



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



Sistema Inteligente para Detecção de Manchas de Óleo na Superfície Marinha através de Imagens de SAR

Danilo Lima de Souza

Orientador: Prof. Dr. Adrião Duarte Dória Neto

Co-orientador: Prof. Dr. Wilson da Mata

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da UFRN (área de concentração: Engenharia de Computação) como parte dos requisitos para obtenção do título de Mestre em Ciências.

Número de ordem PPgEE: M174
Natal, RN, julho de 2006

Divisão de Serviços Técnicos

Catálogo da publicação na fonte. UFRN / Biblioteca Central Zila Mamede

Souza, Danilo Lima de.

Sistema Inteligente para detecção de manchas de óleo na superfície marinha através de imagens de SAR / Danilo Lima de Souza - Natal, RN, 2006.

103 f. : il.

Orientador: Adrião Duarte Dória Neto.

Co-orientador: Wilson da Mata.

Dissertação (Mestrado) - Universidade Federal do Rio Grande do Norte. Centro de Tecnologia. Programa de Pós-Graduação em Engenharia Elétrica.

1. Algoritmos - Dissertação. 2. Processamento digital de imagens - Dissertação. 3. Classificadores neurais - Dissertação. 4. Derramamento de óleo - Superfície marinha - Dissertação. 5. Mancha de óleo - Imagens de SAR - Dissertação. I. Dória Neto, Adrião Duarte. II. Mata, Wilson da. III. Universidade Federal do Rio Grande do Norte. IV. Título.

RN/UF/BCZM

CDU 004.421(043.3)

Sistema Inteligente para Detecção de Manchas de Óleo na Superfície Marinha através de Imagens de SAR

Danilo Lima de Souza

Dissertação de Mestrado aprovada em 24 de julho de 2006 pela banca examinadora composta pelos seguintes membros:

Prof. Dr. Adrião Duarte Dória Neto (orientador) DCA/UFRN

Prof. Dr. Wilson da Mata (co-orientador) DEE/UFRN

Prof. Dr. José Manuel Seixas COPPE/UFRJ

Prof. Dr. Agostinho de Medeiros Brito Júnior DCA/UFRN

Agradecimentos

Ao meu orientador e ao meu co-orientador, professores Adrião Duarte e Wilson da Mata, sou grato pela orientação.

Aos amigos Patric, Rafael e Márcio pelo tempo de convívio.

Aos professores do Departamento de Computação e Automação pelas aulas ministradas.

Aos demais colegas de pós-graduação, pelas críticas, sugestões e conhecimento compartilhado.

Ao professor Venerando Eustáquio e suas orientandas pelas imagens de satélite.

À minha família pelo apoio.

À CAPES, pelo apoio financeiro.

Resumo

Derramamentos de óleo sobre o mar, mesmo que acidentais, geram enormes consequências negativas para a área afetada. Os prejuízos são ambientais e econômicos, principalmente com a proximidade dessas manchas de áreas de preservação e/ou zonas costeiras. O desenvolvimento de técnicas automáticas para a identificação de manchas de óleo sobre a superfície marinha, capturadas através de imagens de Radar, auxiliam num completo monitoramento dos oceanos e mares. Contudo, manchas de diferentes origens podem ser visualizadas nesse tipo de produção de imagem, tornando o monitoramento difícil. O sistema proposto neste trabalho, baseado em técnicas de processamento digital de imagens e redes neurais artificiais, tem o objetivo de identificar a mancha analisada e discernir entre óleo e os demais fenômenos geradores de mancha. Testes nos blocos funcionais que compõem o sistema proposto permitem a implementação de diferentes algoritmos, assim como sua análise detalhada e pontual. Os algoritmos que tratam do processamento digital de imagem (filtragem do ruído *speckle* e gradiente), assim como o de classificação (Perceptron de Múltiplas Camadas, rede de função de Base Radial, Máquina de Vetor de Suporte e Máquina de comitê) são apresentados e comentados. O desempenho final do sistema, com diferentes tipos de classificadores, é apresentado através da curva ROC. As taxas de acertos são consideradas condizentes com o que a literatura de detecção de manchas de óleo na superfície oceânica através de imagens de SAR apresenta.

Palavras-chave: Derramamento de Óleo, Mancha de óleo, Classificadores Neurais, Sistemas Inteligentes, SAR.

Abstract

Oil spill on the sea, accidental or not, generates enormous negative consequences for the affected area. The damages are ambient and economic, mainly with the proximity of these spots of preservation areas and/or coastal zones. The development of automatic techniques for identification of oil spots on the sea surface, captured through Radar images, assist in a complete monitoring of the oceans and seas. However spots of different origins can be visualized in this type of imaging, which is a very difficult task. The system proposed in this work, based on techniques of digital image processing and artificial neural network, has the objective to identify the analyzed spot and to discern between oil and other generating phenomena of spot. Tests in functional blocks that compose the proposed system allow the implementation of different algorithms, as well as its detailed and prompt analysis. The algorithms of digital image processing (speckle filtering and gradient), as well as classifier algorithms (Multilayer Perceptron, Radial Basis Function, Support Vector Machine and Committe Machine) are presented and commented. The final performance of the system, with different kind of classifiers, is presented by ROC curve. The true positive rates are considered agreed with the literature about oil slick detection through SAR images presents.

Keywords: Oil spill, Oil slick, Neural Classifiers, Intelligent Systems, SAR.

Sumário

Lista de Figuras	ix
Lista de Tabelas	xi
Lista de Símbolos e Abreviaturas	xiii
1 Introdução	1
1.1 Estado da Arte	2
1.2 Motivação	4
1.3 Objetivos	5
1.4 Estrutura do Sistema Proposto	5
1.5 Organização do Trabalho	6
2 Radar de Abertura Sintética	7
2.1 Princípios do Radar Imageador	7
2.2 SAR	8
2.2.1 Vantagens e Limitações	9
2.3 Projetos de Sensoriamento Remoto utilizando Radar	10
2.3.1 ERS	10
2.3.2 Radarsat-1	11
2.3.3 Envisat	12
2.4 Manchas em Imagens Marinhas	12
2.5 Considerações Finais	15
3 Processamento Digital de Imagens	17
3.1 Filtragem Espacial	17
3.1.1 Filtragem do Ruído <i>Speckle</i>	18
3.1.2 Filtro Log	22
3.1.3 Filtros por Derivadas	23
3.2 Quantização Vetorial	24
3.3 Limiarização	25
3.4 Morfologia Matemática	25
3.4.1 Elemento Estruturante	26
3.4.2 Dilatação	26
3.4.3 Erosão	27

3.4.4	Abertura	27
3.5	Transformada de Hotelling	27
3.6	Extração de Características	28
3.7	Considerações Finais	31
4	Redes Neurais Artificiais	33
4.1	Definição e Características	33
4.1.1	Aprendizado	34
4.1.2	Desempenho	36
4.2	Classificador de Padrões	37
4.3	Neurônio Artificial	39
4.4	Rede Perceptrons de Múltiplas Camadas	40
4.5	Rede de Funções de Base Radial	41
4.6	Máquinas de Vetor de Suporte	43
4.7	Máquinas de Comitê	44
4.8	Considerações Finais	46
5	Sistema Proposto	47
5.1	Diagrama de blocos	47
5.1.1	Filtragem do ruído <i>speckle</i>	48
5.1.2	Filtro Log	48
5.1.3	Quantização Vetorial	50
5.1.4	Limiarização	50
5.1.5	Morfologia Matemática	50
5.1.6	Filtros por Derivadas	51
5.1.7	Transformada de Hotelling	52
5.1.8	Extração de características	52
5.1.9	Classificador Neural	53
5.2	Considerações Finais	54
6	Implementações Computacionais e Resultados	55
6.1	Processamento Digital da Imagem	55
6.1.1	Filtragem Speckle	56
6.1.2	Gradiente	57
6.1.3	Processando Imagem Radarsat-1	58
6.1.4	Processando Imagem Envisat	60
6.1.5	Processando Imagem ERS-2	62
6.1.6	Considerações	65
6.2	Máquinas de Aprendizado	67
6.2.1	Pré-processamento dos dados	67
6.2.2	Validação Utilizando Dados Artificiais	68
6.2.3	Validação Utilizando Dados do SIOSM	75
6.2.4	Deixe-um-fora	82
6.2.5	Considerações	86

7	Conclusões	87
7.1	Trabalhos Futuros	88
	Referências bibliográficas	90
A	Decomposição por Valor Singular	95
B	Retropropagação em uma MLP	97
C	Algoritmo RBF	99
D	Algoritmo SVM	103

Lista de Figuras

1.1	Procedimento Operacional.	2
2.1	Espalhamento do sinal do Radar em duas superfícies marinhas. Uma livre da presença de óleo e outra não.	14
3.1	Uma máscara 3×3 com coeficientes arbitrários.	17
3.2	Resposta de uma operação de filtragem.	18
3.3	Função do filtro Log.	22
3.4	Máscaras denominadas operadores de Sobel: (a)Gradiente na direção vertical; (b)Gradiente na direção horizontal.	23
3.5	Máscaras denominadas operadores de Prewitt: (a)Gradiente na direção vertical; (b)Gradiente na direção horizontal.	24
4.1	Aprendizado Supervisionado.	35
4.2	Uma curva ROC.	38
4.3	Modelo de um neurônio.	39
4.4	Rede Perceptrons de Múltiplas Camadas.	41
4.5	Rede de Função de Base Radial.	42
4.6	Máquina de Vetor de Suporte.	45
4.7	Hiperplano ótimo de separação.	45
4.8	Arquitetura de uma Máquina estática de Comitê.	46
5.1	Diagrama de blocos detalhado do Sistema de Identificação de Óleo na Superfície Marinha (SIOSM).	49
5.2	Elemento estruturante utilizado na operação morfológica de abertura.	51
5.3	Processo de classificação.	53
6.1	Desempenho comparativo para a segmentação de uma mancha de óleo utilizando diferentes filtros <i>speckle</i>	56
6.2	Imagem Radarsat-1 SAR de 21/05/1999 08:10:33 UTM, órbita 0018490. Fonte: CSA [©]	59
6.3	Processando Imagem Radarsat-1: (a) região de interesse; (b) filtragem <i>speckle</i> ; (c) filtro log; (d) quantização vetorial; (e) limiarização; (f) morfologia matemática; (g) gradiente da imagem (b); (h) gradiente da imagem (f); (i) mancha segmentada.	61
6.4	Imagem Envisat ASAR de 01/06/2004. Fonte: ESA [©]	62

6.5	Processando Imagem Envisat: (a) região de interesse; (b) filtragem <i>speckle</i> ; (c) filtro log; (d) quantização vetorial; (e) limiarização; (f) morfologia matemática; (g) gradiente da imagem (b); (h) gradiente da imagem (f); (i) mancha segmentada.	63
6.6	Imagem ERS-2 SAR de 04/02/2002 11:03:41 GM, órbita 35519 quadro 2885. Fonte: ESA [©]	64
6.7	Processando Imagem ERS-2: (a) região de interesse; (b) filtragem <i>speckle</i> ; (c) filtro log; (d) quantização vetorial; (e) limiarização; (f) morfologia matemática; (g) gradiente da imagem (b); (h) gradiente da imagem (f); (i) mancha segmentada.	66
6.8	Erro médio quadrático apresentado durante o treinamento da MLP com a utilizando de dados extraídos pelo SIOSM.	69
6.9	Curva ROC do classificador MLP validado com dados artificiais.	70
6.10	Curva ROC dos diferentes classificadores RBF validados com dados artificiais.	73
6.11	Erro absoluto apresentado durante o cálculo dos multiplicadores de Lagrange no treinamento da SVM com a utilização de dados extraídos pelo SIOSM.	74
6.12	Curva ROC do classificador SVM validado com dados artificiais.	74
6.13	Curva ROC do classificador heterogêneo de Comitê validado com dados artificiais.	75
6.14	Erro médio quadrático apresentado durante o treinamento da MLP utilizando dados artificiais.	76
6.15	Curva ROC do classificador MLP validado com dados extraídos pelo SIOSM.	77
6.16	Curvas ROC dos classificadores RBF validados com dados extraídos pelo SIOSM.	80
6.17	Erro absoluto apresentado durante o cálculo dos multiplicadores de Lagrange no treinamento da SVM com dados artificiais.	80
6.18	Curva ROC do classificador heterogêneo de Comitê validados com dados extraídos pelo SIOSM.	81
6.19	Curvas do erro médio quadrático apresentadas durante os 12 treinamentos da MLP utilizando a técnica deixe-um-fora.	82
6.20	Curvas do erro absoluto apresentadas durante os 12 cálculos dos multiplicadores de Lagrange da SVM utilizando a técnica deixe-um-fora.	85

Lista de Tabelas

2.1	Comprimento de onda do Radar e frequências usadas em sensoriamento remoto.	8
4.1	Matriz de confusão para n classes distintas.	37
4.2	Funções de Ativação.	40
4.3	Funções de Base Radial.	43
4.4	Núcleos de produto interno.	44
6.1	Estatística dos valores obtidos, com diferentes filtros <i>speckle</i> , para os descritores utilizados no SIOSM.	57
6.2	Estatística dos valores obtidos para os descritores de gradiente de uma mancha de óleo.	58
6.3	Estatística dos valores obtidos para os descritores de gradiente de um assemelhado.	58
6.4	Máxima separação entre os descritores de gradiente para cada uma das classes.	58
6.5	Descritores calculados para a figura 6.3(a).	60
6.6	Descritores calculados para a figura 6.5(a).	65
6.7	Descritores calculados para a figura 6.7(a).	67
6.8	Medidas estatísticas das classes Óleo e Assemelhado.	68
6.9	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede MLP validada com dados artificiais.	70
6.10	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial gaussiana validada com dados artificiais.	71
6.11	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial multiquadrática validada com dados artificiais.	71
6.12	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial <i>thin-plate-spline</i> validada com dados artificiais.	72
6.13	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial multiquadrática inversa validada com dados artificiais.	72
6.14	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a SVM validada com dados artificiais.	73

6.15	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para o classificador heterogêneo de Comitê validado com dados artificiais.	75
6.16	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede MLP validada com dados extraídos pelo SIOSM.	76
6.17	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial gaussiana validada com dados extraídos pelo SIOSM.	78
6.18	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial multiquadrática validada com dados extraídos pelo SIOSM.	78
6.19	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a RBF com função radial <i>thin-plate-spline</i> validada com dados extraídos pelo SIOSM.	79
6.20	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a RBF com função radial multiquadrática inversa validada com dados extraídos pelo SIOSM.	79
6.21	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a SVM validada com dados extraídos pelo SIOSM.	81
6.22	Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a máquina heterogênea de Comitê validada com dados extraídos pelo SIOSM.	81
6.23	Matriz de confusão do classificador MLP utilizando a técnica deixe-um-fora.	82
6.24	Matriz de confusão do classificador RBF com função de base radial gaussiana utilizando a técnica deixe-um-fora.	83
6.25	Matriz de confusão do classificador RBF com função de base radial multiquadrática utilizando a técnica deixe-um-fora.	83
6.26	Matriz de confusão do classificador RBF com função de base radial <i>thin-plate-spline</i> utilizando a técnica deixe-um-fora.	84
6.27	Matriz de confusão do classificador RBF com função de base radial multiquadrática inversa utilizando a técnica deixe-um-fora.	84
6.28	Matriz de confusão do classificador SVM utilizando a técnica deixe-um-fora.	84
6.29	Matriz de confusão do classificador formado por um Comitê de máquinas utilizando a técnica deixe-um-fora.	86

Lista de Símbolos e Abreviaturas

A	Área da mancha
Amt	Fator de amortecimento exponencial
BSd	Desvio Padrão da intensidade de fundo
C	Comparcidade da mancha
Ce	Coefficiente estimado de variação do ruído
Ci	Coefficiente estimado de variação da imagem
$ConMax$	Contraste Máximo entre mancha e fundo
$ConMe$	Contraste Médio entre mancha e fundo
Dp	Desvio padrão dos <i>pixels</i> sob uma janela analisada
$GMax$	Gradiente Máximo da borda da mancha
GMe	Gradiente Médio da borda da mancha
GSd	Desvio Padrão do Gradiente da borda da mancha
I_c	Pixel central de uma janela da imagem
Im	Valor médio dos <i>pixels</i> sob uma janela
L	Distância entre um <i>pixel</i> central e seus vizinhos
N_{look}	Número de visadas da imagem
OSd	Desvio Padrão da intensidade da mancha
P	Perímetro da mancha
R	Valor resultante da convolução sobre uma imagem
S	Espalhamento da mancha
Z_k	Função de ponderação do filtro de Kuan

Z_l	Função de ponderação do filtro de Lee
Z_{lm}	Função de ponderação do filtro de Lee modificado
∇f	Gradiente da função f
m_i	Coefficientes da máscara de convolução
z_i	Coefficientes de uma imagem sob uma máscara de convolução
Radar	Radio Detection and Ranging
SAR	Synthetic Aperture Radar
ASAR	Advanced Synthetic Aperture Radar
ERS	European Remote Sensing satellite
ESA	European Space Agency
CSA	Canadian Space Agency
RNA	Rede Neural Artificial
MLP	Multilayer Perceptron
RBF	Radial Basis Function
SVM	Suporte Vector Machine
SIOSM	Sistema de Identificação de Óleo na Superfície Marinha
ROC	Receiver Operating Characteristic

Capítulo 1

Introdução

Derramamentos de óleo sobre a superfície do mar poluem o meio ambiente marinho gradualmente, especialmente quando ocorrem próximos à costa. Acidentes com navios petroleiros, geralmente mais destacados pela mídia (petroleiro *Prestige* na Europa, assim como o *Exxon Valdez* no Alasca, *Amoco Cadiz* e *Erika* na França ou *Aegean Sea* na Espanha [Response e Division 1992]), representam somente 5% da poluição total, por óleo, do mundo e escondem a poluição regular em zonas de tráfego marinho importantes, como o Mediterrâneo, o mar Báltico e o oceano Atlântico, gerada por perfuração de poços de petróleo ou descargas ilegais de navios em trânsito, limpando seus tanques. Como resultado destas atividades, o derramamento de óleo se mostra como uma séria ameaça à preservação e manutenção dos oceanos.

Com passagem regular sobre os oceanos, os satélites geradores de imagem fornecem dados que podem ser usados para a extração de informação estatística sobre manchas de várias regiões específicas do globo terrestre. Imagens de Sensoriamento Remoto, como as obtidas pelo Radar de Abertura Sintética, têm provado ser uma ferramenta adequada para a identificação de manchas de óleo no oceano, pois os instrumentos não dependem de condições climáticas nem de luz solar para o seu processo de aquisição de dados além de permitir imageamento de alta definição da superfície oceânica com resolução de *pixel* entre 10m e 100m [Girard-Ardhuin et al. 2004].

O desenvolvimento de veículos aéreos dotados deste tipo de sensor, em particular as missões dos satélites de Sensoriamento Remoto Europeu ERS-1, ERS-2 e do Envisat além do Radarsat-1 canadense, têm melhorado a possibilidade de detecção de derramamentos de óleo, permitindo um mais rigoroso e efetivo monitoramento [Frate et al. 2000]. A possibilidade de criação de sistemas com capacidade de examinação de grandes extensões aquáticas e possivelmente em tempo real são alguns dos atrativos encontrados na utilização dos dados gerados pelos sensores imageadores.

O espalhamento da radiação da energia emitida pelo Radar ao atravessar a sessão transversal da superfície de água limpa, com ângulos de incidência entre 25 e 60 graus, pode ser descrito pela teoria de espalhamento de Bragg [Vesecky 1995]. De acordo com essa teoria, a desordem do mar é derivada, principalmente, das ondas de baixa gravidade e das ondas capilares, caracterizadas pelo pequeno comprimento de onda ($\lambda < 1\text{m}$). A presença de um filme de óleo sobre a superfície do mar diminui estes tipos de ondas por

causa da ressonância da película de óleo de comportamento viscoso-elástico descrito pela teoria de Marangoni. Então um filme de óleo sobre a superfície do mar reduz drasticamente o retorno da energia radiada medida, resultando em áreas escuras na imagem do Radar de Abertura Sintética. De fato manchas de óleo mostram um grande efeito descontínuo com relação ao fundo da imagem, funcionando como uma espécie de assinatura que a caracteriza. Contudo, uma análise cuidadosa da imagem é necessária porque manchas escuras podem ter origem biológica (por processo de foto-oxidação e decomposição bacteriológica), geológica (óleo infiltrado do leito oceânico) ou causada por ventos locais fracos. Para evitar falsos alarmes, processadores de imagens e algoritmos de classificação bem sintonizados devem ser empregados [Frate et al. 2000].

Baseado nesse fato, um procedimento operacional pode ser apresentado, conforme ilustrado na figura 1.1

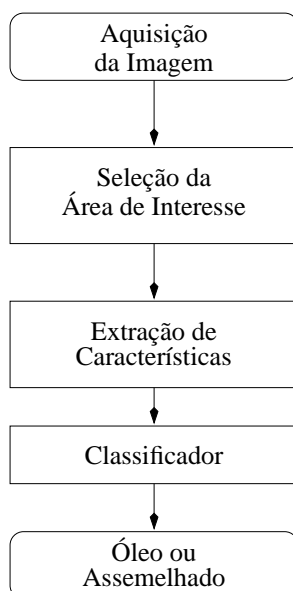


Figura 1.1: Procedimento Operacional.

O procedimento objetiva o mínimo de intervenção humana, com a computação de características físicas e geométricas que possam ser extraídas do objeto, além da classificação do objeto utilizando uma ferramenta inteligente como uma rede neural artificial.

1.1 Estado da Arte

A literatura engloba uma seleta e recente documentação referente ao tratamento computacional aplicado à detecção e classificação de manchas de óleo sobre a superfície marinha, com destaque para trabalhos de caracterização física do problema e dos algoritmos de classificação empregados.

Os primeiros trabalhos na década de 80 tentaram caracterizar, principalmente, os efeitos de diminuição das ondas da superfície oceânica coberta por um filme de óleo. Mais tarde Vesecky (1995) e Gade et al. (1996) descrevem o fenômeno de redução dessas ondas

através de medições da radiação refletida a um sensor Radar em diferentes comprimentos de onda. Ambos realizaram medições para a comprovação da teoria de Marangoni.

Com a viabilidade técnica da medição de manchas sobre a superfície marinha já identificada, devido principalmente aos avanços que o Radar havia recebido após o fim da Segunda Guerra Mundial, os anos seguintes foram para a realização de testes em satélites de sensoriamento remoto. Destaque para os programas das agências espaciais européia e canadense.

Os estudos seguintes desenvolveram-se então na área de processamento de sinais, a maioria sobre dados gerados por satélites imageadores. Hovland et al. (1994) apresentam uma análise dos diversos fenômenos geradores de manchas nas imagens de SAR. Uma introdução a alguns descritores que poderiam ser extraídos de imagens de SAR na caracterização de manchas de óleo são apresentados por Solberg e Solberg (1996) e Solberg e Volden (1997). Mais recentemente Girard-Ardhuin et al. (2003), descrevem as potencialidades e limitações do processo de detecção de manchas utilizando esse tipo imageamento.

Com relação aos algoritmos de processamento de imagem que permearam pesquisas seguintes, Girard-Ardhuin et al. (2004) mostram uma comparação entre alguns modelos propostos.

Já no processo de classificação, Solberg et al. (2003, 1999, 1997) apresentam grandes contribuições com seus modelos estatístico e hierárquico, chamado classificador baseado em função de distribuição de probabilidade multivariada, em associação a um conjunto de regras e funções de perda.

Mais recentemente, usando uma nova abordagem, Calabresi et al. (1999) e Frate et al. (2000, 2004) utilizam uma rede neural artificial, do tipo *Multilayer Perceptron* (MLP), no processo de classificação. Com a obtenção de resultados satisfatórios, eles comprovam a viabilidade técnica desse classificador nesse tipo de tarefa, dita complexa.

Diante desse cenário científico e tecnológico e com a indústria petrolífera apresentando cada vez mais um papel significativo na economia mundial, pesquisas internacionais surgiram tanto nos países produtores quanto nos países que detêm os sistemas de imageamento remoto.

Com o Brasil mostrando a sua autonomia no segmento petrolífero, políticas que garantem uma exploração dos recursos naturais de forma controlada e sem impactos ao meio ambiente são cada vez mais idealizadas. Isso definiu o marco inicial ao combate à poluição por óleo no Brasil, com a oficialização do projeto de Proteção das costas brasileiras, um programa das Nações Unidas (1982), juntamente com o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), Companhia de Tecnologia de Saneamento Ambiental (CETESB) e Petrobras.

Desde então há trabalhos e técnicas sendo desenvolvidas por Universidades, Instituições e Centros de pesquisa no Brasil como por exemplo o Cenpes no Rio de Janeiro com o Centro de Monitoramento de Derramamento de Óleo no Mar (CeMOM).

Com a apresentação desse panorama, o sistema e a investigação propostos neste trabalho localizam-se dentro de áreas científicas e tecnológicas envolvidas em discussões nacionais e internacionais, que buscam solução para um importante problema.

1.2 Motivação

Como 75% das reservas de óleo brasileiras estão em água profundas (entre 400 e mil metros) e ultraprofundas (a partir de mil metros), a Petrobras é hoje a Empresa que tem o maior número de sistemas flutuantes no mundo, as plataformas semi-submersíveis e os navios FPSO (da sigla em inglês para *Floating, Production, Storage and Offloading*, ou Unidade Flutuante de Produção, Armazenamento e Escoamento). A motivação para o trabalho vem então da grandiosidade dos dados apresentados pela indústria petrolífera nacional que mostra a necessidade de preservação dos cenários em que o petróleo brasileiro está contido e da biodiversidade marinha que se apresenta na costa brasileira em que a extração de petróleo é realizada.

Por exemplo, nos 100 mil quilômetros quadrados da Bacia de Campos a Petrobras tinha, em 31 de dezembro de 2004, espalhados por dezenas de campos de petróleo, 7958 poços de óleo e gás, sendo 7307 em terra e 651 no mar, 72 plataformas fixas e 23 flutuantes de produção, 8244 quilômetros de dutos, produção de mais de 1493 barris de óleo e cerca de 42 milhões de metros cúbicos de gás, representando cerca de 85% e 15% da produção nacional de óleo e gás, respectivamente. Em barris equivalentes (boe), a produção total de óleo e gás da região atinge cerca de 1 milhão e 350 mil barris por dia [Petrobras 2006].

O impacto ambiental resultante do vazamento de poluentes no mar depende não apenas do volume e composição do material despejado. A localização da ocorrência é muitas vezes decisiva na determinação do estrago, assim como algumas variáveis biológicas, oceanográficas, meteorológicas, entre outras. No caso de derramamentos de óleo, as propriedades físico-químicas do material possuem grande influência nos efeitos gerados, dessa forma, a identificação dessas ocorrências, em tempo hábil, se torna imprescindível para a minimização dos seus efeitos nocivos. A satisfação desses tempos é obtida com a construção de sistemas cada vez mais automatizados, o que se torna uma motivação a mais para a realização desse trabalho.

Atualmente, este trabalho pode ser feito de diferentes maneiras entre elas por requisição, através de um veículo aéreo ou aquático. Contudo condições climáticas desfavoráveis impossibilitam a verificação de ocorrências. Uma detecção automática por satélite poderia prover periodicidade na verificação das ocorrências inclusive com imagens sendo regularmente produzidas em áreas de difícil acesso, auxiliando no combate às descargas ilegais de óleo.

Por outro lado, outras aplicações podem ser objetivadas com a construção de sistemas de monitoramento da superfície marinha. Manchas naturais são de interesse para biólogos e pescadores pois mostram atividades biológicas intensas na água, assim como para geólogos e meteorologistas interessados em campos de vento e atividade oceânica. Já as manchas provenientes de exsudações são de interesse para a própria indústria petrolífera, pois podem indicar uma nova área de extração.

A grande motivação para a realização desse trabalho é contribuir com a criação de ferramentas automáticas, eficientes e com capacidade de examinação de grandes extensões aquáticas, apropriadas ao monitoramento da enorme costa marítima nacional.

1.3 Objetivos

O objetivo geral do trabalho é:

- O desenvolvimento de um sistema eficiente de identificação de manchas de óleo sobre a superfície marinha através de imagens de SAR.

Contudo para a realização dessa tarefa, é necessário alcançar alguns objetivos específicos, como:

- A construção de algoritmos de segmentação, para o processamento digital de imagens.
- A construção de algoritmos de extração de características.
 - Uma análise qualitativa de alguns dos algoritmos implementados.
- A construção de algoritmos de classificação.
 - Uma análise qualitativa dos classificadores implementados.

