativas viáveis para a obtenção de métodos semi-automáticos na contagem e avaliação da distribuição de axônios. Observa-se, entretanto, que a disponibilidade de tecnologias mais avançadas tem possibilitado aperfeiçoamentos metodológicos. HARMAN et al. (1991), por exemplo, aperfeiçoaram a técnica apresentada por BLIGHT (1983) com o acoplamento de uma câmera de vídeo ao microscópio e a utilização de um microcomputador para a realização dos cálculos estatísticos. Ainda assim, muito trabalho manual é empregado, o que torna a metodologia entediante e custosa.

As soluções que apresentam um maior grau de automação têm, como elemento comum, a utilização de técnicas de processamento e análise de imagens digitais. ZIMMERMAN et al. (1980) utilizam um limiar (*threshold*) global, previamente definido, para binarizar a imagem e, em seguida, aplicam um algoritmo para determinar os centros dos axônios. A partir destes centros, são enviados vetores nas direções 0°, 90°, 180° e 270° para determinar possíveis pontos de transição entre o axônio e a bainha de mielina. Os pontos obtidos são confirmados após um processo de detecção de bordas, que também é válido para traçar os contornos das fibras. A intervenção do operador é necessária para a extração das fibras para as quais o processo de identificação falha. No sistema proposto por VITA et al. (1992), uma binarização global é realizada para segmentar as bainhas de mielina e, na sequência, um algoritmo de fechamento de buracos é utilizado para o preenchimento das áreas definidas pelas fibras. O operador interage com o sistema na definição do limiar de binarização da imagem, na separação de fibras unidas, na eliminação de estruturas estranhas, e no fechamento das bainhas de mielina que resultem abertas após a binarização. AUER (1994) utiliza um *software* disponível comercialmente para apresentar um método semi-automático para a quantificação de fibras mielínicas. Este método realiza uma limiarização (*thresholding*) global, com o valor de limiar definido interativamente pelo operador. As estruturas estranhas são eliminadas, ou pelo sistema através da imposição de um limiar aos tamanhos dos perímetros das regiões segmentadas, ou pelo operador quando essa condição falha. VOGT (1996) descreve

um algoritmo para a extração de fibras mielínicas a partir de transformações definidas na morfologia matemática, aplicadas a imagens não-binárias, combinadas com um processo de limiarização adaptativo.

Embora se observe uma tendência pela busca de métodos completamente automáticos para a obtenção da densidade de axônios, estudos realizados por ZIMMERMAN et al. (1980) e AUER (1994) indicam que, dada a complexidade da tarefa, faz-se necessária a intervenção de um operador no processo, uma vez que a completa automação, ou excluirá uma percentagem variável de pequenas fibras, ou incluirá componentes estranhos, podendo resultar em taxas de erro inaceitáveis.

Dentro da tendência observada na literatura, é proposto, neste trabalho, um sistema semi-automático para a quantificação e qualificação de axônios mielínicos que inclui, além de técnicas de processamento e análise de imagens usuais para este tipo de aplicação, a utilização de um sistema classificador de regiões baseado em regras *fuzzy* e a reclassificação de regiões duvidosas por um processo manual supervisionado pelo usuário. Dentre as técnicas de processamento de imagens utilizadas estão a limiarização (*thresholding*) e a morfologia matemática. Diferentemente da maioria dos métodos de avaliação morfométrica de axônios encontrados na literatura, o processo de limiarização utilizado neste trabalho é realizado de forma local, após verificado que os métodos globais falham para o tipo de imagem utilizada.




Figura 1.1: Imagem de corte transversal de fibras mielínicas.

1.2. Organização do Trabalho

O presente trabalho está dividido em sete capítulos, incluindo este introdutório, e um apêndice.

No capítulo 2, é feita uma revisão sobre a técnica de segmentação de imagens conhecida por limiarização (*thresholding*). Esta revisão é apresentada na forma de um estudo evolutivo da técnica, onde vários métodos relatados na literatura são descritos.

No capítulo 3, são apresentados os conceitos básicos da morfologia matemática, bem como algumas transformações baseadas nesta técnica. As transformações da morfologia matemática apresentadas neste trabalho são empregadas a imagens binárias.

No capítulo 4, é introduzida a noção de conjunto e lógica *fuzzy* e, em seguida, é caracterizado um sistema baseado em regras *fuzzy*, considerando a sua configuração básica.

No capítulo 5, é proposto um sistema de quantificação e qualificação de axônios mielínicos, como uma aplicação das teorias apresentadas nos capítulos 2, 3 e 4.

No capítulo 6, são apresentados os resultados e discussões relativos à aplicação do método exposto no capítulo 5.

No capítulo 7, são expostas as conclusões do trabalho a partir dos resultados obtidos pelo método e apresentam-se algumas sugestões para trabalhos futuros.

E finalmente, no apêndice 1, são apresentadas as imagens processadas pelo método e as imagens dos axônios classificados pela abordagem 2 das duas configurações, para cada uma das imagens processadas.

Capítulo 2

Limiarização de Imagens

2.1. Introdução

A segmentação de imagens digitais é um processo de abstração de detalhes, os quais são dispensáveis sob algum ponto de vista. Segundo FU & MUI (1981), as técnicas de segmentação podem ser divididas em três classes: limiarização (*thresholding*) ou agrupamento (*clustering*), detecção de bordas e extração de regiões.

Dentre essas técnicas, a limiarização é uma das mais poderosas e amplamente utilizadas, geralmente representando um primeiro passo na segmentação de imagens. Todavia, torna-se uma das fases mais críticas quando a segmentação é completamente automática. A aplicação da limiarização objetiva destacar os diversos componentes homogêneos da imagem, isto é, separar o(s) objeto(s) do fundo.

O objetivo deste capítulo é apresentar um estudo evolutivo sobre os métodos de limiarização e descrever algumas abordagens utilizadas para a determinação do limiar ótimo.

2.2. Evolução dos Métodos de Limiarização

Os primeiros métodos de limiarização se aplicavam apenas a imagens para as quais se conhecia a informação da percentagem de área ocupada pelo objeto. Desta

forma, o limiar era definido como o maior nível de cinza que permitisse que a mesma percentagem de pixels fosse mapeada como objeto na imagem binarizada.

Com o desenvolvimento da técnica, qualquer tipo de informação prévia foi deixando de ser uma exigência e a determinação do limiar ótimo feita, geralmente, pela otimização de uma função critério baseada ou no histograma ou em alguma propriedade local da imagem. Dentre as funções critério encontradas na literatura, uma das mais usadas é a entropia (HANNAH et al., 1995).

A utilização de funções critério que possibilitem a limiarização completamente automática é uma tendência observada na literatura. Apesar desta tendência, alguns estudos salientam que segmentações automáticas podem levar a resultados indesejáveis e assim propõem a utilização de funções que permitam a intervenção do usuário no processo. MORII (1995), por exemplo, determina o limiar ótimo com base em uma função de distorção quadrática ponderada, na qual os coeficientes de ponderação são ajustados pelo usuário. Estes métodos supervisionados não serão abordados neste trabalho devido ao fato de se ter decidido utilizar um processo de limiarização automática no método de quantificação e qualificação de axônios mielínicos aqui proposto. Esta decisão foi tomada com o objetivo de se evitar mais uma etapa de intervenção do usuário no processo.

Apesar dessa busca crescente por segmentações cada vez melhores, sabe-se que a qualidade da determinação do limiar está diretamente ligada ao tipo de imagem utilizada (FU & MUI, 1981; TRIER & TAXT, 1995; ZHANG, 1996). Além deste, outro fator que influencia no resultado da segmentação por limiarização é o modo de determinação do limiar. As formas de determinação do limiar ótimo impõem uma classificação, que é apresentada a seguir.

2.3. Classificação dos Métodos de Limiarização

A partir do modo de determinação do limiar, SAHOO et al. (1988) estabelecem uma classificação para os métodos de limiarização em quatro categorias:

- Dependente do ponto: se o nível de limiar ótimo é determinado apenas levando-se em consideração o nível de cinza de cada pixel, isto é, o histograma simples da imagem;
- Dependente de região: se o nível de limiar ótimo é determinado a partir da distribuição do nível de cinza na vizinhança de cada pixel;
- Global: se o limiar ótimo determinado é aplicado em toda a imagem de entrada;
- Local: se a imagem de entrada é dividida em subimagens para que em cada subimagem seja determinado o limiar ótimo e aplicado somente a ela.

A seguir, alguns métodos de limiarização são descritos em duas principais seções: métodos globais e métodos locais, e as outras duas categorias da classificação acima são tratadas como abordagens dentro destas seções.

2.3.1. Métodos Globais

A maioria dos métodos de limiarização encontrados na literatura é de natureza global (SAHOO et al., 1988; LEE et al., 1990) e isto pode ser explicado por sua menor complexidade e conseqüentemente menor tempo de execução (TRIER & TAXT, 1995).

Os métodos globais podem ainda ser classificados de acordo com o número de limiares determinados. Se apenas um nível de limiar é determinado, o método é denominado binível e a imagem resultante é composta apenas por dois níveis de cinza. Por isso mesmo, muitas vezes ele é referido como método de binarização da imagem. Se mais de um limiar é determinado, o método é chamado multinível (PAPAMARKOS & GATOS, 1994; YEN et al., 1995) e a imagem resultante é composta por mais de dois níveis de cinza. Esse tipo de método é geralmente utilizado quando se quer destacar mais de uma classe de objetos na imagem. Os métodos multinível são menos freqüentes na literatura e, neste trabalho, serão desconsiderados.

Observa-se, pela literatura, que os métodos globais utilizam diversas abordagens para a determinação do limiar ótimo. Três dessas abordagens são apresentadas nas subseções seguintes.

2.3.1.1. Determinação do Limiar Ótimo a Partir do Histograma da Imagem

Esta é a mais simples das abordagens e considera apenas o histograma da imagem para a determinação do limiar ótimo (GLASBEY, 1993).

Nesta seção, são apresentados os métodos propostos por KAPUR et al. (1985), SHANBHAG (1994) e HUANG & WANG (1995) e, para facilitar a leitura, eles estão divididos em subseções a seguir.

2.3.1.1.1. Método Proposto por KAPUR et al. (1985)

KAPUR et al. (1985) derivam, inicialmente, duas distribuições de probabilidade (uma para o objeto e outra para o fundo) a partir do histograma da imagem. Essas distribuições são da forma:

$$\frac{p(0)}{p(\text{classe1})}, \frac{p(1)}{p(\text{classe1})}, \dots, \frac{p(T)}{p(\text{classe1})}$$

para o fundo e

$$\frac{p(T+1)}{1-p(\text{classe1})}, \frac{p(T+2)}{1-p(\text{classe1})}, \dots, \frac{p(L-1)}{1-p(\text{classe1})}$$

para o objeto, onde $p(i)$ é a probabilidade de ocorrência do nível de cinza i ; T representa o nível candidato a limiar; L é o número de níveis de cinza da imagem e $p(\text{classe 1})$ é a probabilidade acumulada para a classe 1, que é dada por $p(\text{classe1}) = \sum_{i=0}^T p(i)$. Em seguida, a partir da função de Shannon, definem as funções

de entropia para as duas classes, da seguinte forma:

$$H_1(T) = - \sum_{i=0}^T \frac{p(i)}{p(\text{classe1})} \log \frac{p(i)}{p(\text{classe1})} \quad (2-1)$$

para a classe 1 e

$$H_2(T) = - \sum_{i=T+1}^{L-1} \frac{p(i)}{1-p(\text{classe 1})} \log \frac{p(i)}{1-p(\text{classe 1})} \quad (2-2)$$

para a classe 2.

Obtêm-se os valores dessas entropias para cada candidato a limiar e o nível que maximiza a soma das duas entropias é definido como o limiar ótimo T^* , isto é, $T^* \rightarrow \max \{H_1(t) + H_2(t)\}$.

A Figura 2.1-b mostra a imagem resultante da aplicação deste método à imagem da Figura 2.1-a, cujo histograma é apresentado na Figura 2.2.




Figura 2.1: Binarização pelo método proposto por KAPUR et al., (1985): (a) Imagem original; (b) Resultado da binarização da imagem da Figura 2.1-a.




Figura 2.2: Histograma da imagem da Figura 2.1-a.

2.3.1.1.2. Método Proposto por SHANBHAG (1994)

SHANBHAG (1994) faz uma crítica à medida de informação utilizada pelo método apresentado na subseção anterior e propõe uma modificação para esta medida. Segundo o autor, KAPUR et al. (1985) determinam o grau de incerteza na classificação de um nível de cinza apenas pela probabilidade de ocorrência deste nível dentro da classe correspondente. E, uma vez que isso é independente da distância ao limiar escolhido, a informação obtida em classificar o nível preto, por exemplo, é igual à obtida em classificar algum outro nível de cinza pertencente à mesma classe, quando as probabilidades de ocorrência de ambos são iguais. O método proposto é baseado no conjunto de axiomas a seguir:

Axioma 1: A informação obtida em classificar o mínimo(máximo) nível de cinza da imagem como classe 1(classe 2) é zero;

Axioma 2: Qualquer nível de cinza tem seu coeficiente de pertinência maior ou igual a 0.5 em relação à sua classe correspondente;

Axioma 3: Considerando dois níveis de cinza, g_1 e g_2 , pertencentes à mesma classe, se g_2 está a uma maior distância do limiar do que g_1 , então o coeficiente de pertinência de g_2 , em relação à classe, é maior que o de g_1 . Já a informação obtida em classificar g_1 é maior que a informação obtida em classificar g_2 ;

Axioma 4: O coeficiente de pertinência de um nível de cinza com relação a uma classe depende de e aumenta com a frequência de ocorrência dos pixels com aquele nível de cinza.

A partir destes axiomas, determinam-se as funções de pertinência para os níveis. Por exemplo, para um nível de cinza $T-g$, onde g é uma constante positiva e inteira, o grau de pertinência em relação à classe 1 é dado por:

$$\mu_{1,T}(T-g) = 0.5 + \frac{0.5}{p(\text{classe1})} \sum_{i=T-g}^T p(i), \quad (2-3)$$

onde T é o nível de limiar; $p(i)$ é a probabilidade de ocorrência do nível i ; e $p(\text{classe1}) = \sum_{i=0}^T p(i)$. Similarmente, o grau de pertinência de um nível $T+g$ em relação à classe 2 é dado por:

$$\mu_{2,T}(T+g) = 0.5 + \frac{0.5}{1 - p(\text{classe 1})} \sum_{i=T+1}^{T+g} p(i). \quad (2-4)$$

Considerar valores de pertinência fracionários para os níveis de cinza significa ver a imagem como sendo composta por dois conjuntos *fuzzy*. A partir destes graus de pertinência, então, são determinadas as funções de informação para as duas classes, baseando-se na entropia de Shannon. Essas funções, para um dado limiar T , são definidas como:

$$H_{1,T} = - \frac{1}{p(\text{classe 1})} \sum_{i=0}^T p(i) \cdot \log \mu_{1,T}(i) \quad (2-5)$$

para a classe 1 e

$$H_{2,T} = - \frac{1}{1 - p(\text{classe 1})} \sum_{i=T+1}^{L-1} p(i) \cdot \log \mu_{2,T}(i) \quad (2-6)$$

para a classe 2, onde L é o número de níveis de cinza da imagem.

O processo de *defuzzificação*, ou determinação do limiar ótimo T^* , consiste em encontrar o nível para o qual a diferença absoluta entre os valores das funções de informação é mínima, isto é, $T^* \rightarrow \min |H_{1,T} - H_{2,T}|$.

A Figura 2.3 mostra a imagem resultante da aplicação deste método à imagem da Figura 2.1-a.




Figura 2.3: Binarização da imagem da Figura 2.1-a pelo método proposto por SHANBHAG (1994).

2.3.1.1.3. Método Proposto por HUANG & WANG (1995)

HUANG & WANG (1995) seguem uma linha de raciocínio similar à de SHANBHAG (1994) e também propõem um método de limiarização baseado na

teoria de conjuntos *fuzzy*. Inicialmente, para cada candidato a limiar, os níveis médios das duas classes por ele divididas são calculados pelas expressões:

$$\bar{i}_1 = \frac{\sum_{i=0}^T i \cdot f(i)}{\sum_{i=0}^T f(i)}, \quad (2-7)$$

para a classe 1 e

$$\bar{i}_2 = \frac{\sum_{i=T+1}^{L-1} i \cdot f(i)}{\sum_{i=T+1}^{L-1} f(i)}, \quad (2-8)$$

para a classe 2, onde $f(i)$ é o número de ocorrências do nível de cinza i ; L é o número de níveis de cinza da imagem; e T é o nível candidato a limiar. Em seguida, determinam-se os graus de pertinência dos níveis em relação às classes correspondentes por:

$$\mu_{1,T}(i) = \frac{1}{1 + \frac{|i - \bar{i}_1|}{C}}, \quad (2-9)$$

para a classe 1 e

$$\mu_{2,T}(i) = \frac{1}{1 + \frac{|i - \bar{i}_2|}{C}}, \quad (2-10)$$

para a classe 2, onde C é uma constante tal que $\frac{1}{2} \leq \mu \leq 1$. Destas funções de pertinência, observa-se que quanto mais próximo um nível estiver do valor médio, maior será o grau de pertinência em relação à classe correspondente.

