

Identificação automática de eventos ambientais costeiros e oceânicos detectáveis em imagens de radares orbitais

Cristina Maria Bentz¹
Nelson F. F. Ebecken²
Alexandre Tadeu Politano¹

¹ PETROBRAS/CENPES - Centro de Pesquisas
Av. Jequitibá, 950 - Ilha do Fundão - 21949-900 - Rio de Janeiro - RJ, Brasil
{cris, politano.gorceix}@petrobras.com.br

² Universidade federal do Rio de Janeiro – COPPE/UFRJ
Cidade Universitária, Ilha do Fundão – 21949-900 – Rio de Janeiro - RJ, Brasil
nelson@ntt.ufrj.br

Abstract: A classification procedure using machine learning algorithms was developed to identify different types of pollution and meteo-oceanographic events, detected in SAR (Synthetic Aperture Radar) images. The classification is done in two steps: first the features area classified in one of two classes - oil pollution or meteo-oceanographic event. In the second step, the identification of tree classes of oil pollution and four classes or meteo-oceanographic events is done. Spectral, geometric, and contextual features are evaluated. The classification training and test was done using examples extracted from 402 RADARSAT-1 images acquired in Campos Basin, southeastern Brazilian coast. Different configurations of decision trees, neural networks and support vector machines are tested.

Palavras-chave: synthetic aperture radar, oil spill and ocean features detection, classification, machine learning, radares de abertura sintética, detecção de óleo e feições oceânicas, classificação, aprendizagem de máquina.

1. Introdução e objetivos

Com a crescente disponibilidade de satélites comerciais, operando na faixa de microondas, o uso de imagens de radares orbitais tem sido uma alternativa para otimizar o monitoramento de extensas áreas oceânicas e costeiras na região do Mar do Norte (Pedersen et al., 1996), na Região Sul do Golfo do México (Miranda et al., 2002) e na margem continental brasileira (Bentz et al., 2005). Radares instalados em satélites são capazes de cobrir grandes extensões simultaneamente, podendo adquirir imagens durante o dia ou à noite. As imagens geradas fornecem dados com resolução espacial suficiente para a detecção de diferentes tipos de ocorrências ambientais. O processamento e entrega das imagens em tempo próximo do real de alguns sistemas, viabiliza o uso desta tecnologia para orientar as verificações de campo e ações de contingenciamento, quando necessário.

Atualmente, não há dúvidas sobre a capacidade de imagens de radares detectarem diversos eventos, associados ao descarte de poluentes, em áreas costeiras e oceânicas. Contudo, uma série de ambigüidades, inerentes ao processo de formação das imagens pode induzir a interpretações equivocadas. Diversos fenômenos meteo-oceanográficos e eventos associados à presença de substâncias que alterem a tensão superficial produzem feições escuras nas imagens, semelhantes às associadas à presença de óleo (Clemente-Colón e Yan, 2000). Assim, o processo de interpretação das imagens é dependente do grau de experiência dos intérpretes, assim como na disponibilidade de informações complementares.

Com o objetivo de otimizar a análise de imagens diversos autores têm investigado métodos para automatizar a detecção de feições produzidas por vazamentos de óleo, em imagens de radar (Kubat et al., 1998; Espedal e Whal, 1999; Del Frate et al., 2000; Solberg et al., 2003). Como as feições produzidas por óleo apresentam características espectrais que

podem ser semelhantes às de outros eventos, técnicas baseadas no agrupamento de píxeis das imagens – fatiamentos, segmentações – não são eficazes para diferenciá-las. Assim, a maioria dos procedimentos propõe a utilização de diferentes algoritmos, em três etapas principais: individualização de feições, cálculo de atributos e classificação; para a separação das feições em duas classes: óleo e assemelhados.

Apesar dos resultados satisfatórios reportados, os procedimentos ainda estão em desenvolvimento, indisponíveis para uso operacional ou mesmo avaliação. Entre as principais dificuldades, destaca-se a obtenção de exemplos confiáveis para treinamento e a necessidade de ajustes nos parâmetros contextuais, para áreas geográficas específicas.