1.4 Estrutura do Sistema Proposto

Neste trabalho assume-se que um operador, por inspeção visual, realiza o primeiro passo, enquanto os dois últimos são executados automaticamente. A atenção deste trabalho está focada sobre os algoritmos de processamento digital de imagem, dos aspectos gerais dos algoritmos de extração de características além dos algoritmos de classificação.

As imagens obtidas dos satélites de sensoriamento remoto, são pré-processadas com técnicas de processamento digital, possibilitando a filtragem, segmentação e extração de características das manchas imageadas para posterior classificação dentro de um determinado padrão, fazendo uso de redes neurais artificiais. Vale salientar que essas características extraídas formam um espaço de entrada não linear e de alta dimensionalidade.

Alguns algoritmos de classificação de padrões utilizam a decisão *Bayesiana* ou outra decisão estatisticamente baseada. O inconveniente desses métodos é o processo complexo que abrange a estimativa das distribuições de probabilidades, devido a muitas não linearidades e ao fraco entendimento sobre os fatores envolvidos. Esse tipo de dificuldade pode ser contornado com uma abordagem neural.

O uso de Redes Neurais Artificiais em sensoriamento remoto tem frequentemente sido estudado [Calabresi et al. 1999, Frate et al. 2000, Frate e Salvatori 2004] por possibilitar, simultaneamente, um mapeamento não linear do espaço de entrada multidimensional sobre a saída, fazendo frente à complexos modelos estatísticos. As Redes Neurais artificiais, ao contrário dos classificadores estatísticos, não requerem uma relação entre entrada e saída explicitamente bem definida, pois determinam seus próprios discriminantes de entrada-saída diretamente de um conjunto de dados de treinamento, usado para extrair os limites de decisão [Frate et al. 2000].

Quatro tipos de máquinas de aprendizado são apresentadas no trabalho, cada uma com suas particularidades. A rede Perceptron de Múltiplas Camadas com sua massiva conectividade e mapeamento interno não linear dos dados para um espaço de características,

a rede de Função de Base Radial com o agrupamento dos dados possibilitando ótimos aproximadores locais, as Máquinas de Vetor de Suporte com a construção do hiperplano de separação ótima baseado nos vetores de suporte e a Máquina de Comitê que faz uso de redes especialista na solução de um problema complexo. O uso de alguns dos classificadores apresentados não foi ainda discutido na literatura.

A atuação de todas as máquinas de aprendizado mencionadas é feita da mesma forma: o sistema recebe como parâmetro de entrada uma imagem com suspeita de mancha de óleo, de onde se extrai um conjunto de descritores, provendo informação sobre a cena analisada; esses descritores são inseridos no classificador, cuja saída determina a probabilidade de a mancha analisada ser ou não uma mancha de óleo.

1.5 Organização do Trabalho

Este documento é composto por 7 capítulos, que podem ser estruturados em: problema, fundamentos, aplicação e conclusão.

Este capítulo fez uma introdução ao problema em análise, além de algumas considerações que o cercam.

Os capítulos seguintes fazem uma introdução aos fundamentos e técnicas usadas para entendimento do problema exposto. O capítulo 2 apresenta uma introdução aos satélites imageadores enfatizando os sistemas que o utilizam o Radar como sensor, assim como a observação de manchas nas imagens geradas. O capítulo 3 trata dos fundamentos do processamento digital de imagens utilizados no sistema proposto. O capítulo 4 apresenta uma introdução as redes neurais artificiais, com destaque para as redes Perceptrons de Múltiplas Camadas, redes de Funções de Base Radial, Máquinas de Vetor de Suporte e Máquina de Comitê, implementadas para atuarem como classificadores dentro do sistema.

O capítulo 5 detalha o sistema de identificação de manchas de óleo sobre a superfície marinha. Implementações Computacionais e alguns resultados, tanto para o processamento da imagem, quanto para a performance da classificação neural são mostrados no capítulo 6.

Por fim o capítulo 7 apresenta as conclusões do trabalho além de alguns pontos que podem ser explorados em trabalhos futuros.

Quatro apêndices são inclusos no final do documento.

O apêndice A diz respeito a Decomposição por Valor Singular aplicada na obtenção dos autovalores da matriz de covariância oriunda da Transformada de Hotelling. Dentro do apêndice B o algoritmo da retropropagação utilizado numa rede Perceptron de Múltiplas Camadas é apresentado. Para a rede de Função de Base Radial o apêndice C detalha o algoritmo de aprendizagem, e o apêndice D faz o mesmo, contudo para a Máquina de Vetor de Suporte.

Capítulo 2

Radar de Abertura Sintética

A aquisição de dados através das complexas técnicas de sensoriamento remoto compreende o envolvimento de um número grande de diferentes especialistas no seu tratamento, desde a geração até a transformação em informação. Deste modo o processo de sensoriamento remoto é, cada vez mais, encarado como um sistema de aquisição de informações.

Este capítulo realiza uma apresentação do Radar de Abertura Sintética, assim como os princípios e as técnicas de imageamento de manchas de óleo sobre a superfície marinha com esse tipo de sensor.

2.1 Princípios do Radar Imageador

O termo Radar vem do inglês **RA**dio **D**etection **A**nd **R**anging, ou detecção de alvos e avaliação de distâncias por sinais de rádio. O princípio básico de funcionamento do Radar consiste na emissão de radiação eletromagnética direcionada ao alvo desejado e na gravação da intensidade e tempo de retardo da energia retroespalhada pelo mesmo.

Os pulsos eletromagnéticos emitidos são modificados por algumas propriedades inerentes ao alvo, tais como: rugosidade, propriedades eletromagnéticas (permeabilidade, permissividade e condutividade) e orientação em relação à direção do pulso do Radar.

O sinal de retorno (eco) traz informações sobre os alvos imageados. Estas informações são definidas por características tanto do sinal incidente quanto do sinal retroespalhado, são elas: comprimento de onda ou frequência, polarização, direção de propagação, amplitude e fase.

O Radar utilizado pelos principais satélites imageadores emite pulsos de radiação com comprimentos de onda entre 1cm e 1m (a capacidade de penetração abaixo das superfícies é aumentada com comprimentos de onda maiores). Essa faixa de comprimento de onda, conhecida como microondas, é especialmente adequada para aplicações em sensoriamento remoto, pois nesse intervalo do espectro de frequência as ondas eletromagnéticas sofrem pequena atenuação atmosférica possibilitando, assim, o imageamento mesmo sob condições climáticas adversas.

A tabela 2.1 mostra algumas bandas utilizadas em sensoriamento remoto.

Tabela 2.1: Comprimento de onda do Radar e frequências usadas em sensoriamento remoto.

Banda	Comprimento de Onda (cm)	Frequência (GHz)
Ka	0,8 a 1,1	40 a 26,5
K	1,1 a 1,7	26,5 a 18
Ku	1,7 a 2,4	18 a 12,5
X	2,4 a 3,8	12,5 a 8
C	3,8 a 7,5	8 a 4
S	7,5 a 15	4 a 2
L	15 a 30	2 a 1
P	30 a 100	1 a 0,3

A polarização traz informações a respeito da orientação dos campos elétrico e magnético dos sinais emitido e recebido pelo Radar. Normalmente se associa a polarização de uma onda eletromagnética à orientação de seu campo elétrico. O Radar pode ter diferentes configurações de polarização. As polarizações lineares HH, VV, HV, VH são as mais comuns, onde a primeira letra indica a polarização do pulso emitido e a segunda letra indica a polarização do pulso captado pelo sensor (H - horizontal e V - vertical). Uma porção da energia que retorna ao sensor é despolarizada pela superfície do terreno e vibra em várias direções. O mecanismo responsável não é totalmente conhecido, mas as múltiplas reflexões na superfície é a explicação mais aceita. Isso é verificado pelo fato de os efeitos da despolarização serem maiores para áreas de vegetação do que para terrenos de complexidade simples.

Os sistemas de Radar podem ser agrupados em imageadores e não imageadores. Entre os imageadores encontra-se o Radar de visada lateral de Abertura Sintética, do inglês *Synthetic Aperture Radar* - SAR.

2.2 SAR

O SAR, desenvolvido na década de 50 possui uma antena que ilumina os alvos através de um feixe na direção perpendicular a direção de vôo da aeronave. A varredura de geração da imagem é feita pelo próprio movimento da aeronave durante sua passagem lateral a área imageada.

A resolução do sistema SAR é dependente do comprimento da antena. Contudo a resolução azimutal (paralela à trajetória da aeronave) desse sistema independe da distância entre o Radar e o alvo, podendo, portanto, operar a bordo de plataformas móveis, como aeronaves ou satélites.

Para contornar a indesejada dependência do comprimento da antena faz-se uso da técnica de abertura sintética. A técnica consiste na simulação de uma antena de comprimento maior que o real, pela compensação coerente de cada sinal de retorno. Quando o Radar se aproxima de um ponto na superfície, os sinais de retorno são alterados pelo efeito *Doppler* (construtivamente na aproximação e destrutivamente no afastamento), o que possibilita o imageamento do ponto durante todo o tempo em que este se encontra sob a iluminação

do Radar.

O satélite americano Seasat, lançado em 1978 carregava o primeiro SAR civil para o espaço. O satélite esteve em operação somente por três meses e meio mas o resultado foi considerado dentro do esperado. Alguns outros lançamentos ocorreram durante os anos 80. Nos anos 90 o uso do SAR realmente cresceu resultando em muitos lançamentos de satélites. Os parâmetros dos sistemas ainda eram quase os mesmos do bem sucedido Seasat, contudo alguns melhoramentos eram constantemente feitos. A última contribuição européia, Envisat, carrega um Avançado Radar de Abertura Sintética, do inglês *Advanced Synthetic Aperture Radar* - ASAR. Algumas das suas características incrementais são: capacidade de polarização dupla e imageamento de áreas com resolução variável.

2.2.1 Vantagens e Limitações

O Radar é um sistema ativo, ou seja, possui sua própria fonte de radiação, não necessitando de uma fonte externa, ao contrário de sensores óticos como câmeras fotográficas, *scanners* de varredura, entre outros. Por esse motivo, o Radar pode obter imagens em qualquer hora do dia ou da noite. Além disso, as microondas podem facilmente transpor nuvens e poluentes atmosféricos, pois a atenuação atmosférica dessas ondas é relativamente baixa. Apesar de inúmeras vantagens, o Radar também possui limitações, dentre as quais as mais significativas são: presença do ruído *speckle* e necessidade de um grande suporte computacional para o processamento dos dados brutos e das imagens. Estes problemas têm sido parcialmente solucionados, mas ainda constituem-se de fontes de pesquisa para melhoria do uso operacional do Radar.[Albuquerque 2004]

O ruído *speckle* é sempre associado a sistemas de imageamento coerente, tais como os obtidos por microondas, Laser e ultra-sonografia. A resposta ao Radar do tipo SAR, mesmo que para um simples tipo de superfície, contém importantes variações do nível de discretização que podem ocorrer entre células de resolução adjacentes. Considere que a célula de resolução de uma cena imageada possui um número muito grande de elementos difusores, estes elementos são responsáveis pela formação de cada *pixel* da imagem, e estão aleatoriamente distribuídos. Os retroespalhamentos de cada um destes elementos interferem entre si construtivamente ou destrutivamente, fazendo aparecer variações súbitas de intensidade da imagem, caracterizando o ruído *speckle* [ESA 2004].

A informação dominante de imagens SAR com frequência e polarização únicas se manifesta na forma de variações espaciais locais de tonalidade, como detalhes texturais e estruturais. O ruído *speckle*, que é inerente ao SAR, dificulta a interpretação das imagens, e portanto deve ser minimizado. O *speckle* pode ser reduzido através de processamento multivisada e/ou técnicas de filtragem [ESA 2004].

As imagens com mais de uma visada (*look*) são oriundas do processamento multivisada, o qual consiste na divisão dos dados disponíveis em vários setores que são, então processados independentemente. A imagem final é composta pela média de intensidade das imagens de cada visada, geradas separadamente. Supõe-se que as imagens de cada visada sejam estatisticamente independentes entre si. Esta técnica aumenta a relação sinal-ruído da imagem final, e por conseqüência, diminui o efeito do ruído *speckle* [ESA 2004].

Apesar do ruído *speckle*, muitas vezes, dificultar a visualização das feições nas ima-

gens, ele é protagonista na formação das diferenças de textura e tonalidade. Dessa forma, é importante tratar o ruído de modo a otimizar a possibilidade de separação de alvos, porém com o mínimo de perda das informações contidas na imagem.

2.3 Projetos de Sensoriamento Remoto utilizando Radar

Abaixo alguns grandes projetos que envolvem ou envolveram o imageamento da superfície terrestre utilizando sensores com tecnologia de Radar a bordo de satélites:

- ERS (*European Remote Sensing satellite*), da Agência Espacial Européia (*European Space Agency - ESA*) [ESA 2005b].
- Radarsat-1, da Agência Espacial Canadense (*Canadian Space Agency - CSA*) [CSA 2005].
- Envisat, mais recentemente, também da ESA [ESA 2005a].

2.3.1 ERS

O programa ERS iniciou-se com o ERS-1, cujo lançamento se deu em 17 de julho de 1991 pelo lançador francês Ariane 4 a partir da base de lançamentos de Kourou, na Guiana Francesa. O ERS-1 foi o 1º satélite de observação terrestre da ESA. O ERS-2 foi lançado em 21 de abril de 1995 também pelo veículo lançador Ariane 4 em Kourou. Os dois satélites têm órbita síncrona com o Sol, quase polar ($98,5^\circ$), com altitude de 800km, período de órbita de 100 minutos e um intervalo de revisita de 35 dias [ESA 2005b].

Na época dos seus lançamentos os dois satélites ERS eram os mais sofisticados veículos de observação terrestre desenvolvidos e lançados, na Europa. Esses altamente bem sucedidos satélites ESA têm colecionado uma grande quantidade de dados valiosos nas superfícies de terra, nos oceanos, e nas calotas polares e foram convocados para monitorar desastres naturais tais como inundações ou terremotos em partes remotas do mundo [ESA 2005b].

O ERS-1 carregava uma ampla carga incluindo um imageador SAR, um Radar altímetro e outros poderosos instrumentos para medição da temperatura da superfície oceânica e ventos no mar.

O ERS-2, que é semelhante ao ERS-1, tem dimensões de $2\text{m} \times 2\text{m}$ de base e 3m de altura com um painel solar de $12\text{m} \times 2,4\text{m}$ e carrega um sensor adicional para estudos atmosféricos da camada de ozônio. O ERS-2 é constituído de um SAR, com antena de 10m, e que pode operar no chamado modo “imagem”, em banda C (frequência de 5,3 GHz ou comprimento de onda $\approx 5,6$ cm), com polarização VV (transmissão e recepção vertical), e num ângulo de visada fixo em 23° no meio da faixa de imageamento. Fornece imagens com resolução espacial de $30\text{m} \times 30\text{m}$, numa cena de $100\text{km} \times 100\text{km}$. Esse modo de operação é largamente utilizado para aplicações terrestres. Mas esse Radar também pode operar no modo “onda” (*wave mode*) e então adquire imagens de $5\text{km} \times 5\text{km}$ a cada 200km ou 300 km, num sistema de amostragem, com aplicações em oceanografia, usado para derivar a altura média de ondas do oceano. Recentemente grandes imagens estão

sendo usados por investigadores para detectar elevadas ondas individuais, ondas gigantes (*tsunamis*) [ESA 2005b].

Logo depois do lançamento do ERS-2 em 1995, a ESA decidiu ligar os dois veículos espaciais na primeira missão conjunta que durou nove meses. Durante este tempo o aumento da frequência e do nível dos dados disponíveis aos cientistas ofereceram uma oportunidade única de observar mudanças sobre um espaço muito curto do tempo [ESA 2005b].

Em 1999, o satélite ERS-1 ficou finalmente sem combustível, excedendo seu tempo planejado de operação. Espera-se que o ERS-2 continue operando por mais alguns anos.

2.3.2 Radarsat-1

Outro satélite com sistema Radar, de grande importância para o sensoriamento remoto é o Radarsat-1, da CSA, lançado em 4 de novembro de 1995. Radarsat-1 é um projeto de observação avançada da Terra, através de satélite, desenvolvido para monitorar mudanças ambientais e dar suporte aos recursos sustentáveis. O Radarsat-1, que teve um planejamento inicial de tempo de operação de 5 anos, está equipado com um sensor SAR.

O Radarsat-1 tem órbita circular em torno da Terra com período de 100,7 minutos (14 vezes por dia) numa altitude de 798km, com inclinação de $98,6^\circ$ em relação ao equador. Sua órbita é heliossíncrona, e o período de revisita é de 24 dias para um mesmo modo de operação e ângulo de incidência, embora possa ter imageamentos distanciados de apenas 4,5 dias para ângulos de incidência diferentes. Essa configuração orbital permite que o Radarsat-1 explore ao máximo as condições de iluminação de seu painel solar, e ao mesmo tempo passe sobre as estações de recepção em horários não utilizados por outros satélites, evitando assim, conflitos de gravação dos dados [CSA 2005].

O Radarsat-1 com massa de 3200kg, opera um sensor SAR na banca C (frequência de 5,3 GHz ou comprimento de onda $\approx 5,6$ cm), em polarização HH (transmissão e recepção horizontal). O fato do Radarsat-1 estar equipado com um sensor SAR fornece vantagens significativas em observação sob circunstâncias que impossibilitariam um satélite que utiliza a faixa do espectro óptico. O sistema possui vários modos de imageamento. Pode variar o ângulo de incidência de 20° até 50° , com sua antena de $15\text{m} \times 1,5\text{m}$. A largura da área imageada pode variar de 35km a 500km, e as resoluções espaciais podem variar de 10m a 100m. O tempo entre a aquisição e a transmissão da imagem pode ser realizado dentro de um dia [CSA 2005].

O Radarsat-1 pode capturar dados em imagens num período de 28 minutos de 1.1 milhão quilômetros quadrados da superfície da Terra. Afim servir a usuários comerciais, os dados são transferidos em tempo real ou armazenados em um dos dois registradores de fita que o veículo espacial possui e passados posteriormente para a estação de recepção [CSA 2005].

O Radarsat-1 entrega sete produtos em diferentes padrões de dados que refletem as opções de imageamento do SAR. Estes estão disponíveis em três categorias de fidelidade geométrica - *quick look*, *georeferenced*, e o *geocoded*. O *quick look* consiste de imagens SAR não corrigidas. Os produtos de *georeferenced* são corrigidos geometricamente para compensar a curvatura da Terra. No Radarsat-1 *geocoded* a informação posicional precisa

da fonte dos dados é suprida para projeções de mapas padrão [CSA 2005].

O programa Radarsat-1, com sua flexibilidade operacional, fornece qualidade elevada aos investigadores e aos profissionais ambientais. Para sustentar a posição internacional, a CSA prepara um outro programa de Sensoriamento Remoto, Radarsat-2. Neste programa espera-se explorar ainda mais o potencial adquirido com o Radarsat-1 para produzir novas informações ambientais, proporcionando uma contínua observação da Terra.

2.3.3 Envisat

Lançado em 2002, o Envisat é o maior veículo de observação terrestre. Ele carrega 10 sofisticados instrumentos ópticos e de Radar, para prover um contínuo monitoramento de terras, oceanos, atmosfera e calotas polares da Terra. Os dados do Envisat fornecem coletivamente uma grande riqueza de informações.

Além disso, os dados retornados por seus instrumentos estão facilitando também o desenvolvimento de um número de aplicações operacionais e comerciais.

Seu maior instrumento é o Radar Avançado de Abertura Sintética, do inglês *Advanced Synthetic Aperture Radar* (ASAR), operando na banda C, assegura a continuidade na geração dos dados após o ERS-2. Suas características melhoram as capacidades em termos da cobertura, na escala de ângulos da incidência, na polarização, e nas modalidades de operação. As melhorias permitem o direcionamento da elevação do feixe do Radar e a seleção dos diferentes imageamentos, de 100km ou de 400km de largura [ESA 2005a].

O Espectrômetro Imageador de Resolução Média, do inglês *Medium Resolution Imaging Spectrometer* (MERIS), é um espectrômetro imageador que mede a radiação solar refletida pela terra. Com resolução espacial de 300m e com 15 bandas espectrais, na faixa visível e no infravermelho próximo e programável na largura e na posição, o MERIS permite a cobertura global da terra a cada 3 dias [ESA 2005a].

A missão primária do MERIS é a medição da coloração de oceanos e áreas costeiras. O conhecimento da cor marinha pode ser convertido em uma medida da concentração do pigmento clorofila, da concentração de sedimento suspenso e das áreas marinhas com excesso de cargas de aerossol. É usado também para a monitoração de terras e da atmosfera.

O Envisat foi lançado em 1º de março de 2002 através do lançador Ariane 5 da base aérea Kourou na Guiana Francesa. O satélite tem órbita síncrona com o Sol, quase polar, com inclinação de 98° a uma altitude de 800km. O tempo de uma órbita é de 101 minutos e o ciclo de revisita é de 35 dias, porém muitos sensores possuem vários modos de imageamento e podem observar todo o planeta a cada alguns dias [ESA 2005a].

2.4 Manchas em Imagens Marinhas

A relação entre ressonância e amortecimento das ondas da superfície aquática está associada ao fato de que as superfícies elásticas podem transportar (dentre outros) dois tipos de ondas: as chamadas ondas de Marangoni e as ondas de gravidade e capilares, consideradas na literatura como de um único tipo, gravidade-capilares. As ondas de Marangoni são ondas longitudinais predominantes na camada limite ou de separação. As ondas do tipo gravidade-capilares são geradas por ventos [Albuquerque 2004].

A teoria de Marangoni mostra que ocorre um máximo no amortecimento das ondas, quando para uma dada frequência o número de onda das ondas de Marangoni e gravidade-capilares coincidem. A frequência e a magnitude do amortecimento máximo dependem da estrutura química e da constituição das moléculas do filme [Albuquerque 2004].

As ondas capilares e de gravidade são as principais responsáveis pelo processo de espalhamento da radiação incidente na superfície oceânica sob as mais variadas condições do mar e de visada do Radar. As ondas capilares refletem os sinais oriundos do Radar, pois possuem comprimento de onda compatível com o exigido para uma condição ressoante de Bragg. Embora sejam as ondas capilares as responsáveis pelo retroespalhamento de Bragg, este é modulado pelas ondas de gravidade e por outros fenômenos cinemáticos e/ou dinâmicos presentes nas camadas superiores do oceano. A teoria de Bragg estabelece que, para uma superfície aleatória, dividida em seus componentes espectrais, a energia retroespalhada dominante origina-se das componentes que estiverem em ressonância com a onda incidente [Vesecky 1995].

A rugosidade de um alvo não é uma propriedade intrínseca deste, mas depende das irregularidades de sua superfície em relação ao comprimento de onda e ao ângulo de incidência da radiação que o ilumina. Casos em que as dimensões das irregularidades superficiais são comparáveis ao comprimento de onda do sinal do Radar, tem-se a ocorrência do chamado espalhamento Rayleigh. Portanto, considerando o comprimento de onda da radiação incidente uma superfície com irregularidades de poucos centímetros pode ser rugosa na banda C ($\lambda \sim 5,6\text{cm}$) e lisa na banda P ($\lambda \sim 75\text{cm}$).

Como exemplo, as superfícies de águas relativamente calmas aparecem como regiões escuras em imagem de Radar (banda C), pois a maior parte do pulso incidente é refletida em um ângulo fora do alcance de visado do receptor. Diz-se nesse caso que houve um espalhamento especular, processo inverso ao retroespalhamento (onde o pulso refletido retorna pelo mesmo caminho em que chegou à superfície), como mostra a figura 2.1. A interação entre a superfície oceânica e as microondas é muito sensível a variações na rugosidade e condutividade elétrica (por esta razão, no mar, a profundidade de penetração das microondas é desprezível).

Discretizando a intensidade da energia de retorno numa escala em níveis de cinza, onde os tons mais escuros são atribuídos para intensidades fracas e tons mais claros para intensidades fortes, algumas assinaturas de alvos podem ser inferidas. Por causa dos diversos formatos e orientações, a vegetação produz assinaturas com intensidades intermediárias variantes. Objetos metálicos, tal como pontes, navios, produzem um retorno muito forte e assinaturas brilhosas por causa de suas geometrias e propriedades elétricas. A energia do Radar em águas bastante calmas ou cobertas por substâncias oleosas é quase totalmente refletida com valor de ângulo de reflexão igual ao ângulo de incidência em relação ao alvo, mas com sinal oposto. Uma quantidade reduzida de energia é retornada para a antena e uma assinatura negra é obtida. Superfícies lisas são chamadas de alvos especulares, pois como espelhos refletem a energia incidente do Radar.

Em particular, para velocidades de vento inferiores a 2 – 3m/s, áreas escuras podem ser visualizadas. Para velocidades de ventos superiores a 7 – 8m/s mas inferiores a 15m/s, manchas naturais são dispersadas enquanto que manchas de óleo permanecem visíveis. Para velocidades de vento superiores a 15m/s é possível ter emulsão entre água e óleo tal




Figura 2.1: Espalhamento do sinal do Radar em duas superfícies marinhas. Uma livre da presença de óleo e outra não.

que manchas de óleo tornam-se ambíguas para o SAR [Frate e Salvatori 2004].

Alguns fenômenos e objetos que se caracterizam em imagens de Radar por áreas escuras são: filmes naturais, campos de vento, células de chuva, camadas de gelo e ondas internas [Albuquerque 2004].

2.5 Considerações Finais

A resolução nominal espacial dos dados de imageamento por Radar é, geralmente, em torno de $25\text{m} \times 25\text{m}$, mas para detecção de manchas de óleo imagens com baixa resolução ($100\text{m} \times 100\text{m}$) são suficientes [Frate e Salvatori 2004]. Desde que disponíveis, imagens dos três satélites imageadores citados anteriormente poderão ser utilizadas no sistema proposto.

Através da extração de características da cena analisada, as propriedades descritas na seção 2.4 serão incorporadas de forma indireta no processo de classificação. Para isso os algoritmos de processamento digital de imagem, apresentado no capítulo seguinte, tornam-se indispensáveis.

Capítulo 3

Processamento Digital de Imagens

Nesta capítulo, serão apresentadas e discutidas as diferentes técnicas de processamento digital de imagens aplicadas no sistema de identificação de manchas de óleo sobre a superfície marinha, assim como as características extraídas dos objetos em questão.

O processamento aqui aplicado tem o intuito de auxiliar a percepção autônoma de máquinas para um dado evento por elas investigado. O foco principal é a extração de características que possam facilitar o reconhecimento e a classificação de padrões presentes na imagem de sensoriamento remoto descrita no capítulo anterior.

3.1 Filtragem Espacial

O uso de operadores (máscaras) espaciais para o processamento digital de imagens é usualmente chamado filtragem espacial, e as máscaras são chamadas filtros espaciais. A utilização de filtros espaciais lineares e não lineares para realce de imagens é vastamente encontrada na literatura [Gonzalez e Woods 2003]. A figura 3.1 mostra uma máscara genérica 3×3 .

m_1	m_2	m_3
m_4	m_5	m_6
m_7	m_8	m_9

Figura 3.1: Uma máscara 3×3 com coeficientes arbitrários.

Denotando os níveis de cinza dos *pixels* da imagem sob a máscara em qualquer posição da mesma por z_1, z_2, \dots, z_9 , a resposta de uma máscara linear é

$$R = m_1 \cdot z_1 + m_2 \cdot z_2 + \dots + m_9 \cdot z_9 \quad (3.1)$$

como ilustra a figura 3.2.

Se o centro da máscara estiver numa posição (o, p) na imagem, o nível de cinza deste *pixel* é substituído por R . A máscara é então movida para a próxima posição de *pixel* na

imagem e o processo se repete. Isso continua, geralmente, até que todas as posições da imagem tenham sido cobertas. O valor de R é computado através do uso de vizinhanças parciais para *pixels* que estão posicionados nos limites da imagem.

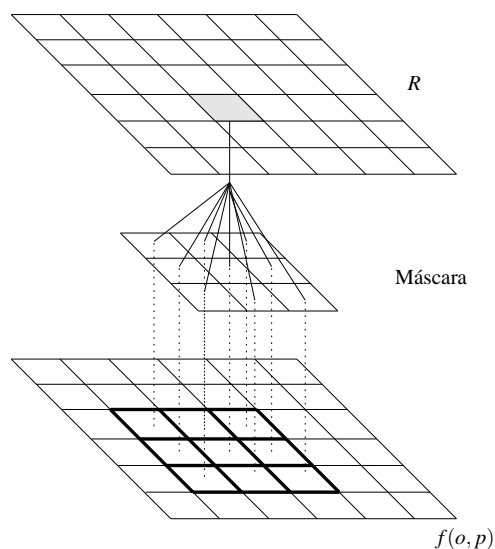


Figura 3.2: Resposta de uma operação de filtragem.

