

IDENTIFICAÇÃO DE MANCHAS DE ÓLEO NA SUPERFÍCIE MARINHA ATRAVÉS DE IMAGENS DE SAR: CLASSIFICADOR RBF

DANILO L. DE SOUZA*, ADRIÃO D. D. NETO†, WILSON DA MATA‡

**Laboratório de Processamento de Sinais, COPPE/POLI
Universidade Federal do Rio de Janeiro CP 68504, CEP 21941-972
Rio de Janeiro, RJ, Brasil*

†*Departamento de Engenharia da Computação e Automação
Universidade Federal do Rio Grande do Norte CEP 59072-970
Natal, RN, Brasil*

‡*Departamento de Engenharia Elétrica
Universidade Federal do Rio Grande do Norte CEP 59072-970
Natal, RN, Brasil*

Emails: danilo@lps.ufrj.br, adriao@dca.ufrn.br, wilson@ct.ufrn.br

Abstract— Oil spill on the sea, accidental or not, generates enormous negative consequences for the affected area. 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. The classifier algorithm (Radial Basis Function Network) is presented and commented. The final performance of the system is presented by ROC curve, and SP product. The true positive rates are considered agreed with the literature about oil slick detection through SAR images presents.

Keywords— Oil spill, Oil slick, Neural Classifier, Intelligent Systems, SAR.

Resumo— Derramamentos de óleo sobre o mar, mesmo que acidentais, geram enormes conseqüências negativas para a área afetada. 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. O algoritmo que trata da classificação (Rede de função de Base Radial) é apresentado e comentado. O desempenho final do sistema medido através da curva ROC e do produto SP. 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, Classificador Neural, Sistemas Inteligentes, SAR.

1 Introdução

Manchas de óleo sobre a superfície marinha causam danos ao ecossistema marinho, especialmente quando ocorrem próximas da costa. Com passagem regular sobre mares e oceanos, os satélites de sensoriamento remoto fornecem dados que podem ser usados na extração de informação estatística dessas manchas em regiões específicas da Terra. As técnicas atuais de identificação e detecção de manchas de óleo usam imagens de SAR (*Synthetic Aperture Radar*) numa busca pela automatização.

A presença da camada de óleo na superfície marinha diminui as pequenas ondas devido ao aumento da viscosidade da camada superior marinha reduzindo drasticamente a energia medida que retorna ao Radar, resultando na formação de áreas escuras nas imagens de SAR. Contudo, uma interpretação cuidadosa é requerida pois manchas escuras em imagens de SAR podem ser causadas, também, por ventos locais fracos, óleo do leito

oceânico, plâncton, entre outros, todos denominados assemelhados (Frate et al., 2000).

A busca por algoritmos mais eficientes na segmentação de manchas e extração de suas características assim como no estágio de classificação é constante. O uso de técnicas ditas “inteligentes”, como redes neurais artificiais, torna possível o processamento de um grande número de dados com o mínimo de intervenção humana, reultando em mais agilidade na análise das imagens.

Algumas abordagens para análise de manchas de óleo são conhecidas (Frate et al., 2000; Solberg et al., 1999), contudo uma sistema automático de imagens de SAR não é rotineiramente aplicado, ainda. As pesquisas recentes se concentram sobre o algoritmo de classificação, mas um bloco consistente de processamento de imagem e extração de características é indispensável (Souza, 2006; Souza et al., 2006a; Souza et al., 2006b).

O estágio de classificação, estudado aqui, trabalha com um conjunto de características que são

extraídas das manchas analisadas. Essas características podem ser referentes a geometria do objeto em termos de extensão e forma, bem como intensidade do sinal captado através de relações entre os *pixels* da mancha analisada e da região ao seu redor. Para solucionar o clássico problema de classificação binária (óleo ou assemelhado) são usadas algumas dessas características como variáveis de entrada.

O foco do trabalho é apresentar um estudo do classificador neural RBF (*Radial Basis Function*) usando a arquitetura proposta por Souza (2006, 2006a, 2006b). A seção 2 apresenta o processo de detecção de mancha de óleo, as características de interesse obtidas pelo extrator de características. A base de dados utilizada é descrita na seção 3. Na seção 4 o classificador é apresentado. A seção 5 mostra o desempenho do classificador e por fim a seção 6 resume as conclusões e indica trabalhos futuros.