Neste contexto, este trabalho apresenta os resultados obtidos no estabelecimento de um modelo classificatório para a identificação automática de feições detectáveis nas imagens de radar, em áreas costeiras e oceânicas da margem sudeste brasileira.. Diferentes conjuntos de atributos e métodos de aprendizado de máquina (redes neurais, árvores de decisão e máquinas de suporte vetorial) foram avaliados para a classificação automática das feições das imagens em sete classes, divididas em duas categorias:

Categoria I: Associadas à presença de poluentes: Vazamentos Operacionais, Descarte de Navios e Manchas Órfãs.

Categoria II: Associadas a fenômenos meteo-oceanográficos: Óleos Biológicos e/ou Ressurgências, Florações, Baixas de Vento, Células Convectivas (Chuvas).

O trabalho envolveu as seguintes etapas (**Figura 1**): a) Seleção de exemplos, b) Segmentação das feições selecionadas, c) Cálculo de atributos para a caracterização espacial, espectral e contextual das feições. d) Avaliação de diferentes modelos classificatórios para o estabelecimento dos melhores procedimentos.

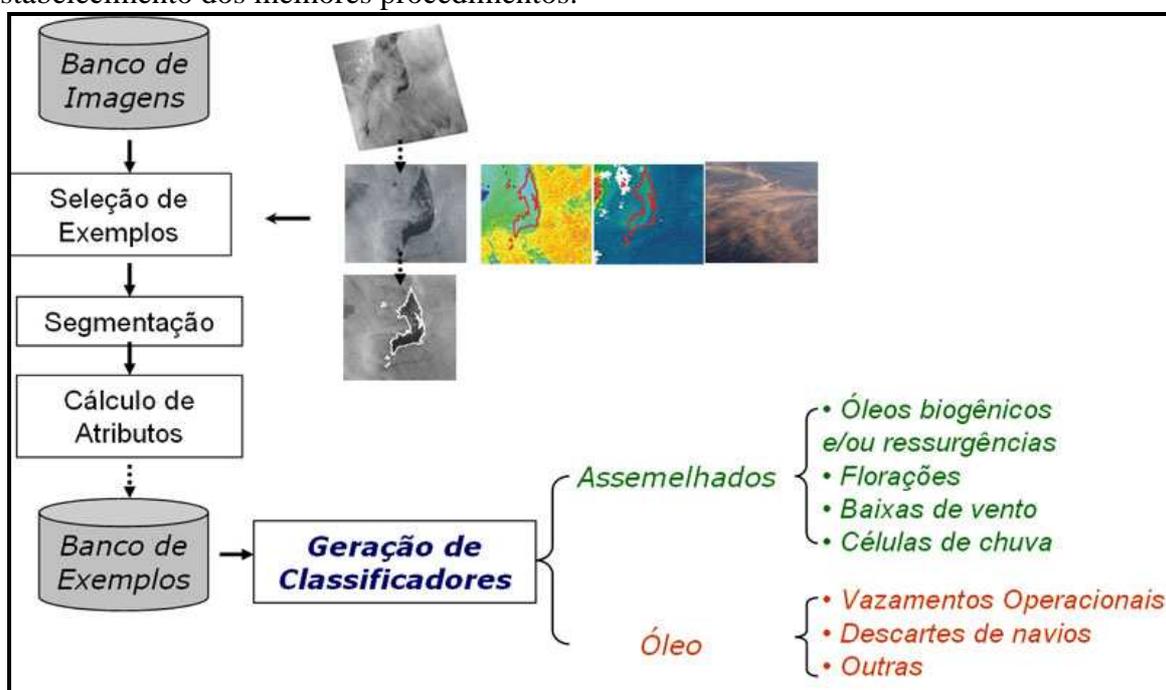


Figura 1 – Etapas de trabalho.

2. Metodologia

A seleção de exemplos representativos dos eventos a serem caracterizados envolveu a análise de 402 imagens RADARSAT-1, adquiridas entre julho de 2001 e junho de 2003, no litoral sudeste brasileiro - em três modos de operação: ScanSAR Narrow A (SNA), ScanSAR Narrow B (SNB) e Extended Low 1 (EXTL1). A identificação dos eventos foi realizada com

a interpretação visual das imagens, conferida por verificações aéreas *in situ*, assim como por dados contextuais meteo-oceanográficos e de localização.