Filtros espaciais não-lineares também operam em vizinhanças. Em geral, entretanto, a operação desses filtros baseia-se diretamente nos valores dos *pixels* da vizinhança considerada, não utilizando coeficientes da maneira descrita na equação (3.1). Ex: filtro max, filtro min.

3.1.1 Filtragem do Ruído *Speckle*

Uma boa filtragem do ruído *speckle* precisa preservar os valores médios da região analisada além da variabilidade espacial (informação de textura) da cena.

Filtro da Mediana

Esse método é particularmente efetivo quando o padrão ruidoso apresenta componentes fortes, sendo que a característica a ser preservada é a precisão das bordas. Os filtros por mediana são não-lineares. A mediana de um conjunto de valores é tal que metade dos valores ordenados no conjunto são maiores ou iguais à mesma. Assim, a função principal da filtragem por mediana é forçar pontos com intensidades distintas assemelharem-se à seus vizinhos, efetivamente eliminando picos de intensidade que apareçam isolados na área da máscara do filtro [Gonzalez e Woods 2003].

Filtro de Lee

O filtro de Lee adota um modelo multiplicativo para o ruído e obedece o critério do mínimo erro local médio quadrático linear. É dito local, porque utiliza estatísticas locais

do *pixel* a ser filtrado, admitindo a não estacionariedade da média e da variância do sinal. É um filtro linear porque realiza uma linearização por expansão em série de Taylor da multiplicação do sinal e o ruído em torno da média, utilizando apenas os termos lineares. O resultado da linearização transforma o modelo multiplicativo do ruído em aditivo, ou seja, o ruído e o sinal tornam-se independentes; e, finalmente, mínimo médio quadrático, porque minimiza o erro médio quadrático através do filtro de Wiener. O filtro de Lee é um filtro adaptativo [DPI/INPE 2002].

O valor resultante R do *pixel* analisado é:

$$R = I_c \cdot Z_l + Im \cdot (1 - Z_l) \quad (3.2)$$

onde:

- $Z_l = 1 - Ce^2/Ci^2$
- $Ce = \sqrt{(1/N_{look})}$
- $Ci = Dp/Im$
- I_c . *pixel* central da janela, o *pixel* analisado.
- Im . Valor médio dos *pixels* sob a janela.
- Dp . Desvio padrão dos *pixels* sob a janela analisada.
- N_{look} . Número de visadas da imagem.

A quantidade Ce acima é o coeficiente estimado de variação do ruído e a quantidade Ci é o coeficiente de variação da imagem. Z_l é uma função de ponderação do filtro de Lee.

Filtro de Frost

O filtro de Frost é um filtro convolucional linear, derivado da minimização do erro médio quadrático sobre o modelo multiplicativo do ruído. Neste filtro incorpora-se a dependência estatística do sinal original, uma vez que se supõe uma função de correlação espacial exponencial entre *pixels* [DPI/INPE 2002].

Este filtro utiliza uma máscara de convolução exponencialmente amortecida que se adapta às características baseadas em estatísticas locais. O filtro de Frost difere dos filtros de Lee e de Kuan com respeito a como a reflectividade da cena é estimada, convoluindo a imagem observada com a resposta ao impulso do sistema SAR. A resposta ao impulso do sistema do SAR é obtida minimizando o erro quadrático médio entre a imagem observada e o modelo de reflectividade da cena que é suposto para ser um processo autoregressivo.

A implementação deste filtro consiste da definição do tamanho de uma janela onde o valor das ponderações sobre cada *pixel* na imagem é definida pelos pesos de M :

$$M = \exp(-A \cdot L) \quad (3.3)$$

onde

- $A = Amt \cdot Ci^2$
- $Ci = Dp/Im$
- Im . Valor médio dos *pixels* sob a janela.

- Dp . Desvio padrão dos *pixels* sob a janela analisada.
- L . Distância medida entre o *pixel* central analisado e seus vizinhos na janela.
- Amt . Fator de amortecimento exponencial.

O valor resultante R do *pixel* analisado é:

$$R = \frac{(z_1 \cdot m_1 + z_2 \cdot m_2 + \dots + z_n \cdot m_n)}{(m_1 + m_2 + \dots + m_n)} \quad (3.4)$$

onde z_1, \dots, z_n são os *pixels* da imagem e m_1, \dots, m_n são os fatores de ponderação da máscara sobre a área analisada.

Filtro de Kuan

O filtro de Kuan adota um modelo multiplicativo para o ruído. O procedimento é semelhante àquele de Lee, onde a estimação ponto a ponto é feita utilizando-se o filtro de Wiener. A diferença entre eles, entretanto, consiste no fato de que no filtro de Kuan não se realiza nenhuma aproximação. É também um filtro adaptativo e geral [DPI/INPE 2002].

O filtro de Kuan transforma primeiramente o modelo multiplicativo do ruído em um modelo aditivo. O critério de minimização do erro médio quadrático é aplicado então ao modelo. O filtro resultante tem a mesma forma que o filtro de Lee mas com uma função ponderativa diferente. Por não fazer nenhuma aproximação ao modelo original, pode-se considerar o filtro de Kuan superior ao filtro de Lee [DPI/INPE 2002].

O valor resultante R do *pixel* analisado é:

$$R = I_c \cdot Z_k + Im \cdot (1 - Z_k) \quad (3.5)$$

onde:

- $Z_k = (1 - Ce^2/Ci^2) / (1 + Ce^2)$
- $Ce = \sqrt{(1/N_{look})}$
- $Ci = Dp/Im$
- I_c . *pixel* central da janela, o *pixel* analisado.
- Im . Valor médio dos *pixels* sob a janela.
- Dp . Desvio padrão dos *pixels* sob a janela analisada.
- N_{look} . Número de visadas da imagem.

A quantidade Z_k é uma função de ponderação do filtro de Kuan.

Filtro de Lee modificado

A proposição da divisão da imagem em áreas de três diferentes classes proposta por Lopes et al. (1990) é uma alternativa mais recente. Nesta divisão a primeira classe corresponde a áreas homogêneas em que o ruído *speckle* pode ser eliminado simplesmente pela passagem de um filtro passa-baixa. A segunda classe corresponde a áreas heterogêneas em que o ruído *speckle* é reduzido, enquanto a textura é preservada. E a terceira classe

são áreas contendo pontos (alvos) isolados, em que o filtro preservaria o valor observado. A classificação das regiões mencionadas é baseada em coeficientes de variação.

A saída do filtro é:

$$R = \begin{cases} I_m & \text{se } C_i \leq C_e \\ I_m \cdot Z_{le} + I_c \cdot (1 - Z_{le}) & \text{se } C_e < C_i < C_{max} \\ I_c & \text{se } C_i \geq C_{max} \end{cases} \quad (3.6)$$

onde

- $Z_{le} = \exp(-Amt \cdot (C_i - C_e) / (C_{max} - C_i))$
- $C_e = \sqrt{(1/N_{look})}$
- $C_i = Dp / I_m$
- $C_{max} = \sqrt{(1 + 2/N_{look})}$
- I_c . *pixel* central da janela, o *pixel* analisado.
- I_m . Valor médio dos *pixels* sob a janela.
- Dp . Desvio padrão dos *pixels* sob a janela analisada.
- L . Distância medida entre o *pixel* central analisado e seus vizinhos na janela.
- Amt . Fator de amortecimento exponencial.
- N_{look} . Número de visadas da imagem.

A quantidade Z_{lm} é uma função de ponderação do filtro de Lee modificado.

Filtro de Frost modificado

O filtro de Frost modificado é semelhante ao filtro de Lee modificado que considera três tipos diferentes de áreas da imagem separada: áreas homogêneas, áreas heterogêneas, e alvos pontuais isolados. No caso heterogêneo, a saída do filtro é obtida da convolução da imagem com uma máscara de ponderação [Lopes et al. 1990].

A saída do filtro é:

$$R = \begin{cases} I_m & \text{se } C_i \leq C_e \\ R_f & \text{se } C_e < C_i < C_{max} \\ I_c & \text{se } C_i \geq C_{max} \end{cases} \quad (3.7)$$

R_f é o resultado da convolução da imagem com a máscara M de ponderação

$$M = \exp(-A \cdot L) \quad (3.8)$$

onde

- $A = Amt \cdot (C_i - C_e) / (C_{max} - C_i)$
- $C_e = \sqrt{(1/N_{look})}$
- $C_i = Dp / I_m$
- $C_{max} = \sqrt{(1 + 2/N_{look})}$
- I_c . *pixel* central da janela, o *pixel* analisado.
- I_m . Valor médio dos *pixels* sob a janela.
- Dp . Desvio padrão dos *pixels* sob a janela analisada.
- L . Distância medida entre o *pixel* central analisado e seus vizinhos na janela.

- Amt . Fator de amortecimento exponencial.
- N_{look} . Número de visadas da imagem.

O valor resultante Rf do *pixel* analisado é:

$$Rf = \frac{(z_1 \cdot m_1 + z_2 \cdot m_2 + \dots + z_n \cdot m_n)}{(m_1 + m_2 + \dots + m_n)} \quad (3.9)$$

onde z_1, \dots, z_n são os *pixels* da imagem e m_1, \dots, m_n são os fatores de ponderação da máscara sobre a área analisada.

No capítulo 6 é feita uma análise comparativa de todos os filtros expostos em um exemplo numérico com uma das imagens utilizadas no treinamento do classificador.

3.1.2 Filtro Log

O realce da imagem pelo uso da função logarítmica (figura 3.1.2) considera somente o valor isolado do pixel da imagem, sem realizar nenhuma observação sobre seus vizinhos. A função logarítmica tem como propriedade um mapeamento próximo do linear para valores de entrada pequeno. Isso é interessante, pois o objeto de interesse na cena é composto de tonalidades escuras, ou seja, valores discretizados de amplitude pequenos. Já para valores elevados de entrada a função logarítmica tende a mapear a saída para valores também elevados, porém próximos.

Essa condição preserva a ordem dos níveis de cinza cujo valor está próximo do valor do objeto de interesse, minimizando assim a criação de artefatos na intensidade da imagem processada. Além disso possibilita a redução do número de vetores utilizados no bloco de quantização vetorial, agilizando o processo como um todo.




Figura 3.3: Função do filtro Log.

-1	-2	-1
0	0	0
1	2	1

(a)

-1	0	1
-2	0	2
-1	0	1

(b)

Figura 3.4: Máscaras denominadas operadores de Sobel: (a) Gradiente na direção vertical; (b) Gradiente na direção horizontal.

3.1.3 Filtros por Derivadas

Com o intuito de extrair as características de borda das manchas analisadas, algoritmos de derivação são utilizados para a extração do gradiente da imagem.

O cálculo da média dos *pixels* sobre uma região tende a borrar os detalhes de uma imagem. Assim como o cálculo da média é análogo à integração, pode-se esperar que a diferenciação tenha efeito oposto.

O método mais comum de diferenciação em aplicações de processamento de imagens é o gradiente. Para uma função $f(o, p)$ o gradiente de f nas coordenadas (o, p) é definido como o vetor

$$\nabla f = \begin{bmatrix} \frac{\partial f}{\partial o} \\ \frac{\partial f}{\partial p} \end{bmatrix} \quad (3.10)$$

A magnitude desse vetor

$$\nabla f = \text{mag}(\nabla f) = \left[\left(\frac{\partial f}{\partial o} \right)^2 + \left(\frac{\partial f}{\partial p} \right)^2 \right]^{1/2} \quad (3.11)$$

comumente aproximada com os valores absolutos

$$\nabla f \approx \left| \left(\frac{\partial f}{\partial o} \right) \right| + \left| \left(\frac{\partial f}{\partial p} \right) \right| \quad (3.12)$$

é a base para várias abordagens de diferenciação de imagens. A equação 3.11 pode ser aproximada no ponto central da máscara de várias maneiras. Na literatura encontramos os operadores de Sobel, Prewitt entre outros, que realizam essa tarefa [k. Jain 1989].

Os operadores de Sobel possuem a vantagem de fornecer a um só tempo os efeitos de diferenciação e de suavização. Uma vez que a derivação aumenta o ruído, o efeito de suavização é uma característica particularmente atrativa. A figura 3.4 mostra as máscaras de Sobel.

As derivadas baseadas nas máscaras do operador de Sobel são

$$\frac{\partial f}{\partial o} = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \quad (3.13)$$

-1	-1	-1
0	0	0
1	1	1

(a)

-1	0	1
-1	0	1
-1	0	1

(b)

Figura 3.5: Máscaras denominadas operadores de Prewitt: (a)Gradiente na direção vertical; (b)Gradiente na direção horizontal.

e

$$\frac{\partial f}{\partial p} = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7) \quad (3.14)$$

em que, como anteriormente, os z são os níveis de cinza dos *pixels* sobrepostos pelas máscaras em qualquer posição da imagem [Gonzalez e Woods 2003].

Os operadores de Prewitt são mostrados na figura 3.5. Esses operadores realizam uma aproximação da equação 3.12 para o ponto central z_5 de uma máscara 3×3 .

$$\nabla_f = |(z_7 + z_8 + z_9) - (z_1 + z_2 + z_3)| + |(z_3 + z_6 + z_9) - (z_1 + z_4 + z_7)| \quad (3.15)$$

O capítulo 5, que apresenta o sistema proposto, detalha a inserção do cálculo do gradiente para a obtenção de alguns descritores.

3.2 Quantização Vetorial

A quantização vetorial é utilizada como passo importante no processo de autosegmentação. Por se tratar de um algoritmo não supervisionado, mantém a automatização desejada além de possuir um tempo de processamento aceitável para um número pequeno de classes [Gonzalez e Woods 2003].

O principal objetivo dos algoritmos de quantização vetorial é armazenar um conjunto grande de vetores de entrada em um conjunto menor de vetores protótipos, de forma a oferecer uma boa aproximação para o espaço de entrada original. Essa abordagem tem como principal motivação a redução de dimensionalidade ou compressão de dados.

A grande questão é o erro ou distorção que essa técnica insere nos dados finais, em relação ao conjunto de dados originais. A compressão com o mínimo de distorção é o paradigma buscado pelos seus usuários. A tolerância à perda pode variar, para as mais variadas aplicações da técnica.

As condições para a minimização da distorção esperada D são incorporadas no algoritmo de Lloyd generalizado [Haykin 2001]. São duas essas condições:

1. Dado o vetor de entrada \mathbf{x} , escolhe-se o vetor centro \mathbf{t} para minimizar a distorção de erro quadrado $\|\mathbf{x} - \mathbf{t}\|^2$.

2. Dado o centro \mathbf{t} , calcula-se o vetor reconstruído $\hat{\mathbf{x}}$ como o centróide dos vetores de entrada \mathbf{x} que satisfazem a condição 1.

A condição 1 é conhecida como a regra de codificação do vizinho mais próximo. As condições 1 e 2 implicam que a distorção média D é estacionária em relação as possíveis variações no processo. Para implementar a quantização vetorial, o algoritmo de Lloyd generalizado opera em modo de treinamento por lote. Basicamente, o algoritmo consiste em otimizar sucessivamente o codificador de acordo com a condição 1, e então otimizar o decodificador com a condição 2, até que a distorção esperada D alcance um mínimo [Haykin 2001, Linde et al. 1980].

Para superar o problema do mínimo local, pode ser necessário executar o algoritmo de Lloyd generalizado várias vezes com diferentes vetores código iniciais.

3.3 Limiarização

O objetivo dessa transformação é a redução do número de tons da imagem. Quando os valores dos níveis de cinza dos objetos e do fundo são razoavelmente consistentes, na imagem como um todo, somente um único valor de limiar é necessário para efetuar a separação dos objetos do fundo da imagem. Esse método é conhecido como limiarização global.

Esse tipo de manipulação é de grande interesse quando a imagem é formada por objetos de classes com um nível de separação no espaço de amostragem identificável. O objetivo é a separação de tudo aquilo que não tiver relevância para o objeto de estudo. Para imagens sem ruído, o limiar de separação é escolhido para que todos os *pixels* dentro de uma faixa de valores sejam reconhecidos como objetos de interesse.

A limiarização é um processo extremamente veloz, geralmente realizado em um único passo, que respeita a seguinte regra para um caso de partição binária, opção utilizado nesse trabalho, onde o objeto é de tonalidade mais escura que o fundo da imagem

$$\begin{cases} \text{se } f(o, p) > l & f(o, p) \in \text{fundo} \\ \text{senão} & f(o, p) \in \text{mancha} \end{cases} \quad (3.16)$$

l é um parâmetro chave, pois determina a partição ótima das classes, e conhecido como limiar.

3.4 Morfologia Matemática

O termo morfologia matemática é empregado na designação de ferramentas para extração de componentes de imagens que sejam úteis na representação e descrição da forma de uma região, como: fronteiras, esqueletos e fechos convexos, utilizadas nesse trabalho. Essa ferramenta possibilita técnicas de pré-processamento, como: filtragem morfológica, afinamento e poda [Gonzalez e Woods 2003].

A base da morfologia matemática é a teoria de conjuntos ou a álgebra de reticulados. Os conjuntos em morfologia matemática representam as formas dos objetos em uma imagem. Em imagens binárias, os conjuntos em questão são membros do espaço bidimensional de números inteiros \mathbb{Z}^2 , em que cada elemento do conjunto é um vetor bidimensional cujas coordenadas são as coordenadas dos *pixels* do objeto em análise.

Sejam \mathcal{A} e \mathcal{B} conjuntos de \mathbb{Z}^2 , com componentes $\mathbf{a} = (a_1, a_2)$ e $\mathbf{b} = (b_1, b_2)$, respectivamente. A translação de \mathcal{A} por $\mathbf{q} = (q_1, q_2)$, denotada por $(\mathcal{A})_q$, é definida como

$$(\mathcal{A})_q = \{\mathbf{s} | \mathbf{s} = \mathbf{a} + \mathbf{q}, \text{ para } \mathbf{a} \in \mathcal{A}\} \quad (3.17)$$

A reflexão de \mathcal{B} , denotada por $\hat{\mathcal{B}}$, é definida como

$$\hat{\mathcal{B}} = \{\mathbf{q} | \mathbf{q} = -\mathbf{b}, \text{ para } \mathbf{b} \in \mathcal{B}\} \quad (3.18)$$

O complemento do conjunto \mathcal{A} que é o conjunto dos elementos não pertencentes ao mesmo, é definido como

$$\mathcal{A}^c = \{\mathbf{q} | \mathbf{q} \notin \mathcal{A}\} \quad (3.19)$$

Por fim, a diferença entre dois conjuntos \mathcal{A} e \mathcal{B} é o conjunto dos elementos que pertençam a \mathcal{A} mas que não pertençam a \mathcal{B} , denotada por $\mathcal{A} - \mathcal{B}$ e definida como

$$\mathcal{A} - \mathcal{B} = \{\mathbf{q} | \mathbf{q} \in \mathcal{A}, \mathbf{q} \notin \mathcal{B}\} = \mathcal{A} \cap \mathcal{B}^c \quad (3.20)$$

3.4.1 Elemento Estruturante

A idéia de morfologia é que uma imagem consiste de *pixels* que são reunidos em grupos tendo uma estrutura bidimensional. Certas operações matemáticas em conjuntos de *pixels* podem ser usadas para ressaltar aspectos específicos das formas, permitindo que sejam contadas ou reconhecidas [k. Jain 1989].

A essência da morfologia consiste em extrair de uma imagem desconhecida a sua geometria a partir da utilização de uma outra imagem completamente definida. Ou seja, extrair as informações relativas a geometria e topologia de um conjunto desconhecido pela transformação através de outro conjunto bem-definido, chamado elemento estruturante. Com isso torna-se importante o contexto de teoria de conjuntos, pois esta é a base utilizada na morfologia matemática.

3.4.2 Dilatação

A operação de dilatação é designada como uma das operações básicas da morfologia digital. O processo pode ser resumido na alteração de uma pequena área relacionada a um *pixel* para um determinado padrão.

Tomando-se \mathcal{A} e \mathcal{B} como conjuntos de \mathbb{Z}^2 e \emptyset como o conjunto vazio, define-se a dilatação de \mathcal{A} por \mathcal{B} como

$$\mathcal{A} \oplus \mathcal{B} = \left\{ x \mid \left[\left(\hat{\mathcal{B}} \right)_x \cap \mathcal{A} \right] \subseteq \mathcal{A} \right\} \quad (3.21)$$

3.4.3 Erosão

A operação de erosão é outra operação básica da morfologia digital. O processo pode ser resumido no apagamento dos *pixels* que não atendem a um determinado padrão.

Novamente tomando-se \mathcal{A} e \mathcal{B} como conjuntos de \mathbb{Z}^2 e \emptyset como o conjunto vazio, defini-se a erosão de \mathcal{A} por \mathcal{B} como

$$\mathcal{A} \ominus \mathcal{B} = \{x | (\mathcal{B})_x \subseteq \mathcal{A}\} \quad (3.22)$$

3.4.4 Abertura

A dilatação expande uma imagem enquanto a erosão a reduz. A abertura geralmente suaviza o contorno de uma imagem, quebra istmos estreitos e elimina protusões finas.

Abertura de um conjunto \mathcal{A} por um elemento estruturante \mathcal{B} , denotada por $\mathcal{A} \circ \mathcal{B}$, é definida como

$$\mathcal{A} \circ \mathcal{B} = (\mathcal{A} \ominus \mathcal{B}) \oplus \mathcal{B} \quad (3.23)$$

Significando que a abertura de \mathcal{A} por \mathcal{B} é simplesmente a erosão de \mathcal{A} por \mathcal{B} seguido da dilatação do resultado por \mathcal{B} . Muitos outros operadores morfológicos podem ser definidos em termos dos operadores de dilatação e erosão [Gonzalez e Woods 2003].

3.5 Transformada de Hotelling

Essa transformada também é comumente denominada e conhecida como análise de componentes principais ou transformada discreta de Karhunen-Loève.

A transformada de Hotelling baseia-se em propriedades estatísticas de representação de vetores. O objetivo da transformada é a representação do conjunto de dados originais, em um conjunto de componentes principais (Espaço de Hotelling), em que a informação está hierarquizada pelo grau de relevância que ela traz do conjunto de dados originais [Gonzalez e Woods 2003].

O objeto visualizado é tratado como um conjunto bidimensional. Cada *pixel* no objeto é tratado como um vetor bidimensional \mathbf{q} , em que q_1 e q_2 são as coordenadas de cada *pixel* com respeito as eixos da imagem. Esses vetores são usados para computar o vetor médio e a matriz de covariância do conjunto.

Considerando um conjunto de vetores do tipo

$$\mathbf{q} = \begin{bmatrix} q_1 \\ q_2 \end{bmatrix} \quad (3.24)$$

uma matriz de covariância é extraída do conjunto de dados iniciais

$$\mathbf{C}_q = E \left\{ (\mathbf{q} - \mathbf{m}_q) (\mathbf{q} - \mathbf{m}_q)^T \right\} \quad (3.25)$$

onde

$$\mathbf{m}_q = E \{ \mathbf{q} \} \quad (3.26)$$

é o vetor médio, e $E\{\cdot\}$ é o valor esperado do argumento. Para N amostras, pode-se aproximar discretamente a equação (3.25) e (3.26) por

$$\mathbf{C}_q = \frac{1}{N} \sum_{k=1}^N \mathbf{q}_k \mathbf{q}_k^T - \mathbf{m}_q \mathbf{m}_q^T \quad (3.27)$$

e

$$\mathbf{m}_q = \frac{1}{N} \sum_{k=1}^N \mathbf{q}_k \quad (3.28)$$

de tal forma que o elemento c_{ii} de \mathbf{C}_q é a variância de q_i , e os elementos c_{ij} são as covariâncias entre os elementos q_i e q_j desses vetores. Se os elementos q_i e q_j não estão correlacionados, suas covariâncias são igual a zero, $c_{ij} = c_{ji} = 0$ [Gonzalez e Woods 2003].

Como \mathbf{C}_q é real e simétrica, é sempre possível encontrar um conjunto de n autovetores ortonormais [Gonzalez e Woods 2003]. A utilização da Decomposição por Valor Singular pode ser aplicada aqui, como mostra o apêndice A. Seja \mathbf{T} uma matriz cujas colunas são formadas a partir dos autovetores de \mathbf{C}_q , ordenada de modo que sua primeira coluna é o autovetor obtido a partir do maior autovalor, e a última coluna é o autovetor obtido a partir do menor autovalor de \mathbf{C}_q (o autovetor correspondente ao maior autovalor pode ser interpretado como a marca espectral contendo a informação mais comum de todos os *pixels* do objeto). A transformada de Hotelling é obtida através de

$$\mathbf{r} = \mathbf{T}^T (\mathbf{q} - \mathbf{m}_q) \quad (3.29)$$

onde a matriz de transformação \mathbf{T} mapeia os vetores \mathbf{q} em vetores \mathbf{r} , compondo os planos de componentes principais. A média dos vetores \mathbf{r} resultante dessa transformação é zero, e a matriz de covariância do plano de componentes principais pode ser obtida em termos de \mathbf{T} e \mathbf{C}_q através de

$$\mathbf{C}_r = \mathbf{T}^T \mathbf{C}_q \mathbf{T} \quad (3.30)$$

Além disso, \mathbf{C}_r é uma matriz diagonal cujos elementos são os autovalores de \mathbf{C}_q .

$$\mathbf{C}_r = \begin{bmatrix} \gamma_1 & 0 \\ 0 & \gamma_n \end{bmatrix} \quad (3.31)$$

Os elementos fora da diagonal de \mathbf{C}_r possuem valor 0, o que comprova que os componentes dos vetores \mathbf{r} estão descorrelacionados [Gonzalez e Woods 2003].

3.6 Extração de Características

Alguns dos descritores que podem ser extraídos de imagens de sensores SAR na caracterização de manchas sobre a superfície marinha, para os variados satélites citados no capítulo 2, são destacados na literatura [Solberg e Solberg 1996, Solberg e Volden 1997, Calabresi et al. 1999, Frate et al. 2000]. Abaixo são detalhados os descritores utilizados.

As características podem ser de três diferentes tipos. Algumas delas contêm infor-

mação do gradiente da intensidade do retroespalhamento da radiação (calculado em dB) ao longo da borda da mancha analisada: Máximo Gradiente ($Gmax$), Gradiente Médio (Gme), Desvio Padrão do Gradiente (GSd); outras focam sobre o retroespalhamento da radiação em manchas e/ou de fundo: Desvio Padrão do Objeto (OSd), Desvio Padrão de fundo (BSd), Contraste máximo ($ConMax$), Contraste Médio ($ConMe$); e uma terceira categoria utiliza a descrição da geometria interna e o formato das manchas: Área (A), Perímetro (P), Compacidade de uma região (C), Espalhamento (S). Neste trabalho, nenhuma característica adicional extra imagem será considerada. Mesmo sabendo que o conhecimento do vento local é certamente importante, pois é o responsável pelas ondas de baixa gravidade e as superfícies de ondas curtas, de forma que a velocidade do vento pode influenciar fortemente o aparecimento de manchas na água em imagens SAR, isto seria um complicador adicional, levando em conta a dificuldade já encontrada na aquisição das imagens [Frate et al. 2000]. Contudo, a inclusão de quaisquer outros dados oriundos de quaisquer outras fontes (temperatura de superfície marinha, velocidade dos ventos locais entre outras) na entrada do classificador é obtida sem a modificação da estrutura do sistema de extração de características proposto e detalhado no capítulo 5.

Abaixo os descritores detalhados:

1. Área (A). Área (em km^2) do objeto. Os assemelhados são geralmente maiores que manchas de óleo.

$$A = \sum_{i=1}^{N_{o,p}} i, \quad i \in \text{mancha} \quad (3.32)$$

2. Perímetro (P). Tamanho (em km) da borda do objeto.

$$P = \sum_{i=1}^{N_{o,p}} i, \quad i \in \text{borda} \quad (3.33)$$

3. Compacidade (C). A compacidade é definida como:

$$C = \frac{P}{2\sqrt{\pi A}} \quad (3.34)$$

Esta característica irá gerar um pequeno valor numérico para regiões com geometria simples, aproximadamente círculos, e grandes valores para regiões complexas geometricamente. Manchas de óleo têm menor complexidade e formato mais fino. A compacidade é uma quantidade sem dimensão e invariância de escala.

4. Espalhamento (S). Esta característica é derivada da análise de componentes principais dos vetores cujas componentes são as coordenadas dos *pixels* do objeto analisado. Se γ_1 e γ_2 são dois autovalores associados com a matriz de covariância computada e $\gamma_1 > \gamma_2$, o valor do espalhamento é computado usando a expressão

$$S = \frac{100\gamma_2}{\gamma_1 + \gamma_2} \quad (3.35)$$

S irá ser baixo para objetos longos e finos e alto para objetos com formato próximo ao circular. Os valores da radiação refletida nos objetos assemelhados são mais

dispersos, exatamente pela alta complexidade apresentada pelos mesmos [Frate et al. 2000].