2 Extração de Características

O processo de detecção de manchas de óleo proposto por Souza (2006, 2006a, 2006b) é mostrado na figura 1, onde as flechas indicam o fluxo da informação. Um operador humano, que seleciona uma área de interesse a ser submetida ao sistema realiza o primeiro passo do processo. Os estágios seguintes, extração de características e classificação, são realizados automaticamente, resultando numa probabilidade estimada da mancha analisada ser uma mancha de óleo.

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 do candidato ser uma mancha de óleo, formando assim um classificador probabilístico.

Alguns dos descritores que podem ser extraídos de imagens de SAR na caracterização de manchas de óleo na superfície marinha são detalhados por Solberg and Solberg (1996, 1997) e Frate et al. (2000, 1999). Os descritores nesse trabalho são de três diferentes tipos. Alguns deles contêm informação referente a intensidade do gradiente do sinal captado pelo Radar ao longo da borda da mancha analisada: Gradiente Máximo (*Gmax*), Gradiente Médio (*GMe*), Desvio Padrão do Gradiente (*GSd*), todos em dB; outros focam na energia captada pelo Radar sobre a mancha e/ou na região ao seu redor: Desvio Padrão do Objeto (*OSd*), Desvio Padrão do Fundo (*BSd*), Contraste Máximo (*ConMax*), Contraste Médio (*ConMe*), também em dB; uma terceira categoria que leva em consideração a geometria e a forma da mancha: Área (*A*) em km^2 , Perímetro (*P*) em km, Comparcidade (*C*), Espalha-

mento (*S*) (Frate et al., 2000; Frate and Salvatori, 2004; Souza, 2006; Souza et al., 2006a; Souza et al., 2006b).

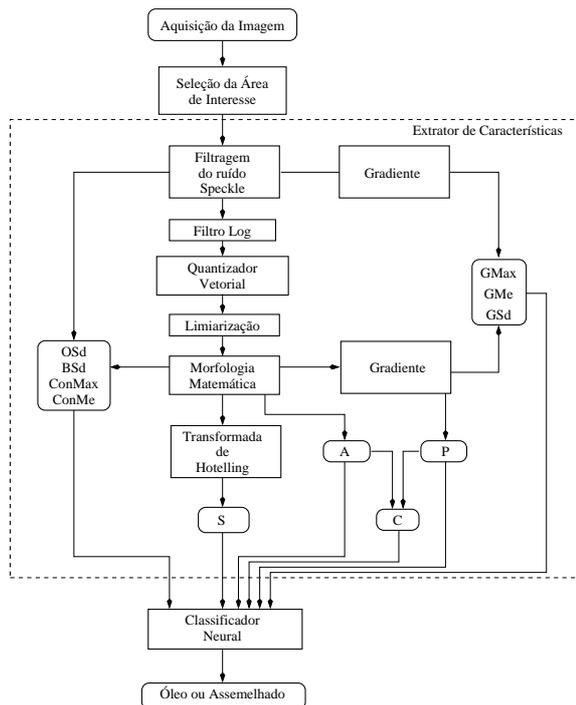


Figura 1: Sistema de detecção de mancha de óleo. Detalhe sobre o bloco extrator de características.

3 Base de Dados

Devido ao alto custo de imagens de sensoriamento remoto obtidas por satélites que utilizam o Radar como equipamento de geração de imagem, a formação de um banco de dados é um dos principais problemas encontrados na construção e validação de classificadores empregados na tarefa de identificação de manchas de óleo na superfície marinha. Além do custo elevado, imagens caracterizando um vazamento ou derramamento de óleo também são de difícil obtenção, complicando ainda mais a composição de um número suficiente de dados. Esses dois problemas foram determinantes para formação da base de dados utilizada no trabalho.