As informações contextuais meteo-oceanográficas utilizadas incluem a Temperatura da Superfície do Mar (TSM) derivada de dados NOAA (*National Oceanic and Atmospheric Administration*) /AVHRR (*Advanced Very High Resolution Radiometer*); a concentração de clorofila-a derivada de dados SeaWiFS (*Sea-viewing Wide Field-of-view Sensor*) e MODIS (*Moderate-resolution Imaging Spectroradiometer*); a direção e a intensidade do campo de ventos, derivados de dados QuikSCAT. As informações contextuais de localização foram representadas por dados referentes às das instalações de exploração e produção (E&P) na área de estudo (dutos submarinos, plataformas móveis e fixas, embarcações sonda).

A individualização dos polígonos foi realizada com procedimento de segmentação com resoluções múltiplas (Batz et al., 2003). Antes da segmentação as imagens de radar foram processadas para otimização espacial e radiométrica.

Para cada feição individualizada no processo de segmentação foram calculados os descritores, normalmente utilizados na análise de regiões em imagens; assim como outros, de utilização inédita, específicos para a caracterização dos eventos meteo-oceanográficos e associados a vazamentos de óleo.

Os seguintes atributos foram calculados:

- 1- Número de manchas: número de feições escuras detectadas na cena.
- 2- Soma área mancha: soma das áreas das feições escuras detectadas na cena.
- 3- A manchas / A oceânica: razão entre o atributo anterior e a área oceânica imageada.
- 4- Heterogeneidade da Mancha: Coeficiente de Variação (CV)= Desvio Padrão/Média do ND na área da feição.
- 5- Heterogeneidade da Vizinhança: CV= Desvio Padrão/Média dos ND das áreas vizinhas às feições.
- 6- Diferença à vizinhança: diferença entre a média dos ND da feição e a média dos ND das vizinhanças.
- 7- Razão à vizinhança: razão entre a média dos ND da feição e a média dos ND das vizinhanças.
- 8- Contraste textural: calculado conforme a matriz de co-ocorrência dos ND não calibrados (GLCM – Grey Level Co-occurrence matrix).
- 9- Entropia textural: calculada conforme GLCM dos ND não calibrados.
- 10- Área
- 11- Perímetro
- 12- Alongamento: $A = \text{Comprimento} / \text{Largura}$
- 13- Assimetria: $K = 1 - (n / m)$, onde n e m são a largura e o comprimento das feições, respectivamente.
- 14- Densidade: $D = \sqrt{n} / (1 + \sqrt{\text{Var}(X) + \text{Var}(Y)})$, onde n é o número de píxeis da imagem, e o raio é estimado a partir da matriz de covariância. Quanto mais parecido com um quadrado, maior será a densidade de uma feição.
- 15- Compactação: $C = 4 \pi \text{Área} / \text{Perímetro}^2$. Mostra quanto uma feição se aproxima da forma de um círculo.
- 16- Índice de Forma: $IF = e / 4 \sqrt{A}$, onde e é o perímetro da feição e A é a sua área. O IF mede o grau de suavização das bordas de uma feição. Quanto mais fractal a feição, maior será o IF.
- 17- Curvatura: soma das variações de direção da linha principal (linha imaginária, equidistante aos lados de maior comprimento de uma feição), expressas em graus.
- 18- Número de partes: número de polígonos associados a um mesmo evento.
- 19- TSM med: média da Temperatura da Superfície do Mar (TSM) na área da feição.

- 20- TSM dif: diferença entre a TSM média da feição e a TSM média das vizinhanças.
- 21- TSM raz: razão entre a média da TSM na área da feição e a média das vizinhanças.
- 22- Clor med: média da concentração de Clorofila-a na área da feição.
- 23- Clor dif: diferença entre a concentração de clorofila-a média da feição e a média nas vizinhanças.
- 24- Clor raz: razão entre a média concentração de clorofila-a na área da feição e a média das vizinhanças.
- 25- Vven med: média da velocidade do vento na área da feição.
- 26- Vven dif: diferença entre a velocidade média do vento na área da mancha e a média nas vizinhanças.
- 27- Vven raz: razão entre a velocidade média do vento na área da feição e a média nas vizinhanças.
- 28- Nuvens: presença de nuvens coincidentes com a feição.
- 29- Plat fix c: distância em metros do centro da feição à unidade petrolífera fixa mais próxima.
- 30- Plat fix: menor distância entre a borda da feição e uma unidade petrolífera fixa.
- 31- Plat mov c: distância do centro da feição à unidade petrolífera móvel mais próxima.
- 32- Plat mov: menor distância entre a borda da feição e uma unidade petrolífera móvel.
- 33- Duto c: distância do centro da feição ao duto submarino mais próximo.
- 34- Duto: menor distância entre a borda da feição e um duto submarino.
- 35- Lcosta c: distância do centro da feição à linha de costa.
- 36- Lcosta: menor distância entre a borda da feição e a linha de costa.
- 37- Bat c: Cota batimétrica do centro da feição.
- 38- Bat: Cota batimétrica média da feição.
- 39- Zona c: zona do centro da feição.
- 40- Zonas: zonas de ocorrência ocupadas simultaneamente pela feição.