5. Desvio padrão do objeto (*OSd*). Desvio padrão (em *dB*) do valor da intensidade dos *pixels* pertencentes ao candidato a mancha de óleo.

$$OSd = 10 \log \sqrt{\frac{\sum_i^{N_{o,p}} (x_i - \bar{x}_i)^2}{N_{o,p} - 1}}, \quad i \in \text{mancha} \quad (3.36)$$

Onde \bar{x} é a média do conjunto de dados.

6. Desvio padrão de fundo (*BSd*). Desvio padrão (em *dB*) do valor da intensidade dos *pixels* pertencentes a região externa ao objeto.

$$BSd = 10 \log \sqrt{\frac{\sum_j^{N_{o,p}} (x_j - \bar{x}_j)^2}{N_{o,p} - 1}}, \quad j \in \text{fundo} \quad (3.37)$$

7. Contraste máximo (*ConMax*). Diferença (em *dB*) entre o valor médio de fundo e o mais baixo valor dentro do objeto.

$$ConMax = 10 \log (\bar{x}_j - \min x_i), \quad j \in \text{fundo}, i \in \text{mancha} \quad (3.38)$$

Onde \bar{x} é a média do conjunto de dados.

8. Contraste médio (*ConMe*). Diferença (em *dB*) entre o valor médio de fundo e o valor médio do objeto.

$$ConMe = 10 \log (\bar{x}_j - \bar{x}_i), \quad j \in \text{fundo}, i \in \text{mancha} \quad (3.39)$$

9. Gradiente Máximo (*GMax*). Máximo valor (em *dB*) do gradiente da borda. Essa característica é importante pelo fato das manchas de óleo apresentarem a intensidade local do gradiente mais elevada do que os assemelhados.

$$GMax = 10 \log \{ \max [\text{mag} (\nabla_i f)] \}, \quad i \in \text{borda} \quad (3.40)$$

10. Gradiente Médio (*GMe*). Valor médio do gradiente da borda (em *dB*). Manchas de óleo apresentam valor médio de gradiente ao longo da borda maior que dos assemelhados.

$$GMe = 10 \log (\bar{\nabla}_i f) \quad i \in \text{borda} \quad (3.41)$$

11. Desvio Padrão do Gradiente (*GSd*). Desvio padrão (em *dB*) do valor do gradiente da borda.

$$GSd = 10 \log \sqrt{\frac{\sum_i^{N_{o,p}} (\nabla_i f - \bar{\nabla}_i f)^2}{N_{o,p} - 1}} \quad i \in \text{borda} \quad (3.42)$$

Onde $\bar{\nabla}$ é a média do conjunto de dados.

As características extraídas formam o seguinte vetor característico.

$$\text{Descritores} = \begin{bmatrix} A \\ P \\ C \\ S \\ OSd \\ BSd \\ ConMax \\ ConMe \\ GMax \\ GMe \\ GSd \end{bmatrix} \quad (3.43)$$

3.7 Considerações Finais

Todas as técnicas de processamento digital de imagem apresentadas, operam no domínio espacial da imagem, o que torna o seu efeito sobre os dados processados de fácil interpretação para o operador humano, inclusive na interpretação dos descritores extraídos.

O conjunto de vetores característicos, extraídos das cenas de sensoriamento remoto analisadas, é utilizado para a geração de um banco de dados. Banco de dados posteriormente utilizado para o processo de treinamento e/ou validação do algoritmo de classificação implementado.

O processo de classificação, realizado por uma máquina de aprendizado é apresentado e discutido nos capítulos 4 e 5.

Capítulo 4

Redes Neurais Artificiais

A construção de máquinas capazes de aprender através da experiência tem sido objeto de pesquisas acadêmicas por vários anos. O aspecto técnico tem recebido um enorme impulso com o avanço da computação. Esse avanço tem demonstrado que máquinas podem apresentar um nível significativo de habilidade de aprendizagem, embora os limites desta aprendizagem não estejam totalmente definidos.

A disponibilidade de sistemas de aprendizado eficientes é de importância estratégica em diferentes campos de aplicação, principalmente onde nenhum modelo matemático do problema seja conhecido. Dentre eles, a classificação de padrões em um ambiente de estatística desconhecida.

4.1 Definição e Características

Uma Rede Neural Artificial (RNA) pode ser vista como um modelo matemático composto de elementos computacionais lineares ou não, chamados neurônios, trabalhando em paralelo e massivamente conectados por ligações caracterizadas por diferentes pesos denominadas sinapses [Haykin 2001]. Os modelos neurais são principalmente especificados pela topologia da rede, características dos neurônios e regras de treinamento e aprendizado.

Segundo Haykin (2001) as redes neurais artificiais podem fornecer as seguintes propriedades úteis:

- Mapeamento de Entrada-Saída. Um paradigma popular da aprendizagem, chamado aprendizagem supervisionada, envolve a modificação dos parâmetros livres de uma rede neural pela aplicação de um conjunto de amostras de treinamento rotuladas. Cada exemplo consiste de um sinal de entrada único e da resposta desejada correspondente. Apresentando para a rede exemplos escolhidos ao acaso do conjunto de dados, os parâmetros livres da rede são modificados para minimizar a diferença entre a resposta desejada e a resposta real da rede, produzida pelo sinal de entrada, de acordo com um critério estatístico apropriado. O treinamento da rede é repetido até que a mesma alcance um estado estável onde não haja modificações significativas. Assim, a rede aprende a construir, dos exemplos, um mapeamento entrada-saída para o problema considerado.

- **Adaptabilidade.** As redes neurais têm uma capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente. Em particular, uma rede neural treinada para operar em um ambiente específico pode ser retreinada para lidar com pequenas modificações nas condições de operação do ambiente. Além disso, quando está operando em um ambiente não estacionário (onde as estatísticas mudam com o tempo), uma rede neural pode ser projetada para modificar seus pesos sinápticos em tempo real.
- **Resposta a Evidências.** No contexto de classificação de padrões, uma rede neural pode ser projetada para fornecer informação não somente sobre qual padrão particular selecionar, mas também sobre a confiança ou crença na decisão tomada. Esta última informação pode ser utilizada para rejeitar padrões ambíguos, caso eles estejam presentes, e, com isso, melhorar o desempenho de classificação da rede.
- **Tolerância a Falhas.** Uma rede neural tem o potencial de ser inerentemente tolerante a falhas, ou capaz de realizar computação robusta, no sentido de que seu desempenho se degrada suavemente sob condições de operação adversa. Se um neurônio ou suas conexões são danificados, por exemplo, a recuperação de um padrão armazenado é prejudicada em qualidade. Contudo, devido à natureza distribuída da informação armazenada na rede, o dano deve ser extenso para que a resposta global da rede seja degradada seriamente.

4.1.1 Aprendizado

Existem tarefas, problemas, de complicada solução por uma abordagem matemática tradicional onde os modelos são complexos ou a modelagem torna-se difícil devido a aspectos de não-linearidade ou por o processo incorporar estatísticas presentes porém desconhecidas.

Algumas abordagens para a solução desse tipo de problema podem fazer uso de uma máquina de aprendizado. Os pares entrada/saída tipicamente refletem uma relação funcional, embora isso nem sempre seja o caso para exemplos em que as saídas estão corrompidas por ruído. Quando uma função básica de mapeamento entrada/saída existe ela é referida como função alvo. A estimativa da função alvo que é aprendida pelo algoritmo é conhecida como a solução do problema de aprendizagem. No caso de classificação de padrões esta função é algumas vezes referenciada como a função decisão. A solução é escolhida de um conjunto de funções candidatas que realizam o mapeamento do espaço de entrada para espaço de saída. Os algoritmos que utilizam os dados de treinamento e selecionam uma função do espaço de funções são referenciados como algoritmos de aprendizagem, dentre estes três modelos recebem destaque

- Aprendizado Supervisionado.
- Aprendizado Não Supervisionado.
- Aprendizado por Reforço.

No caso particular em que os exemplos são pares rotulados de entrada/saída isto é chamado aprendizado supervisionado. Os exemplos de entrada/saída são funcionalmente chamados de dados de treinamento [Haykin 2001]. A figura 4.1 exemplifica o caso de um

ambiente de aprendizado supervisionado, o bloco denominado “professor” é responsável por informar a resposta desejada para o respectivo dado de entrada.

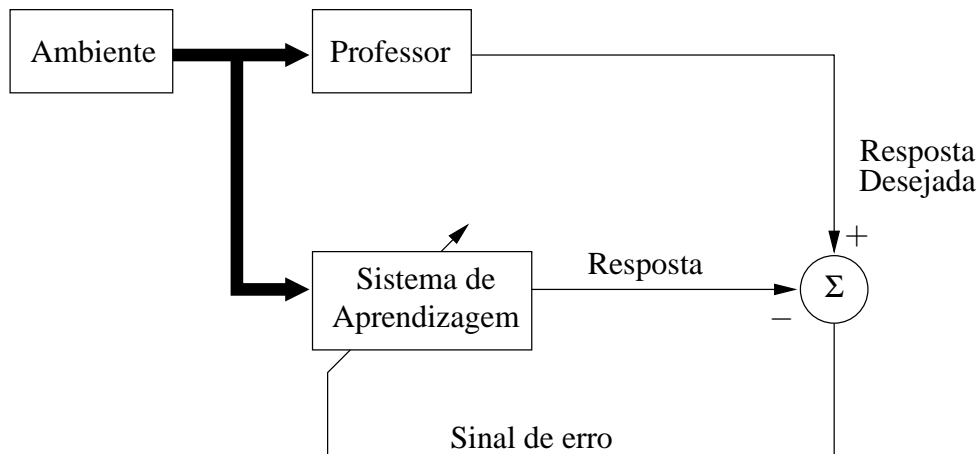


Figura 4.1: Aprendizado Supervisionado.

O aprendizado não-supervisionado considera o caso onde não há valores de entrada-saída rotulados e a tarefa de aprendizagem consiste em obter algum entendimento do processo que gera os dados. Este tipo de aprendizado inclui estimação de densidade, auto-segmentação, agrupamento (*clustering*), entre outros. O algoritmo apresentado na seção 3.2 exemplifica um caso de aprendizado não supervisionado.

A aprendizagem por reforço é realizada com a experimentação direta dos dados. Não se assume a existência de um “professor” que fornece exemplos de treinamento rotulados. Ao invés disso, no aprendizado por reforço a experiência da experimentação é o único professor. A máquina de aprendizagem age sobre o processo para receber sinais (reforços) dele, indicações sobre quão bom está executando a tarefa requerida. Estes sinais são associados geralmente a algumas condições extremas, por exemplo a realização de uma sub-tarefa (recompensa) ou uma falha completa (punição), e o objetivo da máquina é otimizar seu comportamento baseado em alguma medida de desempenho (geralmente minimização de uma função de custo).

Treinamento

Variações nos modelos de aprendizado são encontradas quanto ao modo como os dados de treinamento são gerados e apresentados ao algoritmo. Por exemplo, há uma distinta diferença entre o aprendizado dito em lote no qual os dados são fornecidos ao algoritmo antes do início da aprendizagem, e o aprendizado dito *on-line*, no qual o algoritmo recebe um exemplo por vez e fornece uma estimativa da saída antes de receber a resposta desejada. No aprendizado *on-line*, a função aprendida é atualizada a cada novo exemplo apresentado e a qualidade do aprendizado é avaliada por uma medida de erro.

Validação

A validação de um algoritmo de aprendizagem é a etapa de constatação do conhecimento adquirido no treinamento, geralmente realizada através de um teste de generalização. Nesse processo, um conjunto de dados, denominado conjunto de validação, é apresentado ao algoritmo de aprendizagem que estima a saída correspondente, realizando assim uma inferência sobre dados não observados anteriormente. Valores de saída próximos da saída desejada indicam uma boa generalização enquanto valores de saída divergentes indicam uma má generalização.

Pode-se usar, também, uma subdivisão do conjunto de treinamento, criando uma espécie de conjunto de validação, utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento. Podendo ser empregado como critério de parada do treinamento.

4.1.2 Desempenho

O desempenho de uma máquina de aprendizado pode ser mensurado durante e após o treinamento da mesma segundo o tipo de aprendizado e método de treinamento utilizado.

Algoritmos avançados da aprendizagem de máquina objetivam aprender representações de simples funções simbólicas que poderiam ser compreendidas e verificadas por peritos da aplicação tratada.

A qualidade do treinamento de um algoritmo de aprendizado *on-line* pode ser avaliada em termos do erro médio cometido durante esta fase. Não é imediatamente claro, entretanto, como pode-se avaliar a qualidade da hipótese gerada durante a aprendizagem em lote, mas a maneira habitual é uma relação de erro que envolve também o erro individual de cada exemplo.

Mesmo as medidas de erro na fase de treinamento assumindo valores dentro de um patamar dito aceitável, especificado pelo operador do sistema, a completa validação do mesmo só é obtida após a comprovação da generalização dos resultados para um conjunto de dados de entrada não presentes na fase de treinamento.

Para o caso específico de classificação de padrões, a matriz de confusão, como a da tabela 4.1, pode mensurar esses valores, resultando em algumas medidas de desempenho, como taxa de acerto e erro por classe e taxa de acerto e erro total. A matriz de confusão refere-se ao classificador, mostrando o número de classificações corretas realizadas em oposição às classificações preditas para cada classe. O ideal é que, somente os elementos da diagonal principal obtenham valor, o que indicaria uma correspondência de 100% entre a classificação predita para cada classe e a classificação realizada pelo classificador implementado.

Essas medidas devem ser avaliadas cuidadosamente em casos onde as classes a serem discernidas num problema de classificação de padrões estejam desbalanceadas, tanto no conjunto de treinamento quanto no conjunto de validação.

Abordagens de treinamento e avaliação para casos particulares de conjuntos de treinamento encontram seu caminho na prática. A técnica denominada deixe-um-fora, do inglês *leave-one-out*, que é uma variação da validação cruzada, é empregada principalmente

Tabela 4.1: Matriz de confusão para n classes distintas.

		Real		
		Classes	Classe ₁	...
Máquina	Classe ₁	c_{11}	...	c_{1n}
	⋮	⋮	⋮	⋮
	Classe _n	c_{n1}	...	c_{nn}

quando há uma escassez de exemplos rotulados no conjunto de dados e a inviabilidade da divisão desses exemplos em dados de treinamento e de validação [Haykin 2001].

De acordo com esse procedimento, se N é o número disponível de pontos de dados, a rede é treinada usando $N - 1$ pontos e testada sobre o remanescente. Este processo é repetido, para cada uma das N possíveis escolhas, e o resultado pode fornecer uma primeira estimativa sobre a capacidade de generalização da rede.

Há algumas situações em que um único ponto de dado não respeita as regras internas que a rede tem aprendido dos outros pontos. Isto pode ser explicado como a heterogeneidade do conjunto de dados, que inclui vários exemplos com características muito diferentes, geralmente atribuídas a tarefas de grande dificuldade.

Uma outra alternativa para a medida de desempenho de um classificador pode ser obtida através da curva ROC (Receiver Operating Characteristic). A curva ROC expõe no eixo x a taxa de falsos positivos enquanto no eixo y a taxa de exemplos positivos corretamente classificados, com ela é possível mostrar uma relação entre falsos alarmes e o total de acertos para o classificador específico. O classificador perfeito corresponde ao ponto $(0, 1)$: nenhum falso positivo e 100% de precisão na classificação de exemplos positivos. Os pontos extremos da curva $(0, 0)$ e $(1, 1)$, correspondem à classificação de todos os exemplos como negativos e positivos, correspondentemente. A figura 4.2 mostra uma típica curva ROC.

As curvas ROC são consideradas bons indicadores do desempenho do classificador em diversas aplicações. Uma comparação entre classificadores pode ser obtida através do cálculo da área sob a curva.

A área sobre a curva é freqüentemente usada como uma medida de qualidade de um classificador probabilístico. Um classificador aleatório apresenta um valor para a área sob a curva igual a 0,5, enquanto um classificador perfeito apresenta um valor igual a 1.

4.2 Classificador de Padrões

Os seres humanos são bons no reconhecimento de padrões. Recebemos dados do mundo à nossa volta através dos nossos sentidos e somos capazes de reconhecer a fonte dos dados. Freqüentemente, somos capazes de fazer isso quase que imediatamente e praticamente sem esforço. Podemos, por exemplo, reconhecer um rosto familiar de uma pessoa muito embora esta pessoa tenha envelhecido desde o último encontro entre ambos, identificar uma pessoa familiar pela sua voz ao telefone, apesar de uma conexão ruim,




Figura 4.2: Uma curva ROC.

entre outros exemplos. Os humanos realizam o reconhecimento de padrões através de um processo de aprendizagem; e assim acontece com as redes neurais artificiais [Haykin 2001].

O reconhecimento de padrões é formalmente definido como o processo pelo qual um padrão/sinal recebido é atribuído a uma classe dentre um número predeterminado de classes (categorias). Uma rede neural supervisionada realiza o reconhecimento de padrões passando inicialmente por uma seção de treinamento, durante a qual se apresenta à rede um conjunto de padrões de entrada junto com a categoria à qual cada padrão particular pertence. Mais tarde, apresenta-se à rede um novo padrão que não foi visto antes, mas que pertence a mesma população de padrões utilizada para treiná-la. A rede é capaz de identificar a classe daquele padrão particular por causa da informação que ela extraiu dos dados de treinamento. O reconhecimento de padrões realizado por uma rede neural é de natureza estatística, com os padrões sendo representados por pontos em um espaço de decisão multidimensional. O espaço de decisão é dividido em regiões, cada uma das quais associada a uma classe. As fronteiras de decisão são determinadas pelo processo de treinamento. A construção dessas fronteiras é tornada estatística pela variabilidade inerente que existe dentro das classes e entre as classes [Haykin 2001].

Para que o desempenho do classificador para novos padrões de entrada (diferentes dos usado na fase de treinamento) possa ser avaliado, o classificador passa por uma fase de teste. Durante esta fase, deve ser observado o número de acertos e erros realizados pelo classificador. Uma boa estimativa do potencial do classificador é obtida com a apresentação das porcentagens de padrões corretamente e incorretamente classificados, como mencionado na seção anterior.

Diversas aplicações de RNA dizem respeito à classificação de padrões. Para aplicações de alto risco o custo de uma tomada de decisão errada pode ser muito alto, sendo melhor rejeitar os padrões que não haja certeza, quanto a classe a que pertençam, na fase de treinamento. Além disso na fase de treinamento devem ser apresentados conjuntos

de padrões representativos para cada uma das várias classes consideradas, e o número de padrões de treinamento deve ser idealmente o mesmo, para cada uma das classes [Braga et al. 2000].

A construção de um classificador neural pode ser realizada por uma variedade de configurações e modelos. Nas seções 4.4, 4.5 e 4.6 três tipos de máquina de aprendizado que podem ser implementadas como classificadores são apresentadas.

Os classificadores podem ser do tipo probabilístico ou binário. O classificador probabilístico apresenta na sua saída a probabilidade do candidato de pertencer a uma dada classe. O classificador binário realiza uma rotulação em função de um limiar de separação entre as classes de saída.

4.3 Neurônio Artificial

O neurônio (Perceptron) é a unidade de processamento da informação fundamental para a operação de uma rede neural. Nele se identificam três elementos básicos, mostrados na figura 4.3, de acordo com o modelo dos cientistas McCulloch e Pitts [Haykin 2001]. O conjunto de pesos sinápticos w , responsáveis pela ponderação dos estímulos de entrada x . O somador, que soma as entradas ponderadas pelos pesos sinápticos, atuando como um combinador linear. E a função de ativação, que além de restringir a amplitude de saída de um neurônio, pode inserir alguma característica no mapeamento entrada/saída.

O modelo inclui ainda um *bias* aplicado externamente, representado por b . O *bias* tem o efeito de aumentar ou diminuir a saída da função de ativação.




Figura 4.3: Modelo de um neurônio.

O neurônio computa a soma de suas entradas, adiciona o termo de polarização e conduz o resultado através de uma função de ativação para expressar na saída o seu nível de ativação.

A saída de um neurônio pode ser definida matematicamente pela equação 4.1

$$y_k = \varphi(v_k + b) \quad (4.1)$$

onde

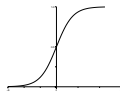
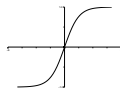
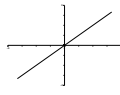
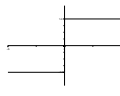
$$v_k = \sum_{j=1}^m w_j x_j \quad (4.2)$$

4.4 Rede Perceptrons de Múltiplas Camadas

As redes Perceptrons de Múltiplas Camadas, do inglês *Multilayer Perceptrons* (MLP), surgiram como alternativa para a resolução de problemas de complexidade não linear. A solução dessa classe de problemas passa pelo uso de redes com uma ou mais camadas intermediárias alimentadas adiante (*feedforward*), onde cada camada é composta de um conjunto de neurônios em que nas camadas intermediárias (ocultas) é comum a utilização de funções de ativação não-linear.

Para treinar as redes com mais de uma camada, as utilizações mais comuns são de métodos que se baseiam no gradiente descendente. O principal algoritmo utilizado para o treinamento dessas redes é o algoritmo supervisionado da retropropagação (*back-propagation*) [Haykin 2001], além de algumas variações. Estes algoritmos são baseados na regra de aprendizagem por correção de erro. Para que esse método possa ser utilizado, a função de ativação precisa ser contínua e diferenciável. A função de ativação (as mais comuns estão listadas na tabela 4.2) deve possibilitar a inferência dos erros cometidos pela rede para as camadas interiores com a maior precisão possível.

Tabela 4.2: Funções de Ativação.

Função	Equação	Gráfico
Sigmóide	$f(v) = \frac{1}{1 + \exp(-av)}$	
Tangente Hiperbólica	$f(v) = \tanh(v)$	
Linear	$f(v) = a \cdot v + b$	
Binária	$f(v) = \begin{cases} 1 & \text{se } v > 0 \\ 0 & \text{se } v < 0 \end{cases}$	

A aprendizagem por retropropagação de erro consiste de dois passos.

- Propagação. Na propagação um padrão (vetor) de entrada é aplicado aos nós sensoriais da rede e seu efeito se propaga através da mesma, camada por camada. Durante esse passo os pesos sinápticos da rede não se alteram.
- Retropropagação. No passo para trás, os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro. Especificamente, a resposta real é subtraída de uma resposta desejada para produzir um sinal de erro. Este sinal é então

propagado para trás através da rede, em oposição a direção das conexões sinápticas. Os pesos sinápticos são ajustados para fazer com que a resposta real da rede se aproxime da resposta desejada.

O algoritmo da retropropagação é apresentada no apêndice B.

A figura 4.4 mostra um exemplo de arquitetura de uma rede MLP, com duas camadas ocultas totalmente conectada (um neurônio de qualquer camada está conectado a todos os neurônios da camada anterior). Esses neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões de entrada. Eles fazem isso realizando uma transformação não-linear dos dados de entrada para um novo espaço denominado espaço de características. Neste novo espaço a as classes de interesse, num problema de classificação de padrões, podem ser mais facilmente separadas do que no espaço original de entrada [Haykin 2001]. A MLP tem como característica um alto grau de conectividade, determinado pelas sinapses da rede.




Figura 4.4: Rede Perceptrons de Múltiplas Camadas.

4.5 Rede de Funções de Base Radial

A Rede de Função de Base Radial, do inglês *Radial Basis Function* (RBF) possui esse nome devido à utilização, pelos neurônios da camada intermediária, de funções de base radial.

Ambas as rede RBF e MLP são exemplos de redes em camadas alimentadas adiante, e não-lineares, por conseguinte são aproximadores universais de funções. A RBF pode ser considerada uma alternativa às MLP em algumas aplicações.

Aos nós computacionais de uma RBF localizados em camadas distintas compreendem papéis totalmente diferentes, em oposição aos da MLP que compartilham o mesmo modelo neural. Ao contrário das redes MLP que constroem aproximações globais de um mapeamento de entrada-saída não linear, a rede RBF, utilizando não linearidades com decaimento exponencial, constroem aproximações locais para mapeamentos de entrada-saída não lineares [Haykin 2001].

Algumas dessas características, além de um processo alternativo de aprendizado mais rápido, viabilizam a utilização da RBF como um bom classificador de padrões.

A associação de redes RBF com apenas uma camada intermediária é comum, contudo nada impede a utilização um número maior. A arquitetura típica pode ser visualizada

na figura 4.5. Apesar da rede apresentar somente um neurônio na camada de saída, esse número pode ser aumentado, dependendo do problema tratado.

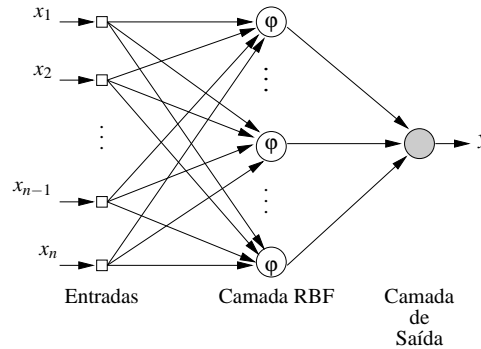


Figura 4.5: Rede de Função de Base Radial.

Cada camada da rede desempenha um papel específico. A camada intermediária, cujos neurônios utilizam funções de base radial, agrupa os dados de entrada, cada neurônio define uma hiperelipsóide no espaço dos padrões de entrada, construindo dessa forma aproximadores locais. Esta camada transforma um conjunto de padrões de entrada não linearmente separáveis em um conjunto de saídas linearmente separáveis. A camada de saída procura classificar os padrões recebidos da camada anterior. Esta camada pode ser formada por um perceptron, uma vez que seus padrões de entrada são linearmente separáveis [Braga et al. 2000].

Quando uma RBF é usada para realizar uma tarefa complexa de classificação de padrões encontra justificativa no teorema de Cover (*apud* Haykin (2001)) que considera que “Um problema complexo de classificação de padrões disposto não linearmente em um espaço de alta dimensão tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade”.


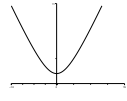
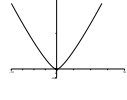
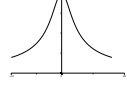
As funções radiais representam uma classe especial de funções cujo valor diminui ou aumenta em relação à distância de um ponto central. Diferentes funções de base radial têm sido utilizadas em redes RBF. As mais comuns são apresentadas na tabela 4.3 onde u é dado geralmente pela distância euclidiana entre o vetor de entrada \mathbf{x} e o centro da função radial \mathbf{t} , $\|\mathbf{x} - \mathbf{t}\|$, e ψ é a largura da função radial. A distância euclidiana do vetor de entrada ao vetor centro serve de parâmetro para a função radial, que retorna o valor de ativação da unidade intermediária [Braga et al. 2000].

Dentro da estratégia de aprendizagem de uma rede RBF, existem diferentes caminhos a se seguir dependendo de como os centros das funções de base radial são especificados. Dentre as mais utilizadas tem-se:

- Centros fixos selecionados ao acaso
- Seleção auto-organizada de centros
- Seleção supervisionada de centros

O apêndice C apresenta uma estratégia de projeto que se refere a uma rede RBF cuja formulação é baseada na teoria de interpolação utilizando a seleção auto-organizada dos centros das funções de base radial.

Tabela 4.3: Funções de Base Radial.

Função	Equação	Gráfico
Gaussiana	$f(u, \psi) = \exp\left(-\frac{u^2}{2\psi^2}\right)$	
Multiquadrática	$f(u, \psi) = \sqrt{(u^2 + \psi^2)}$	
<i>Thin-plate-spline</i>	$f(u) = u^2 \log(u)$	
Multiquadrática Inversa	$f(u, \psi) = \frac{1}{\sqrt{(u^2 + \psi^2)}}$	

Assim como ocorre com a Rede Perceptron de Múltiplas Camadas, durante o projeto da Rede de Função de Base Radial é necessário definir o número de neurônios da camada intermediária. Como cada neurônio agrupa um conjunto de padrões, que são posteriormente utilizado pelos neurônios da camada de saída. Essa escolha deve ser realizada de forma criteriosa [Braga et al. 2000].

4.6 Máquinas de Vetor de Suporte

A Máquina de Vetor de Suporte, do inglês *Support Vector Machine* (SVM), assim como a MLP e a RBF, pode ser usada para a classificação de padrões. Nesse contexto, a idéia principal de uma SVM é construir um hiperplano ótimo como superfície de decisão, de tal forma que a margem de separação entre os exemplos apresentados seja máxima.