Os fragmentos utilizados para a composição da base de dados são parte de imagens de três satélites distintos, ambos utilizando o Radar como equipamento de produção de imagens. A primeira imagem, 2(a), foi obtida pelo satélite Radarsat-1 às 08:10:33 UTM no dia 21 de maio de 1999 (órbita 0018490). A cena é da bacia potiguar na região próxima da cidade de Guamaré, RN. Nela é possível observar diversas manchas de diferentes origens.

Na segunda imagem, 2(b), obtida pelo satélite Envisat no dia 01 de junho de 2004, também da bacia potiguar próxima da cidade de Guamaré, RN, é possível visualizar manchas próximas da

costa. A terceira imagem, 2(c), obtida às 11:03:41 GM no dia 04 de fevereiro de 2002 (órbita 35519, quadro 2885) foi captada pelo satélite ERS-2. A área observada cobre o Estreito de Gibraltar.

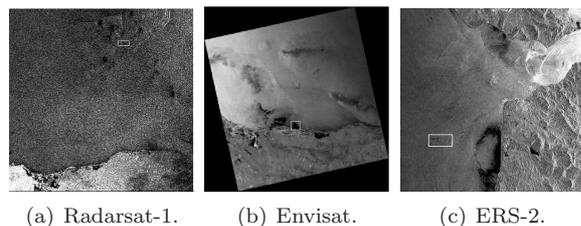


Figura 2: Imagens de SAR.

O retângulo branco, em cada uma das cenas, marca uma região de interesse a ser analisada. Cada uma delas com diferentes níveis de dificuldade. Uma descrição detalhada da metodologia utilizada na segmentação e extração de características dos fragmentos analisados é apresentada por Souza (2006, 2006a, 2006b). As figuras 3, 4 e 5 apresentam três diferentes tipos de manchas analisadas e os resultados da segmentação, respectivamente.

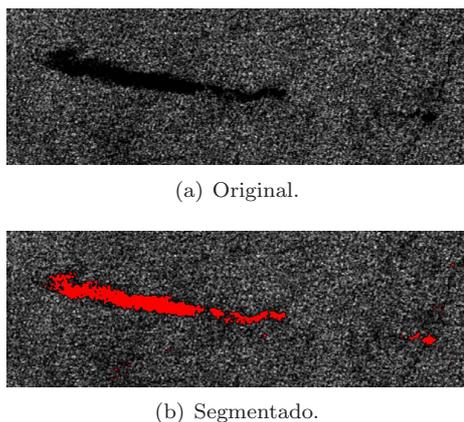


Figura 3: Segmentação de fragmento Radarsat-1.

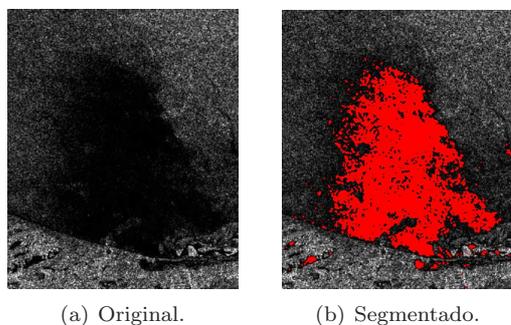


Figura 4: Segmentação de fragmento Envisat.

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

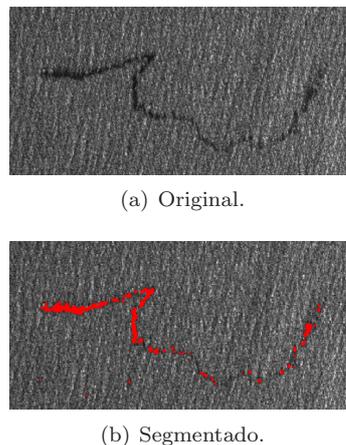


Figura 5: Segmentação de fragmento ERS-2.

tuladas por um especialista. Diante desses números alguns problemas relacionados ao aprendizado do algoritmo de classificação 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 balanceamento pode ser realizado através de uma amostragem dos dados da classe maior e/ou duplicando os exemplos de treinamento ou criando novos exemplos da classe menor. Solberg and Solberg (1996) implementam as duas técnicas com sucesso. Fazendo uso da segunda abordagem, 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 desvio padrão amostrais dos descritores extraídos do conjunto de manchas analisadas. A tabela 1 mostra o resultado. Foi assumido uma distribuição normal para cada uma das variáveis aleatórias (descritores) na geração artificial dos dados.