O próximo passo é medir o grau de espalhamento dos níveis dentro das classes. Para isto, os autores propõem a utilização da entropia de um conjunto *fuzzy*, que é baseada na função de Shannon, ou da medida de incerteza de Yager.

A medida de entropia de um conjunto *fuzzy* é dada por:

$$H = \frac{1}{MN \ln 2} \sum_{i=0}^{L-1} \left\{ -\mu(i) \ln \mu(i) - [1 - \mu(i)] \ln [1 - \mu(i)] \right\} \cdot f(i), \quad (2-11)$$

onde M e N são as dimensões da imagem.

A medida de incerteza de Yager é dada por:

$$\eta = 1 - \frac{D_p(X, \bar{X})}{(MN)^{1/p}}, \quad (2-12)$$

onde $D_p(X, \bar{X})$ é a distância entre um conjunto imagem *fuzzy* X e seu complemento $\bar{X}$, a qual é definida por:

$$D_p(X, \bar{X}) = \left[\sum_{i=0}^{L-1} |\mu(i) - \bar{\mu}(i)|^p \right]^{1/p} \cdot f(i), \quad (2-13)$$

onde $\bar{\mu}(i) = 1 - \mu(i)$. Para $p=1$, tem-se a distância de Hamming e para $p=2$, tem-se a distância Euclidiana.

O nível que minimiza a medida utilizada é considerado o limiar ótimo.

2.3.1.2. Determinação do Limiar Ótimo a Partir da Informação da Distribuição Espacial dos Pixels

A abordagem anterior não leva em consideração qualquer relação espacial entre os pixels da imagem. Com isso, duas imagens diferentes que tivessem histogramas iguais ou muito semelhantes, seriam tratadas da mesma forma. Uma segunda abordagem para a determinação do limiar ótimo é utilizar, de alguma maneira, a informação da distribuição espacial dos pixels. Os métodos propostos por ABUTALEB (1989), BRINK(1995) e uma extensão do método proposto por SHANBHAG (1994) se enquadram nesta abordagem e são apresentados nas subseções seguintes.

2.3.1.2.1. Método Proposto por ABUTALEB (1989)

ABUTALEB (1989) propõe um método onde o nível de cinza de cada pixel e o nível de cinza médio de sua vizinhança são estudados. Calcula-se a frequência de ocorrência de cada dupla de níveis de cinza e, a partir dessas frequências, obtém-se uma superfície que, presumidamente tem dois picos e um vale. De posse desta

superfície, as funções de entropia bidimensional para as duas classes são determinadas por:

$$H_{1,(T,S)} = - \sum_{i=0}^T \sum_{j=0}^S \frac{p(i,j)}{p(\text{classe 1})} \ln \frac{p(i,j)}{p(\text{classe 1})} \quad (2-14)$$

para a classe 1, e

$$H_{2,(T,S)} = - \sum_{i=T+1}^{L-1} \sum_{j=S+1}^{L-1} \frac{p(i,j)}{1-p(\text{classe 1})} \ln \frac{p(i,j)}{1-p(\text{classe 1})} \quad (2-15)$$

para a classe 2, onde L é o número de níveis de cinza da imagem; (T,S) é a dupla de *limiares*; e $p(\text{classe 1}) = \sum_{i=0}^T \sum_{j=0}^S p(i,j)$.

O limiar ótimo é determinado na dupla de níveis que maximiza a soma das duas entropias.

2.3.1.2.2. Extensão do Método Proposto por SHANBHAG (1994)

SHANBHAG (1994) propõe uma extensão ao seu método de limiarização, tornando-o dependente de região, através da informação da distribuição espacial dos pixels. Essa informação é obtida pela matriz de co-ocorrência entre o nível de um pixel e o nível do seu adjacente. Desta forma, supondo a dupla de níveis $(T-g_1, T-g_2)$, onde g_1 e g_2 são constantes inteiras positivas, o grau de pertinência desta dupla à classe 1 é dado por:

$$\mu_{1,T}[(T-g_1, T-g_2)] = 0.5 + \frac{0.5}{p(\text{classe 1})} \sum_{i=T-g_1}^T \sum_{j=T-g_2}^T p(i,j), \quad (2-16)$$

onde $p(i,j)$ representa a probabilidade de ocorrência da dupla (i,j) e $p(\text{classe 1}) = \sum_{i=0}^T \sum_{j=0}^T p(i,j)$. Similarmente, para uma dupla $(T+g_1, T+g_2)$, o grau de

pertinência com relação à classe 2 é dado por:

$$\mu_{2,T}[(T+g_1, T+g_2)] = 0.5 + \frac{0.5}{1-p(\text{classe 1})} \sum_{i=T+1}^{T+g_1} \sum_{j=T+1}^{T+g_2} p(i,j). \quad (2-17)$$

As funções de informação são dadas por:

$$H_{1,T} = - \frac{1}{p(\text{classe 1})} \sum_{i=0}^T \sum_{j=0}^T p(i,j) \cdot \log \mu_{1,T}(i,j), \quad (2-18)$$

para a classe 1 e

$$H_{2,T} = -\frac{1}{1 - p(\text{classe1})} \sum_{i=T+1}^{L-1} \sum_{j=T+1}^{L-1} p(i,j) \cdot \log \mu_{2,T}(i,j), \quad (2-19)$$

para a classe 2, onde L é o número de níveis de cinza da imagem. O limiar ótimo T^* é também determinado para o nível que minimiza a diferença absoluta entre as duas entropias.

A Figura 2.4 mostra as imagens resultantes da aplicação da extensão do método proposto por SHANBHAG (1994) à imagem da Figura 2.1-a, quando consideradas vizinhanças 7×7 , 9×9 e 11×11 pixels.




Figura 2.4: Imagens resultantes da aplicação da extensão do método proposto por SHANBHAG (1994) à imagem da Figura 2.1-a, quando consideradas as vizinhanças: (a) 7×7 ; (b) 9×9 ; e (c) 11×11 .

2.3.1.2.3. Método Proposto por BRINK (1995)

BRINK (1995) utiliza entropia espacial, que é vista como uma medida de desordem espacial e que tem seu valor como função da distância entre os pixels, para determinar o limiar ótimo. Inicialmente, a imagem é binarizada para todo valor possível de limiar. Em cada imagem binarizada, percorre-se uma janela de dimensão 3×3 para a obtenção de co-ocorrências binárias de acordo com a distância espacial dentro da janela. Assim, para uma dupla de níveis (g, g') , a uma distância λ , tem-se:

$$p(g, g')_{\lambda} = \{p(0,0)_{\lambda}, p(0,1)_{\lambda}, p(1,0)_{\lambda}, p(1,1)_{\lambda}\} \quad \forall \lambda = (\lambda_i, \lambda_j), \lambda_i, \lambda_j = -1, 0, +1.$$

A partir dessas probabilidades, define-se a entropia espacial por:

$$H(T, \lambda) = - \sum_{g=0}^1 \sum_{g'=0}^1 p(g, g')_{\lambda} \cdot \log p(g, g')_{\lambda}. \quad (2-20)$$

Para normalizar esta entropia, define-se uma medida relativa normalizada, que é dada por:

$$H_R(T, \lambda) = \frac{H(T, \lambda) - H(T, 0)}{H(T, 0)}, \quad (2-21)$$

O valor médio dessa medida sob a vizinhança 3×3 , para todos os valores possíveis de λ , é dado por:

$$\bar{H}_R(T) = \frac{1}{9} \sum H_R(T, \lambda). \quad (2-22)$$

Porém, visto que a vizinhança considerada pelo autor é simétrica, este valor médio pondera mais os níveis que estão dispostos simetricamente com relação à origem (centro) da janela, já que $p(g, g')_{\lambda} = p(g', g)_{\lambda}$. Para corrigir essa redundância, considera-se uma região assimétrica como, por exemplo, a apresentada na Figura 2.5. Desta forma, a função corrigida para o valor médio é dada por:

$$\bar{H}_R(T) = \frac{1}{5} \sum H_R(T, \lambda). \quad (2-23)$$

Uma vez que esta entropia fornece uma medida de desordem da imagem, o limiar ótimo é definido no nível que minimiza o valor médio.




Figura 2.5: Região assimétrica (pintada) considerada por BRINK (1995) para corrigir a redundância no cálculo do valor médio da entropia espacial.

2.3.1.3. Determinação do Limiar Ótimo a Partir da Entropia Relativa

Devido ao alto custo computacional envolvido no cálculo de entropias bidimensionais, a abordagem anterior pode se tornar ineficiente. Este fato foi o principal motivador para o surgimento de uma abordagem mais recente para a

determinação do limiar ótimo, a qual faz uso da entropia relativa, também conhecida como entropia cruzada. Esta entropia, que é amplamente utilizada na área de codificação para avaliar o descasamento entre duas fontes, fornece um critério para medir a discrepância entre duas distribuições de probabilidade. Para a limiarização de imagens, em especial, obtém-se a discrepância entre a imagem original e o resultado de sua segmentação, e o limiar ótimo é determinado como o nível que minimiza a entropia. Os métodos propostos por LI & LEE (1993), CHANG et al. (1994), BRINK & PENDOCK (1996) e PAL (1996) utilizam esta abordagem para determinarem o limiar ótimo e são apresentados nas subseções a seguir.

2.3.1.3.1. Método Proposto por LI & LEE (1993)

LI & LEE (1993) definem a entropia relativa por:

$$H_{CE_T} = \sum_{i=0}^T i \cdot f(i) \cdot \log \frac{i}{b_1} + \sum_{i=T+1}^{L-1} i \cdot f(i) \cdot \log \frac{i}{b_2}, \quad (2-24)$$

onde L é o número de níveis de cinza da imagem; b_1 e b_2 são os níveis de cinza que

compõem a imagem binarizada, que são dados por $b_1 = \frac{\sum_{i=0}^T i \cdot f(i)}{\sum_{i=0}^T f(i)}$ e $b_2 = \frac{\sum_{i=T+1}^{L-1} i \cdot f(i)}{\sum_{i=T+1}^{L-1} f(i)}$; e

$f(i)$ é a frequência de ocorrência do nível i . O limiar ótimo T^* é selecionado por $T^* = \min(H_{CE_T})$.

2.3.1.3.2. Método Proposto por CHANG et al. (1994)

CHANG et al. (1994) consideram a definição genérica da entropia relativa para a proposição do critério para a determinação do limiar ótimo. Em sua forma genérica, a entropia relativa é dada por:

$$H_{CE}(p_i, q_i) = \sum_{i=0}^{L-1} p_i \log \frac{p_i}{q_i}, \quad (2-25)$$

onde p é uma distribuição de probabilidade *a priori* (no caso, a imagem original) e q é uma distribuição de probabilidade *a posteriori* (no caso, a imagem binarizada).

Expandindo (2-25), tem-se:

$$H_{CE}(p_i, q_i) = \sum_{i=0}^{L-1} p_i \log p_i - \sum_{i=0}^{L-1} p_i \log q_i. \quad (2-26)$$

Como o primeiro termo de (2-26) é independente do nível de limiar, a minimização da entropia é equivalente a maximizar o segundo termo da mesma equação. Estes termos são obtidos através da matriz de co-ocorrência entre os níveis de cinza dos pixels e de suas vizinhanças.

2.3.1.3.3. Método Proposto por BRINK & PENDOCK (1996)

BRINK & PENDOCK (1996) impõem simetria à função da entropia relativa e a definem como:

$$H_{CE_T} = \sum_{i=i_{\min}}^T f(i) \left[b_1 \cdot \log \frac{b_1}{i} + i \cdot \log \frac{i}{b_1} \right] + \sum_{i=T+1}^{i_{\max}} f(i) \left[b_2 \cdot \log \frac{b_2}{i} + i \cdot \log \frac{i}{b_2} \right], \quad (2-27)$$

onde $i_{\min}$ e $i_{\max}$ são os níveis de cinza mínimo e máximo, respectivamente, da imagem; $f(i)$ é a frequência de ocorrência do nível de cinza i ; e b_1 e b_2 são os níveis de cinza da imagem binarizada, dados por $b_1 = \sum_{i=i_{\min}}^T i \cdot p(i)$ e $b_2 = \sum_{i=T+1}^{i_{\max}} i \cdot p(i)$. Após iteragir sobre todos os possíveis valores de T , determina-se o limiar ótimo no nível que minimiza H_{CE_T} .

2.3.1.3.4. Método Proposto por PAL (1996)

PAL (1996) enfatiza a definição da entropia relativa como um tipo de informação da distância entre duas distribuições de probabilidade e com isso aponta uma falha conceitual na proposta de LI & LEE (1993). Segundo o autor, no método referido, os níveis de cinza são utilizados diretamente na equação da entropia relativa e, visto que os termos do conjunto de níveis, com exceção dos dois primeiros, são maiores que a unidade, tal conjunto não pode ser considerado uma distribuição de probabilidade. Como proposta à solução, o autor considera a equação genérica e simétrica da entropia relativa, para as distribuições de probabilidade P e Q . Assim:

$$H_{CE}(P, Q) = \sum_{i=0}^{L-1} p_i \log \frac{p_i}{q_i} + \sum_{i=0}^{L-1} q_i \log \frac{q_i}{p_i}. \quad (2-28)$$

Considerando o nível de limiar T , a distribuição de probabilidade P é obtida diretamente da imagem e pode ser dividida em $P^O = \{p^O(0), p^O(1), \dots, p^O(T)\}$ como a distribuição dos níveis na região do objeto e $P^F = \{p^F(T+1), p^F(T+2), \dots, p^F(L-1)\}$ como a distribuição dos níveis de cinza na região de fundo, onde:

$$p^O(i) = \frac{f(i)}{\sum_{i=0}^T f(i)}, i=0, 1, \dots, T$$

e

$$p^F(i) = \frac{f(i)}{MN - \sum_{j=0}^T f(j)}, i=T+1, T+2, \dots, L-1,$$

sendo M e N as dimensões da imagem. A distribuição Q , que também é dividida em Q^O e Q^F , é estimada baseando-se em algum modelo, como por exemplo a distribuição Poisson.

A partir dessas distribuições, redefine-se a entropia como:

$$H_{CE_T}(P, Q) = H_{CE_T}^O(P^O, Q^O) + H_{CE_T}^F(P^F, Q^F). \quad (2-29)$$

O nível de cinza que minimiza esta equação é definido como o limiar ótimo.

2.3.2. Métodos Locais

Os métodos locais, como já mencionado na seção 2.3., dividem a imagem original em subimagens para que, em cada subimagem, seja determinado o limiar ótimo e aplicado o processo de segmentação. A divisão da imagem em subimagens pode ser feita, basicamente, de duas maneiras: a primeira por “fatiar” a imagem original em regiões quadriláteras iguais, não-sobrepostas, formando uma espécie de grade. Cada componente desta grade é, agora, considerada uma nova imagem. Para evitar possíveis descontinuidades nas bordas de subimagens subseqüentes, pode-se fazer a divisão acima sobrepondo-se as subimagens. A segunda forma de dividir a imagem original é fazer percorrer uma janela de certa dimensão, pixel a pixel, através da imagem e considerar cada deslocamento da janela como uma subimagem.

Intuitivamente fica claro que esses métodos envolvem um alto custo computacional. Porém, por trabalharem com regiões muito inferiores, comparadas à imagem original, podem fornecer segmentações de melhor qualidade, principalmente quando se quer destacar pequenos detalhes da imagem. Isto gera uma relação custo/benefício quanto à sua aplicação, que deve ser decidida pelo usuário, ou pelo nível de exigência da aplicação.

A literatura a respeito de limiarização local não é muito vasta e muitas vezes os métodos são desenvolvidos após a verificação de que os globais falham para a imagem que se deseja segmentar.

YANOWITZ & BRUCKSTEIN (1989) combinam a informação dos níveis de cinza com a informação do gradiente da imagem para determinar a superfície de limiarização. Inicialmente suavizam a imagem original através da aplicação de um filtro de média, derivam a imagem de magnitudes do gradiente e aplicam um limiar a esses gradientes para determinar seus pontos de máximos locais. Os níveis de cinza correspondentes a esses pontos são considerados bons candidatos a limiar local. Para obter a superfície de limiarização, amostram os pontos de máximo gradiente na imagem suavizada e, a partir de um conhecimento prévio dos níveis de cinza dos pixels de borda da imagem, interpolam esses valores por toda a imagem. Após obtida a superfície de limiarização, segmentam a imagem.

TRIER & TAXT (1995) realizam um estudo de avaliação de onze métodos de binarização local. Essa avaliação é realizada como base para a implementação de uma das etapas de um sistema de digitalização automática de mapas, que é constituído pelas fases de aquisição e binarização da imagem e reconhecimento de símbolos, linhas e textos. Como o tipo de imagem para essa aplicação geralmente não é de boa qualidade e também os objetos constituintes têm uma dimensão muito pequena, os autores chegam à conclusão que se faz necessário trabalhar com métodos de binarização que rotule corretamente toda a informação presente, mesmo em áreas de baixo contraste, e que também seja insensível a variações de intensidade do fundo e a ruídos estocásticos. Para assegurar que o limiarização global é insuficiente para segmentar imagens de mapas adequadamente, os autores envolvem quatro métodos de binarização global na avaliação.