A máquina apresenta esta propriedade desejável seguindo uma abordagem fundamentada na teoria da aprendizagem estatística. Mais precisamente, a Máquina de Vetor de Suporte é uma implementação do método de minimização estrutural de risco. Este princípio indutivo é baseado no fato de que a taxa de erro de uma máquina de aprendizagem sobre dados de teste é limitada pela soma da taxa de erro de treinamento e por um termo que depende da dimensão de Vapnick-Chervonenkis (V-C); no caso de padrões separáveis, uma SVM produz um valor zero para o primeiro termo e minimiza o segundo. Conseqüentemente um bom desempenho de generalização em problemas de classificação de padrões pode ser fornecido pela SVM, apesar do fato de que ela não incorpora conhecimento do domínio do problema. Este atributo é único das Máquinas de Vetor de Suporte [Haykin 2001].

Tabela 4.4: Núcleos de produto interno.

Tipo de Máquina de Vetor de Suporte	Núcleo de Produto interno $K(\mathbf{x}, \mathbf{x}_i)$
Máquina de aprendizagem polinomial	$(\mathbf{x}^T \mathbf{x}_i + 1)^p$
Rede de Função de Base Radial	$\exp\left(-\frac{1}{2\sigma^2} \ \mathbf{x} - \mathbf{x}_i\ ^2\right)$
Perceptron de duas camadas	$\tanh(\beta_0 \mathbf{x}^T \mathbf{x}_i + \beta_1)$

A SVM se apóia, assim com a RBF, no teorema de Cover para o problema de classificação complexa de padrões. Contudo, o teorema de Cover não discute se o hiperplano de separação é ótimo. É apenas pelo uso de um hiperplano de separação ótimo que a dimensão V-C é minimizada e a generalização é alcançada [Haykin 2001].

Uma noção que é central à construção do algoritmo de aprendizagem por vetor de suporte é o núcleo do produto interno entre um vetor suporte \mathbf{x}_i e o vetor de entrada \mathbf{x} retirado do espaço de entrada. Os vetores de suporte consistem de um pequeno subconjunto dos dados de treinamento extraído pelo algoritmo. Dependendo de como este núcleo de produto interno é gerado, pode-se construir diferentes máquinas de aprendizagem, caracterizadas pelas superfícies de decisão não-lineares, próprias. Em particular, pode-se usar o algoritmo de aprendizagem por vetor de suporte para construir os três seguintes tipos de máquinas de aprendizagem mostrados na tabela 4.4.

Isto é, para cada uma dessas redes pode-se, usar o algoritmo de aprendizagem por vetor de suporte para implementar o processo de aprendizagem, usando um determinado conjunto de dados de treinamento, determinando automaticamente o número necessário de unidades ocultas. Enquanto o algoritmo de retropropagação é planejado especificamente para treinar um perceptron de múltiplas camadas, o algoritmo de aprendizagem por vetor de suporte é de natureza mais genérica, porque tem aplicabilidade mais ampla [Haykin 2001].

O apêndice D apresenta o algoritmo para a construção de um hiperplano ótimo de separação de classes, num problema de classificação de padrões. A figura 4.6 mostra a arquitetura típica de uma máquina de vetor de suporte.

A figura 4.7 mostra um cenário onde a separação das classes poderia ser implementada por diferentes hiperplanos, todos corretos, contudo a Máquina de Vetor de Suporte maximiza a separação entre as mesmas ou minimiza o risco de classificação incorreta.

4.7 Máquinas de Comitê

Na aprendizagem supervisionada, um bom desempenho, dependendo da tarefa a ser realizada, pode ser alcançado distribuindo-se a tarefa de aprendizagem entre um número de especialistas que, por sua vez, dividem o espaço de entrada em um conjunto de sub-espacos. Diz-se que a combinação de especialistas constitui uma Máquina de Comitê. Basicamente, ela funde o conhecimento adquirido por especialistas para chegar a uma




Figura 4.6: Máquina de Vetor de Suporte.

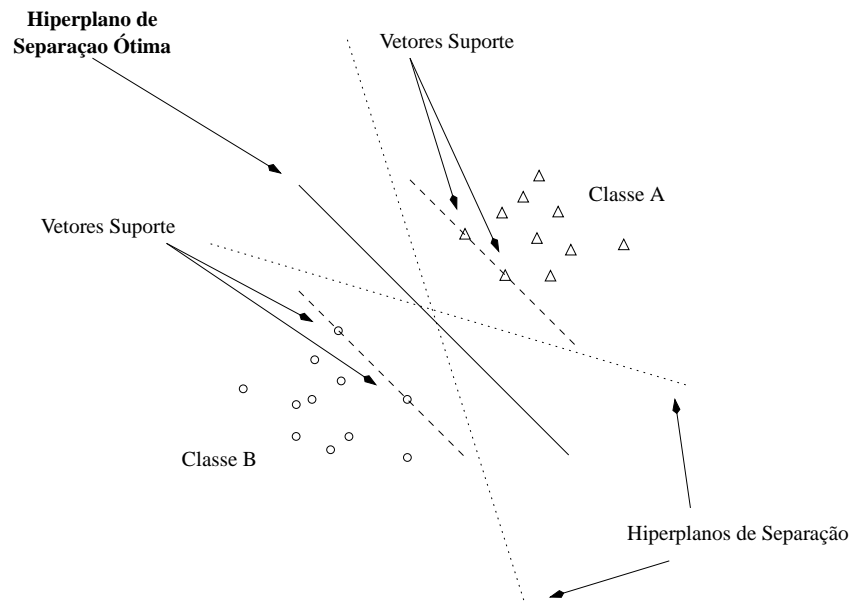


Figura 4.7: Hiperplano ótimo de separação.

decisão global que é supostamente superior àquela alcançável por qualquer um deles isoladamente [Haykin 2001]. As máquinas de comitê são aproximadores universais. Elas podem ser classificadas em duas grandes categorias:

- Estruturas Estáticas. Nesta classe de máquinas de comitê, as respostas de vários previsores são combinadas por meio de um mecanismo que não envolve o sinal de

entrada, por isso a designação estática. Essa categoria inclui: a média de *ensemble*, reforço e votação.

- Estruturas Dinâmicas. Mistura de Especialistas e Mistura Hierárquica de Especialistas. Nesta categoria, o sinal de entrada está envolvido na atuação do mecanismo que integra as saídas dos especialistas individuais em uma saída global, através de uma rede de passagem.




Figura 4.8: Arquitetura de uma Máquina estática de Comitê.

A construção desse tipo de máquina pode compreender a utilização de várias especialistas de uma mesmo tipo (Máquina de Comitê Homogênea) ou a combinação de diferentes especialistas (Máquina de Comitê Heterogênea). A figura 4.8 apresenta o diagrama de blocos de uma Máquina estática de Comitê.

4.8 Considerações Finais

Os algoritmos de aprendizado abordados neste capítulo foram escolhidos por abrange diferentes técnicas na solução de um mesmo problema.

O capítulo 5 mostra como cada um dos algoritmos de aprendizagem apresentados podem ser inseridos dentro do sistema proposto. As características de saída, resposta que o sistema fornece ao operador, são comentadas.

Tanto os testes quanto as medidas de desempenho para cada uma das máquinas de aprendizado, são discutidas no capítulo 6.

Capítulo 5

Sistema de Identificação de Óleo na Superfície Marinha - SIOSM

Este capítulo detalha o sistema de identificação e classificação de manchas de óleo sobre a superfície marinha, fazendo uso das técnicas e ferramentas descritas nos capítulos 3 e 4. O capítulo mostra principalmente o fluxo da informação dentro do sistema proposto, assim como a troca de dados entre os blocos que o formam.

O sistema proposto foi implementado em software livre e de código aberto, com a construção de classes de dados dentro do paradigma de programação orientada a objetos. A escolha desse tipo de plataforma objetiva dar maior liberdade de aperfeiçoamento e portabilidade para o usuário do sistema, inclusive permitindo a modificação dos algoritmos dos blocos funcionais sem prejuízo para o cálculo dos descritores do sistema como um todo.

Para o ambiente de simulação e testes, foi escolhido o software matemático Scilab[©]. Nesse ambiente foi possível implementar tanto os algoritmos de processamento digital de imagens e extração de características quanto as máquinas de aprendizado utilizadas como classificadores de padrões.

Com a robustez dos algoritmos implementados em cada uma das partes que compõem o sistema sendo alcançada, a conversão do código Scilab[©] para uma linguagem computacional que proporcionasse mais velocidade ao processo foi utilizada. A linguagem computacional escolhida foi C++.

Todo esse processo foi executado sobre o sistema operacional GNU/Linux.

5.1 Diagrama de blocos

O sistema proposto, denominado de agora em diante como SIOSM é apresentado de forma detalhada e em diagrama de blocos na figura 5.1, com as setas indicando o fluxo da informação entre as partes presentes.

O procedimento se inicia com a definição da região de interesse dentro da imagem de sensoriamento remoto (onde haja suspeita de mancha).

O fragmento de imagem inserido passa pelo bloco de filtragem do ruído *speckle*, onde diferentes algoritmos podem atuar sobre o mesmo. Desse ponto em diante ocorre uma

divisão no fluxo de informação. A imagem filtrada é inserida em dois blocos distintos.

O primeiro, denominado Gradiente, recebe a imagem filtrada e realiza o cálculo do gradiente sobre ela, aguardando os dados de saída de um outro bloco do sistema para o processamento de alguns descritores extraídos.

O segundo bloco, denominado Filtro Log, aplica um realce na imagem e o resultado dessa operação é inserido no bloco de Quantização Vetorial. A quantização vetorial realiza a auto-segmentação da imagem e a entrega para o operador de limiarização. A partir desse estágio a imagem está binarizada.

O bloco seguinte, Morfologia Matemática, realiza uma filtragem sobre os dados com o intuito de preservar as características morfológicas dos objetos presentes na cena. Desse ponto, novamente, os dados seguem dois caminhos. No primeiro, o bloco Gradiente recebe uma imagem segmentada e aplica o operador sobre a mesma para em conjunto com a resposta do primeiro bloco Gradiente computar o cálculo de alguns descritores.

No segundo, o bloco Transformada de Hotelling realiza a última etapa referente a extração de características com cálculo do 11º descritor utilizado.

Adiante é detalhado o funcionamento de cada bloco.

5.1.1 Filtragem do ruído *speckle*

Após a aquisição da imagem ruidosa, uma filtragem para a eliminação ou minimização do efeito do ruído *speckle* (mascara 3×3) é realizada. Esse primeiro passo do processo é de fundamental importância, pois, como mencionado no capítulo 2, as imagens SAR possuem a informação dominante na forma de variações espaciais locais de tonalidade, como detalhes texturais e estruturais. O ruído dificulta a interpretação dos dados portanto deve ser minimizado, contudo é importante tratar o ruído de modo a otimizar a possibilidade de separação de alvos com o mínimo de perda das informações contidas na imagem. De acordo com isso uma investigação a respeito do melhor tipo de filtragem foi realizado e os resultados serão apresentados no capítulo 6.

A qualidade da imagem de saída do bloco de filtragem do ruído *speckle* é importante para todos os outros blocos do SIOSM, principalmente para o bloco Gradiente. Como a magnitude do gradiente é diretamente proporcional às variações bruscas características do ruído, a necessidade de dados com o menor nível de ruído possível é importante para a obtenção de resultado satisfatório.

5.1.2 Filtro Log

Após o fragmento de imagem ser filtrado pelo estágio anterior do processo, o realce torna-se uma etapa auxiliar à auto-segmentação que vem a seguir.

O realce deve compreender uma operação de fácil assimilação pelo especialista em processamento de imagens, em parceria, muitas vezes, com o menor tempo possível de execução.

Essas duas características são obtidas com o uso da função log descrita na seção 3.1.2.

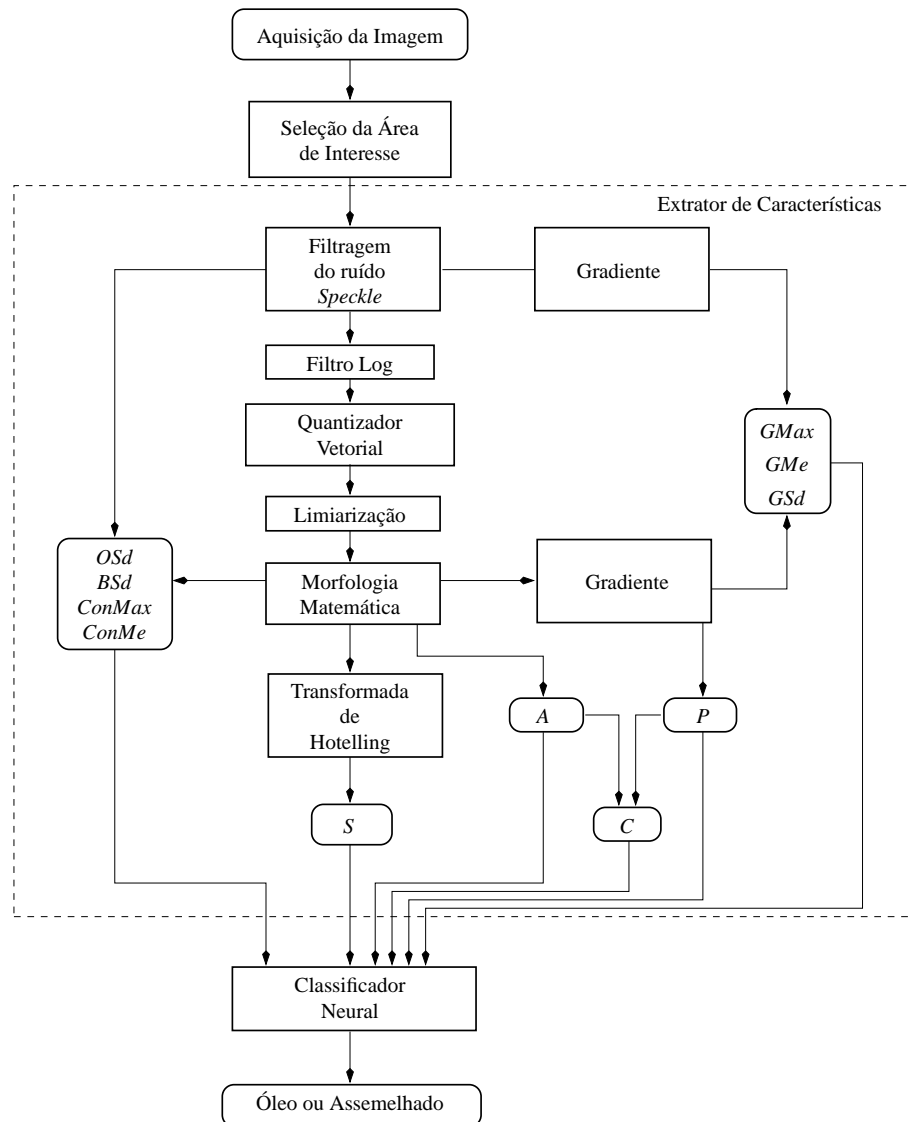


Figura 5.1: Diagrama de blocos detalhado do Sistema de Identificação de Óleo na Superfície Marinha (SIOSM).

5.1.3 Quantização Vetorial

A informação de entrada do bloco quantizador é composta pelo número de centros ou classes representantes além da imagem originada na saída do bloco nomeado Filtro Log.

Para esse caso específico de imagens com tonalidades em escalas de cinza e caracterizadas por poucos padrões em cena, optou-se por uma distribuição inicial dos vetores código ao longo de todo espaço de valores possível, igualmente espaçados. Dessa forma o algoritmo de quantização vetorial aplicado se comporta de maneira adequada, eliminando a aplicação da técnica várias vezes, na busca de uma fuga para o problema de mínimo local. Como o tempo de processamento do algoritmo é dependente da quantidade de classes determinadas, a utilização de dicotomia na cena (mancha ou mar), ou para um maior refinamento o uso de três classes (mancha, mar e um intermediário entre as duas primeiras) reduz o tempo total do processo ocupado por esse bloco.

A escolha do número de classes usadas no processo de quantização vetorial, para um grande conjunto de imagens, é selecionada de maneira a otimizar o processo, já que a maior parte dos dados é composta de imagens de grandes proporções.

Neste trabalho optou-se pelo uso de duas classes distintas.

5.1.4 Limiarização

O processo de limiarização é realizado para separar os pontos da imagem em uma partição binária, objeto e fundo.

A automação e agilidade do sistema proposto encontra aqui outro atrativo, pois a informação recebida por esse bloco de processamento (imagem oriunda do bloco de quantização vetorial) elimina a intervenção humana na escolha do limiar (l) ótimo. Esse valor é selecionado com a incorporação da única informação *a priori* que se tem a respeito da observação das manchas nas imagens de SAR. Como as manchas sempre se manifestam sob as tonalidades mais escuras, ou seja valores discretos baixos, o valor de limiar escolhido é: o valor mais baixo do centróide obtido pela quantização vetorial.

Para o caso de identificação de manchas de óleo sobre a superfície marinha, a limiarização respeita a equação 3.16, onde o objeto é a mancha, e o fundo é o mar ou tudo o que não for de interesse na cena observada.

A saída de dados desse bloco é uma imagem binarizada.

5.1.5 Morfologia Matemática

A última etapa de processamento da imagem realizada para a obtenção da mancha analisada segmentada é desempenhada pelo bloco de morfologia matemática. Após a limiarização realizar uma partição dos dados resultando numa imagem binarizada, algumas vezes numa mancha praticamente segmentada, fragmentos espúrios rotulados como pertencentes ao objeto de interesse ainda podem restar na imagem. A operação de abertura morfológica realiza a eliminação da maior parte desses fragmentos, tentando sempre preservar as características morfológicas da mancha em estudo.

A escolha do elemento estruturante aplicado pode ser realizada de várias formas. Para objetivos finais conhecidos, a utilização de alguns elementos estruturantes já é fundamen-

tada na literatura de processamento de imagens [k. Jain 1989], contudo a utilização de uma metodologia empírica não é incomum. Neste trabalho, a utilização do elemento estruturante mostrado na imagem 5.2 é decorrente da sua utilização em problemas tratados na literatura que envolvem a eliminação de “ilhas” em uma imagem binária.

0	1	0
1	1	1
0	1	0

Figura 5.2: Elemento estruturante utilizado na operação morfológica de abertura.

O ponto circundado representa o centro do elemento estruturante. O elemento escolhido é referenciado na literatura como “cruz” ou “círculo”. Na implementação, percorre-se a imagem a ser erodida (que compõe o primeiro passo na operação morfológica de abertura) com o elemento estruturante centrado em cada *pixel* da imagem, verificando se a máscara que compõe o elemento está ou não contida na imagem percorrida. Para cada resposta positiva, um *pixel* na imagem resultante é marcado como objeto identificado, ou pertencente ao conjunto imagem. Na etapa de dilatação, a imagem resultante da erosão é agora percorrida pelo mesmo elemento estruturante; contudo, para cada *pixel* anteriormente marcado como pertencente ao objeto, uma região vizinha a este (modelada pela geometria do elemento estruturante) é também marcada como pertencente ao objeto.

Com isso é possível extrair as primeiras características de interesse para o nosso classificador. A área (A) pode ser calculada por uma contagem simples dos *pixels* rotulados como mancha e multiplicada por um fator de escala. A combinação da saída gerada por esse bloco, que serve para mapear o que é mancha na imagem, com a imagem filtrada na etapa de filtragem do ruído *speckle* permite a extração das características *OSd*, *BSd*, *ConMax* e *ConMe*.

5.1.6 Filtros por Derivadas

O operador de gradiente atuando na saída dos blocos de morfologia matemática e após a filtragem do ruído *speckle* capta as características de variação da imagem. A sua aplicação após a filtragem do ruído *speckle* computa a magnitude do gradiente dos vários contornos apresentados na cena, enquanto que o operador aplicado após a etapa de morfologia matemática mapeia os *pixels* que fazem parte da borda da mancha analisada da imagem original.

Dessa forma, é possível extrair as seguintes características: Perímetro P , Gradiente Máximo $GMax$, Gradiente Médio GMe e Desvio Padrão do Gradiente GSD . Com P e A combinados, mais uma característica pode ser calculada, a Complexidade C .

O capítulo 6 apresenta uma comparação a respeito de dois algoritmos implementados no cálculo dos descritores extraídos diretamente a partir desse bloco.

5.1.7 Transformada de Hotelling

Os autovalores da matriz de covariância calculados para a transformada de Hotelling, no último bloco de extração de características permitem medir a variância da mancha em cada direção do espaço, obtendo-se assim uma medida de espalhamento S da mesma.

Os vetores bidimensionais utilizados como parâmetro de entrada para a realização do processo são mapeados pela saída do bloco de morfologia matemática, que diz quais *pixels* fazem parte e quais não fazem parte da mancha na imagem.

5.1.8 Extração de características

A extração de todas as características (mostradas no capítulo 3) realizada nos passos anteriores, formam um vetor com 11 descritores, ordenados de acordo com a equação 3.43, servindo como parâmetro de entrada para o treinamento do classificador neural.

Para cada mancha negra analisada, um conjunto de descritores é computado. As características abrangem grandezas relativas tanto à mancha quanto à região ao redor.

Em condições de vento moderado, pode-se verificar grandes regiões escuras na imagem, que correspondem muitas vezes a assemelhados, devido ao fraco retorno da radiação emitida pelo Radar. Se essas áreas (A) apresentam uma grande dimensão, a probabilidade de ser um assemelhado será maior. Se a área for pequena, a probabilidade de ser uma mancha de óleo será maior; contudo essa característica sozinha não pode determinar a classificação final. O perímetro (P) por conseguinte, tende a assumir o mesmo significado.

A comparidade (C) e o espalhamento (S) potencializam as informações de área e perímetro. As manchas de óleo tendem a apresentar geometria simples, devido às características de viscosidade apresentadas pelo óleo, o que resulta numa dispersão mais lenta em condições de velocidade de vento mais fortes. A comparidade engloba essa informação apresentando valores menores nessa situação. Já o espalhamento faz uso das informações dos eixos principais da mancha analisada. Manchas de óleo provenientes de descargas de navio e exsudação apresentam uma forma longa e afilada, o que resulta em um valor pequeno para esse descritor.

O desvio padrão do objeto (OSd) e o desvio padrão de fundo (BSd) são parâmetros da imagem que medem a homogeneidade apresentada por cada região segmentada. O OSd tenta captar a mínima variação presente na mancha de óleo e no assemelhado, usando-a como elemento de decisão. Já o BSd mede a variação de fundo. Se esse valor for grande o fundo da imagem será heterogêneo. Se, em adição, a mancha segmentada possui comparidade alta, a probabilidade da mesma ser um assemelhado será maior. Se esse valor for baixo e a cena não for muito complexa, a probabilidade de ser óleo será maior [Solberg e Solberg 1996].

Os contraste médio ($ConMe$) e máximo ($ConMax$) usados em combinação com as características anteriores, tentam mensurar a relação entre o fundo da imagem e a mancha analisada, criando uma relação óleo-fundo e assemelhado-fundo que os diferenciem na etapa de classificação.

Os descritores gradiente médio (GMe), máximo ($GMax$) e desvio padrão do gradiente (GSd) são descritores de borda do objeto analisado. As características de borda são

interessantes pelas propriedades viscosas apresentadas pelo óleo, mantendo-se o menos disperso possível num primeiro estágio de contato com a água do mar. Isso produz uma variação brusca da tonalidade da imagem analisada. A intensidade dessa mudança, de fundo para mancha, é observada pelo cálculo do gradiente, que tende a apresentar valores maiores do que o dos assemelhados, caracterizados pelo decréscimo gradual de tonalidade.

É possível ainda a incorporação de outros descritores além dos mencionados anteriormente, sem prejuízo para processo de extração de características proposto. Os novos descritores aumentariam a dimensão do vetor de entrada do classificador neural e essas informações poderiam compreender dados meteorológicos, de geo-referenciamento entre outros desejados pelo especialista da área.

A modularização dos estágios de extração de características e de classificação, torna-se uma funcionalidade do SIOSM, pois fornece uma maior robustez para o sistema como um todo, além de permitir a reconfiguração de partes separadas do processo sem prejuízo para os blocos não modificados.

5.1.9 Classificador Neural

Após a coleta dos descritores da cena analisada formando um vetor de características, a inserção do mesmo no classificador implementado estima a possibilidade da mancha ser óleo ou assemelhado. O algoritmo de aprendizagem é capaz de identificar a classe daquele padrão particular por causa da informação que ele extraiu dos dados de treinamento, em etapa anterior à incorporação do classificador no sistema. A figura 5.3 exemplifica esse processo.

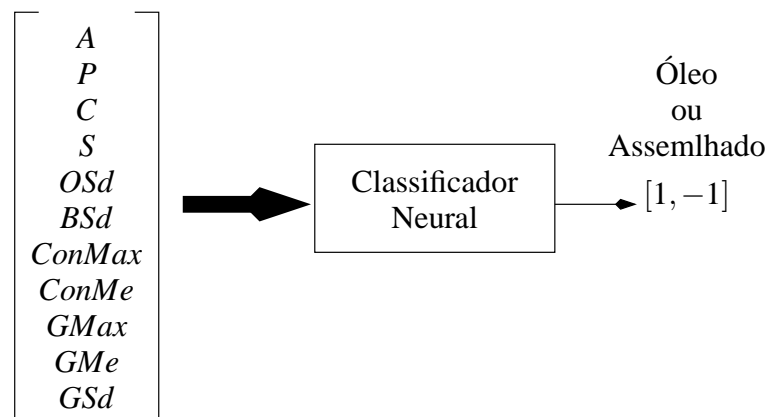


Figura 5.3: Processo de classificação.

Dentre os variados classificadores neurais que podem ser implementado descritos nas seções 4.4, 4.5, 4.6 e 4.7, todos trazem consigo alguma particularidade interessante para o problema de classificação de padrões.

O perceptron de múltiplas camadas, com neurônios possuindo funções de ativação não-linear nas suas camadas ocultas, desempenha um papel crucial como detector de características. O espaço oculto composto pelos nodos das camadas intermediárias mapeia

os dados de entrada em um espaço onde as não linearidades inseridas potencializam a separação entre as classes a serem discernidas pela camada de saída da rede.

A rede de função de base radial, com seus nodos da camada intermediária desempenhando o papel de aproximadores locais, através do agrupamento dos padrões de entrada, aumenta a probabilidade do conjunto de dados não linearmente separável no espaço de entrada ser linearmente separável no espaço de alta dimensionalidade. A tarefa de separação dos padrões no espaço de alta dimensionalidade é executada pela camada de saída da rede.

A máquina de vetor de suporte, fazendo uso da teoria de separabilidade de padrões em um espaço de alta dimensionalidade, utiliza, como superfície de decisão o chamado “hiperplano ótimo” de separação. A construção do hiperplano maximiza a separação entre as classes que compõem o espaço de saída, minimizando assim o risco de classificação trocada dos padrões de entrada em análise.

A máquina de comitê baseia-se no princípio de dividir para conquistar. Dessa forma ela resolve uma tarefa complexa, como a classificação de padrões não linearmente separáveis, dividindo-a em um número de tarefas simples, combinando então as soluções dessas tarefas na estimação final da sua saída. A máquina de comitê pode ser composta por cada uma das máquinas descritas acima.

O objetivo inicial é que os resultados da classificação desempenhada pela máquinas de aprendizados não sejam ambíguos, que a saída assuma os valores extremos no campo $[-1, 1]$, onde 1 indica óleo e -1 indica assemelhado, e valores intermediários sejam encarados como probabilidades de ser uma mancha de óleo, formando assim um classificador probabilístico. Contudo um classificador binário é obtido com o uso de um valor de limiar que melhor separe as classes desejadas.

5.2 Considerações Finais

Se mais que um objeto escuro está presente na área selecionada, o processo descrito pode ser estendido para o objeto próximo, de tal modo que um vazamento consistindo de múltiplas manchas de óleo pode também ser analisado. Nestes casos, as características são primeiro calculadas para cada elemento e então trabalhadas para descrever um único objeto representativo.

Os resultados e testes dos algoritmos implementados nos blocos de filtragem do ruído *speckle*, bloco do cálculo do gradiente e para cada um dos classificadores comentados, do sistema proposto, são apresentados no próximo capítulo.

Capítulo 6

Implementações Computacionais e Resultados

Este capítulo apresenta os resultados obtidos com os algoritmos e técnicas apresentadas nos capítulos anteriores e que estão presentes no SIOSM. Os resultados estão divididos em duas partes. A primeira parte analisa os algoritmos de filtragem do ruído *speckle* e gradiente utilizados no processamento digital de imagem e a suas implicações no valores das características extraídas. A segunda parte analisa o desempenho dos classificadores neurais, comentados no capítulo 4 e aqui implementados.

6.1 Processamento Digital da Imagem

O bloco extrator de características, responsável pelo processamento digital da imagem do SIOSM, foi testado com um total de 12 imagens, obtendo sucesso em todas as abordagens.

A seguir são apresentados resultados com imagens obtidas dos três tipos de satélite mencionados no capítulo 2. Uma análise comparativa dos descritores extraídos e da segmentação de uma mancha para os diferentes filtros mostrados na seção 3.1.1 (filtragem do ruído *speckle*) são apresentados. Uma comparação de dois algoritmos implementados no cálculo do gradiente, em função do valor dos descritores relacionados a esse bloco do sistema, é apresentada também.