Utilizaram-se atributos representativos de características da cena de ocorrência (1 - 3), espectrais (4 - 7), texturais (8 e 9), geométricas (10 a 18), do contexto meteo-oceanográfico (19 - 28) e de localização (29 - 40). Para o cálculo dos atributos espectrais foram utilizados os valores não calibrados, expressos na forma de números digitais (ND). Esta opção levou em consideração a viabilidade de utilização operacional futura do classificador, em tempo próximo do real. O acesso aos dados brutos e a geração dos produtos calibrados (em decibéis - dB) aumentariam significativamente o tempo computacional necessário para o pré-processamento dos dados.

Os atributos espectrais, texturais e geométrico foram calculados automaticamente, no mesmo ambiente onde foi realizada a segmentação. O cálculo dos demais, foi realizado com procedimentos de análise geográfica, modelados em ambiente de SIG.

Foi possível a individualização e cálculo da totalidade dos atributos para 779 feições, assim distribuídas: Categoria I (358): Atividades de E&P (214), Descarte de Navios (76) e Manchas Órfãs (68). Categoria II (421): Óleos Biológicos e/ou Ressurgência (264), Florações (61), Baixa de Vento (51), Células Convectivas (79).

3. Modelos classificatórios

A classificação consiste da inferência de um modelo para a descrição de classes, a partir de um conjunto de objetos já classificados. Como há vários objetos de uma dada classe na amostra, com diferentes valores em seus atributos, supõe-se que exista uma função implícita nestes dados. O objetivo da tarefa de classificação é obter uma aproximação desta função para que então, dado um outro objeto qualquer não-classificado, seja possível deduzir a sua classe.

Para a tarefa de construção de classificadores, é necessário escolher uma estratégia de aprendizado, um conjunto de dados para treinamento e testes. Para a implementação da estratégia considerada, técnicas das mais diferentes áreas da estatística e da inteligência artificial têm sido aplicadas. Neste trabalho, foram utilizados três modelos classificatórios - árvores de decisão (AD), redes neurais (RN) e máquinas de suporte vetorial (MSV).

A definição da estratégia de classificação envolveu testes com o objetivo de avaliar se a classificação poderia ser realizada em uma única etapa, ou seja, resolver o problema com um único classificador, para separar as sete classes existentes. Os resultados dos testes desanimaram a adoção desta estratégia, visto que o classificador com melhor desempenho resultou ineficiente e complexo. Assim, a estratégia adotada foi a classificação em etapas. Na primeira, os eventos são classificados de acordo com a categoria (Categoria I ou II) e na segunda, de acordo com as classes específicas de cada categoria. Nesta estratégia, são necessário três classificadores para resolução dos seguintes casos:

Caso 1) Qual a categoria do evento ?

Caso 2) Se o evento for da Categoria I, qual é a sua classe?

Caso 3) Se o evento for da Categoria II, qual é a sua classe?

Com o objetivo de identificar o melhor conjunto de variáveis para a resolução de cada um dos três casos, realizou-se processo de seleção de atributos, baseado na análise da importância preditiva e frequência de uso dos atributos em regras, produzidas por árvores de decisão (AD), com diferentes critérios de separação. Os atributos meteo-ocenográficos não foram considerados para a solução do Caso 2, enquanto os de localização relativa às unidades petrolíferas não foram utilizados para a solução do Caso 3. Também foi testado o desempenho dos modelos para a solução dos Casos 1 e 3, sem a utilização dos dados contextuais meteo-oceanográficos. Problemas na aquisição e disponibilização destes dados podem ocorrer, já que são adquiridos em outras plataformas e dependem da cobertura de nuvens.

Assim o desempenho dos classificadores foi avaliado para o conjunto total de atributos disponíveis, com e sem os dados meteo-oceanográficos, assim como para os subconjuntos (**Tabela 1**) selecionados com o processo de seleção de atributos (Bentz, 2006). Um conjunto com 20% dos dados foi escolhido aleatoriamente para teste, realizado com validação cruzada em 10 vezes.