LIE (1995) desenvolve um algoritmo de limiarização localmente adaptativo, aplicado à extração de alvos de um dado campo de fundo. O método se propõe a resolver as deficiências dos métodos convencionais globais, baseados no histograma, em detectar pequenos alvos que, possivelmente, têm baixo contraste. Isto é feito pela introdução de uma medida de conectividade de forma baseada em estatística de segunda ordem, através da co-ocorrência, para avaliação do limiar. Além disso, é proposto um paradigma de processamento local baseado na varredura da imagem por uma janela, enfatizando-se três aspectos: o modo de sobreposição da janela para prevenir a fragmentação dos alvos, a identificação local da situação “não-alvo”, eliminando assim os possíveis ruídos, e a combinação de limiares locais, ao invés de técnicas de interpolação ou filtragem. Uma informação a priori de alvo/fundo é usada para ajudar a localizar pequenos alvos.

Métodos locais também são obtidos através da aplicação de métodos globais a uma certa região da imagem, após a subdivisão desta imagem.

Neste trabalho, métodos de limiarização global (KAPUR et al., 1985; SHANBHAG, 1994) foram, inicialmente, testados para a segmentação das seções transversais dos axônios. Entretanto, os resultados obtidos não foram satisfatórios visto que os métodos não conseguiram separar todos os axônios do espaço endoneural, principalmente em se tratando das pequenas fibras. Decidiu-se, então, testar esses mesmos métodos em uma abordagem local, fazendo percorrer uma janela pela imagem e determinando o limiar a cada deslocamento da janela. Este limiar apenas era aplicado ao pixel correspondente ao centro da janela. A Figura 2.6, por exemplo, mostra as imagens resultantes da aplicação do método proposto por KAPUR et al. (1985) à imagem da Figura 2.1-a quando se faz percorrer a imagem original, pixel a pixel, por janelas de tamanhos 3×3 , 5×5 , 7×7 e 9×9 . A Figura 2.7 apresenta as imagens resultantes quando o método proposto por SHANBHAG (1994) é aplicado à imagem da Figura 2.1-a com a mesma filosofia apresentada acima e para os mesmos tamanhos de janela.




Figura 2.6: Imagens resultantes da aplicação do método de KAPUR et al. (1985) à imagem da Figura 2.1-a, em uma abordagem local, quando consideradas janelas de dimensões: (a) 3×3 ; (b) 5×5 ; (c) 7×7 ; (d) 9×9 .




Figura 2.7: Imagens resultantes da aplicação do método de SHANBHAG (1994) à imagem da Figura 2.1-a, em uma abordagem local, quando consideradas janelas de dimensões: (a) 3×3 ; (b) 5×5 ; (c) 7×7 ; (d) 9×9 .

Capítulo 3

Transformações Baseadas na Morfologia Matemática

3.1. Introdução

A palavra morfologia, já bastante conhecida e de significado muito difundido, quando usada em conjunto com a palavra matemática denota uma ferramenta de extração de componentes em imagens digitais que são úteis na representação e descrição da forma da região. A morfologia matemática pode ser definida como um conjunto de técnicas não-lineares baseadas em operações de forma. Suas bases foram lançadas em 1964 pelos pesquisadores Georges Matheron e Jean Serra na Escola Nacional Superior de Minas de Paris (SERRA, 1982).

Diferentemente do processamento linear, que tem o espaço vetorial e a adição como estrutura e lei fundamentais, respectivamente, a morfologia matemática utiliza o reticulado completo como estrutura básica e o supremo e o ínfimo como leis fundamentais. A linguagem da morfologia matemática é a teoria de conjuntos.

A morfologia matemática vem se tornando, cada vez mais, uma ferramenta poderosa no processamento de imagens, sejam estas imagens binárias ou não. Neste trabalho, entretanto, será considerada apenas a aplicação da morfologia matemática a imagens binárias.

Cinco são as operações básicas da morfologia matemática: a erosão, a dilatação, a união, a interseção e a complemento. As outras operações podem ser geradas a partir de composições dessas cinco. A filosofia empregada nas operações

de dilatação e erosão é percorrer uma imagem por um elemento estruturante fazendo a verificação de possíveis inclusões deste elemento.

Neste capítulo, inicialmente são introduzidos alguns conceitos básicos da Morfologia Matemática para que, em seguida, algumas transformações baseadas nesta técnica sejam apresentadas.

3.2. Reticulado Completo e Elemento Estruturante

O reticulado completo, que é a estrutura básica para a utilização da morfologia matemática, pode ser entendido como conjuntos $P(E)$, onde E representa um espaço ou conjunto arbitrário, tais que existe uma relação de ordem parcial, chamada inclusão, e para cada família, finita ou não, de elementos pertencentes a $P(E)$ existe um supremo e um ínfimo (SERRA, 1986). Neste ponto, vale recordar que o supremo é o menor dos limitantes superiores e o ínfimo, o maior dos limitantes inferiores.

O elemento estruturante é um conjunto completamente definido e conhecido (forma, tamanho) que é comparado, a partir de uma transformação, ao conjunto desconhecido da imagem (FACON, 1996).

3.3. Dilatação e Erosão

Antes de definir estas duas operações, faz-se necessário o entendimento de translação de conjuntos.

A translação de um subconjunto $B \in P(E)$ é dada por:

$$B + u = \{b + u \mid b \in B\} \in P(E), \quad \forall b \in B.$$

A dilatação de um conjunto $A \in P(E)$ por um elemento estruturante $B \in P(E)$ pode ser definida como o lugar das posições do centro do elemento estruturante B , quando B intercepta A . Em termos matemáticos:

$$\delta_B(A) = A \oplus B, \quad (3-1)$$

onde $A \oplus B$ é a soma de Minkowski, que é dada por:

$$A \oplus B = \{a + b / a \in A \text{ e } b \in B\}. \quad (3-2)$$

A Figura 3.1 mostra um exemplo do processo de dilatação morfológica quando utilizado um disco de diâmetro 20 como elemento estruturante. A Figura 3.1-a apresenta a imagem original; a Figura 3.1-b apresenta uma ilustração do processo, onde os pontos em cinza escuro representam o elemento estruturante, os pontos em cinza claro representam as regiões resultantes da dilatação, e os pontos em branco dentro das regiões em cinza claro representam os contornos das regiões na imagem original; e a Figura 3.1-c apresenta a imagem resultante do processo.




Figura 3.1: Processo de dilatação morfológica: (a) Imagem original; (b) Ilustração da transformação; (c) Imagem resultante da dilatação da Figura 3.1-a utilizando um elemento estruturante do tipo disco de diâmetro 20.

Já a erosão de um conjunto $A \in P(E)$ por um elemento estruturante $B \in P(E)$ pode ser entendida como o lugar das posições do centro do elemento estruturante B , quando B está incluído no conjunto A . Matematicamente:

$$\varepsilon_B(A) = \{c \in E / (B + c) \subset A\}. \quad (3-3)$$

A Figura 3.2 mostra o processo de erosão morfológica quando utilizado um disco de diâmetro 20 como elemento estruturante. A Figura 3.2-a apresenta a imagem original; a Figura 3.2-b apresenta um exemplo ilustrativo do processo, onde os pontos em branco representam os objetos originais, os pontos em cinza escuro, o

elemento estruturante, e em cinza claro estão representados os pontos das regiões de erosão, propriamente ditas; e a Figura 3.2-c apresenta a imagem resultante do processo.




Figura 3.2: Processo de erosão morfológica: (a) Imagem original; (b) Visualização da transformação; (c) Imagem resultante da erosão da imagem da Figura 3.2-a quando utilizado um elemento estruturante do tipo disco de diâmetro 20.

3.3.1. Propriedades da Dilatação e da Erosão

Considerando os conjuntos $A \in P(E)$ e $X \in P(E)$ e o elemento estruturante $B \in P(E)$, as propriedades da dilatação e erosão são as seguintes:

1) Dualidade:

As transformações morfológicas ocorrem aos pares; quando se define uma transformação genérica ψ , introduz-se também, pelo mesmo ato, outra transformação ψ^* chamada a dual de ψ (SERRA, 1986). Desta forma, tem-se que a erosão é dual à dilatação, ou vice-versa, isto é:

$$\varepsilon_B(A) = \left(\delta_B(A^c) \right)^c \quad (3-4)$$

ou

$$\delta_B(A) = \left(\varepsilon_B(A^c) \right)^c, \quad (3-5)$$

onde o sobrescrito C denota o complemento.

2) *Extensividade:*

Se a origem do elemento estruturante está contida nele próprio, isto é, se $\vec{O} \in B$, então:

$$\varepsilon_B(A) \subset A$$

e

$$\delta_B(A) \supset A ,$$

o que significa que a erosão é uma transformação anti-extensiva e a dilatação, extensiva.

3) *Crescentes:*

Se $A \subset X$, então:

$$\varepsilon_B(A) \subset \varepsilon_B(X)$$

e

$$\delta_B(A) \subset \delta_B(X).$$

4) *Comutação:*

Por definição a erosão comuta com a interseção e a dilatação comuta com a união, isto é:

$$\varepsilon_B(A \cap X) = \varepsilon_B(A) \cap \varepsilon_B(X) \quad (3-6)$$

e

$$\delta_B(A \cup X) = \delta_B(A) \cup \delta_B(X). \quad (3-7)$$

5) *Separabilidade:*

$$\varepsilon_{B_1}(\varepsilon_{B_2}(A)) = \varepsilon_W(A) , \quad W = \delta_{B_1}(B_2)$$

e

$$\delta_{B_1}(\delta_{B_2}(A)) = \delta_W(A) , \quad W = \delta_{B_1}(B_2).$$

Esta propriedade permite que erosões ou dilatações por elementos estruturantes muito grandes possam ser obtidas pela composição de erosões ou dilatações por uma série de elementos estruturantes de menores dimensões, apropriadamente escolhidos. Isto é muito vantajoso em termos de velocidade de processamento.

3.4. Abertura e Fechamento

Devido ao fato de as transformações morfológicas serem não-lineares, transformações inversas a elas não existem. Se é feita uma composição de uma erosão seguida de uma dilatação, por exemplo, tem-se o que se chama de abertura morfológica. Então, a abertura morfológica de um conjunto $A \in P(E)$, por um elemento estruturante $B \in P(E)$, é dada por:

$$\gamma_B(A) = \delta_B(\varepsilon_B(A)). \quad (3-8)$$

A abertura morfológica pode ser entendida como a união de todas as versões transladadas do elemento estruturante que “encaixam” dentro da imagem (BRAGA NETO, 1994). Em termos matemáticos:

$$\gamma_B(A) = \bigcup \{ (B + a) \subset A \}. \quad (3-9)$$

A Figura 3.3 mostra um exemplo do processo de abertura morfológica quando utilizado um disco de diâmetro 10 como elemento estruturante. A Figura 3.3-a apresenta a imagem original; a Figura 3.3-b ilustra o procedimento, onde os pontos em branco representam o objeto original, os pontos em cinza escuro, o elemento estruturante, e em cinza claro estão representados os pontos da região resultante da abertura; e, enfim, a Figura 3.3-c apresenta a imagem resultante do processo.




Figura 3.3: Processo de abertura morfológica: (a) Imagem original; (b) Ilustração da transformação; (c) Imagem resultante da abertura da imagem da Figura 3.3-a quando utilizado um elemento estruturante do tipo disco de diâmetro 10.

Como foi visto na seção 3.3.1., a cada transformação morfológica tem-se automaticamente sua dual. A transformação dual da abertura se chama fechamento morfológico e é definido por:

$$\varphi_B(A) = \left[\gamma_B(A^c) \right]^c \quad (3-10)$$

ou

$$\varphi_B(A) = \varepsilon_B(\delta_B(A)). \quad (3-11)$$

A Figura 3.4 mostra um exemplo da transformação fechamento morfológico quando utilizado um disco de diâmetro 10 como elemento estruturante. A Figura 3.4-a apresenta a imagem original; a Figura 3.4-b apresenta uma ilustração do processo, onde os pontos em cinza escuro representam o elemento estruturante, os pontos em cinza claro representam as regiões resultantes do fechamento, e os pontos em branco dentro das regiões em cinza claro representam os contornos das regiões na imagem original; e a Figura 3.4-c apresenta a imagem resultante do processo.




Figura 3.4: Fechamento morfológico: (a) Imagem original; (b) Ilustração da transformação; (c) Imagem resultante do fechamento da imagem da Figura 3.4-a, quando utilizado um elemento estruturante disco de diâmetro 10.

3.4.1. Propriedades da Abertura e do Fechamento

Assim como a erosão e a dilatação, a abertura e o fechamento têm propriedades em comum. Abaixo, estas propriedades são enumeradas, não incluindo

mais a dualidade pelo motivo de esta já ter sido apresentada acima:

1) Crescente:

Por serem composições de operações crescentes (erosão e dilatação), a abertura e fechamento também são transformações crescentes. Assim, se dois conjuntos A e X são considerados, com a relação de ordem $A \subset X$, então:

$$\gamma_B(A) \subset \gamma_B(X)$$

e

$$\phi_B(A) \subset \phi_B(X).$$

2) Extensividade:

O fechamento, igualmente à dilatação, é extensivo e a abertura, igualmente à erosão, é anti-extensiva:

$$\gamma_B(A) \subset A$$

e

$$\phi_B(A) \supset A.$$

3) Idempotência:

Tanto a abertura quanto o fechamento são operações idempotentes, isto é:

$$\gamma_B(\gamma_B(A)) = \gamma_B(A)$$

e

$$\phi_B(\phi_B(A)) = \phi_B(A).$$

É pela propriedade da idempotência que a abertura e o fechamento diferem da erosão e da dilatação. Esta propriedade é muito importante para o processo de filtragem (FACON, 1996), já que um filtro morfológico se caracteriza por toda transformação crescente e idempotente. Desta forma, então, é que a abertura e o fechamento são considerados filtros morfológicos.

3.5. Reconstrução

Para a definição da operação reconstrução, faz-se necessário falar de outra transformação morfológica, a dilatação geodésica, ou condicional. Define-se,

matematicamente, a dilatação geodésica de um conjunto $A \in P(E)$ por um elemento estruturante $B \in P(E)$, condicional ao conjunto $H \in P(E)$, como:

$$\delta_{B,H}(A) = \delta_B(A) \cap H. \quad (3-12)$$

Observa-se que operações de dilatação geodésica sucessivas em A sempre convergirão para um novo conjunto. Depois que a convergência é atingida, a operação se torna idempotente. Ao resultado destas sucessivas dilatações geodésicas, até atingir a convergência, é dado o nome de reconstrução. Na reconstrução, o conjunto inicial A é conhecido como o conjunto dos marcadores. O resultado da reconstrução representa os componentes conexos de H que têm alguma conectividade com os marcadores. Se o conjunto $M \in P(E)$ é considerado como o conjunto dos marcadores e $B \in P(E)$, como o elemento estruturante, a reconstrução de M por B , condicional ao conjunto $A \in P(E)$, é expressa por:

$$\rho_{B,M}(A) = \delta_{B,A}(\delta_{B,A}(\dots(\delta_{B,A}(M))\dots)). \quad (3-13)$$

Da forma como está escrita, a equação 3-13 pode induzir que o número de dilatações requerido para o processo de reconstrução seja infinito. Entretanto, deve-se ter claro de que tal processo é alcançado com um número finito de dilatações, que depende do elemento estruturante utilizado. A escolha do elemento estruturante desempenha um papel importante no processo, pois especifica a regra de conectividade utilizada. Os elementos estruturantes mais utilizados são conectividade 4 e 8.

Verificando-se as propriedades da reconstrução, é possível classificá-la como uma abertura algébrica, que se caracteriza por todo filtro morfológico anti-extensivo.

O conjunto M , de marcadores, é fixo durante a operação e pode ser obtido por vários processos, como por exemplo, erosão do conjunto original A , ou mesmo de forma manual.

A Figura 3.5 apresenta um exemplo da transformação de reconstrução, para um conjunto de marcadores obtidos manualmente.




Figura 3.5: Processo de reconstrução: (a) Imagem original; (b) Imagem dos marcadores (obtidos manualmente); (c) Imagem resultante da reconstrução da imagem na Figura 3.5-b, condicional à imagem da Figura 3.5-a, utilizando um elemento estruturante de conectividade 4.

3.6. Fechamento de Buracos

Esta operação, como o próprio nome diz, tem como intenção eliminar os buracos das regiões conexas em uma imagem. O processo consiste em fazer uma reconstrução no complemento da imagem original, utilizando uma imagem *frame* como o conjunto marcador e depois obtendo-se o complemento deste resultado. O fechamento de buracos de um conjunto A por um elemento estruturante B , a partir de um *frame* F é dado por (BARRERA et al., 1994):

$$\Phi_B(A) = \left[\rho_{B,F}(A)^c \right]^c, \quad (3-14)$$

onde *frame* é uma imagem onde todos os pixels de borda têm nível de cinza máximo e todos os outros pixels têm nível de cinza zero.

A Figura 3.6 mostra um exemplo da transformação fechamento de buracos, utilizando-se um elemento estruturante de conectividade 4.



Figura 3.6: Exemplo do processo de fechamento de buracos.