Testes com os três blocos de fundamental importância dentro do sistema proposto foram realizados. Os testes com os algoritmos de filtragem do ruído *speckle*, de uma forma geral, influem sobre todas as características extraídas da cena. Os algoritmos que implementam o cálculo do gradiente foram testados exatamente por não alterarem as características dos descritores senão os que estão diretamente relacionados com a saída desse bloco *GMax*, *GMe* e *GSd*. Já os algoritmos de classificação foram testados com o intuito de averiguar o comportamento de cada um para um caso de classificação complexa de padrões, objetivando o uso do que apresentou o melhor desempenho nos diferentes testes realizados.

6.1.1 Filtragem Speckle

Os primeiros experimentos realizados no sistema proposto dizem respeito ao teste de robustez dos valores de descritores extraídos, frente aos diferentes algoritmos aplicados no bloco de filtragem do ruído *speckle*.

A figura 6.1 apresenta o desempenho do SIOSM para a segmentação de uma mancha de óleo presente na imagem 6.3(a). Nela foram utilizados cada um dos filtros *speckle* apresentados na seção 3.1.1.




Figura 6.1: Desempenho comparativo para a segmentação de uma mancha de óleo utilizando diferentes filtros *speckle*.

Para todos os filtros, o sistema conseguiu realizar a segmentação e extração de características da mancha presente na imagem. Nota-se que os filtros concordaram em grande parte sobre a região da mancha segmentada (coloração vermelha).

Os filtros adaptativos (Lee, Frost, Kuan, Lee modificado e Frost modificado) obtiveram resultados muito similares, diferenciando-se apenas o filtro de Frost que, para alguns pontos da imagem, conseguiu segmentar uma área maior, contudo não considerada espúria. Os resultados da segmentação para os filtros adaptativos apresentaram uma menor quantidade de área aparentemente descorrelacionada com a mancha analisada, o que indicaria uma não eliminação do ruído presente na imagem.

O filtro da mediana, de toda forma, realizou a segmentação das mesmas regiões que os filtros adaptativos, contudo apresentando uma região final rotulada com nível maior de ruído, refletindo-se diretamente nos valores dos descritores A , P , C e S . Nota-se também que uma maior região de fronteira, óleo-mar, foi segmentada pelo filtro da mediana em relação aos filtros adaptativos (coloração amarela). Isso pode ser explicado pelo fato das bordas e da região ruidosa próxima apresentarem padrões de tonalidade muito próximos, o que compromete o desempenho do filtro que tem seu potencial alcançado com padrões ruidosos sobre uma região homogênea (ruído aditivo).

A tabela 6.1 compara o valor final dos descritores obtidos pelo SIOSM para cada um dos filtros *speckle* mencionados, apresentando a média (μ) e o desvio padrão (σ) calculados.

Tabela 6.1: Estatística dos valores obtidos, com diferentes filtros *speckle*, para os descritores utilizados no SIOSM.

Descritores	Filtros <i>speckle</i>						μ	σ
	Mediana	Frost	Lee	Kuan	Lee mod.	Frost mod.		
<i>A</i>	7,784	6,54	5,883	5,883	5,883	5,883	6,309	0,343
<i>P</i>	187,83	142,35	114,48	114,48	114,48	114,48	131,35	13,34
<i>C</i>	18,99	15,70	13,31	13,31	13,31	13,31	14,655	1,041
<i>S</i>	2,363	0,960	0,554	0,554	0,554	0,554	0,923	0,323
<i>OSd</i>	-2,611	-1,439	-1,064	-1,064	-1,064	-1,064	-1,384	0,276
<i>BSd</i>	14,465	14,325	14,275	14,275	14,275	14,275	14,315	0,34
<i>ConMax</i>	17,652	17,66	17,666	17,666	17,666	17,666	17,663	0,002
<i>ConMe</i>	17,64	17,629	17,634	17,634	17,634	17,634	17,634	0,001
<i>GMax</i>	27,824	26,776	24,972	24,972	24,972	24,972	25,748	0,557
<i>GMe</i>	20,501	18,806	17,483	17,483	17,483	17,483	18,199	0,553
<i>GSd</i>	19,459	18,137	16,709	16,709	16,709	16,709	17,406	0,517

O valor médio e o desvio padrão de cada um dos descritores levam a conclusão de que as características dependentes da geometria da mancha como *A*, *P*, *C* e *S* obtiveram as maiores disparidades entre os algoritmos testados, pois são fortemente dependentes do estágio de segmentação e esse bastante susceptível ao ruído. Para os demais descritores os valores de desvio padrão foi considerada pequeno, o que comprova a robustez do sistema ao algoritmo utilizado nesse bloco do processo.

Por fim, decidiu-se pela utilização do filtro de Frost por apresentar valores intermediários, entre o filtro da mediana e os outros filtros adaptativos, para os descritores com maior desvio padrão, e por conseguinte variância, além de apresentar valores muito próximos para os descritores: Desvio padrão de fundo (*BSd*), Contraste Máximo (*ConMax*) e Contraste Médio (*ConMe*) em relação ao filtros adaptativos.

6.1.2 Gradiente

Após a escolha do algoritmo utilizado na filtragem do ruído *speckle*, o bloco de cálculo do Gradiente foi testado com dois algoritmos diferentes.

A tabela 6.2 apresenta uma comparação dos três descritores dependentes do gradiente, extraídos do SIOSM para a imagem 6.3(a) utilizando o operador de Sobel e de Prewitt no cálculo. Todos os outros descritores não apresentaram variação, como era esperado. A média (μ) e o desvio padrão (σ) são calculados para os três descritores.

O mesmo processo foi realizado para a imagem 6.5(a), que também não apresentaram variação para os descritores que não *GMax*, *GMe* e *GSd*. Os descritores obtidos são apresentados na tabela 6.3.

O dados apresentados na tabela 6.2 referem-se a uma mancha rotulada como óleo, enquanto os dados mostrados na tabela 6.3 referem-se a uma mancha rotulada como as-

Tabela 6.2: Estatística dos valores obtidos para os descritores de gradiente de uma mancha de óleo.

Descritores	Gradiente		μ	σ
	Sobel	Prewitt		
<i>GMax</i>	26,776	25,428	26,102	0,953
<i>GMe</i>	18,806	17,524	18,165	0,906
<i>GSd</i>	18,137	16,768	17,452	0,968

Tabela 6.3: Estatística dos valores obtidos para os descritores de gradiente de um assemelhado.

Descritores	Gradiente		μ	σ
	Sobel	Prewitt		
<i>GMax</i>	28,375	26,972	27,674	0,992
<i>GMe</i>	15,185	13,874	14,53	0,927
<i>GSd</i>	15,616	14,288	14,952	0,939

semelhado, de forma que a escolha do algoritmo a ser implementado no bloco do cálculo do gradiente respeitou a máxima separação obtida entre as classes para o maior número de descritores. O escolhido foi o operador de Sobel, que para os descritores *GMax* e *GSd* apresentou a maior separação entre as classes, enquanto o operador de Prewitt foi melhor apenas para o descritor *GMe*. Esses resultados se refletiram para a maior parte das imagens que formam o banco de dados gerados.

Tabela 6.4: Máxima separação entre os descritores de gradiente para cada uma das classes.

Descritores	Máx. separação	
	Sobel	Prewitt
<i>GMax</i>	1,599	1,544
<i>GMe</i>	3,620	3,649
<i>GSd</i>	2,52	2,479

Tendo em vista que Frate et al. (2000) destaca a alta significância dos descritores de gradiente na decisão final tomada pelo classificador, o formalismo na escolha do algoritmo a ser utilizado por esse bloco do sistema é importante para ajudar o classificador neural na sua tarefa de mapeamento da função de decisão que melhor separa as classes em questão.

6.1.3 Processando Imagem Radarsat-1

Na cena da figura 6.2 imageada pelo satélite Radarsat-1 no dia 04/02/2002, da Baía Potiguar na região próxima da cidade de Guamaré, é possível visualizar diversas manchas, de diferentes naturezas, algumas inclusive de óleo [Albuquerque 2004].




Figura 6.2: Imagem Radarsat-1 SAR de 21/05/1999 08:10:33 UTM, órbita 0018490. Fonte: CSA[©].

A figura 6.3 apresenta a evolução dos dados dentro do SIOSM no processamento da região de interesse selecionada, mostrada na figura 6.3(a). A mancha presente nessa região é atribuída a uma descarga de navio, já em alto mar [Albuquerque 2004]. O formato alongado da mancha é um diferencial marcante nesse tipo de situação. A imagem 6.3(b) apresenta o resultado da aplicação da filtragem do ruído *speckle* na área inicialmente selecionada. Uma sutil diferença é notada, principalmente nos elementos isolados e de variação brusca de tonalidade em relação a sua vizinhança. O filtro log, etapa seguinte, é aplicado sobre a figura 6.3(b) e o resultado do processamento é visualizado na figura 6.3(c). Aqui nota-se o efeito desejado do realce, mencionado na seção 3.1.2, com as características da morfológicas da mancha preservadas ao máximo, enquanto o fundo da imagem é praticamente todo aproximado para um valor discreto distinto da mancha.

A etapa de quantização vetorial, para 2 classes distintas e recebendo como entrada a figura 6.3(c) apresenta o resultado observado na imagem 6.3(d). Os dados processados são compostos agora de duas únicas tonalidade, onde a distorção foi minimizada pelas propriedades apresentadas na seção 3.2. A limiarização dos dados, como próximo passo do processo, seleciona o valor mais baixo dentre as classes presentes na imagem 6.3(d) usando-o como limiar, resultando na imagem 6.3(e).

Com os dados binarizados a abertura morfológica pode ser aplicada, figura 6.3(f), resultando na mancha segmentada presente na figura 6.3(i).

Duas etapas, referentes aos operadores de gradiente, são aplicadas sobre as figuras 6.3(b) e 6.3(f), resultando nas figuras 6.3(g) e 6.3(h), respectivamente. Nota-se na

imagem 6.3(g) que a maior parte dos *pixels* rotulados em 6.3(i) como mancha estão presentes na grande área escura onde o gradiente encontrou pouca variação, mostrando a uniformidade dessa região da mancha a ser segmentada.

O valor dos descritores obtidos da figura 6.3(a) são mostrados na tabela 6.5.

Tabela 6.5: Descritores calculados para a figura 6.3(a).

Descritores	
<i>A</i>	6,54
<i>P</i>	142,35
<i>C</i>	15,701
<i>S</i>	0,96
<i>OSd</i>	-1,439
<i>BSd</i>	14,325
<i>ConMax</i>	17,66
<i>ConMe</i>	17,629
<i>GMax</i>	26,776
<i>GMe</i>	18,806
<i>GSd</i>	18,137

6.1.4 Processando Imagem Envisat

Na figura 6.4 imageada pelo satélite Envisat no dia 01/06/2004, da Bacia Potiguar, na região próxima da cidade de Guamaré, é possível visualizar algumas manchas próximas da costa, na parte central da imagem.

Na figura 6.5 é possível visualizar os dados em cada um dos blocos de processamento digital de imagem dentro do SIOSM, para um fragmento de imagem oriundo do satélite Envisat.

Como no caso descrito para o fragmento de imagem Radarsat-1, o processo se inicia com a seleção da região de interesse, figura 6.5(a). A mancha presente nessa região é atribuída a um assemelhado próximo a costa. A imagem 6.5(b) apresenta o resultado da aplicação da filtragem do ruído *speckle* na área inicialmente selecionada. A minimização do efeito do ruído com a máxima preservação das características de textura são visualizados principalmente nos elementos isolados e de variação brusca de tonalidade em contrapartida aos dados da região costeira na imagem. O efeito positivo do filtro log, figura 6.5(c), é novamente notado quando aplicado sobre a figura 6.5(b).

A etapa de quantização vetorial recebe como entrada de dados a figura 6.5(c) e apresenta o resultado observado na imagem 6.5(d). Os dados processados são compostos agora de duas únicas tonalidade, onde a distorção foi minimizada pelas propriedades apresentadas na seção 3.2. Neste exemplo específico a seleção da área de interesse englobou um pedaço da imagem sobre a costa, em que micro manchas escuras estão presentes. Como o processamento não faz distinção espacial dos dados (terra e água), esses frag-




Figura 6.3: Processando Imagem Radarsat-1: (a) região de interesse; (b) filtragem *speckle*; (c) filtro log; (d) quantização vetorial; (e) limiarização; (f) morfologia matemática; (g) gradiente da imagem (b); (h) gradiente da imagem (f); (i) mancha segmentada.




Figura 6.4: Imagem Envisat ASAR de 01/06/2004. Fonte: ESA[©].

mentos, que apresentam tonalidade compatível com a da mancha, são segmentados como pertencente a mesma classe.

A limiarização dos dados, como próximo passo do processo, seleciona o valor mais baixo dentre as classes presentes na imagem 6.5(d) usando-o como limiar, o resultado é mostrado na figura 6.5(e).

Após a binarização da imagem 6.5(d) pelo bloco de limiarização, a abertura morfológica pode realizar uma filtragem morfológica, figura 6.5(f), resultando na mancha segmentada presente na figura 6.5(i).

As etapas de cálculo do gradiente aplicadas sobre as imagens 6.5(b) e 6.5(f) produzem as imagens 6.5(g) e 6.5(h), respectivamente.

O valor dos descritores obtidos da figura 6.5(a) são mostrados na tabela 6.6.

6.1.5 Processando Imagem ERS-2

A figura 6.6 imageada pelo satélite ERS-2 no dia 04/02/2002, apresenta uma cena onde é possível visualizar o Estreito de Gibraltar. Através do Estreito, uma corrente contínua entra no mar Mediterrâneo do Oceano Atlântico, e as correntes fluem ao longo das costas Européia e Africana. Em toda parte, no oceano há tráfego de navio em abundância.

A figura 6.7 apresenta a evolução dos algoritmos de processamento de imagem do SIOSM no processamento da região de interesse selecionada mostrada na figura 6.7(a). A mancha presente nessa região é atribuída a uma exsudação. O formato estreito da mancha




Figura 6.5: Processando Imagem Envisat: (a) região de interesse; (b) filtragem *speckle*; (c) filtro log; (d) quantização vetorial; (e) limiarização; (f) morfologia matemática; (g) gradiente da imagem (b); (h) gradiente da imagem (f); (i) mancha segmentada.




Figura 6.6: Imagem ERS-2 SAR de 04/02/2002 11:03:41 GM, órbita 35519 quadro 2885.
Fonte: ESA[©].

Tabela 6.6: Descritores calculados para a figura 6.5(a).

Descritores	
<i>A</i>	6,769
<i>P</i>	298,375
<i>C</i>	32,351
<i>S</i>	34,297
<i>OSd</i>	0,695
<i>BSd</i>	15,279
<i>ConMax</i>	16,875
<i>ConMe</i>	16,737
<i>GMax</i>	28,375
<i>GMe</i>	15,185
<i>GSd</i>	15,616

assim como a descarga de navio é um diferencial nesse tipo de situação.

A imagem seguinte 6.7(b) é o resultado da aplicação da filtragem do ruído *speckle* na figura 6.7(a). O filtro log é aplicado sobre a figura 6.7(b) e o resultado do processamento é visualizado na figura 6.7(c). Tanto a mancha, quanto o fundo da imagem são mapeados para tonalidades claras, contudo ainda nota-se uma sutil diferença explorada pelo algoritmo de quantização vetorial.

O resultado da quantização vetorial é mostrado na figura 6.7(d), contudo nele não é totalmente possível visualizar artefatos ainda presentes na cena clarificados na imagem 6.7(e), após o processo de limiarização.

A filtragem que deve ser aplicada na retirada desses objetos indesejados é realizada pela morfologia matemática, figura 6.7(f), com a tentativa de preservação das características morfológicas da mancha. O resultado de todo o processo é a mancha segmentada, visualizada aqui na figura 6.7(i).

Mais duas etapas referentes aos gradientes são aplicadas sobre as figuras 6.7(b) e 6.7(f), resultando nas figuras 6.7(g) e 6.7(h), respectivamente. Na figura 6.7(g) não é notada nenhuma região de pouca variação na magnitude do gradiente, como nas manchas segmentadas anteriormente. Essa variação no gradiente pode servir como um indicador de dificuldade da tarefa de segmentação realizada.

Esse resultado é expressivo por mostrar a robustez do sistema nesse tipo de situação, com a segmentação da mancha englobando grande parte do que é perceptível visualmente.

O valor dos descritores obtidos da figura 6.7(a) são mostrados na tabela 6.7.

6.1.6 Considerações

Os resultados apresentados pelo SIOSM para a extração dos descritores em imagens dos três diferentes satélites que incorporam o SAR como sensor imageador mostram a robustez do sistema ao processo, assim como a atuação do algoritmo de segmentação de imagem detalhando o fluxo de informação do SIOSM. As manchas analisadas em cada

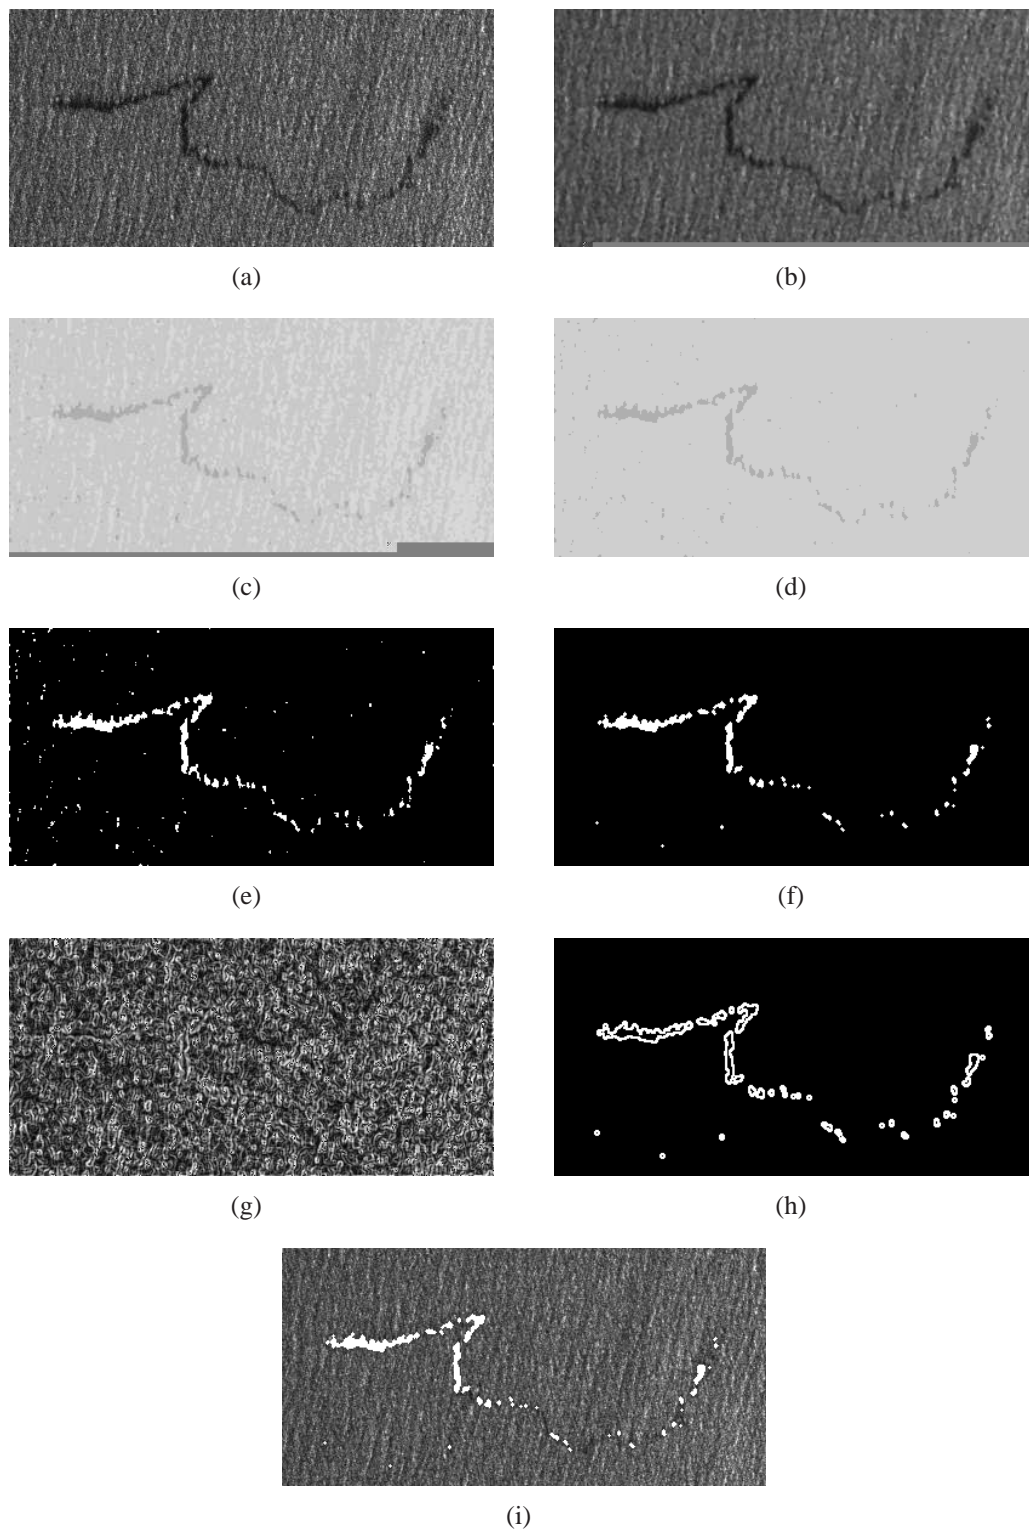


Figura 6.7: Processando Imagem ERS-2: (a) região de interesse; (b) filtragem *speckle*; (c) filtro log; (d) quantização vetorial; (e) limiarização; (f) morfologia matemática; (g) gradiente da imagem (b); (h) gradiente da imagem (f); (i) mancha segmentada.

Tabela 6.7: Descritores calculados para a figura 6.7(a).

Descritores	
<i>A</i>	0,3106
<i>P</i>	22,15
<i>C</i>	11,211
<i>S</i>	7,204
<i>OSd</i>	7,13
<i>BSd</i>	12,102
<i>ConMax</i>	18,345
<i>ConMe</i>	17,399
<i>GMax</i>	25,132
<i>GMe</i>	20,578
<i>GSd</i>	17,175

cena apresentavam, visualmente, graus de dificuldade diferentes. Mesmo sendo esse um conceito subjetivo, a magnitude do gradiente da imagem após a filtragem do ruído *speckle* pode representar isso bem.

6.2 Máquinas de Aprendizado

Os testes realizados com cada uma das máquinas apresentadas no capítulo 4 foram divididos em 3 partes.

A primeira parte foi realizada com o treinamento e validação utilizando somente um conjunto de dados extraídos pelo SIOSM. A segunda parte utilizou os mesmo dados extraídos pelo SIOSM e a validação foi realizada sobre dados artificialmente gerados. E por fim, a terceira parte compreendeu o treinamento de cada máquina com dados artificiais e a validação com os dados extraídos pelo SIOSM. Os resultados são apresentados a seguir.

6.2.1 Pré-processamento dos dados

O conjunto de dados extraído pelo sistema é composto por 12 manchas, sendo 3 da classe óleo e 9 da classe assemelhado.

Diante desses números alguns problemas relacionados ao aprendizado das máquinas (descritos no capítulo 4) devem ser tratados. Além do número de exemplos de treinamento ser considerado pequeno, o conjunto de dados é formado por classes com um número desbalanceado de representantes.

O conjunto de dados pode ser balanceado realizando uma amostragem dos dados da classe maior e/ou duplicando os exemplos de treinamento ou criando novos exemplos da classe menor. Solberg e Solberg (1996) implementam as duas técnicas com sucesso.

Dessa maneira um conjunto de 1000 exemplos de dados (500 da classe óleo e 500 da classe assemelhado) foram gerados artificialmente a partir dos valores de média e des-

vio padrão dos descritores extraídos do conjunto de manchas existente, mostrados na tabela 6.8. Foi assumido uma distribuição normal para cada uma das variáveis aleatórias (descritores).

Tabela 6.8: Medidas estatísticas das classes Óleo e Assemelhado.

Descritores	Óleo		Assemelhado	
	μ	σ	μ	σ
<i>A</i>	2,614	2,415	32,231	11,333
<i>P</i>	77,363	42,916	702,693	247,173
<i>C</i>	15,34	2,807	34,379	6,331
<i>S</i>	2,988	2,582	19,474	5,074
<i>OSd</i>	2,346	3,037	0,829	1,096
<i>BSd</i>	13,688	0,977	14,978	0,182
<i>ConMax</i>	18,356	0,496	17,914	0,405
<i>ConMe</i>	18,006	0,606	17,702	0,373
<i>GMax</i>	26,473	0,861	27,076	0,672
<i>GMe</i>	19,494	0,671	17,363	0,387
<i>GSd</i>	17,932	0,479	16,486	0,299

A primeira etapa então, dos testes realizados, consiste na utilização desses dados pelas máquinas de aprendizado, ora treinando com dados reais e validando com os artificiais, ora utilizando dados artificiais no treinamento e validando com os dados reais. Essas situações permitem medir a capacidade de generalização dos algoritmos. Seja extrapolando ou interpolando o conjunto de treinamento.

A segunda etapa dos testes de validação das máquinas de aprendizado compreende a realização do treinamento e validação utilizando a técnica deixe-um-para, com o intuito de analisar o desempenho de cada máquina em relação aos dados extraídos pelo SIOSM.

6.2.2 Validação Utilizando Dados Artificiais

A primeira etapa dos testes divide-se em dois passos. O primeiro consiste no treinamento da máquina de aprendizado com dados extraídos pelo SIOSM e a validação utilizando os dados artificiais compilados anteriormente. Os resultados são apresentados a seguir.

Perceptron de Múltiplas Camadas

Vários esforços inicialmente foram feitos para apropriadamente selecionar o número de unidades a serem considerados nas camadas ocultas da MLP. A topologia 11 – 8 – 8 – 1 foi finalmente escolhida por sua boa performance em termos de precisão de classificação assim como tempo de treinamento. De fato, um número em torno de 8000 épocas de treinamento foi suficiente para ter a rede treinada. A arquitetura utilizada foi:

- Camadas: 3.

- Configuração: 11 – 8 – 8 – 1.
- Função de ativação nas camadas ocultas: tangente hiperbólica.
- Taxa de Aprendizado: 0,001.
- Termo do Momento: 0,0001.
- Tolerância ao erro: 10^{-6} .
- Épocas de treinamento: 8000.

A figura 6.8 apresenta a evolução do erro médio quadrático no treinamento da MLP. O decréscimo suave termina com o valor final do erro entre 10^{-4} e 10^{-3} . A tabela 6.9 mostra os valores obtidos na classificação dos exemplos de validação, onde v.p. significa verdadeiros positivo e v.f. significa falsos positivo. Os valores foram obtidos com diferentes limiares de separação na saída do classificador.




Figura 6.8: Erro médio quadrático apresentado durante o treinamento da MLP com a utilização de dados extraídos pelo SIOSM.

O melhor desempenho na separação das classes, 99%, é obtido com valor de limiar igual a $-0,99$. O número maior de exemplos de dados na etapa de validação permitiu refinar o desempenho obtido, de forma que a taxa de classificação correta para a classe assemelhado nessas condições foi muito próxima da ótima, com a maioria dos exemplos da classe obtendo valor de saída próximo do desejado, -1 , e que, o mínimo afastamento no limiar de separação foi suficiente para eliminar um grande número de falsos positivos. A generalização para a classe óleo também é considerada expressiva, principalmente considerando-se o problema da escassez de exemplos da classe no conjunto de treinamento.

A figura 6.9 mostra a curva ROC obtida através dos valores da tabela 6.9. O valor da área sob a curva, uma das medidas de desempenho mostradas na seção 4.1.2, para o classificador em questão foi igual a 0,991, próximo do ótimo.

Tabela 6.9: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede MLP validada com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	500	500	-0,3	370	1	0,4	296	1
-0,9	494	4	-0,2	356	1	0,5	280	1
-0,8	463	3	-0,1	344	1	0,6	263	1
-0,7	436	3	0	333	1	0,7	250	1
-0,6	415	3	0,1	327	1	0,8	222	1
-0,5	397	3	0,2	317	1	0,9	192	1
-0,4	386	2	0,3	305	1	0,99	41	1




Figura 6.9: Curva ROC do classificador MLP validado com dados artificiais.