Tabela 1: Medidas estatísticas das classes Óleo e Assemelhado.

Descr.	Óleo		Assemelhado	
	μ	σ	μ	σ
<i>A</i>	2,614	2,415	32,231	11,333
<i>P</i>	77,363	42,916	702,69	247,17
<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

Considerando a natureza multiplicativa do

ruido característico (*speckle*) na formação de cada um dos elementos de imagem (*pixels*) que compõem a cena, assim como o cálculo realizado na obtenção de cada um dos descritores, a geração dos dados artificiais se fundamentou no teorema do limite central. Sendo S_n a soma de n variáveis aleatórias com média m_n e variância σ_n^2 finitas, a função densidade de S_n , dada por $f_{S_n}(\cdot)$, converge para uma distribuição normal (gaussiana) com o aumento de n . O teorema do limite central é a razão principal que justifica o modelamento de muitos fenômenos aleatórios como variáveis aleatórias gaussianas (Haykin, 2001).

4 Classificador RBF

A Rede de Função de Base Radial utiliza neurônios da camada intermediária com funções de ativação ditas de base radial. A rede RBF é um exemplo de rede em camadas, alimentadas adiante e, não-lineares, por conseguinte é um aproximador universal de funções.

A rede RBF, utilizando não-linearidades com decaimento exponencial, constrói aproximações locais para mapeamentos de entrada-saída não-lineares. A camada intermediária, cujos neurônios utilizam funções de base radial, agrupa os dados de entrada. Cada neurônio define uma hipersuperfície 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. Já a camada de saída procura classificar os padrões recebidos da camada anterior, ela pode ser formada por um perceptron, uma vez que seus padrões de entrada são linearmente separáveis (Haykin, 2001).

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 e seleção supervisionada de centros. Neste trabalho optou-se pelo uso da seleção auto-organizada dos centros das funções de base radial.

4.1 Desempenho e Análise de Relevância

O desempenho do classificador implementado é medido através do Produto SP. O produto SP é uma medida adimensional obtida através do produto da soma das eficiências pelo produto destas, ou seja:

$$SP = (Ef_o + Ef_a) \cdot (Ef_o \cdot Ef_a) \quad (1)$$

onde Ef_o é a eficiência de detecção da classe óleo e Ef_a é a eficiência de detecção da classe assemelhado. O valor máximo do Produto SP para uma classificação binária é 2.

Essa medida qualifica o classificador estudado, contudo é interessante, por vezes, qualificar-se as variáveis que descrevem ou caracterizam o fenômeno. Neste trabalho isso é feito através de uma análise de relevância.

A análise de relevância, como o próprio nome sugere, busca mensurar a importância da variável de entrada do sistema na tomada de decisão final. A análise é feita da seguinte forma: para o conjunto de teste, no lugar de cada uma das variáveis de entrada estudadas, que podem assumir diferentes valores possíveis, o seu respectivo valor médio é inserido no classificador, uma por vez. A equação 2 mostra o cálculo realizado

$$R_i = \frac{1}{n} \sum_{j=1}^n (S(\mathbf{x}_j) - S(\mathbf{x}_j | x_{ji} = \bar{x}_i))^2 \quad (2)$$

onde $S(\cdot)$ é saída do classificador. Quanto maior o valor obtido para R_i mais relevante é a variável para a tarefa de classificação (Seixas et al., 1996).

5 Implementação Computacional

Os testes do classificador foram divididos em três etapas. A primeira consiste no uso dos dados reais (obtidos pelo sistema) para o treinamento do classificador e sua validação medida com os dados artificialmente gerados. A segunda etapa, utiliza dados artificiais no treinamento e dados reais na validação. Essas situações permitem medir a capacidade de generalização dos algoritmos, seja através de extrapolações ou interpolações, como a sensibilidade a *outliers*, muitas vezes refletindo processos físicos reais.