3.7. Esqueletização por Afinamento

Para entender esta operação morfológica, é necessário definir duas outras: a operação *hit-miss* (SERRA, 1986) e a operação afinamento. A operação *hit-miss* é uma generalização das transformações do tipo erosão ou dilatação, que utiliza um par de elementos estruturantes disjuntos $\{B_1, B_2\} \in P(E)$. Ela consiste em testar as partes interna e externa de um conjunto. Isto é conseguido por testar um conjunto A a partir do elemento estruturante B_1 e o conjunto complementar A^c a partir do elemento estruturante B_2 . A transformação *hit-miss* de um conjunto A pelos elementos B_1 e B_2 é dada por:

$$\lambda_{B_1, B_2}(A) = \varepsilon_{B_1}(A) \cap \varepsilon_{B_2}(A^c). \quad (3-15)$$

A transformação de afinamento é definida como o resíduo entre o conjunto inicial e sua transformação por *hit-miss*, ou ainda, a interseção entre o conjunto inicial e o complemento de sua transformada de *hit-miss*. Desta forma, o afinamento do conjunto A pelos mesmos elementos estruturantes anteriormente considerados é dada por:

$$\sigma(A) = A \cap [\lambda_{B_1, B_2}(A)]^c. \quad (3-16)$$

O afinamento homotópico é utilizado, na morfologia matemática, para construir transformações que conservem a homotopia. Dois conjuntos são

homotópicos se são topologicamente equivalentes, isto é, têm o mesmo número de elementos e cada elemento de um conjunto possui um correspondente no outro conjunto com relação ao número de buracos e ilhas que possui.

A esqueletização por afinamento é definida por sucessivos afinamentos no mesmo conjunto, quando os elementos estruturantes sofrem rotação a cada passo. Neste processo de esqueletização, a escolha dos elementos estruturantes é muito importante. De acordo com o par de elementos utilizados, diferentes tipos de esqueleto são obtidos. Se o par de elementos utilizados é o apresentado na Figura 3.7, obtém-se o esqueleto homotópico. A Figura 3.8 apresenta um exemplo da transformação esqueletização homotópica.




Figura 3.7: Elementos estruturantes utilizados para a obtenção do esqueleto homotópico: (a) B_1 ; (b) B_2 .




Figura 3.8: Esqueletização homotópica: (a) Imagem original; (b) Imagem resultante da esqueletização, quando utilizados os elementos estruturantes apresentados na Figura 3.7.

Se o par de elementos utilizados é o apresentado na Figura 3.9, o resultado do processo de esqueletização por afinamento é uma imagem composta pelos contornos

dos objetos da imagem original. A Figura 3.10 apresenta um exemplo desta esqueletização, aplicada à imagem da Figura 3.8-a.




Figura 3.9: Elementos estruturantes utilizados para a obtenção dos contornos dos objetos de uma imagem no processo de esqueletização por afinamento: (a) B_1 ; (b) B_2 .




Figura 3.10: Esqueletização da imagem da Figura 3.8-a, quando utilizados os elementos estruturantes apresentados na Figura 3.9.

Capítulo 4

Classificador *Fuzzy*

4.1. Introdução

Um sistema *fuzzy* fornece um mecanismo para converter uma estratégia descrita lingüisticamente em um algoritmo computacional. A abordagem via sistemas *fuzzy* é útil quando os processos são muito complexos para análise por técnicas quantitativas convencionais ou quando as fontes de informação disponíveis são interpretadas de forma qualitativa, inexata ou incerta.

Desde 1974, quando as primeiras aplicações de sistemas *fuzzy* foram relatadas, muitos avanços têm sido alcançados, seja no campo experimental ou industrial. PEDRYCZ (1993) distingue duas fases no desenvolvimento de sistemas *fuzzy*: a primeira concentrada nos experimentos laboratoriais e desenvolvimento de protótipos, com relativamente raras instalações industriais. A segunda, começando no final dos anos 80, com um vasto número de aplicações comerciais. Alguns exemplos da aplicação *fuzzy* podem ser encontrados nas ciências naturais, sociais, engenharia, medicina, e muitas outras áreas (KLIR & FOLGER, 1988).

Neste capítulo, são apresentadas as noções básicas da teoria de conjuntos *fuzzy*, definindo-se algumas operações com estes conjuntos e, na sequência, são descritos o princípio básico de operação de um sistema *fuzzy* e as partes constituintes deste sistema, quando considerada uma configuração básica. O objetivo deste capítulo é fornecer as bases para a implementação de um sistema classificador baseado em regras *fuzzy*.

4.2. Noções da Teoria de Conjuntos Fuzzy

4.2.1. Lógica Fuzzy

Lógica é a ciência dos princípios formais normativos do raciocínio (ZADEH, 1978, *apud* BUCK, 1990). Lógica *fuzzy*, especificamente, é a parte da lógica matemática que concerne aos princípios formais do raciocínio incerto ou aproximado, e que por isso mesmo está mais próxima em espírito ao pensamento humano e linguagem natural (LEE, 1990). Ela se baseia na teoria dos conjuntos *fuzzy* e difere dos sistemas lógicos tradicionais em suas características (GOMIDE & GUDWIN, 1994).

A lógica *fuzzy* fornece as bases para o que pode ser chamado de raciocínio aproximado, que é o modo de raciocínio no qual os valores verdade e as regras de inferência são imprecisos ao invés de precisos.

4.2.2. Conjunto Fuzzy

A noção de conjuntos *fuzzy* foi inicialmente apresentada por Zadeh com o objetivo de definir conjuntos que não possuem bordas, ou fronteiras, bem definidas (ZADEH, 1965, *in* ZADEH, 1987).

Seja U uma coleção de objetos denotados genericamente por $\{u\}$. U é chamado de universo de discurso, podendo ser discreto ou contínuo, e u representa um elemento genérico de U . Desta forma, um conjunto *fuzzy* A no universo de discurso U é caracterizado pela função de pertinência μ_A que associa cada ponto em U a um número real no intervalo $[0,1]$, onde o valor de $\mu_A(u)$ representa o grau de pertinência do elemento u em relação ao conjunto A . Um grau de pertinência 0 indica uma total exclusão do elemento ao conjunto e um grau de pertinência 1 indica uma completa pertinência do elemento ao conjunto. Mais claramente, um conjunto *fuzzy* A em U pode ser representado como um conjunto de pares ordenados de um

elemento genérico u e seu grau de pertinência, isto é, $A = \{(u, \mu_A(u)) \mid u \in U\}$. Por exemplo, se o universo U é considerado como os inteiros positivos e por A deseja-se representar o conjunto de números muito maiores que 10, então uma possível representação de A seria:

$$A = \{(10, 0), (50, 0.01), (100, 0.2), (1000, 0.95), (5000, 1)\}.$$

4.2.2.1. Suporte de um Conjunto Fuzzy

O suporte de um conjunto *fuzzy* A é definido como o conjunto ordinário dos elementos u em U tais que $\mu_A(u) > 0$. Para exemplificar, o suporte do conjunto A apresentado acima é dado por:

$$\text{sup}(A) = \{50, 100, 1000, 5000\}$$

Um conjunto *fuzzy* cujo suporte é um único ponto no universo U , com $\mu_A = 1$, é referido como um conjunto unitário *fuzzy* (*fuzzy singleton*).

4.2.2.2. Número Fuzzy

Um número *fuzzy* F em um universo de discurso contínuo U é um conjunto *fuzzy* F em U que é normal e convexo, isto é,

$$\max_{u \in U} \mu_F(u) = 1 \quad (\text{normal})$$

e

$$\mu_F[\lambda u_1 + (1 - \lambda)u_2] \geq \min[\mu_F(u_1), \mu_F(u_2)], \quad u_1, u_2 \in U, \lambda \in [0, 1]. \quad (\text{convexo})$$

A Figura 4.1 mostra um exemplo de número *fuzzy*, enquanto a Figura 4.2 mostra um exemplo de conjunto *fuzzy* não-convexo.




Figura 4.1: Exemplo de número fuzzy.




Figura 4.2: Exemplo de conjunto fuzzy não-convexo.

4.3. Algumas Operações com Conjuntos Fuzzy

Sejam A e B dois conjuntos fuzzy no universo U com funções de pertinência μ_A e μ_B , respectivamente. As operações de união, interseção e complemento são definidas através de duas funções de pertinência. A seguir são apresentadas algumas operações básicas para conjuntos fuzzy:

União

Na união, a função de pertinência $\mu_{A \cup B}$ é definida ponto a ponto para todo $u \in U$ por:

$$\mu_{A \cup B}(u) = \max \{ \mu_A(u), \mu_B(u) \}.$$

Interseção

A função de pertinência da interseção $\mu_{A \cap B}$ é definida ponto a ponto para todo $u \in U$ por:

$$\mu_{A \cap B}(u) = \min \{ \mu_A(u), \mu_B(u) \}.$$

Complemento

Para o complemento de um conjunto *fuzzy*, a função de pertinência $\mu_{\bar{A}}$ é definida ponto a ponto para todo $u \in U$ por:

$$\mu_{\bar{A}}(u) = 1 - \mu_A(u).$$

Produto Cartesiano

Se $A_1, \dots, A_n$ são conjuntos *fuzzy* em $U_1, \dots, U_n$, respectivamente, o produto cartesiano desses conjuntos, $A_1 \times A_2 \times \dots \times A_n$, é um conjunto *fuzzy* em $U_1 \times \dots \times U_n$ com função de pertinência definida por:

$$\mu_{A_1 \times A_2 \times \dots \times A_n}(u_1, u_2, \dots, u_n) = \mu_{A_1}(u_1) \cdot \mu_{A_2}(u_2) \cdot \dots \cdot \mu_{A_n}(u_n)$$

ou

$$\mu_{A_1 \times A_2 \times \dots \times A_n}(u_1, u_2, \dots, u_n) = \min \{ \mu_{A_1}(u_1), \mu_{A_2}(u_2), \dots, \mu_{A_n}(u_n) \}.$$

Relação Fuzzy

Uma relação *fuzzy* n -ária é um conjunto *fuzzy* em $U_1 \times \dots \times U_n$ e expressa por:

$$R_{U_1 \times \dots \times U_n} = \{ ((u_1, \dots, u_n), \mu_R(u_1, \dots, u_n)) \mid (u_1, \dots, u_n) \in U_1 \times \dots \times U_n \}$$

Composição Sup-*

Se R e S são relações *fuzzy* em $U \times V$ e $V \times W$, respectivamente, a composição de R e S é uma relação *fuzzy* denotada por $R \circ S$ e definida por:

$$R \circ S = \left\{ \left[(u, w), \sup_v (\mu_R(u, v) * \mu_S(v, w)) \right], u \in U, v \in V, w \in W \right\},$$

onde $*$ pode ser um operador do tipo *mínimo*, ou *produto algébrico*, ou *produto drástico*, por exemplo.

4.4. Variáveis Lingüísticas

Uma variável lingüística pode ser entendida como uma variável cujos valores são palavras ou sentenças em uma linguagem natural ou artificial e que, no caso de ser

fuzzy, são modeladas por conjuntos *fuzzy*. Cada variável lingüística envolve uma coleção finita, geralmente pequena, de termos lingüísticos genéricos (às vezes chamados de termos primários). Segundo ZADEH (1975, *in* ZADEH, 1987), uma variável lingüística é formalmente definida pela quintupla $(\alpha, T(\alpha), U, G, M)$ na qual α é o nome da variável; $T(\alpha)$ é a coleção de termos de α , isto é, o conjunto dos valores lingüísticos de α ; U é o universo de discurso no qual os termos são definidos; G é uma regra sintática para gerar os termos de $T(\alpha)$; e M é uma regra semântica para associar a função de pertinência de cada termo lingüístico.

Na regra sintática, os modificadores desempenham um importante papel. Os modificadores são termos que em combinação com os primários formam novos termos lingüísticos. Exemplos de modificadores são: *muito*, *pouco*, *muito pouco*, *mais ou menos*, etc. Para uma variável chamada *velocidade*, por exemplo, pode-se definir os termos *muito baixa*, *baixa*, *nula*, *alta* e *muito alta*.

4.5. Mecanismos de Inferência Fuzzy

A inferência *fuzzy* é realizada de modo que, a partir de uma série de regras e de proposições *fuzzy*, seja possível deduzir outras proposições *fuzzy* e com elas gerar os sinais de saída após, quando necessário, o processo de *defuzzificação*.

Diversas regras de inferência *fuzzy* podem ser encontradas na literatura, dentre as quais uma das mais importantes é a regra composicional proposta por ZADEH (1973), que é definida a seguir.

4.5.1. Regra Composicional *sup*-* de Inferência

Seja R uma relação *fuzzy* em $U \times V$ e X um conjunto *fuzzy* em U , então o conjunto *fuzzy* Y em V , induzido por X é dado por:

$$Y = X \circ R,$$

onde $X \circ R$ é a composição *sup*-* (seção 4.3) de X com R .

ZADEH (1976, *in* ZADEH, 1987) mostra que impondo certas condições à regra composicional, chega-se ao *modus ponens generalizado*, que é uma generalização da regra básica de inferência da lógica clássica, chamada *modus ponens*. Estas duas últimas diferem entre si principalmente porque os conjuntos envolvidos no *modus ponens generalizado* podem ser *fuzzy*.

O *modus ponens generalizado* é particularmente útil nos sistemas baseados em regras *fuzzy*. Sua forma mais simples é:

proposição:	$x \text{ é } A'$
regra:	$\text{se } x \text{ é } A \text{ então } y \text{ é } B$
proposição:	$y \text{ é } B'$

Algumas regras de inferência *fuzzy* podem ser encontradas em (ZADEH, 1979 *in* ZADEH, 1987). Observa-se ainda que, apesar de muitos métodos se basearem na regra composicional para estabelecerem a inferência *fuzzy*, existem alguns que não seguem este esquema. FIGUEIREDO et al. (1993) analisa a performance de um método não-composicional comparando-a com a performance de duas regras composicionais muito conhecidas.

4.6. Sistema Fuzzy

Como já foi dito na Introdução deste capítulo, o estudo de um sistema *fuzzy* servirá de base para a implementação de um classificador baseado em regras *fuzzy*.

A configuração básica de um sistema baseado em regras *fuzzy* é apresentada na Figura 4.3. Seus principais componentes são: a interface de *fuzzificação*, a base de conhecimento, a lógica de tomada de decisão e a interface de *defuzzificação*. De forma a descrever um sistema, cada um dos componentes principais é caracterizado nas subseções seguintes.




Figura 4.3: Configuração básica de um sistema *fuzzy*.

4.6.1. Interface de *Fuzzificação*

Quando os dados provenientes de um processo são valores *não-fuzzy*, faz-se necessária uma interface de *fuzzificação* para acoplar um sistema *fuzzy* a esse processo. Esta interface é responsável por obter os valores das variáveis de entrada, fazer um escalonamento para adequar esses valores aos universos de discurso correspondentes, e traduzir os valores numéricos de entrada em valores lingüísticos *fuzzy*.

As principais estratégias para traduzir os valores numéricos de entrada são as seguintes (LEE, 1990):

- converter um valor *não-fuzzy* em um *fuzzy singleton* dentro de um certo universo de discurso. Essa estratégia é muito usada visto que é natural e fácil de implementação;
- os dados de entrada são distorcidos randomicamente. Neste caso, o operador de *fuzzificação* deve converter o dado probabilístico em números *fuzzy*;
- utilizar o conceito de números híbridos, que envolve tanto números *fuzzy* quanto números randômicos. Esta estratégia é aplicada, principalmente, a sistemas de larga escala onde algumas observações sobre o sistema são precisas, outras são mensuráveis apenas estatisticamente, e ainda outras requerem ambas caracterizações probabilística e possibilística.

4.6.2. Base de Conhecimento

A base de conhecimento é constituída por dois componentes: a base de dados e a base de regras *fuzzy*.

4.6.2.1. Base de Dados

A base de dados armazena as informações sobre discretizações e normalizações dos universos de discurso, as partições *fuzzy* dos espaços de entrada e saída e as definições de funções de pertinência.

No processo de discretização, a escolha dos níveis de quantização tem uma influência essencial em quão fina pode ser obtida uma decisão do sistema.

A partição *fuzzy* dos espaços de entrada e saída determina o número de termos em que uma variável deve tomar seu valor. O número de termos das variáveis de entrada determina o número máximo de regras *fuzzy* que podem ser construídas. Por exemplo, se num sistema de duas entradas e uma saída, as variáveis de entrada tomam valores em conjuntos com 3 e 5 termos, o sistema pode ter até $3 \times 5 = 15$ regras *fuzzy*. Esta partição, em geral, é pré-definida e não é única. Um procedimento empírico é usualmente necessário à determinação da partição ótima para uma dada aplicação.

Quanto à definição das funções de pertinência, ela pode ser feita de duas maneiras: a primeira, chamada de definição numérica, representa o grau de pertinência de um conjunto *fuzzy* como um vetor de números cuja dimensão depende do grau de discretização. A segunda, chamada definição funcional, expressa a pertinência de um conjunto *fuzzy* por meio de funções, tais como triangulares, trapezoidais, etc. A Figura 4.4 mostra um exemplo de uma função triangular e uma trapezoidal, definidas para o mesmo universo de discurso. Observa-se que funções não-lineares também são admitidas.