Rede de Função de Base Radial

Para os classificadores RBF foram testadas 4 funções de base radial diferentes, e em todos os classificadores a arquitetura utilizada foi:

- Camadas: 3.
- Configuração: 11 – 12 – 1.
- Seleção auto-organizada dos centros.

As tabelas 6.10, 6.11, 6.12 e 6.13 mostram os valores obtidos na classificação dos exemplos de validação com o uso das redes de Função de Base Radial com função gaussiana, multiquadrática, *thin-plate-spline* e multiquadrática inversa, respectivamente.

O melhor resultado, apresentado pela RBF com função radial gaussiana, com taxas de 99,4% para a classe óleo e 98% para a classe assemelhado totaliza 98,7% dos exemplos corretamente classificados. Essas taxas foram obtidas com um valor de limiar igual a $-0,4$ na saída do classificador, como mostra a tabela 6.10.

Tabela 6.10: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial gaussiana validada com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	500	500	-0,3	464	1	0,4	151	0
-0,9	500	500	-0,2	414	0	0,5	96	0
-0,8	500	500	-0,1	361	0	0,6	31	0
-0,7	500	470	0	318	0	0,7	0	0
-0,6	500	89	0,1	269	0	0,8	0	0
-0,5	500	24	0,2	229	0	0,9	0	0
-0,4	497	10	0,3	199	0	0,99	0	0

A RBF com função radial multiquadrática apresentou um desempenho onde 99% dos dados foram corretamente classificados. Resultado formado por 99,2% do exemplos da classe óleo e 98,8% dos exemplos da classe assemelhado corretamente classificados. Números obtidos com valor de limiar na saída do classificador igual a $-0,3$, como mostra a tabela 6.11.

Tabela 6.11: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial multiquadrática validada com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	500	500	-0,3	496	6	0,4	216	0
-0,9	499	500	-0,2	483	3	0,5	158	0
-0,8	499	500	-0,1	455	0	0,6	82	0
-0,7	499	355	0	407	0	0,7	8	0
-0,6	499	105	0,1	359	0	0,8	0	0
-0,5	499	26	0,2	309	0	0,9	0	0
-0,4	499	12	0,3	262	0	0,99	0	0

A RBF com função radial *thin-plate-spline* foi a que apresentou o pior desempenho dentre as redes de Função de Base Radial testadas. A sua taxa de classificação correta foi de apenas 81,2% para os dados da classe óleo e 90,6% da classe assemelhado, resultando num desempenho total de 85,9%. O melhor desempenho foi obtido com valor de limiar igual a $-0,4$, como mostra a tabela 6.12.

A RBF com função radial do tipo multiquadrática inversa acompanhou o desempenho obtido pela RBF com função radial gaussiana e multiquadrática. O resultado para a classificação da classe óleo, 99%, junto com o resultado na classificação dos assemelhados, 97,2%, resultaram num desempenho final de 98,1%. O limiar de separação que maximiza o desempenho é de $-0,4$, como mostra a tabela 6.13.

Os melhores valores de limiar, $-0,4$ e $-0,3$, obtidos por cada uma das redes, mostram que a rotulação dos exemplos de validação para a classe assemelhado, que contou com um maior número de exemplos de treinamento, não acompanhou a MLP.

Tabela 6.12: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial *thin-plate-spline* validada com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	495	498	-0,3	371	23	0,4	118	0
-0,9	491	498	-0,2	335	10	0,5	79	0
-0,8	491	496	-0,1	300	6	0,6	40	0
-0,7	490	493	0	263	3	0,7	29	0
-0,6	482	410	0,1	236	0	0,8	20	0
-0,5	452	133	0,2	200	0	0,9	14	0
-0,4	406	47	0,3	164	0	0,99	1	0

Tabela 6.13: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial multiquadrática inversa validada com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	500	500	-0,3	462	8	0,4	146	0
-0,9	500	500	-0,2	411	5	0,5	89	0
-0,8	500	500	-0,1	365	1	0,6	21	0
-0,7	500	500	0	317	1	0,7	0	0
-0,6	500	193	0,1	267	0	0,8	0	0
-0,5	500	35	0,2	232	0	0,9	0	0
-0,4	495	14	0,3	197	0	0,99	0	0

Dentre todas as RBF testadas, a rede implementada com função radial gaussiana foi a que apresentou o melhor desempenho final, levando-se em conta o conjunto de limiares testados e área sob a curva ROC construída para cada um dos classificadores, como mostra a figura 6.10. Os valores obtidos foram: 0,998; 0,997; 0,904 e 0,995 para as redes gaussiana, multiquadrática, *thin-plate-spline* e multiquadrática inversa, respectivamente. O resultado mostra o melhor resultado final obtido por alguns dos classificadores em relação a MLP.

A criação das redes de Função de Base Radial envolveu uma pequena elevação de dimensionalidade na camada intermediária. Essa elevação no espaço, acrescida da não linearidade, baseada no teorema de Cover, foi suficiente para que a RBF apresentasse um ótimo desempenho.

Máquina de Vetor de Suporte

A curva ROC, mostrada na figura 6.12 e a evolução do erro absoluto no cálculo dos multiplicadores de Lagrange da figura 6.11, mostram o desempenho obtido e a estabilidade no treinamento, respectivamente, apresentados pelo classificador SVM. A curva do erro converge suavemente para um valor entre 10^{-5} e 10^{-4} . A máquina é formado por um kernel polinomial onde 7 vetores do conjunto de dados de treinamento são vetores de

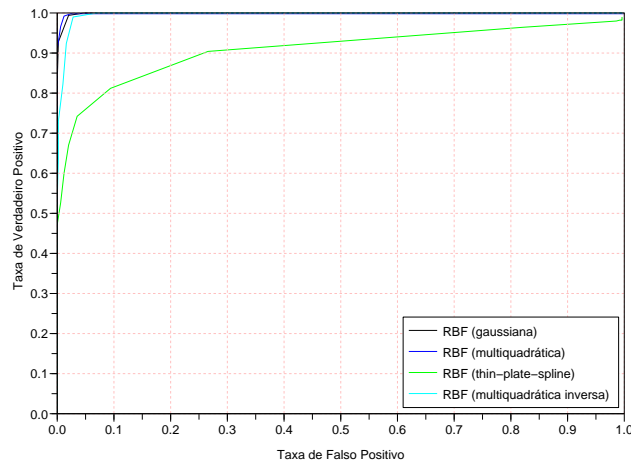


Figura 6.10: Curva ROC dos diferentes classificadores RBF validados com dados artificiais.

suporte, utilizados na construção do hiperplano de separação das classes.

O melhor desempenho na separação das classes, 96%, é obtido com valor de limiar igual a $-0,4$, como mostra a tabela 6.14, acompanhando o limiar apresentado pelas RBF. A melhor rotulação dos exemplos de validação não ficou tão próxima da idealizada no treinamento e como aconteceu para a classe assemelhado com o uso da MLP, contudo isso pode ser explicado pela pequena quantidade de exemplos de dados de treinamento que no caso da SVM tem implicações diferentes na construção e treinamento da máquina.

Tabela 6.14: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a SVM validada com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
$-0,99$	500	500	$-0,3$	474	18	0,4	378	6
$-0,9$	499	415	$-0,2$	462	14	0,5	348	6
$-0,8$	498	191	$-0,1$	453	10	0,6	308	5
$-0,7$	496	101	0	442	8	0,7	272	5
$-0,6$	496	61	0,1	430	7	0,8	211	5
$-0,5$	490	37	0,2	417	6	0,9	129	4
$-0,4$	486	26	0,3	404	6	0,99	5	1

O valor da área sob a curva, 0,983, mostra o bom desempenho obtido por esse classificador, com uma boa relação entre falsos e verdadeiros positivos, próxima da ótima. Os resultados apresentados pela SVM mostram a suas qualidades mesmo sob condições adversas, como o pequeno número de vetores de treinamento e por conseguinte, um pequeno número de vetores de suporte, que são primordiais na criação do hiperplano de separação ótima.




Figura 6.11: Erro absoluto apresentado durante o cálculo dos multiplicadores de Lagrange no treinamento da SVM com a utilização de dados extraídos pelo SIOSM.




Figura 6.12: Curva ROC do classificador SVM validado com dados artificiais.

Máquina heterogênea de Comitê

A máquina de Comitê heterogênea, com elemento combinador baseado na média de *ensemble*, a partir dos melhores classificadores individuais: MLP, RBF com função radial gaussiana e a SVM, apresentou um desempenho melhor do que o a MLP e a SVM individualmente. O desempenho foi alavancado pelo RBF, contudo não melhor do que a mesma isoladamente.

A melhor separação das classes (menor taxa de falsos positivos e com maior taxa de verdadeiros positivos) é obtida com valor de limiar igual a $-0,5$, como mostra a tabela 6.15. Com esse valor de limiar 98,6 dos exemplos de validação são corretamente

Tabela 6.15: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para o classificador heterogêneo de Comitê validado com dados artificiais.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	500	500	-0,3	462	5	0,4	3	0
-0,9	500	500	-0,2	413	5	0,5	0	0
-0,8	500	370	-0,1	344	3	0,6	0	0
-0,7	500	89	0	247	1	0,7	0	0
-0,6	500	24	0,1	138	1	0,8	0	0
-0,5	496	10	0,2	28	1	0,9	0	0
-0,4	487	6	0,3	10	0	0,99	0	0

rotulados.




Figura 6.13: Curva ROC do classificador heterogêneo de Comitê validado com dados artificiais.

A curva ROC apresentada na figura 6.13 totaliza uma área de valor igual a 0,995, concordando com todos os classificadores testados anteriormente e bem próximo do valor ideal.

6.2.3 Validação Utilizando Dados do SIOSM

Completando a primeira etapa dos testes, o segundo passo no treinamento e validação das máquinas de aprendizado foi realizado com dados artificiais no treinamento e dados extraídos pelo SIOSM na validação. Essa não é uma tarefa fácil, tendo em vista principalmente a não-linearidade do vetor de alta dimensão apresentado na entrada do algoritmo e o escasso número de exemplos de dados para a realização das medidas de desempenho.

Perceptron de Múltiplas Camadas

A figura 6.14 mostra o erro médio quadrático alcançado durante o treinamento da MLP. O treinamento com um número maior de elementos permitiu um melhor aprendizado sobre a estatística que envolve a composição dos descritores das duas classes. Como as camadas ocultas da MLP se comportam como detectores de características, a definição e rotulação dos exemplos de validação, nesse caso os dados extraídos pelo SIOSM, tendem a assumir valores extremos dentro dos rótulos pré-estabelecidos para as duas classes, como mostra a tabela 6.16 para diferentes valores de limiar na saída do classificador.

O valor final do erro de treinamento esteve próximo de 10^{-5} , com um decréscimo suave durante todo o treinamento. A arquitetura utilizada foi a mesma do teste anterior.

Tabela 6.16: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede MLP validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	9	-0,3	3	2	0,4	3	1
-0,9	3	2	-0,2	3	2	0,5	3	1
-0,8	3	2	-0,1	3	2	0,6	3	1
-0,7	3	2	0	3	2	0,7	3	1
-0,6	3	2	0,1	3	1	0,8	3	1
-0,5	3	2	0,2	3	1	0,9	3	1
-0,4	3	2	0,3	3	1	0,99	0	0




Figura 6.14: Erro médio quadrático apresentado durante o treinamento da MLP utilizando dados artificiais.

A curva ROC apresentada pelo classificador MLP é mostrada na figura 6.15. O valor de área sob a curva foi igual a 0,944. Valor inferior ao apresentado no teste de validação

com o uso de dados artificiais, porém justificado pela falta de resolução em função de um número menor de dados de validação.




Figura 6.15: Curva ROC do classificador MLP validado com dados extraídos pelo SI-OSM.

O resultados apresentados pela MLP nesse teste e no teste anterior dão uma dimensão da capacidade de aprendizado e generalização desse tipo de máquina para duas situações diferentes. A primeira formada por um pequeno número de dados de treinamento porém com bom conjunto de validação, permitindo um refinamento nos números de desempenho apresentados. E a segunda formada um número grande de dados de treinamento, refinando o aprendizado da máquina, porém com um número pequeno e desbalanceado de dados para a captação das medidas de desempenho.

Rede de Função de Base Radial

Para os classificadores RBF foram adotadas a mesma arquitetura:

- Camadas: 3.
- Configuração: 11 – 25 – 1.
- Seleção auto-organizada dos centros.

Com um número maior de dados para o treinamento das RBF, a elevação de dimensionalidade da camada intermediária pelo uso dos centros de função de base radial, sempre baseada no teorema de Cover, pressupõe uma melhora nos resultados do classificador nos testes de validação. A idéia é a composição de um número maior de aproximadores locais e melhor definição na construção dos mesmos, para que uma boa generalização possa englobar casos não observados no treinamento.

As tabelas 6.17, 6.18, 6.19 e 6.20 mostram os valores obtidos na classificação dos exemplos de validação com o uso das redes de Função de Base Radial com função gaussiana, multiquadrática, *thin-plate-spline* e multiquadrática inversa, respectivamente.

A RBF com função de base radial gaussiana conseguiu rotular corretamente todos os exemplos de dados do conjunto de validação, como mostra a tabela 6.17.

Tabela 6.17: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial gaussiana validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	9	-0,3	3	3	0,4	3	0
-0,9	3	9	-0,2	3	2	0,5	3	0
-0,8	3	9	-0,1	3	2	0,6	2	0
-0,7	3	9	0	3	1	0,7	0	0
-0,6	3	9	0,1	3	1	0,8	0	0
-0,5	3	7	0,2	3	1	0,9	0	0
-0,4	3	7	0,3	3	1	0,99	0	0

As redes neurais construídas com as outras funções de base radial não obtiveram o mesmo sucesso que a RBF gaussiana. Os exemplos de validação utilizados apresentaram variâncias que não foram capazes de ser aprendidas no treinamento dessas máquinas.

A RBF com função de base radial multiquadrática não conseguiu rotular corretamente todos os exemplos de dados do conjunto de validação, como mostra a tabela 6.18.

Tabela 6.18: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a rede RBF com função radial multiquadrática validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	9	-0,3	3	3	0,4	3	1
-0,9	3	8	-0,2	3	3	0,5	3	1
-0,8	3	8	-0,1	3	3	0,6	1	0
-0,7	3	7	0	3	3	0,7	0	0
-0,6	3	5	0,1	3	1	0,8	0	0
-0,5	3	3	0,2	3	1	0,9	0	0
-0,4	3	3	0,3	3	1	0,99	0	0

A RBF com função de base radial *thin-plate-spline* obteve o pior desempenho dentre as RBF construídas como mostra a tabela 6.19 e a área sob a sua curva ROC mostra na figura 6.16. Isso pode ser explicado pelo fato da função *thin-plate-spline* ser a única função radial que não considera uma largura (variância dos dados de treinamento para o aproximador local em questão) na sua construção, como mostrado no capítulo 4.5.

A RBF com função de base radial multiquadrática inversa apresentou um resultado intermediário ao apresentado pela RBF multiquadrática e pela RBF *thin-plate-spline*, como mostra a tabela 6.20.

Dentre todas as RBF testadas, a rede implementada com função radial gaussiana foi a que apresentou o melhor desempenho final, levando-se em conta o conjunto de limiares

Tabela 6.19: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a RBF com função radial *thin-plate-spline* validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	7	-0,3	3	3	0,4	3	1
-0,9	3	6	-0,2	3	3	0,5	3	1
-0,8	3	6	-0,1	3	3	0,6	1	1
-0,7	3	5	0	3	3	0,7	0	0
-0,6	3	5	0,1	3	2	0,8	0	0
-0,5	3	4	0,2	3	1	0,9	0	0
-0,4	3	3	0,3	3	1	0,99	0	0

Tabela 6.20: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a RBF com função radial multiquadrática inversa validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	9	-0,3	3	5	0,4	3	1
-0,9	3	9	-0,2	3	4	0,5	2	1
-0,8	3	9	-0,1	3	4	0,6	0	0
-0,7	3	9	0	3	3	0,7	0	0
-0,6	3	9	0,1	3	2	0,8	0	0
-0,5	3	8	0,2	3	1	0,9	0	0
-0,4	3	6	0,3	3	1	0,99	0	0

testados e área sob a curva ROC construída para cada um dos classificadores, como mostra a figura 6.16. Os valores obtidos foram: 1; 0,962; 0,684 e 0,925 para as redes gaussiana, multiquadrática, *thin-plate-spline* e multiquadrática inversa, respectivamente.

Máquina de Vetor de Suporte

Para a SVM treinada com um conjunto de dados maior foi possível selecionar melhor os vetores de suporte, essenciais à construção do hiperplano de separação ótima. O kernel utilizado foi o polinomial com um número total de vetores de suporte igual a 32. A evolução do erro absoluto no cálculo dos multiplicadores de Lagrange é mostrada na figura 6.11, com o valor do final entre 10^{-1} e 10^{-2} .

A tabela 6.21 mostra os número de verdadeiros e falsos positivos obtidos na rotulação dos exemplos de validação com diferentes valores de limiar na saída do classificador. O valor da área sob a curva desse classificador foi igual a 1, acompanhando o ótimo resultado apresentado pela RBF com função radial gaussiana. Mesmo com a baixa resolução na validação do classificador, devido ao pequeno número de vetores característicos, pode-se dizer que o número maior de elementos utilizados na construção e treinamento da




Figura 6.16: Curvas ROC dos classificadores RBF validados com dados extraídos pelo SIOSM.




Figura 6.17: Erro absoluto apresentado durante o cálculo dos multiplicadores de Lagrange no treinamento da SVM com dados artificiais.

máquina foram determinantes na boa generalização obtida.

Máquina heterogênea de Comitê

A máquina de Comitê, composta pela MLP, RBF gaussiana e pela SVM, não acompanhou o desempenho dos melhores especialistas. A tabela 6.22 apresenta os resultados obtidos com o classificador para diferentes valores de limiar de saída.

O valor da área sob a curva ROC, mostrada na figura 6.18, ainda assim está dentro da faixa considerado boa, 0,962, contudo isso não justificaria a sua utilização, devido a

Tabela 6.21: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a SVM validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	9	-0,3	3	3	0,4	3	2
-0,9	3	8	-0,2	3	3	0,5	3	0
-0,8	3	7	-0,1	3	2	0,6	3	0
-0,7	3	7	0	3	2	0,7	3	0
-0,6	3	6	0,1	3	2	0,8	2	0
-0,5	3	4	0,2	3	2	0,9	0	0
-0,4	3	4	0,3	3	2	0,99	0	0

Tabela 6.22: Estatísticas de verdadeiros e falsos positivos por valor de limiar de decisão para a máquina heterogênea de Comitê validada com dados extraídos pelo SIOSM.

limiar	v.p.	f.p.	limiar	v.p.	f.p.	limiar	v.p.	f.p.
-0,99	3	9	-0,3	3	1	0,4	2	1
-0,9	3	9	-0,2	3	1	0,5	2	0
-0,8	3	9	-0,1	3	1	0,6	1	0
-0,7	3	7	0	3	1	0,7	0	0
-0,6	3	5	0,1	3	1	0,8	0	0
-0,5	3	3	0,2	3	1	0,9	0	0
-0,4	3	3	0,3	3	1	0,99	0	0

complexidade da sua configuração.




Figura 6.18: Curva ROC do classificador heterogêneo de Comitê validados com dados extraídos pelo SIOSM.

6.2.4 Deixe-um-fora

A segunda parte dos testes realizados com os algoritmo de classificação restringiu-se ao treinamento, classificação e validação das máquinas de aprendizado com a técnica deixe-um-fora, explicada na seção 4.1.1, utilizando somente dados extraídos pelo SIOSM. Os limiares de cada classificador foram escolhidos com base nos melhores resultados obtidos por cada um no primeiro teste, onde as máquinas foram testadas com dados extraídos pelo SIOSM e validadas com dados artificiais.

Perceptron de Múltiplas Camadas

A configuração utilizada pela MLP foi a mesma dos dois primeiros testes. Na figura 6.19 é possível visualizar a evolução do erro médio quadrático nos 12 treinamentos da MLP. Todas as curvas apresentam uma certa suavidade, assim como uma convergência para uma taxa de erro aceitável, entre 10^{-4} e 10^{-3} . A tabela 6.23 mostra a matriz de confusão para o classificador MLP.




Figura 6.19: Curvas do erro médio quadrático apresentadas durante os 12 treinamentos da MLP utilizando a técnica deixe-um-fora.

Tabela 6.23: Matriz de confusão do classificador MLP utilizando a técnica deixe-um-fora.

		Real	
		Mancha	Óleo
MLP	Óleo	2	1
	Assemelhado	1	8

Estes valores indicam um desempenho positivo acima de 66% na classificação da classe óleo e 88% na classificação da classe assemelhado, resultando num desempenho

total em torno de 83%. O resultado apresentado pela MLP é considerado dentro do esperado. A classe óleo é considerada de fácil aprendizado, contudo de difícil generalização pela escassez dos dados de treinamento, o que pode explicar a classificação errada de uma das manchas rotulada como óleo, enquanto que a classe assemelhado possui uma variabilidade grande para alguns dos descritores o que justifica a única classificação errada obtida.

Rede de Função de Base Radial

Para os classificadores RBF foi utilizada a mesma arquitetura:

- Camadas: 3.
- Configuração: 11 – 11 – 1.
- Seleção auto-organizada dos centros.

As tabelas 6.24, 6.25, 6.26 e 6.27 mostram as matrizes de confusão dos classificadores RBF com função de base radial gaussiana, multiquadrática, *thin-plate-spline* e multiquadrática inversa, respectivamente.

Tabela 6.24: Matriz de confusão do classificador RBF com função de base radial gaussiana utilizando a técnica deixo-um-fora.

		Real	
		Mancha	Óleo
RBF	Óleo	2	0
	Assemelhado	1	9

Para a utilização da função de base radial gaussiana o resultado mostra um desempenho acima de 66% na classificação da classe óleo, além da classificação correta de todos os exemplos da classe assemelhado, resultando num desempenho positivo total próximo de 91%.

Tabela 6.25: Matriz de confusão do classificador RBF com função de base radial multiquadrática utilizando a técnica deixo-um-fora.

		Real	
		Mancha	Óleo
RBF	Óleo	2	1
	Assemelhado	1	8

Na utilização da função multiquadrática um desempenho em torno de 66% para a classe óleo e 88% para a classe assemelhado, resultam num desempenho total de 83%.

A RBF construída com a função de base radial *thin-plate-spline* apresentou uma taxa de acerto próxima de 66% na classificação da classe óleo e 66% para a classificação da classe assemelhado, e por conseguinte num desempenho total de 66%.

Tabela 6.26: Matriz de confusão do classificador RBF com função de base radial *thin-plate-spline* utilizando a técnica de *deixe-um-fora*.

		Real	
		Mancha	Óleo
RBF	Óleo	2	3
	Assemelhado	1	6

Tabela 6.27: Matriz de confusão do classificador RBF com função de base radial multi-quadrática inversa utilizando a técnica de *deixe-um-fora*.

		Real	
		Mancha	Óleo
RBF	Óleo	2	1
	Assemelhado	1	8

Já a função multiquadrática inversa apresentou um desempenho próximo de 66% na classificação da classe óleo e 88% para a classificação da classe assemelhado, o que representa um desempenho positivo total em torno de 83%. Dentre todas as redes RBF testadas, foi a rede implementada com função radial gaussiana a que apresentou o melhor resultado, com taxa de acerto para a classe óleo igual ao apresentado pela MLP e superior para a classe assemelhado.

Os resultados apresentados por cada RBF mostram a heterogeneidade de cada uma das funções de base radial na solução de um mesmo problema. Como explicado na seção 4.5, esse tipo de máquina de aprendizado caracteriza-se por aproximações locais o que pode ter ajudado a solução obtida por algumas funções e comprometido o desempenho de outras, devido ao pequeno número de exemplos de treinamento.

Máquina de Vetor de Suporte

O terceiro classificador implementado, a Máquina de Vetor de Suporte, foi composto por um kernel polinomial e contou, na média dos treinamentos, com um total de 7 vetores de suporte. A tabela 6.28 mostra a matriz de confusão apresentada pelo classificador.

Tabela 6.28: Matriz de confusão do classificador SVM utilizando a técnica de *deixe-um-fora*.

		Real	
		Mancha	Óleo
SVM	Óleo	2	1
	Assemelhado	1	8

A figura 6.20 apresenta a evolução do erro absoluto no cálculo dos multiplicadores de Lagrange nos 12 treinamentos realizados pela técnica *leave-one-out*. As curvas apre-

sentam um erro final que oscilou entre 10^{-7} e 10^{-4} , o que está diretamente associado a heterogeneidade do conjunto de dados.




Figura 6.20: Curvas do erro absoluto apresentadas durante os 12 cálculos dos multiplicadores de Lagrange da SVM utilizando a técnica deixe-um-fora.

A qualidade da classificação da SVM pode ser medida pela taxa de acerto, por volta de 66% na classificação da classe óleo e 88% para a classificação da classe assemelhado, totalizando um desempenho final próximo de 83%.

Este resultado é igual ao apresentado pela MLP. A dificuldade do algoritmo na classificação dos padrões encontra-se na determinação dos vetores de suporte. Como são poucos os exemplos de treinamento, principalmente se tratando da classe óleo que conta com apenas três representantes, a Máquina de Vetor de Suporte pode não ter alcançado a sua potencialidade por esse motivo. Contudo, o resultado apresentado pode ser considerado consistente para as condições adversas impostas.

Máquina heterogênea de Comitê

A máquina de comitê implementada utilizou como elemento combinador a média entre as saídas de cada especialista.

A tabela 6.29 mostra a matriz de confusão apresentada pela Máquina de Comitê com função de decisão obtida como a média entre as respostas das diferentes especialistas: MLP, RBF (gaussiana) e SVM. A máquina foi treinada assim como as outras redes apresentadas até aqui.

O desempenho de 66% na classificação da classe óleo e 88% para a classificação da classe assemelhado resulta num desempenho total de 83%.

Nos resultados é possível visualizar que a saída ficou limitada pelo desempenho das MLP e SVM, que juntas obtiveram um maior impacto na determinação da resposta do classificador, não aproveitando assim o adicional conseguido pela RBF.

Tabela 6.29: Matriz de confusão do classificador formado por um Comitê de máquinas utilizando a técnica de *deixe-um-fora*.

		Real	
		Mancha	Óleo
Comitê	Óleo	2	1
	Assemelhado	1	8

6.2.5 Considerações

Os resultados apresentados pelos classificadores nos três diferentes testes realizados mostraram a diversidade de soluções encontradas por cada máquina de aprendizado treinada. A maioria das máquinas testadas apresentaram desempenhos acima dos 90%, o que poderia ser considerado aceitável em determinadas aplicações de classificação padrões, contudo a tarefa considerada nesse trabalho envolve tomadas de decisões de custo elevado, dessa forma um classificador com melhor desempenho é primordial para a sua inclusão no sistema.

Dentre todos os classificadores testados, a RBF com função gaussiana e a SVM foram as máquinas de aprendizado que conseguiram conciliar isso em todos os testes realizados, chegando inclusive a apresentar um desempenho em torno de 98% nos testes de generalização com dados gerados artificialmente.

Capítulo 7

Conclusões

A dissertação apresentada investigou o problema de identificação de manchas de óleo sobre a superfície marinha utilizando imagens de SAR conjuntamente com uma máquina de aprendizado atuando como classificador.

Um processo de segmentação de manchas assim como um processo de extração de características foram propostos. Testes de diferentes algoritmos atuando em alguns dos seus blocos funcionais foram realizados e os resultados apresentados.

Os testes com o bloco de filtragem do ruído *speckle* apresentaram a robustez do sistema proposto para seis diferentes algoritmos de filtragem: Mediana, Lee, Frost, Kuan, Lee modificado e Frost modificado. Os resultados mostraram uma uniformidade nos valores de descritores extraídos, com baixo desvio padrão entre eles. A informação de saída deste bloco do sistema é importante para todos os blocos seguintes, pois o ruído *speckle* (que está presente em todas as imagens de SAR, inclusive nos produtos dos três satélites avaliados) interfere no desempenho de cada um, devido a diagramação interna apresentada pelo SIOSM.

A avaliação do bloco do cálculo do gradiente (que resulta diretamente na extração de três descritores), através de dois algoritmos, mediu o seu impacto no valor e concordância da saída. A utilização do operador de Sobel em relação ao operador de Prewitt mostrou uma margem de separação maior para os descritores *GMax* e *GSd* entre duas imagens de classes distintas analisadas (óleo e assemelhado).

Testes de desempenho com imagens de três satélites imageadores distintos foram apresentados com a extração de descritores de cada uma das manchas analisadas na cena, assim como a atuação do algoritmo de segmentação de imagem detalhando o fluxo de informação do SIOSM. As manchas analisadas em cada cena apresentavam, visualmente, graus de dificuldade diferentes. Mesmo sendo esse um conceito subjetivo, a magnitude do gradiente da imagem após a filtragem do ruído *speckle* pode representar isso bem.