A terceira etapa dos testes compreende a realização tanto do treinamento quanto da validação com dados reais. Para isso, a validação cruzada foi empregada. O intuito é analisar o classificador unicamente em relação aos dados extraídos pelo sistema.

5.1 Validação Utilizando Dados Artificiais

O classificador RBF foi implementado e testado com função de base radial gaussiana. A configuração escolhida foi: 11 – 12 – 1.

O melhor resultado obtido na classificação dos exemplos de validação apresentou taxas de 99,4% de acerto para a classe óleo e 98% de acerto para a classe assemelhado, totalizando 98,7% dos exemplos corretamente classificados. Essas taxas foram obtidas com um valor de limiar igual a $-0,39$ na saída do classificador. Este valor mostra que os exemplos da classe assemelhado apresentam uma saída que está em grande parte comprimida no intervalo $[-1; -0,39]$. Por outro lado mostra, também, que os exemplos da classe óleo podem assumir valores de saída numa faixa mais larga, resultado esse explicado pela fraca estatística extraída

dos poucos exemplos usados no treinamento do classificador, contudo ainda assim satisfatório. O valor máximo do Produto SP foi 1,94.

As figuras 6, 7 apresentam o histograma da saída do classificador RBF, a curva do produto SP, respectivamente, para o treinamento com dados reais e a validação com dados artificiais.

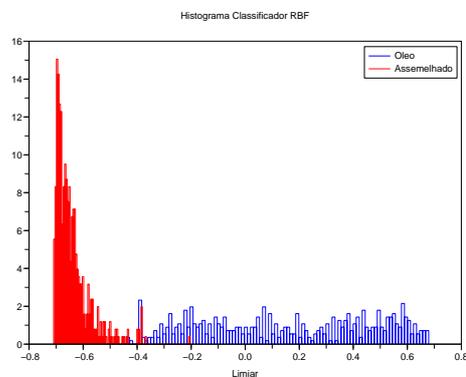


Figura 6: Histograma da saída do classificador.

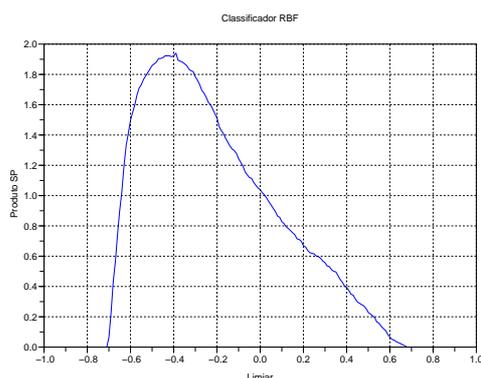


Figura 7: Curva Produto SP.

A criação das redes de Função de Base Radial envolveu uma pequena elevação de dimensionalidade na camada intermediária que, acrescida da não-linearidade e baseada no teorema de Cover (Haykin, 2001), foi suficiente para que a RBF apresentasse um bom desempenho. Contudo, os valores extremos desejados (-1 e 1) para cada uma das classes não foram alcançados, como mostra a figura 6.

5.2 Validação Utilizando Dados do Reais

O segundo passo no treinamento e validação da máquina de aprendizado foi realizado com dados artificiais no treinamento e dados extraídos do sistema na validação. O classificador RBF foi implementado com a seguinte configuração: $11 - 20 - 1$.

Com um número maior de dados para o treinamento da RBF, a elevação de dimensionalidade

da camada intermediária, 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. Além disso, os resultados mostram quão dispersos os dados originais estão no espaço de alta dimensão e a influência que eles exercem na geração dos dados artificiais.

O resultado é a classificação correta de todos os exemplos de validação numa faixa de limiar entre $[0,32; 0,36]$. 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 máquina foram determinantes na boa generalização obtida.

5.3 Validação Cruzada

A validação cruzada é empregada principalmente quando há uma escassez de exemplos rotulados no conjunto de dados e/ou 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 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. O classificador RBF foi implementado com a seguinte configuração: $11 - 11 - 1$.

O resultado mostra um desempenho acima de 66% na classificação da classe óleo, 2 dos 3 exemplos, além da classificação correta de todos os 9 exemplos da classe assemblado, resultando num desempenho total próximo de 91%. 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, enquanto que a classe assemblado possui uma variabilidade grande para alguns dos descritores porém generalizada pelos vetores remanescentes.