Figura 4.4: Exemplos de funções de pertinência: (a) triangular; (b) trapezoidal.

4.6.2.2. Base de Regras

O comportamento dinâmico de um sistema *fuzzy* é caracterizado por um conjunto de regras lingüísticas, freqüentemente derivadas do conhecimento especialista, que usualmente são da forma:

SE (um conjunto de condições é satisfeito) ENTÃO (um conjunto de conclusões pode ser inferido)
ANTECEDENTE
CONSEQÜENTE

Uma vez que os antecedentes e os conseqüentes dessas regras estão associados com conceitos *fuzzy*, eles são geralmente chamados de declarações condicionais *fuzzy*. Desta forma, uma regra *fuzzy* pode ser entendida como uma declaração condicional *fuzzy* na qual o antecedente é uma condição no seu domínio de aplicação e o conseqüente é uma conclusão ou uma ação para o processo ao qual o sistema *fuzzy* está acoplado. Considerando um sistema de duas entradas e uma saída, um exemplo de regra *fuzzy* é apresentado abaixo:

R_i : SE x é A_i e y é B_i ENTÃO z é C_i ,

onde R_i é a i -ésima regra do sistema, x e y são as variáveis de entrada; z é a variável de saída; A_i , B_i e C_i são valores lingüísticos das variáveis x , y e z representadas pelos respectivos conjuntos *fuzzy* nos universos de discurso U , V e W , respectivamente.

A coleção destas regras forma a base, ou conjunto, de regras características de um sistema *fuzzy* baseado em regras.

4.6.3. Lógica de Tomada de Decisão

Esta parte do sistema é responsável por processar os dados *fuzzy* de entrada, conjuntamente com as regras, de modo a inferir as conclusões ou ações *fuzzy*, aplicando o operador e as regras de inferência da lógica *fuzzy*.

Uma regra como a seguinte:

$$\text{SE } (x \text{ é } A_i \text{ e } y \text{ é } B_i) \text{ ENTÃO } (z \text{ é } C_i)$$

é interpretada como uma relação *fuzzy* R_i , definida da seguinte forma:

$$\mu_{R_i}^{\Delta} = \mu_{(A_i \text{ e } B_i \rightarrow C_i)}(u, v, w) = [\mu_{A_i}(u) \text{ e } \mu_{B_i}(v)] \rightarrow \mu_{C_i}(w),$$

onde $(A_i \text{ e } B_i)$ é um conjunto *fuzzy* $A_i \times B_i$ em $U \times V$; $R_i^{\Delta} = (A_i \text{ e } B_i) \rightarrow C_i$ é uma relação *fuzzy* em $U \times V \times W$; e $\rightarrow$ denota a semântica que define R_i . Se as entradas do sistema são adotadas como conjuntos unitários *fuzzy* (seção 4.2.2.1.), o processo de inferência fica simplificado, bastando interpretar o conectivo “e” do antecedente e a semântica de “ $\rightarrow$ ”.

O conectivo “e” pode ser interpretado, por exemplo, pelos operadores mínimo ou produto. Desta forma, o conjunto *fuzzy* $(A_i \text{ e } B_i)$ tem a função de pertinência dada por:

$$\mu_{A \times B}(u, v) = \min \{ \mu_A(u), \mu_B(v) \}$$

ou

$$\mu_{A \times B}(u, v) = \mu_A(u) \cdot \mu_B(v).$$

Para interpretar a semântica de $\rightarrow(R_i)$, vários operadores podem ser utilizados, dentre os quais o produto algébrico (relação de Larsen) e o mínimo (relação de Mamdani).

Além disso, o comportamento do sistema é caracterizado pelo conjunto das relações *fuzzy* associadas às regras. Desta forma, o sistema como um todo é representado por uma única relação *fuzzy* que é uma combinação de todas as relações *fuzzy* provenientes de todas as regras. Esta combinação envolve um operador de agregação:

$$R = \text{agreg}(R_1, R_2, \dots, R_n).$$

Embora exista uma ampla classe de operadores de agregação (LEE, 1990), o operador máximo é usualmente utilizado.

4.6.3.1. Exemplo Ilustrativo do Processo de Inferência Fuzzy

Para ilustrar o processo de inferência, seja considerado um sistema de duas variáveis de entrada e uma de saída, cuja base de regras é apresentada na TABELA 4-I.

TABELA 4-I: Base de regras utilizada para o exemplo ilustrativo do processo de inferência fuzzy

		x	
		A ₁	A ₂
y	B ₁	C ₁	
	B ₂		C ₂

Esta referida tabela pode ser interpretada da seguinte forma:

R_1 : SE x é A_1 e y é B_1 ENTÃO z é C_1

R_2 : SE x é A_2 e y é B_2 ENTÃO z é C_2 ,

onde R_1 é a regra fuzzy de número 1, R_2 é a regra fuzzy de número 2, x e y são as variáveis de entrada e z é a variável de saída.

Se as entradas do sistema são tratadas como *fuzzy singletons*, x_0 e y_0 , então seus graus de pertinência em relação aos correspondentes conjuntos são $\mu_{A_1}(x_0)$, $\mu_{B_1}(y_0)$, $\mu_{A_2}(x_0)$ e $\mu_{B_2}(y_0)$. Interpretando o conectivo e do antecedente como o operador *mínimo*, os graus de ativação da primeira e segunda regras, α_1 e α_2 respectivamente, são dados por:

$$\alpha_1 = \min \{ \mu_{A_1}(x_0), \mu_{B_1}(y_0) \}$$

$$\alpha_2 = \min \{ \mu_{A_2}(x_0), \mu_{B_2}(y_0) \}.$$

Neste exemplo, serão considerados os processos de inferência utilizando as relações de Mamdani e de Larsen.

Segundo a relação de Mamdani, a i -ésima regra conduz a uma decisão dada por $\mu_{C_i}(w) = \min\{\alpha_i, \mu_{C_i}(w)\}$. E, se o operador de agregação de regras é dado pelo operador de *máximo*, então a função de pertinência μ_C do conseqüente inferido é dada, ponto a ponto, por:

$$\mu_C(w) = \max\{\mu_{C_1}, \mu_{C_2}\} = \max\{\min[\alpha_1, \mu_{C_1}(w)], \min[\alpha_2, \mu_{C_2}(w)]\}.$$

A Figura 4.5 mostra uma representação gráfica desta relação.




Figura 4.5: Diagrama representativo da relação fuzzy de Mamdani.

Por outro lado, pela relação de Larsen, a i -ésima regra leva à decisão $\mu_{C_i}(w) = \alpha_i \cdot \mu_{C_i}(w)$. Desta forma, novamente considerando que o operador de agregação é interpretado como o *máximo*, a função de pertinência μ_C do conseqüente inferido é, ponto a ponto, dada por:

$$\mu_C(w) = \max\{\mu_{C_1}, \mu_{C_2}\} = \max\{[\alpha_1 \cdot \mu_{C_1}(w)], [\alpha_2 \cdot \mu_{C_2}(w)]\}.$$

A Figura 4.6 mostra uma interpretação gráfica da relação acima.




Figura 4.6: Diagrama representativo da relação *fuzzy* de Larsen.

4.6.4. Interface de Defuzzificação

Após a inferência *fuzzy*, muitas vezes é necessária a determinação de uma ação *não-fuzzy* para que seja efetivamente enviada ao processo. Por isso é que existe a interface de *defuzzificação*, a qual tem como função transformar as ações *fuzzy* inferidas em ações *não-fuzzy*.

Não há um procedimento sistemático para escolher uma estratégia de *defuzzificação*. Entretanto, três estratégias são muito utilizadas: o critério do máximo, da média dos máximos e o método do centro de área.

O critério do máximo (MAX) determina o primeiro ponto do universo onde a função inferida atinge o valor máximo.

A média dos máximos (MDM) representa o valor médio de todos os pontos de máximo valor de pertinência. Mais especificamente, para o caso de um universo de discurso discreto, o ponto de *defuzzificação* é determinado por:

$$z_0 = \sum_{j=1}^h \frac{w_j}{h}$$

onde w_j é o valor do suporte e h é a cardinalidade do conjunto suporte.

O método do centro de área (CDA), como o próprio nome diz, determina o centro de área, ou centro de gravidade, da função de saída inferida. Para o caso de um universo de discurso discreto, este ponto é obtido por:

$$z_0 = \frac{\sum_{j=1}^n \mu_c(w_j) \cdot w_j}{\sum_{j=1}^n \mu_c(w_j)},$$

onde n é o número de níveis de quantização da saída.

A Figura 4.7 mostra uma interpretação gráfica das três estratégias de *defuzzificação* apresentadas acima.




Figura 4.7: Representação esquemática das técnicas de *defuzzificação*: máximo (MAX), centro de área (CDA) e média dos máximos (MDM).

Capítulo 5

Avaliação Morfológica e Morfométrica de Axônios Mielínicos

5.1. Introdução

Como uma aplicação das teorias apresentadas nos capítulos 2, 3 e 4, propõe-se, neste capítulo, um método de quantificação e qualificação de axônios mielínicos, que é o objetivo principal deste trabalho.

Inicialmente, é apresentada uma visão geral do sistema, a partir de um diagrama apresentando as suas partes constituintes e as imagens resultantes dessas partes. Em seguida, para descrever o sistema, cada uma de suas partes é apresentada separadamente.

5.2. Uma Visão Geral do Sistema

As diversas etapas do processo de quantificação e qualificação de axônios mielínicos, proposto neste trabalho, estão apresentadas na Figura 5.1. Por conveniência, algumas etapas foram agrupadas na figura. Na referida figura, também são apresentadas as imagens resultantes de cada uma das etapas.

A idéia empregada no sistema é realizar sucessivas transformações na imagem de entrada que possibilitem a obtenção de uma imagem composta apenas por regiões classificadas como axônios, tornando a etapa de contagem e qualificação fácil e direta.

Cada uma das etapas envolvidas no processo é descrita nas seções seguintes.




Figura 5.1: Visão Geral do Sistema de Avaliação Morfológica e Morfométrica de Axônios Mielínicos.

5.3. Aquisição da Imagem

As imagens de seções transversais de axônios mielínicos utilizadas neste trabalho foram adquiridas em um *scanner* a uma resolução de 100 dpi¹, a partir de fotos de cortes transversais do nervo ciático de camundongos, obtidas através do acoplamento de uma câmera fotográfica a um microscópio ótico com aumento de 100× e ampliadas por um fator de 6.3. De cada uma dessas imagens, foi extraída uma região de tamanho 128×128 pixels para ser processada pelo método.

A Figura 5.2 apresenta uma imagem típica para a aplicação do método proposto neste trabalho. Nela, estão apontados exemplos de axônio, bainha de mielina e espaço endoneural.

¹ dpi = dots per inch (pontos por polegada)




Figura 5.2: Imagem típica processada pelo método de avaliação morfológica e morfométrica de axônios mielínicos proposto neste trabalho .

O axônio é a extensão longa e delgada do corpo celular de um neurônio, capaz de transportar informações neuronais em forma de pulsos elétricos e que pode ser dos tipos mielínico ou amielínico dependendo se existe ou não, respectivamente, bainha de mielina o envolvendo. Na imagem, a seção transversal de um axônio é caracterizada por toda região clara completamente envolvida por uma mais escura.

A bainha de mielina é justamente a região escura que envolve o axônio. Uma de suas funções é aumentar a velocidade de condução dos impulsos elétricos em uma célula nervosa. A seção transversal do axônio mais a bainha de mielina compõem o que se chama de fibra mielínica.

O espaço entre as fibras mielínicas é chamado espaço endoneural.

5.4. Binarização da Imagem de Entrada

Para a implementação desta etapa, alguns métodos de limiarização global foram testados (KAPUR et al., 1985; SHANBHAG, 1994) (ver seção 2.3.1.). Os resultados obtidos não foram satisfatórios, visto que os métodos não conseguiram a separação de todos os axônios com relação ao espaço endoneural, principalmente para as pequenas fibras. Desta forma, considerando que o processo seria inviabilizado

por um excessivo erro, optou-se pela utilização de métodos locais de limiarização, apesar do maior custo computacional envolvido.

Neste caso, faz-se percorrer uma janela pela imagem, pixel a pixel. A cada deslocamento, obtém-se o histograma da imagem sob a janela e, através do método proposto por SHANBHAG (1994) (seção 2.3.1.1.2.), determina-se o limiar ótimo, que é aplicado apenas ao pixel da imagem correspondente ao centro da janela. Vários tamanhos de janelas foram testados, sendo que os melhores resultados foram obtidos por uma janela de 7×7 pixels. Esse método foi utilizado por ter apresentado resultados superiores aos outros já referenciados. Esta superioridade pode ser atribuída ao fato do método considerar a imagem como um conjunto *fuzzy*, e utilizar uma função critério que pondera mais os níveis de cinza próximos ao ponto de limiar. A Figura 5.3-a mostra uma imagem de entrada do sistema e a Figura 5.3-b, o resultado de sua binarização.




Figura 5.3: Processo de binarização: (a) Imagem de entrada; (b) Resultado da binarização.

5.5. Fechamento de Regiões e Eliminação de Pequenos Artefatos

Em decorrência do processo de binarização, pode-se observar, eventualmente, o aparecimento de buracos em regiões conexas, ou ainda, o aparecimento de pequenos artefatos, resultantes da fragmentação do espaço endoneural ou da segmentação de estruturas citológicas.

A eliminação dos buracos é feita pela transformação fechamento de buracos, fundamentada na morfologia matemática e, como já visto na seção 3.6., definida pela seguinte expressão (BARRERA et al., 1994) :

$$\Phi_B(A) = [\rho_{B,F}(A)^c]^c$$

onde $\rho_{B,F}(A)$ representa a reconstrução do conjunto A utilizando o elemento estruturante B , a partir de um *frame* f . O sobrescrito C indica o complemento da imagem, ou a negação no caso de imagens binárias. O conjunto *frame*, como já explicado na seção 3.6., é representado por uma imagem onde os pixels de borda da imagem têm intensidade máxima e todos os demais pixels têm intensidade nula.

Foram testados diferentes tipos e tamanhos para o elemento estruturante B . Os melhores resultados foram observados para um disco euclidiano de diâmetro 4.

A eliminação dos pequenos artefatos é feita através da operação morfológica erosão, considerando um elemento estruturante linear de tamanho 1×3 , seguida de uma reconstrução. Esta sequência de operações é suficiente para a eliminação deste tipo de falha.

A Figura 5.4-a apresenta o resultado da transformação fechamento de buracos, aplicada à imagem da Figura 5.3-b, enquanto a Figura 5.4-c apresenta a imagem resultante das transformações aplicadas à imagem da Figura 5.4-a para a eliminação de pequenos artefatos. Os artefatos eliminados para a imagem da Figura 5.4-a podem ser vistos na imagem da Figura 5.4-b.




Figura 5.4: Pós-Processamento da imagem binarizada (Figura 5.3-b): (a) Fechamento de buracos; (b) Artefatos eliminados da imagem da Figura 5.4-a; (c) Imagem resultante da eliminação de pequenos artefatos aplicada à imagem da Figura 5.4-a.

5.6. Eliminação do Espaço Endoneural

A eliminação do espaço endoneural é feita através do processo de esqueletização da imagem. O conceito de esqueleto de formas geométricas foi inicialmente proposto por BLUM (1967, *apud* GONZALEZ & WOODS, 1993), quando apresentou a transformada do eixo mediano. A transformada de uma região R com borda B é resumida da seguinte forma: para cada ponto p em R , encontra-se o seu vizinho mais próximo em B . Se existem mais de um vizinho mais próximo para p , então o ponto p é dito pertencer ao eixo mediano (esqueleto) de R , salientando-se que o conceito de “mais próximo”, no mundo discreto, depende da função distância utilizada. Embora o resultado obtido pela transformada de eixo mediano seja considerado bom, a implementação direta desta transformada é proibitiva computacionalmente.

O alto custo computacional envolvido na transformada do eixo mediano foi o principal motivador para o desenvolvimento de outros métodos de esqueletização. Uma grande variedade de métodos para a determinação de esqueletos é descrita na literatura, sendo a maioria deles restrita a imagens binárias. MAHMOUD et al. (1991) determinam o esqueleto baseado em um algoritmo de agrupamento (*clustering*). Inicialmente, os dados são agrupados em um número pré-determinado

de grupos (*clusters*), através da técnica *fuzzy* ISODATA (SCHALKOFF, 1992). O algoritmo de agrupamento também determina os centros de cada grupo. Os centros de grupos adjacentes são unidos para formarem o esqueleto da região; TRAHANIAS (1992) realiza a esqueletização através de operações da morfologia matemática, obtendo o esqueleto morfológico; KIMMEL et al. (1995) determinam o esqueleto a partir de mapas de distância. A borda da região é segmentada nos pontos de máxima curvatura positiva e um mapa de distância de cada segmento é calculado. O esqueleto é determinado aplicando-se algumas regras aos conjuntos de diferença zero entre mapas de distância; e SHIH & PU (1995) determinam o esqueleto de uma região através da transformada da distância euclidiana. Para cada pixel da região é obtida sua distância mínima em relação ao fundo. Depois de calculadas as distâncias para todos os pixels, o esqueleto é determinado nos pontos de máximo valor.