O diagrama de blocos da etapa de extração de características propostos no SIOSM potencializa a modularização do processo como um todo, permitindo a alteração do algoritmo a ser utilizado em cada um dos seus blocos funcionais sem prejuízo para as partes seguintes do sistema. A alteração pode ser evidenciada e investigada pelo operador do sistema com a visualização dos resultados das técnicas de processamento digital de imagens aplicadas no domínio espacial da cena analisada.

Quanto aos algoritmos de classificação, a dissertação apresentou 4 diferentes classificadores supervisionados. Testes com as redes Perceptrons de Múltiplas Camadas (MLP), redes de Função de Base Radial (RBF), Máquinas de Vetor de Suporte (SVM) e Máquinas de Comitê foram investigados e os respectivos resultados apresentados.

As redes MLP apresentaram, no geral, computando todos os testes apresentados, um bom desempenho final, como era esperado [Frate e Salvatori 2004], principalmente pela característica de mapeamento interno dos dados, criando para isso o seu espaço de característica. Os testes e resultados apresentados pela RBF, não encontrados na literatura, em certos momentos superiores aos apresentados pela MLP, mostram a viabilidade desse tipo de máquina de aprendizado na solução de problemas complexos de classificação de padrões. Destaque para a máquina de aprendizado composta por funções de base radial do tipo gaussiana, que superou no conjunto de testes as outras redes de Função de Base Radial implementadas. A SVM, com a estrutura de decisão baseada em um vetor característico da mancha analisada, também não encontrada na literatura apresentou, no conjunto de testes, uma boa generalização para o problema de classificação. Este resultado é pontualmente importante pois mostra a capacidade da máquina de aprendizado mesmo submetida a limitação do número de exemplos de treinamento em um dos testes realizados. A máquina de comitê implementada, composta dos classificadores heterogêneos anteriores, não apresentou resultados melhores do que os obtidos por alguns dos classificadores usados na sua formação.

Embora não se possa realizar nenhuma comparação direta entre os resultados obtidos neste trabalho e os encontrados na literatura (com taxa de classificação trocada de até 14% [Frate et al. 2000] e 10% [Frate e Salvatori 2004]), devido a diferentes base de dados e descritores utilizados, pode-se observar que as menores taxas de classificação incorreta obtidas nos experimentos realizados (até 1%, com a SVM) são consideradas aceitáveis e condizentes com o problema de classificação de manchas de óleo sobre a superfície marinha através de imagens de SAR.

O sistema apresentado possibilita a resposta a evidências. No contexto de classificação de padrões, uma rede neural pode ser projetada para fornecer informação não somente sobre qual padrão particular selecionar, mas também sobre a confiança ou crença na decisão tomada. Esta última informação é de grande valor para o analista do sistema.

Baseado neste estudo conclui-se que o procedimento apresentado pode corretamente classificar manchas de óleo na superfície marinha através de imagens de SAR, mesmo considerando as limitações apresentadas pelo banco de dados utilizado.

7.1 Trabalhos Futuros

Como trabalhos futuros pode-se destacar alguns pontos interessantes a serem abordados.

- Quanto ao bloco de extração de características, a utilização e avaliação de outros algoritmos atuando no bloco de quantização vetorial.
- Avaliar descritores meteorológicos como velocidade de vento, temperatura de superfície marinha entre outros para os classificadores estudados.

- A criação de um banco de dados pelo SIOSM, extraídos de imagens dos 3 diferentes satélites imageadores apresentados possibilitaria a investigação de diferentes algoritmos de classificação sem a necessidade de construção dos blocos anteriores do sistema proposto.
- Analisar a utilização de outros tipos de elementos de combinação na composição da Máquina de Comitê heterogênea, como: a votação ou o reforço.
- Analisar a utilização de uma Máquina de Comitê com a utilização de especialistas homogêneos.
- A implementação de um filtro que seleciona objetos escuros na imagem, eliminando assim a necessidade de um operador externo, possibilitando o processo como um todo ser considerado automático.

Referências Bibliográficas

- Albuquerque, R.C.L. (2004), Aplicação do sensoriamento remoto e do sistema de informações geográficas na detecção de manchas de óleo na região do pólo de exploração de guamaré, rn, Dissertação de mestrado, Universidade Federal do Rio Grande do Norte - UFRN, Natal, RN.
- Braga, A.P., T.B. Ludemir e A.C.P.L.F. Carvalho (2000), *Redes Neurais Artificiais, Teoria e Aplicações*, Editora ETC.
- Calabresi, G., F. Del Frate, J. Lichtenegger, A. Petrocchi e P. Trivero (1999), Neural networks for the oil spill detection using ers-sar data, *em* 'Proceedings of the IEEE 1999 International Geoscience and Remote Sensing Symposium, IGARSS 99.', Vol. 1, pp. 215–217.
- CSA, Canadian Space Agency (2005), 'Radarsat-1', <http://radarsat.space.gc.ca/asc/eng/satellites/radarsat1/default.asp>. Última visita em 18/11/2005.
- DPI/INPE (2002), 'Manuais tutorial de geoprocessamento', <http://www.dpi.inpe.br/spring/portugues/tutorial/radar.html>. Última visita em 31/05/2006.
- ESA, Europe Space Agency (2004), *ASAR Product Handbook*, 1.1ª edição, Europe Space Agency - ESA.
- ESA, European Space Agency (2005a), 'Missions observing the earth - envisat overview', http://www.esa.int/esaEO/SEMWYN2VQUD_index_0_m.html. Última visita em 18/11/2005.
- ESA, European Space Agency (2005b), 'Missions observing the earth - ers overview', http://www.esa.int/esaEO/SEMGWH2VQUD_index_0_m.html. Última visita em 18/11/2005.
- Frate, Fabio Del, A. Petrocchi, J. Lichtenegger e G. Calabresi (2000), 'Neural networks for oil spill detection using ers-sar data', *IEEE Transactions on Geoscience and Remote Sensing* **38**(5), 2282–2287.
- Frate, Fabio Del e L. Salvatori (2004), Oil spill detection by means of neural networks algorithms: a sensitivity analysis, *em* 'Proceedings of the 2004 IEEE International Geoscience and Remote Sensing Symposium, IGARSS 04.', Vol. 2, pp. 1370–1373.

- Gade, M., W. Alpers, Mingquan Bao e H. Huhnerfuss (1996), Measurements of the radar backscattering over different oceanic surface films during the sir-c/x-sar campaigns, em 'Proceedings of the 1996 International Geoscience and Remote Sensing Symposium, IGARSS 96. Remote Sensing for a Sustainable Future.', Vol. 2, pp. 860–862.
- Girard-Ardhuin, F., G. Mercier, F. Collard e R. Garello (2004), Oil slick detection by sar imagery: algorithms comparison, em 'Proceedings of the 2004 IEEE International Geoscience and Remote Sensing Symposium, IGARSS 04.', Vol. 7, pp. 4726–4729.
- Girard-Ardhuin, F., G. Mercier e R. Garello (2003), Oil slick detection by sar imagery: potencial and limitation, em 'OCEANS 2003. Proceedings', Vol. 1, San Diego, CA, USA, pp. 164–169.
- Golub, G.H. e C.F. Van Loan (1996), *Matrix Computations*, 3ª edição, Johns Hopkins University Press.
- Gonzalez, R.C. e R.E. Woods (2003), *Processamento de Imagens Digitais*, Edgard Blücher, São Paulo.
- Haykin, Simon (2001), *Redes Neurais, Princípios e prática*, 2ª edição, Bookman.
- Hovland, H.A., J.A. Johannessen e G. Digranes (1994), Slick detection in sar images, em 'Proceedings of the 1994 International Geoscience and Remote Sensing Symposium, IGARSS 94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation.', Vol. 4, pp. 2038–2040.
- k. Jain, Anil (1989), *Fundamentals of Digital Image Processing*, Prantice-Hall Inc., New Jersey.
- Linde, Y., A. Buzo e R. Gray (1980), 'An algorithm for vector quantizer design', *IEEE Transactions on Communications* **28**(1), 84–95.
- Lopes, A., R. Touzi e E. Nezry (1990), 'Adaptive speckle filters and scene heterogeneity', *IEEE Transactions on Geoscience and Remote Sensing* **28**(6), 992–1000.
- Petrobras (2006), 'Bacia de campos', <http://www2.petrobras.com.br/minisite/duvidas/faq/portugues/baciacampos/perg1.html>. Última visita em 20/06/2006.
- Response, Hazardous Materials e Assessment Division (1992), Oil spill case histories 1967-1991, summaries of significant u.s. and international spills, Relatório Técnico HMRAD 92-11, NOAA.
- Solberg, A.H.S. e E. Volden (1997), Incorporation of prior knowledge in automatic classification of oil spills in ers sar images, em 'Proceedings of the 1997 International Geoscience and Remote Sensing Symposium, IGARSS 97. Remote Sensing - A Scientific Vision for Sustainable Development.', Vol. 1, pp. 157–159.

- Solberg, A.H.S. e R. Solberg (1996), A large-scale evaluation of features for automatic detection of oil spills in ers sar images, *em* 'Proceedings of the 1996 International Geoscience and Remote Sensing Symposium, IGARSS 96. Remote Sensing for a Sustainable Future.', Vol. 3, pp. 1484–1486.
- Solberg, A.H.S., S.T. Dokken e R. Solberg (2003), Automatic detection of oil spills in envisat, radarsat and ers sar images, *em* 'Proceedings of the 2003 IEEE International Geoscience and Remote Sensing Symposium, IGARSS '03.', Vol. 4, pp. 2747–2749.
- Vesecky, J.F. (1995), Surface film effects on the radar cross section of the ocean surface, *em* 'Proceedings of the 1995 International Geoscience and Remote Sensing Symposium, IGARSS 95. Quantitative Remote Sensing for Science and Applications.', Vol. 2, pp. 1375–1377.

Apêndice A

Decomposição por Valor Singular

A Decomposição por Valor Singular, do inglês *Singular Value Decomposition* (SVD), é uma técnica de expansão de matrizes em várias matrizes componentes, onde muitas das propriedades de interesse da matriz original são obtidas. Essa decomposição é largamente utilizada na álgebra matricial exatamente por esses benefícios [Golub e Loan 1996].

Sendo \mathbf{C}_x real, simétrica ($\mathbf{C}_x = \mathbf{C}_x^T$), não singular ($|\mathbf{C}_x| \neq 0$) e desde que \mathbf{C}_x^{-1} exista, a aplicação da decomposição SVD resolve o problema do cálculo da matriz de transformação de Hotelling de forma direta.

Aplicando-se a decomposição em \mathbf{C}_x

$$\mathbf{SVD}^T = \mathbf{C}_x \tag{A.1}$$

obtemos as matrizes \mathbf{S} , \mathbf{V} e \mathbf{D} , em que

\mathbf{S} é uma $(n \times n)$ matriz ortogonal ($\mathbf{S}^T \mathbf{S} = \mathbf{I}$, onde \mathbf{I} é a matriz identidade) composta pelos autovetores de \mathbf{C}_x .

\mathbf{V} é uma $(n \times n)$ matriz diagonal composta pelos autovalores de \mathbf{C}_x .

\mathbf{D} é uma $(n \times n)$ matriz ortogonal ($\mathbf{D}^T \mathbf{D} = \mathbf{I}$, onde \mathbf{I} é a matriz identidade) composta pelos autovetores de \mathbf{C}_x .

Além disso a matriz dos vetores singulares a direita e esquerda (\mathbf{S}, \mathbf{D}) são as mesmas, devido a simetria de \mathbf{C}_x . Por conveniência, temos em \mathbf{V} os autovalores arranjados em ordem decrescente, de modo que $\lambda_j > \lambda_{j+1}$, para $j = 1, 2, \dots, n-1$. Consequentemente os respectivos autovetores em \mathbf{S} também estão ordenados [Golub e Loan 1996].

A aplicação de \mathbf{D} como matriz de transformação na equação (3.29) é direta, dado que os autovetores estão arranjados em vetores linha. A escolha de \mathbf{S} exige a transposição.

Apêndice B

Algoritmo da Retropropagação em uma MLP

Defini-se o sinal erro para o neurônio j na camada de saída, na iteração n como,

$$e_j(n) = d_j(n) - y_j(n) \quad (\text{B.1})$$

onde d é a saída desejada e y é a saída obtida.

A partir desse valor, o cálculo instantâneo da energia do erro para o neurônio j é obtido com,

$$E_j(n) = \frac{1}{2} e_j^2(n) \quad (\text{B.2})$$

correspondentemente o valor instantâneo da energia total é obtido, somandose os termos da equação (B.2) de todos os neurônios da camada de saída. Pode-se assim escrever,

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} E_j \quad (\text{B.3})$$

onde o conjunto C inclui todos os neurônios da camada de saída. Considerando que N representa o número total de padrões do conjunto de treinamento, a energia média do erro médio em (B.3) é definida como,

$$\mathcal{E}_{med}(n) = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (\text{B.4})$$

Sendo o neurônio j alimentado por um conjunto de sinais funcionais produzidos pela camada anterior, o campo local induzido $v_j(n)$ produzido na entrada da função de ativação é,

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (\text{B.5})$$

onde m é o número total de entradas. Assim o sinal de saída $y_j(n)$ para o respectivo neurônio na iteração n é

$$y_j(n) = \phi_j(v_j(n)) \quad (\text{B.6})$$

onde $\varphi(\cdot)$ é a função de ativação do neurônio.

O algoritmo da retropropagação aplica uma correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$ que é proporcional a derivada parcial $\partial \mathcal{E}(n) / \partial w_{ji}(n)$.

A correção $\Delta_{ji}(n)$ aplicada a $w_{ji}(n)$ é definida pela regra delta,

$$\Delta_{ji}(n) = \eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} \quad (\text{B.7})$$

onde η é o fator de aprendizagem do algoritmo.

Resolvendo a derivada parcial obtém-se

$$\Delta_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (\text{B.8})$$

onde δ é o gradiente local definido por,

$$\delta_j(n) = e_j(n) \varphi'_j(v_j(n)) \quad (\text{B.9})$$

No caso do neurônio j estar localizado na camada de saída da rede, e tendo-se determinado $e_j(n)$, calcula-se diretamente o gradiente local $\delta_j(n)$, usando a equação (B.9).

Para o caso do neurônio j estar localizado em uma camada oculta, não podemos computar o erro $e_j(n)$ diretamente, correspondentemente, o sinal erro deve ser calculado recursivamente, em termos dos sinais de erro de todos os neurônios aos quais o neurônio oculto está diretamente conectado. Dessa forma podemos redefinir o gradiente local $\delta_j(n)$ para o neurônio j como

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (\text{B.10})$$

onde o apóstrofe em $\varphi'_j(\cdot)$ representa a diferenciação em relação ao argumento.

O ajuste dos pesos sinápticos da rede para a camada de saída é realizado de acordo com

$$w_{ji}(n+1) = w_{ji}(n) + \rho [w_{ji}(n-1)] + \eta \delta(n) y(n) \quad (\text{B.11})$$

e para a camada oculta de acordo com

$$w_{ji}(n+1) = w_{ji}(n) + \rho [w_{ji}(n-1)] + \eta \delta(n) y(n) \quad (\text{B.12})$$

A redução da oscilação no treinamento, permitindo um aprendizado estável, geralmente é conseguida com o uso do termo do momento ρ que insere a propriedade de inércia na rede. Ou seja leva em consideração no cálculo do peso o valor não só atual como na época anterior.

Apêndice C

Calculo dos parâmetros de uma Rede de Funções de Base Radial

A correspondência de um-para-um entre os dados de entrada de treinamento \mathbf{x}_j e a função de Green $G(\mathbf{x}, \mathbf{x}_j)$ para $j = 1, 2, \dots, N$ produz uma rede de regularização que pode ser algumas vezes considerada proibitivamente custosa para ser implementada em termos computacionais, para N grande. Especificamente, o cálculo dos pesos lineares da rede requer inversão de uma matriz N -por- N , que por sua vez cresce polinomialmente com N (aproximadamente N^3). Além disso, a probabilidade de mau condicionamento é maior para matrizes maiores.

O principal problema com o método de centros fixos aleatórios é o fato de que ele requer um grande conjunto de treinamento, para se obter um resultado satisfatório, caindo no problema anterior. Um modo de superar esta limitação é usar um processo de aprendizagem híbrido, consistindo de dois diferentes estágios:

- Estágio de aprendizagem auto-organizada, cujo propósito é estimar localizações adequadas para os centros das funções de base radial na camada oculta.
- Estágio de aprendizagem supervisionada, que completa o projeto da rede estimando os pesos lineares da camada de saída.

Tipicamente, o número de funções de base é menor que o número de pontos de dados ($m_1 \leq N$), e os w_i constituem um novo conjunto de pesos. Tendo em mente as funções de base radial, fazemos

$$\varphi_i(\mathbf{x}) = G(\|\mathbf{x} - \mathbf{t}_i\|), \quad i = 1, 2, \dots, m_1 \quad (\text{C.1})$$

onde o conjunto de centros $\{\mathbf{t}_i | i = 1, 2, \dots, m_1\}$ deve ser determinado. Esta escolha particular de funções de base é a única que garante que no caso de $m_1 = N$, e

$$\mathbf{t}_i = \mathbf{x}_i, \quad i = 1, 2, \dots, N \quad (\text{C.2})$$

a solução correta é recuperada de forma consistente.

Tendo identificado os centros individuais das funções de base radial e sua largura comum o próximo estágio do processo de aprendizagem híbrida é estimar os pesos lineares

da camada de saída da rede. Uma função de base radial centrada em \mathbf{t}_i é definida como

$$G(\|\mathbf{x} - \mathbf{t}_i\|), \quad i = 1, 2, \dots, m_1 \quad (\text{C.3})$$

Um procedimento direto para fazer a estimação dos pesos é usar o método da pseudo-inversa. Especificamente tem-se

$$\mathbf{w} = \mathbf{G}^+ \mathbf{d} \quad (\text{C.4})$$

onde \mathbf{d} é o vetor resposta desejada do conjunto de treinamento. A matriz \mathbf{G}^+ é a pseudo-inversa da matriz \mathbf{G} , que é definida como

$$\mathbf{G} = \begin{bmatrix} G(\mathbf{x}_1, \mathbf{t}_1) & G(\mathbf{x}_1, \mathbf{t}_2) & \cdots & G(\mathbf{x}_1, \mathbf{t}_{m_1}) \\ G(\mathbf{x}_2, \mathbf{t}_1) & G(\mathbf{x}_2, \mathbf{t}_2) & \cdots & G(\mathbf{x}_2, \mathbf{t}_{m_1}) \\ \vdots & \vdots & \ddots & \vdots \\ G(\mathbf{x}_N, \mathbf{t}_1) & G(\mathbf{x}_N, \mathbf{t}_2) & \cdots & G(\mathbf{x}_N, \mathbf{t}_{m_1}) \end{bmatrix} \quad (\text{C.5})$$

O vetor resposta desejada \mathbf{d} é N -dimensional

$$\mathbf{d} = [d_1, d_2, \dots, d_N]^T \quad (\text{C.6})$$

e o vetor de pesos lineares \mathbf{w} é m_1 -dimensional

$$\mathbf{w} = [w_1, w_2, \dots, w_{m_1}]^T \quad (\text{C.7})$$

A Decomposição por Valor Singular mostrada no apêndice A é básica para todos os algoritmos para o cálculo da pseudo-inversa de uma matriz.

Entretanto a matriz \mathbf{G} de funções de Green e o vetor de peso \mathbf{w} têm dimensões diferentes; a matriz \mathbf{G} é N -por- m_1 , não simétrica, e o vetor \mathbf{w} é m_1 -por-1.

O processo de aprendizagem auto-organizada é usado um algoritmo de agrupamento que particione o conjunto fornecido de pontos de dados em subgrupos, cada um dos quais sendo tão homogêneo quanto possível. Uma rede neural artificial com aprendizado não supervisionado pode ser aplicada [Haykin 2001].

O algoritmo de agrupamento atua da seguinte forma:

1. Inicialização. Escolhe-se valores aleatórios para os centros iniciais $\mathbf{t}_k(0)$; a única restrição é que estes valores iniciais sejam diferentes.
2. Amostragem. Retira-se um vetor \mathbf{x} do espaço de entrada e apresenta-se o mesmo à entrada do algoritmo na iteração n .
3. Casamento de similaridade. Considere que $k(\mathbf{x})$ represente o índice do centro com maior similaridade em relação ao vetor de entrada \mathbf{x} . A métrica utilizada no teste de similaridade pode variar, contudo neste trabalho a mínima distância euclidiana

foi utilizada como critério:

$$k(\mathbf{x}) = \min \|\mathbf{x}(n) - \mathbf{t}_k(n)\|, \quad k = 1, 2, \dots, m_1 \quad (\text{C.8})$$

onde $\mathbf{t}_k(n)$ é o centro da k -ésima função de base radial na iteração n .

4. Atualização. Ajusta-se os centros das funções de base radial, usando a regra de atualização:

$$\mathbf{t}_k(n+1) = \begin{cases} \mathbf{t}_k(n) + \eta [\mathbf{x}(n) - \mathbf{t}_k(n)], & k = k(\mathbf{x}) \\ \mathbf{t}_k(n) & \text{caso contrário} \end{cases} \quad (\text{C.9})$$

onde η é um parâmetro da taxa de aprendizagem no intervalo $0 < \eta < 1$.

5. Continuação. Incrementa-se n retornando para o passo 2 do algoritmo, caso o critério de parada não seja atendido (a não modificação dos centros \mathbf{t}_k).

O algoritmo descrito é um caso especial do algoritmo de aprendizagem competitiva, “o vencedor leva tudo”, conhecido como mapa auto-organizável.

Apêndice D

Calculo dos parâmetros livres de uma Máquina de Vetor de Suporte

Considerando que \mathbf{x} represente um vetor retirado do espaço de entrada, que é assumido como tendo dimensão m_0 . Considere que $\{\varphi_j(\mathbf{x})\}_{j=1}^{m_1}$ represente um conjunto de transformações não-lineares do espaço de entrada para o espaço de características: m_1 é a dimensão do espaço de características. Assume-se que $\varphi_j(\mathbf{x})$ é definido *a priori* para todo j . Dado este conjunto de transformações não-lineares, podemos definir um hiperplano atuando como a superfície de decisão como segue:

$$\sum_{j=1}^{m_1} w_j \varphi_j(\mathbf{x}) + b = 0 \quad (\text{D.1})$$

onde $\{w_j\}_{j=1}^{m_1}$ representa um conjunto de pesos lineares conectando o espaço de características com o espaço de saída, e b é o *bias*. Podemos simplificar o desenvolvimento escrevendo

$$\sum_{j=0}^{m_1} w_j \varphi_j(\mathbf{x}) = 0 \quad (\text{D.2})$$

onde foi assumido que $\varphi_0(\mathbf{x}) = 1$ para todo \mathbf{x} , de modo que w_0 represente o *bias* b . A equação (D.2) define a superfície de decisão calculada no espaço de características em termos dos pesos lineares da máquina. A quantidade $\varphi_j(\mathbf{x})$ representa a entrada fornecida ao peso w_j através do espaço de características. Um vetor é definido

$$\boldsymbol{\varphi}(\mathbf{x}) = [\varphi_0(\mathbf{x}), \varphi_1(\mathbf{x}), \dots, \varphi_{m_1}(\mathbf{x})]^T \quad (\text{D.3})$$

onde, por definição, temos

$$\varphi_0(\mathbf{x}) = 1 \text{ para todo } \mathbf{x} \quad (\text{D.4})$$

Na verdade, o vetor $\boldsymbol{\varphi}(\mathbf{x})$ representa a “imagem” induzida no espaço de características pelo vetor de entrada \mathbf{x} . Assim, em termos desta imagem, podemos definir a superfície de decisão na forma compacta:

$$\mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) = 0 \quad (\text{D.5})$$

Adaptando a equação (D.6) de otimização da função lagrangiana utilizada na solução do problema de otimização restrito na busca dos parâmetros ótimos (vetor peso \mathbf{w} e *bias* b)

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \mathbf{x}_i \quad (\text{D.6})$$

à situação envolvendo um espaço de características onde procuramos agora a separabilidade “linear” de características, podemos escrever

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \phi(\mathbf{x}_i) \quad (\text{D.7})$$

onde o vetor de características $\phi(\mathbf{x}_i)$ corresponde ao padrão de entrada \mathbf{x}_i para o i -ésimo exemplo. Dessa forma, substituindo a equação (D.2) em (D.5), podemos definir a superfície de decisão calculada no espaço de características como:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \phi^T(\mathbf{x}_i) \phi(\mathbf{x}) = 0 \quad (\text{D.8})$$

O termo $\phi^T(\mathbf{x}_i) \phi(\mathbf{x})$ representa o produto interno de dois vetores induzidos no espaço de características pelo vetor de entrada \mathbf{x} e o padrão de entrada \mathbf{x}_i relativo ao i -ésimo exemplo. Podemos então introduzir o núcleo do produto interno representado por $K(\mathbf{x}, \mathbf{x}_i)$ e definido por

$$\begin{aligned} K(\mathbf{x}, \mathbf{x}_i) &= \phi^T(\mathbf{x}) \phi(\mathbf{x}_i) \\ &= \sum_{j=0}^{m_1} \phi_j(\mathbf{x}) \phi_j(\mathbf{x}_i) \quad \text{para } i = 1, 2, \dots, N \end{aligned} \quad (\text{D.9})$$

Pode-se concluir que o núcleo do produto interno é uma função simétrica de seus argumentos

$$K(\mathbf{x}, \mathbf{x}_i) = K(\mathbf{x}_i, \mathbf{x}) \quad (\text{D.10})$$

O mais importante é que podemos utilizar o núcleo do produto interno $K(\mathbf{x}, \mathbf{x}_i)$ para construir o hiperplano ótimo no espaço de características sem ter que considerar o próprio espaço de características de forma explícita. Isto pode ser visto usando a equação (D.9) em (D.2), de onde resulta que o hiperplano é agora definido por

$$\sum_{i=1}^N \alpha_i d_i K(\mathbf{x}, \mathbf{x}_i) = 0 \quad (\text{D.11})$$

A expansão do núcleo do produto interno $K(\mathbf{x}, \mathbf{x}_i)$ na equação (D.9) nos permite construir uma superfície de decisão que é não-linear no espaço de entrada, mas cuja imagem no espaço de características é linear. Com base nesta expansão, podemos agora formular a forma dual para a otimização restrita de uma Máquina de Vetor de Suporte como segue

- Dada a amostra de treinamento $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$, encontrar os multiplicadores de La-

grange $\{\alpha_i\}_{i=1}^N$ que minimizem a função objetivo

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (\text{D.12})$$

sujeitos às restrições:

1. $\sum_{i=1}^N \alpha_i d_i = 0$
2. $0 \leq \alpha_i \leq C$ para $i = 1, 2, \dots, N$

onde C é um parâmetro positivo especificado pelo usuário.

A restrição 1 surge da otimização do lagrangiano $Q(\alpha)$ em relação ao *bias* $b = w_0$ para $\varphi_0(\mathbf{x}) = 1$. O problema dual formulado tem a mesma forma como no caso de padrões não-separáveis. Podemos ver $K(\mathbf{x}_i, \mathbf{x}_j)$ como o elemento ij de uma matriz simétrica N -por- N

$$\mathbf{K} = \{K(\mathbf{x}_i, \mathbf{x}_j)\}_{(i,j)=1}^N \quad (\text{D.13})$$

A otimização de $Q(\alpha)$ em relação a cada um dos multiplicadores de Lagrange produz um sistema de equações lineares

$$\frac{\partial Q(\alpha)}{\partial \alpha_i} = 0 \quad \text{para } i = 1, 2, \dots, N \quad (\text{D.14})$$

A resolução do sistema retorna os valores ótimos dos multiplicadores de Lagrange, representados por $\alpha_{o,i}$. A partir desses valores podemos determinar o valor ótimo correspondente ao vetor linear de pesos \mathbf{w}_o , que conecta o espaço de características ao espaço de saída adaptando a equação (D.2) à nova situação. Especificamente, reconhecendo que a imagem $\varphi(\mathbf{x}_i)$ desempenha o papel de entrada para o vetor peso \mathbf{w} , podemos definir \mathbf{w}_o como

$$\mathbf{w}_o = \sum_{i=1}^N \alpha_{o,i} d_i \varphi(\mathbf{x}_i) \quad (\text{D.15})$$

onde $\varphi(\mathbf{x}_i)$ é a imagem induzida no espaço de características devido a \mathbf{x}_i . A primeira componente de \mathbf{w}_o representa o *bias* ótimo b_o .

A saída y da Máquina de vetor de suporte é então

$$y = \mathbf{w}^T \varphi(\mathbf{x}) \quad (\text{D.16})$$