5.4 Análise de Relevância

A análise realizada sobre cada um dos 11 descritores foi implementada com os dados originais no treinamento e com os dados artificiais na validação. O valor de desvio padrão de cada um dos descritores mostrados na tabela 1 fornece um indicativo da variabilidade de cada um deles em relação as classes, mas é através da análise de relevância que se consegue mensurar como cada um

deles são importantes internamente para a tomada de decisão do classificador.

Com esse procedimento e o comparativo em função do percentual de relevância, $100 \cdot R_i/R$ onde $R = \sum R_i$, foi possível entender que internamente ao classificador RBF o descritor *OSd* (38% de relevância) é o mais relevante para a tarefa de classificação, enquanto que o descritor *ConMax* (0,002% de relevância) é o menos relevante. Em parte, os valores alcançados são condizentes com o que a literatura apresenta (Frate et al., 2000). Contudo, uma generalização não é possível devido a grandes diferenças encontradas nas bases dados utilizadas.

6 Conclusões

O trabalho investigou o problema de identificação de manchas de óleo sobre a superfície marinha utilizando imagens de SAR conjuntamente com uma RBF atuando como classificador.

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 and 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 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.

A análise de relevância feita para cada característica mostra, em partes, uma concordância das características extraídas usando o sistema proposto por Souza (2006, 2006a, 2006b) e da classificação realizada aqui, com o que a literatura apresenta para outros tipos de classificadores (Frate et al., 2000; Calabresi et al., 1999; Frate and Salvatori, 2004). Contudo diferenças pontuais são observadas, principalmente em função das diferenças nas bases de dados usadas.

7 Agradecimentos

Agradecemos ao apoio financeiro da CAPES, ao Prof. Venerando Eustáquio (UFRN), assim como aos colegas de colaboração.

Referências

- Calabresi, G., Frate, F. D., Lichtenegger, J., Petrocchi, A. and Trivero, P. (1999). Neural networks for the oil spill detection using ers-sar data, *Proceedings of the IEEE 1999 International Geoscience and Remote Sensing Symposium, IGARSS 99.*, Vol. 1, pp. 215–217.
- Frate, F. D., Petrocchi, A., Lichtenegger, J. and Calabresi, G. (2000). Neural networks for oil spill detection using ers-sar data, *IEEE Transactions on Geoscience and Remote Sensing* **38**(5): 2282–2287.
- Frate, F. D. and Salvatori, L. (2004). Oil spill detection by means of neural networks algorithms: a sensitivity analysis, *Proceedings of the 2004 IEEE International Geoscience and Remote Sensing Symposium, IGARSS 04.*, Vol. 2, pp. 1370–1373.
- Haykin, S. (2001). *Redes Neurais, Princípios e prática*, 2 edn, Bookman.
- Seixas, J., Calôba, L. and Delpino, I. (1996). Relevance criteria for variables selection in classifier design, *International Conference on Engineering Applications of Neural Networks*, Londres, Inglaterra, pp. 451–454.
- Solberg, A. and Solberg, R. (1996). A large-scale evaluation of features for automatic detection of oil spills in ers sar images, *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., Storvik, G., Solberg, R. and Volden, V. (1999). Automatic detection of oil spills in ers sar images, *IEEE Transactions on Geoscience and Remote Sensing* **37**(4): 1916–1924.
- Souza, D. L. (2006). *Sistema inteligente para detecção de manchas de óleo na superfície marinha através de imagens de sar*, Master's thesis, Universidade federal do Rio Grande do Norte, Natal, RN, Brasil.
- Souza, D., Neto, A. and da Mata, W. (2006a). Intelligent system for feature extraction of oil slick in sar images: Speckle filter analysis, *International Conference on Neural Information Processing (ICONIP)*, Hong Kong.
- Souza, D., Neto, A. and da Mata, W. (2006b). Intelligent system for feature extraction of oil slick in sar images: Speckle filter analysis, *Lecture Notes in Computer Science* **4233/2006**: 729–736.