Um melhor entendimento do processo de esqueletização pode ser conseguido através das definições ilustrativas de esqueleto apresentadas por MONTANARI (1968, *apud* KIMMEL et al., 1995). Uma delas é a da frente de propagação do fogo em um campo, que diz: o fogo é aceso em todos os pontos do contorno de um campo propagando-se de uma forma isotrópica. Quando as frentes de propagação se encontram, o fogo se extingue. Os pontos onde o fogo se extingue formam o esqueleto da região. A partir dessas definições, pode-se concluir que quanto mais circular for a região, menor será o seu esqueleto.

A implementação do processo de esqueletização, de modo geral, envolve um alto custo computacional.

Para a aplicação em pauta, observa-se que as regiões correspondentes às seções transversais dos axônios aproximam-se de formas circulares e, portanto, possuem pequenos esqueletos. Por outro lado, o espaço endoneural apresenta um esqueleto grande, devido à sua forma alongada. Portanto, a separação entre axônios e espaço endoneural pode ser feita a partir do tamanho do esqueleto.

Neste sistema, o esqueleto é obtido através da esqueletização morfológica homotópica (ver seção 3.7.), que é definida com base na transformação *hit-miss* (SERRA, 1986). A opção por este processo de esqueletização se deu pelo fato da mesma manter a conectividade das regiões e apresentar um custo computacional

relativamente baixo em comparação a outras abordagens. Ainda, segundo MARAGOS & SCHAFER (1986, *apud* TRAHANIAS, 1992), a esqueletização morfológica unifica e generaliza as técnicas anteriormente desenvolvidas.

A Figura 5.5-a mostra o resultado da esqueletização morfológica homotópica aplicada à imagem da Figura 5.4-b, enquanto a Figura 5.5-b mostra um gráfico relacionando o tamanho do esqueleto e sua região correspondente. Em uma abordagem similar à apresentada por AUER (1994), que utiliza o perímetro da maior fibra como limiar para exclusão de regiões não-axônios, utiliza-se, aqui, o tamanho do esqueleto de um axônio grande e de alto fator de forma (*fator de forma* = $\text{perímetro}^2 / (4\pi \times \text{área})$) como limiar de corte para extração do espaço endoneural. O axônio, na imagem, que atende às condições exigidas é indicado pelo usuário. Observa-se, entretanto, que para uma seqüência de imagens similares, o valor estabelecido para uma das imagens pode ser estendido às demais, reduzindo a necessidade de intervenção do usuário.

Por motivos didáticos, a imagem dos esqueletos de tamanho superior ao limiar estabelecido (ver Figura 5.5-b), isto é, a imagem dos esqueletos eliminados é apresentada na Figura 5.6-a. A Figura 5.6-b apresenta a imagem obtida após a reconstrução da imagem da Figura 5.6-a.

Uma vez eliminadas as regiões correspondentes aos esqueletos que excedem o limiar, a imagem é reconstruída pelo processo morfológico de reconstrução, utilizando os esqueletos remanescentes como marcadores. O elemento estruturante utilizado nesse processo deve impor uma conectividade pequena para que nenhuma região já eliminada seja reconstruída. Nesta aplicação, em particular, um elemento estruturante de conectividade 4 é utilizado.

A Figura 5.7 mostra a imagem resultante do processo de eliminação do espaço endoneural aplicado à imagem da Figura 5.4-b e considerando o limiar indicado na Figura 5.5-b.




Figura 5.5: Esqueletização homotópica para a imagem da Figura 5.4-b: (a) Esqueletos das regiões; (b) Tamanho do esqueleto $\times$ Região.




Figura 5.6: (a) Esqueletos eliminados após a limiarização dos tamanhos dos esqueletos da Figura 5.5-a; (b) Imagem obtida após a reconstrução da imagem da Figura 5.6-a.




Figura 5.7: Eliminação do espaço endoneural da imagem da Figura 5.4-b.

5.7. Eliminação das Regiões que Tocam as Bordas da Imagem

A fim de evitar imprecisões nas medidas ou mesmo a classificação incorreta de regiões, é comum, nos estudos morfométricos, extrair os elementos que interceptam os limites da região de observação (ZIMMERMAN, 1980; VITA et al., 1992; AUER, 1994).

Na abordagem proposta neste trabalho, esta etapa é realizada através da operação de interseção da imagem por um *frame*. A imagem resultante é reconstruída, usando o processo morfológico de reconstrução com um elemento estruturante de conectividade 4, e subtraída da imagem inicial (Figura 5.7). A Figura 5.8 mostra a imagem resultante desta eliminação.




Figura 5.8: Eliminação das regiões que tocam as bordas da imagem da Figura 5.7.

5.8. Classificação *Fuzzy* das Regiões

É facilmente observado, pela análise do procedimento e dos resultados, que após a etapa de eliminação do espaço endoneural e das regiões que tocam as bordas da imagem, algumas regiões não-axônios ainda permanecem na imagem (ver Figura 5.9) devido ao fato de apresentarem tamanhos de esqueleto menores que o limiar de corte estabelecido. Observa-se, entretanto, que um operador humano ao analisar a imagem original pode eliminar essas regiões através de uma análise subjetiva da forma, tamanho, cor, textura ou posição, num processo natural, porém de difícil formalização. Como a lógica *fuzzy* está mais próxima da forma do pensamento e da linguagem natural humana do que a lógica tradicional (LEE, 1990) e um sistema baseado nessa lógica dispõe de ferramental mais apropriado para a descrição dos critérios de decisão humana, sugerindo a possibilidade de obtenção de menores erros num processo classificatório, propõe-se, neste trabalho, a utilização de um sistema *fuzzy* para a separação das regiões remanescentes na imagem, através de suas formas.




Figura 5.9: Dois exemplos de regiões não-axônios (em branco), dentre as regiões da imagem apresentada na Figura 5.8.

Uma maneira usualmente considerada para a definição da forma é o estabelecimento de relações entre grandezas físicas medidas diretamente e para as quais a relação estabelecida não se modifica com a alteração da escala física (BOOKSTEIN, 1989).

Para a abordagem *fuzzy* adotada, faz-se necessário, inicialmente, definir as variáveis de entrada e saída do sistema, bem como definir a base de regras para a classificação das regiões. Diversas características inerentes às regiões da imagem podem ser utilizadas para compor o conjunto de variáveis de entrada. Neste trabalho, três dessas características são utilizadas: a área, o fator de forma e a distância em relação à vizinha mais próxima. Para facilitar o entendimento do processo e a manipulação das variáveis, decidiu-se utilizar sistemas *fuzzy* de duas variáveis de entrada. Desta forma, duas combinações de características são utilizadas, resultando, assim, em configurações diferentes para o classificador *fuzzy*. Estas configurações são analisadas separadamente nas subseções seguintes.

5.8.1. Classificador que Utiliza Área e Distância como Variáveis de Entrada

Esta configuração foi montada considerando-se a relação direta que existe entre o tamanho da seção transversal de um axônio e a espessura da bainha de mielina que o envolve. Isto é, quanto maior (menor) for a seção transversal de um axônio, mais (menos) espessa deve ser a bainha de mielina que o envolve.

Esta configuração do classificador *fuzzy* utiliza, então, as seguintes variáveis lingüísticas:

- distância (d): variável de entrada;
- área (a): variável de entrada;
- forma ($form$): variável de saída.

A variável d , definida no universo de discurso $\{1, 2, 3, 4, 5\}$, está associada com a medida da espessura da bainha de mielina. Para cada região da imagem resultante da fase imediatamente anterior, as distâncias entre a região correspondente na imagem resultante do pós-processamento (ver seção 5.5. - Figura 5.4-b) e suas vizinhas são medidas. Para obter essas medidas, realizam-se dilatações sucessivas na região, por um elemento estruturante do tipo disco, até que se atinja uma região vizinha. A distância considerada será, então, o raio do elemento estruturante da dilatação imediatamente anterior. A esta variável são associados cinco termos lingüísticos e a *fuzzificação* adotada para a medida é apresentada na Figura 5.10.




Figura 5.10: Funções de pertinência para a variável distância (d).

A variável a , definida no universo $\{0, 1, \dots, 300\}$, está associada com a área de cada região da imagem. A esta variável são associados nove termos lingüísticos e a *fuzzificação* adotada para a medida é apresentada na Figura 5.11.




Figura 5.11: Funções de pertinência para a variável área (a).

A variável de saída *form* é definida no universo de discurso $[0,20]$. A esta variável são associados três termos lingüísticos como apresentado na Figura 5.12-a.

A inclusão do termo lingüístico DUV (duvidosas) tem como objetivo permitir uma decisão posterior, supervisionada pelo usuário, quanto à classificação das regiões.




Figura 5.12: Funções de pertinência para a variável forma (*form*): (a) Para as Abordagens 2 e 3; (b) Para a Abordagem 1.

A escolha das funções de pertinência para os termos lingüísticos desempenha um papel importante no sucesso da aplicação, porém são definidas subjetivamente, baseando-se na experiência e senso prático (LEE, 1990). Para esta aplicação foram analisadas diferentes funções de pertinência, sendo os melhores resultados obtidos para as funções apresentadas na Figura 5.10, Figura 5.11 e Figura 5.12. Para o processo de *fuzzificação* é adotado o método baseado em *singletons*.

Para a avaliação do método, foram consideradas três abordagens, cada uma utilizando uma base de regras diferente. Na primeira abordagem, a base de regras (TABELA 5-I) permite classificar as regiões apenas como axônios e não-axônios, tornando a classificação totalmente automática. Nesta abordagem, deve-se considerar apenas dois termos lingüísticos para a variável *form*, como apresentado na Figura 5.12-b. Nas abordagens 2 e 3, as bases de regras (TABELA 5-II e TABELA 5-III, respectivamente) incluem a classificação em regiões duvidosas. Na abordagem 3, as regras de decisão estabelecidas para as regiões duvidosas são mais amplas, o que implica em maior interação com o usuário e taxas de erros menores, numa relação custo-benefício a ser determinada pelo usuário.

TABELA 5-I: Base de regras fuzzy para a abordagem 1 da configuração 1

		Distância (d)				
		MP	P	Md	G	MG
Árrea (a)	Mini	AX	N-AX	N-AX	N-AX	N-AX
	MMP	N-AX	AX	N-AX	N-AX	N-AX
	MP	N-AX	AX	AX	N-AX	N-AX
	P	N-AX	AX	AX	N-AX	N-AX
	Md-P	N-AX	AX	AX	N-AX	N-AX
	Md	N-AX	AX	AX	AX	N-AX
	Md-G	N-AX	N-AX	AX	AX	N-AX
	G	N-AX	N-AX	AX	AX	AX
	MG	N-AX	N-AX	AX	AX	AX

TABELA 5-II: Base de regras fuzzy para a abordagem 2 da configuração 1

		Distância (d)				
		MP	P	Md	G	MG
Árrea (a)	Mini	DUV	N-AX	N-AX	N-AX	N-AX
	MMP	DUV	DUV	N-AX	N-AX	N-AX
	MP	N-AX	DUV	DUV	N-AX	N-AX
	P	N-AX	AX	AX	N-AX	N-AX
	Md-P	N-AX	AX	AX	N-AX	N-AX
	Md	N-AX	AX	AX	AX	N-AX
	Md-G	N-AX	N-AX	AX	AX	N-AX
	G	N-AX	N-AX	AX	AX	AX
	MG	N-AX	N-AX	AX	AX	AX

TABELA 5-III: Base de regras fuzzy para a abordagem 3 da configuração 1

		Distância (d)				
		MP	P	Md	G	MG
Árrea (a)	Mini	DUV	N-AX	N-AX	N-AX	N-AX
	MMP	DUV	DUV	DUV	N-AX	N-AX
	MP	DUV	DUV	DUV	N-AX	N-AX
	P	DUV	DUV	DUV	DUV	N-AX
	Md-P	DUV	AX	DUV	DUV	N-AX
	Md	DUV	AX	DUV	DUV	N-AX
	Md-G	DUV	AX	AX	AX	DUV
	G	N-AX	AX	AX	AX	AX
	MG	N-AX	DUV	AX	AX	AX

O operador mínimo é utilizado na interpretação do conectivo “e” do antecedente e o *modus ponens generalizado* é adotado como o mecanismo de inferência, onde o mínimo é utilizado para a definição do operador de inferência e o máximo é utilizado como o operador de agregação de regras.

Como não há um procedimento sistemático para escolher uma estratégia de *defuzzificação* (LEE, 1990), o método do centro de área é adotado neste sistema, dado que o mesmo considera todo o universo de saída ponderado pelos graus de pertinência.

Para fins didáticos, a imagem resultante da etapa de eliminação das regiões que tocam as bordas da imagem é repetida na Figura 5.13. A Figura 5.14 mostra as imagens resultantes após a classificação das regiões da imagem apresentada na Figura 5.13, pela configuração 1, segundo as abordagens 1, 2 e 3.




Figura 5.13: Imagem processada pelo sistema baseado em regras *fuzzy* para a classificação de regiões.




Figura 5.14: Classificação *fuzzy* pela configuração 1. Segundo a abordagem 1: (a1) Axônios; (b1) Não-Axônios. Segundo a abordagem 2: (a2) Axônios; (b2) Não-axônios; (c2) Duvidosos. Segundo a abordagem 3: (a3) Axônios; (b3) Não-axônios; (c3) Duvidosos.

5.8.2. Classificador que Utiliza Área e Fator de Forma como Variáveis de Entrada

Observando que as seções transversais dos axônios, geralmente, têm uma forma mais circular do que as regiões do espaço endoneural, foi montada a segunda configuração para o classificador *fuzzy*, a qual utiliza como variáveis lingüísticas as seguintes:

- fator de forma (*fa_f*): variável de entrada;
- área (*a*): variável de entrada;
- forma (*form*): variável de saída.

A variável *fa_f*, definida no universo de discurso $[0,7]$, representa a medida do fator de forma ($\text{perímetro}^2 / (4\pi \times \text{área})$) da região. Como está definido, *fator de forma* ≥ 1 , onde o valor mínimo é conseguido para um disco perfeito. No espaço discretizado, entretanto, verificam-se regiões com valores de fator de forma menores que a unidade. Para se determinar o fator de forma de cada região, é necessário, inicialmente, obter o perímetro. Para isto, aplica-se um processo de esqueletização por afinamento (ver seção 3.7.) à imagem, utilizando os elementos estruturantes apresentados na Figura 3.9. Em seguida, realiza-se um processo de rotulação de regiões e, finalmente, determina-se o número de pixels de cada perímetro. A esta variável são associados cinco termos lingüísticos e a *fuzzificação* adotada para a medida é apresentada na Figura 5.15.

A variável *a* é definida exatamente da mesma maneira como no sistema apresentado na seção anterior, onde as funções de pertinência para seus termos lingüísticos são repetidas, por conveniência, na Figura 5.16.

A variável *form* também é definida da mesma maneira que no sistema apresentado na seção anterior e as funções de pertinência para seus termos lingüísticos são repetidas na Figura 5.17.




Figura 5.15: Funções de pertinência para a variável fator de forma (*fa_f*).




Figura 5.16: Funções de pertinência para a variável área (*a*).




Figura 5.17: Funções de pertinência para a variável forma (*form*): (a) Para as abordagens 2 e 3; (b) Para a abordagem 1.

A etapa de *fuzzificação* foi realizada por considerar as entradas do sistema como *fuzzy singletons*.

Novamente, para a avaliação do sistema, foram consideradas três abordagens, cada uma utilizando uma base de regras diferente. Semelhantemente à primeira configuração do sistema classificador *fuzzy* (seção 5.8.1.), na primeira abordagem, a base de regras (TABELA 5-IV) permite classificar as regiões apenas como axônios e não-axônios, tornando a classificação totalmente automática. Nesta abordagem, deve-se considerar apenas dois termos lingüísticos para a variável *form*, como apresentado na Figura 5.17-b. Nas abordagens 2 e 3, as bases de regras (TABELA 5-V e TABELA 5-VI, respectivamente) incluem a classificação em regiões duvidosas. Na abordagem 3, as regras de decisão estabelecidas para as regiões duvidosas são mais amplas, o que implica em maior interação com o usuário e taxas de erros menores, numa relação custo-benefício a ser determinada pelo usuário.

TABELA 5-IV: Base de regras fuzzy para a abordagem 1 da configuração 2

		Fator de Forma (fa_f)				
		MP	P	Md	G	MG
Árrea (a)	Mini	N-AX	N-AX	N-AX	N-AX	N-AX
	MMP	N-AX	AX	N-AX	N-AX	N-AX
	MP	N-AX	AX	N-AX	N-AX	N-AX
	P	N-AX	AX	N-AX	N-AX	N-AX
	Md-P	N-AX	AX	AX	AX	N-AX
	Md	N-AX	AX	AX	AX	N-AX
	Md-G	N-AX	AX	AX	AX	N-AX
	G	N-AX	AX	AX	AX	N-AX
	MG	N-AX	AX	AX	AX	N-AX

TABELA 5-V: Base de regras fuzzy para a abordagem 2 da configuração 2

		Fator de Forma (fa_f)				
		MP	P	Md	G	MG
Árrea (a)	Mini	N-AX	N-AX	N-AX	N-AX	N-AX
	MMP	N-AX	DUV	N-AX	N-AX	N-AX
	MP	N-AX	AX	DUV	N-AX	N-AX
	P	N-AX	AX	AX	DUV	N-AX
	Md-P	N-AX	AX	AX	AX	N-AX
	Md	N-AX	AX	AX	AX	N-AX
	Md-G	N-AX	AX	AX	AX	N-AX
	G	N-AX	AX	AX	AX	N-AX
	MG	N-AX	AX	AX	AX	N-AX

TABELA 5-VI: Base de regras fuzzy para a abordagem 3 da configuração 2

		Fator de Forma (fa_f)				
		MP	P	Md	G	MG
Árrea (a)	Mini	N-AX	DUV	N-AX	N-AX	N-AX
	MMP	DUV	DUV	N-AX	N-AX	N-AX
	MP	N-AX	AX	DUV	N-AX	N-AX
	P	N-AX	AX	DUV	DUV	N-AX
	Md-P	N-AX	AX	AX	AX	N-AX
	Md	N-AX	AX	AX	AX	N-AX
	Md-G	N-AX	AX	AX	AX	N-AX
	G	N-AX	AX	AX	AX	N-AX
	MG	N-AX	AX	AX	AX	N-AX

Similarmente à configuração apresentada na seção 5.8.1., o operador mínimo é utilizado para a definição do conectivo “e” do antecedente e o *modus ponens generalizado* é adotado como o mecanismo de inferência, para o qual o mínimo é utilizado como operador de inferência e o máximo, como operador de agregação de regras. Também, o método do centro de área é aplicado como estratégia de *defuzzificação*.

Novamente para facilidade de leitura, a imagem resultante da eliminação das regiões que tocam as bordas da imagem é repetida e está apresentada na Figura 5.18. A Figura 5.19 mostra as imagens resultantes após a classificação das regiões da imagem apresentada na Figura 5.18, pela configuração 2, segundo as abordagens 1, 2 e 3.

Uma avaliação dos resultados obtidos pelas duas configurações do classificador *fuzzy* é apresentada com maiores detalhes no capítulo 6, através do cálculo de erros de contagem e de classificação e ainda de um percentual de interação do usuário no processo de reclassificação de regiões.




Figura 5.18: Imagem processada pelo sistema baseado em regras *fuzzy* para a classificação de regiões.




Figura 5.19: Classificação *fuzzy* pela configuração 2. Segundo a abordagem 1: (a1) Axônios; (b1) Não-Axônios. Segundo a abordagem 2: (a2) Axônios; (b2) Não-axônios; (c2) Duvidosos. Segundo a abordagem 3: (a3) Axônios; (b3) Não-axônios; (c3) Duvidosos.

5.9. Reclassificação das Regiões Duvidosas

Para as abordagens 2 e 3 das duas configurações do classificador *fuzzy* (ver seções 5.8.1. e 5.8.2.), faz-se necessária uma etapa de reclassificação das regiões duvidosas. Esta etapa é conduzida pelo usuário, que indica os axônios dentre as regiões duvidosas.

A Figura 5.20 apresenta as imagens resultantes da reclassificação de regiões para as duas configurações do sistema, quando considerada a abordagem 2.




Figura 5.20: Imagens resultantes da reclassificação de regiões duvidosas, quando considerada a abordagem 2: (a) Para a configuração 1; (b) Para a configuração 2.

5.10. Agrupamento das Regiões Classificadas como Axônios

Apenas para as abordagens 2 e 3, novamente, é necessário um agrupamento das regiões classificadas como axônios pelo sistema *fuzzy* com as regiões reclassificadas pelo usuário para formarem uma imagem composta apenas por regiões classificadas como axônios.

A Figura 5.21-a apresenta a imagem resultante do agrupamento das regiões classificadas como axônios para a configuração 1, quando considerada a abordagem 2 e a Figura 5.21-b, a imagem resultante para o agrupamento das regiões classificadas

como axônios para a configuração 2 do sistema *fuzzy*, quando considerada a abordagem 2.

A Figura 5.22-a mostra as regiões da imagem da Figura 5.21-a sobrepostas na imagem original em níveis de cinza (ver Figura 5.3-a), enquanto a Figura 5.22-b mostra as regiões da Figura 5.21-b sobrepostas na imagem original em níveis de cinza.




Figura 5.21: Agrupamento das regiões classificadas como axônios, segundo a abordagem 2, para: (a) Configuração 1; (b) Configuração 2.




Figura 5.22: (a) Regiões da imagem da Figura 5.21-a sobrepostas na imagem original em níveis de cinza; (b) Regiões da imagem da Figura 5.21-b sobrepostas na imagem original em níveis de cinza.

5.11. Quantificação e Qualificação de Axônios

Ao final do processo, já de posse da imagem composta pelas regiões classificadas como axônios, o processo de quantificação e qualificação é simples e direto. A quantificação dos axônios é realizada por um processo de rotulação de regiões e a qualificação pode ser realizada a partir de diversas medidas tomadas das regiões. Como um exemplo para este processo de qualificação, a Figura 5.23 mostra histogramas das áreas dos axônios classificados pelo método. A Figura 5.23-a mostra o histograma para a imagem apresentada na Figura 5.21-a e a Figura 5.23-b mostra o histograma para a imagem apresentada na Figura 5.21-b.




Figura 5.23: Histograma do tamanho dos axônios: (a) Para a imagem da Figura 5.21-a; (b) Para a imagem da Figura 5.21-b.

Capítulo 6

Resultados e Discussões

6.1. Introdução

Neste capítulo, são apresentados os resultados obtidos pelo método de quantificação e qualificação de axônios mielínicos, proposto no capítulo anterior, quando aplicado a 10 imagens diferentes.

O método foi aplicado em suas duas configurações (seções 5.8.1. e 5.8.2.) e cada configuração, em suas três abordagens.

Para efeito de avaliação do desempenho do método, foram estabelecidos 3 critérios:

- Erro de contagem: informa qual a relação entre o número de regiões contadas pelo método e o número de axônios obtido por um processo de contagem manual. Este erro não leva em consideração se as regiões contadas pelo método estão classificadas corretamente ou não;
- Erro de classificação: indica quantas regiões dentre as classificadas como axônio, pelo método, não o são realmente. Ele é obtido levando-se em consideração os verdadeiros axônios apontados manualmente. Este erro é importante para o processo de avaliação morfológica e morfométrica, pois influencia diretamente na forma do histograma das regiões classificadas como axônios, obtido no final do processo (ver seção 5.11.);

- Percentual de interação: indica quantos axônios, dentre o número total na imagem, são classificados pelo usuário no processo de reclassificação de regiões duvidosas. Observa-se que este critério só é calculado para as abordagens 2 e 3, já que a abordagem 1 é completamente automática e não necessita da intervenção do usuário para a reclassificação de regiões duvidosas.

Para iniciar o capítulo, são feitas algumas considerações de implementação, onde são apresentadas as ferramentas computacionais utilizadas para o desenvolvimento do método proposto neste trabalho. Em seguida, os resultados obtidos pelo método são apresentados e analisados. Ainda, os erros médios de contagem obtidos pelas duas configurações do método são comparados com o resultado obtido pelo método de BLIGHT (1983), quando aplicado às mesmas imagens processadas pelo método aqui proposto.

6.2. Considerações de Implementação

O método proposto neste trabalho foi desenvolvido sob três ambientes diferentes e utilizando diversas ferramentas computacionais. O processo de binarização da imagem, por exemplo, foi implementado em linguagem C, utilizando o sistema operacional Unix. O programa desenvolvido foi otimizado para o menor consumo de tempo possível. Ainda assim, o tempo necessário para a binarização de uma imagem de tamanho 128×128 pixels e com valor máximo de nível de cinza aproximadamente igual a 140 é da ordem de 15 minutos. Verificou-se ainda que esse tempo aumenta bruscamente para imagens com uma maior faixa de níveis de cinza, chegando a ser da ordem de horas para uma imagem cujos níveis de cinza variam dentro da faixa 0 a 255.

As etapas apresentadas nas seções 5.5. a 5.7., inclusive, e a etapa de quantificação de axônios (ver seção 5.11.), foram desenvolvidas no ambiente Khoros (RASURE & KUBICA, 1993 *apud* BRAGA NETO, 1994), que é um sistema de visualização e processamento de imagens desenvolvido na Universidade do Novo

México (EUA). Para a implementação destas etapas, foi utilizada a linguagem de programação visual denominada *cantata*, que é parte constituinte do sistema Khoros, bem como a *toolbox* MMACH, que contém as ferramentas básicas de processamento e análise de imagens por morfologia matemática e que foi desenvolvida por grupos de pesquisa da Universidade de São Paulo, Instituto Nacional de Pesquisas Espaciais e da Universidade Estadual de Campinas.

Já a etapa de classificação de regiões, através de um sistema baseado em regras *fuzzy*, foi implementada no ambiente MATLAB, utilizando-se a *toolbox* FISMAT² (*Fuzzy Inference System toolbox for MATLAB*), que acomoda diversos operadores aritméticos, algoritmos de *fuzzificação* e *defuzzificação*, e relações de implicação *fuzzy*.

Nenhum parâmetro de tempo foi medido para as etapas desenvolvidas no Khoros ou no MATLAB.

A seguir, são apresentados os resultados obtidos pela aplicação do método de avaliação morfológica e morfométrica de axônios mielínicos. Inicialmente, os resultados obtidos por cada uma das duas configurações do sistema *fuzzy* são apresentados separadamente e, em seguida, estes resultados são agrupados para uma facilidade de análise.

6.3. Configuração 1 (Área e Distância como Variáveis de Entrada do Classificador *Fuzzy*)

Considerando o classificador *fuzzy* em sua configuração 1, que utiliza a área da região e a distância em relação à vizinha mais próxima como variáveis de entrada, o sistema foi aplicado às imagens em suas três abordagens: a completamente automática (abordagem 1), a interativa com menor grau de participação do usuário na reclassificação (abordagem 2) e a que exige uma maior intervenção do usuário no processo de reclassificação (abordagem 3).

² <ftp://ftp.mathworks.com/pub/contrib/v4/misc/fismat>

A TABELA 6-I apresenta os erros médios absolutos de contagem e classificação e o percentual de interação obtidos pelas três abordagens deste sistema. Para o cálculo dos erros, considerou-se o processo de reclassificação de regiões duvidosas, supervisionado pelo operador, isento de erro.

TABELA 6-I: Erros médios percentuais de contagem e de classificação de axônios e o percentual médio de interação para as três abordagens do sistema *fuzzy* que utiliza a área e a distância mínima para classificar as regiões.

	Abordagem 1	Abordagem 2	Abordagem 3
erro médio de contagem (%)	6,9	5,2	2,7
erro médio de classificação (%)	17,4	5,5	1,3
interação média (%)	—	21,8	42,8

Pela tabela acima, observa-se que o erro de classificação é decrescente para a sequência de abordagens apresentada. Isto já era esperado visto que o grau de intervenção do operador é crescente para esta mesma sequência. Na abordagem 1, não há intervenção do usuário e o sistema classifica erroneamente em torno de 17% das regiões contadas como axônios; já na abordagem 2, o usuário intervém para a reclassificação de aproximadamente 22% dos axônios e esse erro cai para a ordem de 5%; e na abordagem 3, onde há uma maior intervenção do usuário, quase 43%, o erro diminui para quase 1%.

A Figura 6.1 apresenta um gráfico representativo dos erros de contagem e de classificação obtidos para cada uma das dez imagens processadas, quando considerada a abordagem 1 da primeira configuração. A Figura 6.2 apresenta o mesmo tipo de gráfico, porém considerando a abordagem 2 da mesma configuração, e a Figura 6.3, considerando a abordagem 3.




Figura 6.1: Valores dos erros de contagem e de classificação obtidos pela abordagem 1 da primeira configuração para cada uma das 10 imagens processadas pelo método.




Figura 6.2: Valores dos erros de contagem e de classificação obtidos pela abordagem 2 da primeira configuração para cada uma das 10 imagens processadas pelo método.




Figura 6.3: Valores dos erros de contagem e de classificação obtidos pela abordagem 3 da primeira configuração para cada uma das 10 imagens processadas pelo método.

A Figura 6.4 apresenta um gráfico com o valor do percentual de interação do usuário para cada uma das dez imagens, quando consideradas as abordagens 2 e 3 da primeira configuração.




Figura 6.4: Valores dos percentuais de interação do usuário para as abordagens 2 e 3 da primeira configuração, para cada uma das 10 imagens processadas pelo método.

6.4. Configuração 2 (Área e Fator de Forma como Variáveis de Entrada do Classificador *Fuzzy*)

Considerando o classificador *fuzzy* em sua configuração 2, a que utiliza a área e o fator de forma da região como variáveis de entrada, o método foi aplicado às imagens de entrada em suas três abordagens e, similarmente à configuração anterior, foram obtidos os erros de contagem e de classificação, e o percentual de interação. Estes resultados são apresentados na TABELA 6-II.

TABELA 6-II: Erros médios percentuais de contagem e de classificação de axônios e o percentual médio de interação para as três abordagens do sistema *fuzzy* que utiliza a área e o fator de forma para classificar as regiões.

	Abordagem 1	Abordagem 2	Abordagem 3
erro médio de contagem (%)	6,2	3,7	1,6
erro médio de classificação (%)	11,4	4,2	1,2
interação média	—	15,9	21,2

A mesma observação quanto ao erro de classificação decrescente feita para a configuração 1, também é válida para esta configuração. Na abordagem 1, não há intervenção do usuário e o sistema classifica erroneamente em torno de 11% das regiões contadas como axônios; já na abordagem 2, o usuário intervém para a reclassificação de aproximadamente 16% dos axônios e esse erro cai para a ordem de 4%; e na abordagem 3, onde há uma maior intervenção do usuário, aproximadamente 21%, o erro diminui para quase 1%.

A Figura 6.5 apresenta um gráfico dos valores dos erros de contagem e de classificação obtidos para cada uma das dez imagens processadas, quando considerada a abordagem 1 da segunda configuração. A Figura 6.6 apresenta o mesmo tipo de gráfico quando considerada a abordagem 2 da mesma configuração e a Figura 6.7, o gráfico para a abordagem 3.




Figura 6.5: Valores dos erros de contagem e de classificação obtidos pela abordagem 1 da segunda configuração para cada uma das 10 imagens processadas pelo método.




Figura 6.6: Valores dos erros de contagem e de classificação obtidos pela abordagem 2 da segunda configuração para cada uma das 10 imagens processadas pelo método.




Figura 6.7: Valores dos erros de contagem e de classificação obtidos pela abordagem 3 da segunda configuração para cada uma das 10 imagens processadas pelo método.

A Figura 6.8 apresenta um gráfico com o valor do percentual de interação do usuário para cada uma das dez imagens, quando consideradas as abordagens 2 e 3 da segunda configuração.




Figura 6.8: Valores dos percentuais de interação do usuário para as abordagens 2 e 3 da segunda configuração, para cada uma das 10 imagens processadas pelo método.

6.5. Comparação dos Erros de Contagem do Sistema com o Erro Obtido pela Aplicação do Método de BLIGHT (1983)

O método de BLIGHT (1983) foi aplicado às mesmas imagens processadas pelo método apresentado neste trabalho e o erro médio de contagem foi calculado. Por ser um método puramente de contagem, onde o processo é conduzido pelo usuário, considera-se que o método proposto por BLIGHT (1983) não possui erro de classificação.

Na TABELA 6-III, são apresentados os erros médios de contagem obtidos pelo método de BLIGHT (1983), bem como pelas três abordagens das duas configurações do sistema proposto neste trabalho, os quais foram convenientemente repetidos.

TABELA 6-III: Erros médios de contagem obtidos pelo método de BLIGHT (1983) e pelas três abordagens das duas configurações do sistema proposto neste trabalho.

		ERRO (%)
Configuração 1	Abordagem 1	6,9
	Abordagem 2	5,2
	Abordagem 3	2,7
Configuração 2	Abordagem 1	6,2
	Abordagem 2	3,7
	Abordagem 3	1,6
BLIGHT (1983)		10,2

Verifica-se, pela leitura da tabela acima, que os erros de contagem obtidos pelo sistema proposto neste trabalho, mesmo para a abordagem completamente automática, são em média inferiores ao erro de contagem obtido por BLIGHT (1983), que ficou na ordem de 10%.

6.6. Análise do Comportamento do Classificador *Fuzzy*

Com o objetivo de analisar o comportamento do classificador baseado em regras *fuzzy* utilizado neste trabalho, decidiu-se investigar como é feita a classificação no espaço de atributos. Desta forma, a partir de cinco imagens dentre as dez utilizadas neste trabalho, as classes de axônios e não-axônios foram distribuídas no espaço a partir dos valores da área e fator de forma. A Figura 6.9 apresenta esta distribuição de classes. Observa-se, da referida figura, que as duas classes não são linearmente separáveis no espaço de atributos, o que torna inviável a aplicação de métodos estatísticos paramétricos para a classificação de regiões. Talvez, assim como para as abordagens 2 e 3 do classificador *fuzzy* proposto neste trabalho, se fossem consideradas três classes: axônios, não-axônios e duvidosas, e aplicados métodos não-paramétricos, como por exemplo o classificador de distância mínima ou o de regiões de decisão (SCHALKOFF, 1992), as regiões pudessem ser classificadas com taxas de erro admissíveis. Porém, a determinação de um melhor método estatístico que realize a classificação das regiões não é objetivo deste trabalho.

Então, para entender o princípio de classificação do método *fuzzy* utilizado neste trabalho, decidiu-se gerar todas as combinações possíveis para os valores das variáveis de entrada e verificar a resposta do classificador para cada combinação desses valores. Nesta análise, foi considerada a abordagem 2 da segunda configuração (ver seção 5.8.2.). A Figura 6.10 mostra a classificação realizada para cada par de valores das variáveis de entrada.

Ao analisar a Figura 6.9 e a Figura 6.10 conjuntamente, observa-se que as regiões de área menor que 40, aproximadamente, e fator de forma maior que 1 e menor que 2, que são as regiões de muita dúvida realmente, são bem tratadas pelo classificador *fuzzy*. Entretanto, analisando a Figura 6.9, esperaria-se que a classificação em regiões axônios tivesse uma certa inclinação positiva para áreas maiores que 100, aproximadamente, mas não é o que ocorre na Figura 6.10. Entretanto, esta inclinação pode ser obtida através do ajuste da base de regras do classificador *fuzzy*.




Figura 6.9: Distribuição das classes axônios e não-axônios considerando o fator de forma e a área como atributos, para uma amostra de 5 imagens.




Figura 6.10: Resposta da abordagem 2 do classificador *fuzzy* que utiliza a área e o fator de forma das regiões como variáveis de entrada, quando aplicadas todas as combinações possíveis dos valores destas variáveis.

6.7. Erro de Classificação e Percentual de Interação do Usuário

Para uma comparação mais fácil entre as abordagens e configurações do sistema *fuzzy*, em termos do erro de classificação e percentual de interação do usuário, os valores destes parâmetro são agrupados na TABELA 6-IV e TABELA 6-V, respectivamente.

TABELA 6-IV: Erros médios de classificação obtidos pelas três abordagens das duas configurações do sistema proposto neste trabalho.

		ERRO (%)
Configuração 1	Abordagem 1	17,4
	Abordagem 2	5,5
	Abordagem 3	1,3
Configuração 2	Abordagem 1	11,4
	Abordagem 2	4,2
	Abordagem 3	1,2

TABELA 6-V: Percentual de interação do usuário quanto à classificação de axônios.

		Interação(%)
Configuração 1	Abordagem 2	21,8
	Abordagem 3	42,8
Configuração 2	Abordagem 2	15,9
	Abordagem 3	21,2

Pela TABELA 6-IV e pela TABELA 6-V, observa-se que os erros de classificação e o percentual de interação da configuração 2 são menores do que os da configuração 1 do sistema *fuzzy*. Isto pode ser explicado pelo fato de uma das variáveis da configuração 1, a distância mínima, ser caracterizada por valores discretos dentro de um universo de discurso muito pequeno. Desta forma, a variável,

por si só, contribui com um grau de incerteza ao sistema pois, por qualquer erro de medida ou mesmo falha no processo de segmentação, o valor da variável pode ser alterado e assim interpretado de uma maneira totalmente diferente. É justamente por esse motivo que os parâmetros de classificação das regiões em duvidosas na configuração 1 é muito mais ampla, o que acarreta em uma maior interação do usuário no processo. Essa maior interação, inclusive, pode ser o motivo de um menor erro na abordagem 3 da configuração 1 sobre a mesma abordagem da configuração 2.

Capítulo 7

Conclusões

Neste trabalho, é proposto um método semi-automático para a avaliação morfológica e morfométrica de axônios mielínicos que inclui, além de técnicas de processamento de imagens digitais, a utilização de um sistema classificador de regiões baseado em regras *fuzzy* e a reclassificação de regiões duvidosas por um processo supervisionado pelo usuário.

O método foi testado e os resultados obtidos (ver capítulo 6) indicam que o mesmo é promissor, visto que os erros estão dentro de valores aceitáveis para a aplicação em pauta.

Diante da flexibilidade na definição das variáveis linguísticas de entrada e da base de regras *fuzzy*, é razoável concluir que o método pode ser estendido a aplicações similares em outras áreas de pesquisa.

Ainda, diante dos resultados obtidos, conclui-se que a intervenção do usuário no processo de contagem e qualificação de axônios mielínicos é necessária para manter o erro dentro de valores aceitáveis. Esta conclusão concorda com os estudos realizados por ZIMMERMAN et al. (1980) e AUER (1994).

Para a continuação desta linha de pesquisa, algumas sugestões podem ser feitas. A primeira delas refere-se ao classificador *fuzzy*. Sugere-se a utilização de outros tipos de funções de pertinência, outros operadores do processo de inferência, e ainda, outras estratégias de *defuzzificação*. Após estes experimentos, poder-se-á comparar os resultados obtidos, com os resultados apresentados neste trabalho.

Ainda quanto ao processo de classificação de regiões, sugere-se que outros atributos, além dos apresentados neste trabalho, sejam considerados como uma tentativa de conseguir a separação das classes no espaço de atributos. A partir daí,

uma análise comparativa entre o método *fuzzy*, utilizado neste trabalho, e um método estatístico se torna simples e ilustrativa.

Sugere-se, também, o desenvolvimento de um *software* baseado no método proposto neste trabalho, com possibilidade de o usuário ajustar, interativamente, as funções de pertinência *fuzzy* e escolher os operadores e estratégias de *defuzzificação*.

Por fim, sugere-se a aplicação de técnicas de processamento em imagens não-binárias, levando a etapa de binarização de imagens para o fim do processo, com o objetivo de se trabalhar com o máximo de informação contida na imagem. Esta sugestão, entretanto, pode significar uma completa modificação da sequência de operações proposta neste trabalho, já que implica na utilização de morfologia matemática em níveis de cinza. Possivelmente, as operações morfológicas em níveis de cinza correspondentes às utilizadas neste trabalho não forneçam os mesmos resultados.

Referências Bibliográficas

- ABUTALEB, A. S. Automatic thresholding of gray level pictures using two-dimensional entropy. **Computer Vision, Graphics, and Image Processing**, v. 47, p. 22-32, 1989.
- AUER, R. N. Automated nerve fibre size and myelin sheath measurement using microcomputer-based digital image analysis: theory, method and results. **Journal of Neuroscience Methods**, v. 51, p. 229-238, 1994.
- BARRERA, J.; BANON, J. F. & LOTUFO R. A. Mathematical morphology toolbox for the Khoros system. **Conf. on Image Algebra and Morphological Image Processing V, International Symposium on Optics, Imaging and Instrumentation, SPIE's Annual Meeting**, 24-29 July, San Diego, USA, 1994.
- BEUCHE, W. & FRIEDE, R. L. A quantitative assessment of myelin sheaths in the peripheral nerves of dystrophic, quacking and trembler mutants. **Acta Neuropathologica**, v. 66, p. 29-36, 1985.
- BLIGHT, A. R. Cellular morphology of chronic spinal cord injury in the cat: analysis of myelinated axons by line-sampling. **Neuroscience**, v. 10, n. 2, p. 521-543, 1983.
- BOOKSTEIN, F. L. "Size and shape": a comment on semantics. **Systematic Zoology**, v. 38, n. 2, p. 173-180, 1989.
- BRAGA NETO, U. M. **Reconstrução volumétrica e análise de imagens tridimensionais por morfologia matemática**. Campinas: DCA/FEEC/UNICAMP, 1994. (Dissertação de Mestrado).

- BRINK, A. D. Minimum spatial entropy threshold selection. **IEE Proceedings-Vision Image and Signal Processing**, v. 142, n. 3, p. 128-132, 1995.
- BRINK, A. D. & PENDOCK, N. E. Minimum cross-entropy threshold selection. **Pattern Recognition**, v. 29, n. 1, p. 179-188, 1996.
- BUCK, T. A. **Reconhecimento de caracteres alfanuméricos através de técnicas de lógica nebulosa**. Campinas: DCA/FEEC/UNICAMP, 1990. (Dissertação de Mestrado).
- CHANG, C-I C.; CHEN, K.; WANG, J. & ALTHOUSE, M. L. G. A relative entropy-based approach to image thresholding. **Pattern Recognition**, v. 27, n. 9, p. 1275-1289, 1994.
- ESPIR, M. L. E. & HARDING, D. T. C. Apparatus for measuring and counting myelinated nerve fibres. **Journal of Neurology, Neurosurgery and Psychiatry**, v. 24, p. 287-290, 1961.
- FACON, J. **Morfologia Matemática: teoria e exemplos**. Curitiba: Editora Universitária Champagnat da Pontifícia Universidade Católica do Paraná, 1996.
- FIELDS, R. D. & ELLISMAN, M. H. Axons regenerated through silicone tubes splices. II. Functional morphology. **Experimental Neurology**, v. 92, p. 61-74, 1986.
- FIGUEIREDO, M.; GOMIDE, F.; ROCHA, A. & YAGER, R. Comparison of Yager's level set method for fuzzy logic control with Mamdani's and Larsen's methods. **IEEE Transactions on Fuzzy Systems**, v. 1, n. 2, p. 156-159, 1993.
- FRIEDE, R. L. & BISCHHAUSEN, R. How are sheath dimensions affected by axon caliber and internodal length? **Brain Research**, v. 235, p. 335-350, 1982.
- FRYKMAN, G. K.; McMILLAN, P. J. & YEGGE, S. A review of experimental methods measuring peripheral nerve regeneration in animals. **Orthopedic Clinics of North America**, v. 19, p. 209-219, 1988.
- FU, K. S. & MUI, J. K. A survey on image segmentation. **Pattern Recognition**, v. 13, n. 1, p. 3-16, 1981.

- GLASBEY, C. A. An analysis of histogram-based thresholding algorithms. **CVGIP: Graphical, Models and Image Processing**, v. 55, n. 6, p. 532-537, 1993.
- GOMIDE, F. A. C. & GUDWIN, R. R. Modelagem, controle, sistemas e lógica fuzzy. **Controle & Automação** (Revista da Sociedade Brasileira de Automática), v. 4, n. 3, p. 97-115, 1994.
- GONZALEZ, R.C. & WOODS, R. E. **Digital Image Processing**. Reading: Addison-Wesley, 1993.
- HANNAH, I.; PATEL, D. & DAVIES, R. The use of variance and entropic thresholding methods for image segmentation. **Pattern Recognition**, v. 28, n. 8, p. 1135-1143, 1995.
- HARMAN, K.; KATNICK, J. & DE LA TORRE, J. C. A quick and accurate line-sampling technique to quantify myelinated axons in peripheral nerve cross-sections. **Journal of Neuroscience Methods**, v. 38, p. 107-110, 1991.
- HUANG, L-K & WANG, M-J, J. Image thresholding by minimizing the measures of fuzzyness. **Pattern Recognition**, v. 28, n. 1, p. 41-51, 1995.
- KAPUR, J. N.; SAHOO, P. K. & WONG, A. K. C. A new method for gray-level picture thresholding using the entropy of the histogram. **Computer Vision, Graphics, and Image Processing**, v. 29, p. 273-285, 1985.
- KIMMEL, R.; SHAKED, D.; KIRYATI, N. & BRUCKSTEIN, A. M. Skeletonization via distance maps and level sets. **Computer Vision and Image Understanding**, v. 62, n. 3, p. 382-391, 1995.
- KLIR, G. J. & FOLGER, T. A. **Fuzzy Sets, Uncertainty, and Information**. New Jersey: Prentice-Hall International, Inc., 1988.
- LANGONE, F. **Estudo ultraestrutural e morfométrico de nervos regenerados no interior de próteses tubulares**. São Paulo: ICB/USP, 1991. (Tese de Doutorado).

- LEE, C. C. Fuzzy logic in control systems: fuzzy logic controller - part I & part II. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 20, n.2, p. 404-434, 1990.
- LEE, S. U.; CHUNG, S. Y. & PARK, R. H. A comparative performance study of several global thresholding techniques for segmentation. **Computer Vision, Graphics, and Image Processing**, v. 52, p. 171-190, 1990.
- LI, C. H. & LEE, C. K. Minimum cross entropy thresholding. **Pattern Recognition**, v. 26, n. 4, p. 617-625, 1993.
- LIE, W-N. Automatic target segmentation by locally adaptive image thresholding. **IEEE Transactions on Image Processing**, v. 4, n. 7, p. 1036-1041, 1995.
- MAHMOUD, S. A.; ABUHAIBA, I. & GREEN, R. J. Skeletonization of arabic characters using clustering based skeletonization algorithm. **Pattern Recognition**, v. 24, n. 5, p. 453-464, 1991.
- MORII, F. An image thresholding method using a minimum weighted squared-distortion criterion. **Pattern Recognition**, v. 28, n. 7, p. 1063-1071, 1995.
- PAL, N. R. On minimum cross-entropy thresholding. **Pattern Recognition**, v. 29, n. 4, p. 575-580, 1996.
- PAPAMARKOS, N & GATOS, B. A new approach for multilevel threshold selection. **CVGIP: Graphical Models and Image Processing**, v. 56, n. 5, p. 357-370, 1994.
- PEDRYCZ, W. **Fuzzy Control and Fuzzy Systems**. Taunton: Research Studies Press Ltd., 1993.
- SAHOO, P. K.; SOLTANI, S.; WONG, A. K. C. & CHEN, Y. C. A survey of thresholding techniques. **Computer Vision, Graphics, and Image Processing**, v. 41, p. 233-260, 1988.
- SERRA, J. **Image Analysis and Mathematical Morphology**. London: Academic Press, 1982.

- SERRA, J. Introduction to mathematical morphology. **Computer Vision, Graphics, and Image Processing**, v. 35, p. 283-305, 1986.
- SCHALKOFF, R. J. **Pattern Recognition**: statistical, structural and neural approaches. New York: John Wiley & Sons, Inc., 1992.
- SHANBHAG, A. G. Utilization of information measure as a means of image thresholding. **CVGIP: Graphical Models and Image Processing**, v. 56, n. 5, p. 414-419, 1994.
- SHIH, F. Y. & PU, C. C. A skeletonization algorithm by maxima tracking on Euclidean distance transform. **Pattern Recognition**, v. 28, n. 3, p. 331-341, 1995.
- TRAHANIAS, P. E. Binary shape recognition using the morphological skeleton transform. **Pattern Recognition**, v. 25, n. 11, p. 1277-1288, 1992.
- TRIER, F. D. & TAXT, T. Evaluation of binarization methods for document images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 17, n. 3, p. 312-315, 1995.
- VITA, G.; SANTORO, M.; TROMBETTA, G.; LEONARDI, L. & MESSINA, C. A computer-assisted automatic method for myelinated nerve fiber morphometry. **Acta Neurologica Scandinavica**, v. 85, p. 18-22, 1992.
- VOGT, R. C. Robust extraction of axon fibers from large-scale electron micrograph mosaics. **Mathematical Morphology and its Application to Image and Signal Processing**, p. 433-441, Atlanta: Kluwer Academic Publishers, 1996.
- YANOWITZ, S. D. & BRUCKSTEIN, A. M. A new method for image segmentation. **Computer Vision, Graphics, and Image Processing**, v. 46, p. 82-95, 1989.
- YEN, J-C.; CHANG, F-J. & CHANG, S. A new criterion for automatic multilevel thresholding. **IEEE Transactions on Image Processing**, v. 4, n. 3, p. 370-378, 1995.

ZADEH, L. A. Outline of a new approach to the analysis of complex systems and decision processes. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 1, 1973.

_____ **Fuzzy Sets and Applications:** selected papers by L. A. Zadeh. New York: John Wiley & Sons, Inc., 1987.

ZHANG, Y. J. A survey on evaluation methods for image segmentation. **Pattern Recognition**, v. 29, n. 8, p. 1335-1346, 1996.

ZIMMERMAN, I. R.; KARNES, J. L.; O'BRIEN, P. C. & DYCK, P. J. Imaging system for nerve and fiber tract morphometry: components, approaches, performance, and results. **Journal of Neuropathology and Experimental Neurology**, v. 39, p. 409-419, 1980.

Apêndice 1

Imagens Processadas pelo Método

Neste apêndice, são apresentadas as 10 imagens processadas para a avaliação do método proposto neste trabalho. Também são apresentadas as imagens dos axônios classificados pela aplicação das duas configurações do método, quando considerada a segunda abordagem, a cada uma das imagens de entrada. Os axônios classificados estão apresentados na cor branca e foram sobrepostos na imagem original para uma melhor visualização.


Imagem Processada	Axônios Classificados pela Abordagem 2 da Configuração 1	Axônios Classificados pela Abordagem 2 da Configuração 2
1. 		










Imagem Processada	Axônios Classificados pela Abordagem 2 da Configuração 1	Axônios Classificados pela Abordagem 2 da Configuração 2
2.		
		
3.		
		
4.		
		
















Imagem Processada	Axônios Classificados pela Abordagem 2 da Configuração 1	Axônios Classificados pela Abordagem 2 da Configuração 2
5.		
		
6.		
		
7.		
		

Imagem Processada	Axônios Classificados pela Abordagem 2 da Configuração 1	Axônios Classificados pela Abordagem 2 da Configuração 2
8.		
		
9.		
		
10.		