Tabela 1 – Subconjuntos de atributos.

Subconjuntos		Atributos selecionados	
1	CASO 1 - VAR+	20	1-3, 5, 6, 8, 10, 18, 19, 22, 23, 25, 26, 28, 29, 35-38, 40
2	CASO 1 - VAR+ S/METEO	20	1-3, 5-10, 12, 14, 18, 29, 31, 35-40
3	CASO 2 - VAR+ S/METEO	22	2, 3, 5, 6, 8, 11-14, 16, 18, 29-33, 35-40
4	CASO 3 - VAR+ S/E&P LOC	22	1, 3-5, 7-10, 14, 17-23, 25, 26, 28, 35, 37, 39
5	CASO 3 - VAR+ S/ E&P LOC e S/METEO	22	1-14, 17, 18, 35-40

VAR+ = melhores variáveis; S/METEO= sem os atributos meteo-oceanográficos; S/E&P LOC= sem os atributos de localização relativa às unidades petrolíferas.

As AD foram geradas com o uso de um algoritmo adaptado do CART® (*Classification and Regression Trees*), com algumas implementações adicionais. Foram testadas as três métricas disponíveis: Gini, Chi-square e G-square.

A geração das RN utilizou rotina (*Intelligent Problem Solver - STATISTICA v.7.*) que avalia diferentes arquiteturas de redes, conforme parâmetros especificados pelo usuário. Os modelos utilizando MSV foram gerados utilizando-se a função de núcleo radial (RBF).

4. Resultados

Há várias maneiras descritas na literatura para se realizar a avaliação de classificadores. Neste estudo utilizaram-se as medidas AUC (*Area Under ROC Curve*) e GSS (*G-mean2*), generalizadas para problemas com múltiplas classes através de dois modos diferentes, conforme proposto por Espíndola e Ebecken (2006).

As **Tabelas 2, 3 e 4** apresentam os melhores resultados obtidos para cada caso. Na classificação em duas classes os valores de AUC e GSS foram iguais para quase todos os modelos testados. Para a classificação em múltiplas classes, os resultados estão sendo representados pelos valores de AUC1 e GSS2, que demonstraram ser os mais otimistas e pessimistas, respectivamente, para a grande maioria dos modelos testados.

Tabela 2 - Resultados dos modelos classificatórios para o Caso 1.

CASO 1 – 2 CLASSES			
	AD	RN	MSV
Atributos	AUC (%)	AUC (%)	AUC (%)
1- TOTVAR	84	90	93
2 -TOTVAR S/METEO	83	89	90
3 -VAR+	84	91	92
4 -VAR+ S/METEO	81	82	89

Para o Caso 1, os melhores resultados foram obtidos com o uso de MSV, seguidos pelo modelo de RN, para os quatro conjuntos de atributos (**Tabela 2**). Com exceção do Conjunto 4, foi pequena a diferença no desempenho das MSV e RN (1 a 2 %). A arquitetura de RN que obteve os melhores resultados foi a *Multilayer Perceptron* (MLP).

O modelo utilizando MSV com a totalidade dos atributos (Conjunto 1) apresentou os melhores resultados. Somente o desempenho das RN melhorou com a utilização dos atributos selecionados. A utilização do Conjunto 2 diminuiu 1 e 2% o desempenho dos classificadores. Uma redução mais acentuada no desempenho é verificada com o uso do Conjunto 4.

Os resultados obtidos para a solução do Caso 2 (**Tabela 3**) com o conjunto de vinte e duas variáveis selecionadas, foi semelhante para os três modelos classificatórios, com sutil vantagem para as MSV.

Tabela 3 - Resultados dos modelos classificatórios para o Caso 2.

CASO 2 - 3 CLASSES						
	AD		RN		MSV	
Atributos	AUC1 (%)	GSS2 (%)	AUC1 (%)	GSS2 (%)	AUC1 (%)	GSS2 (%)
1 -TOTVAR S/METEO	84	78	87	84	91	88
2 -VAR+ S/METEO	92	86	90	89	92	89

TOTVAR= todas as variáveis, VAR+ = melhores variáveis; S/METEO= sem os atributos meteo-oceanográficos.

Os melhores resultados para a solução do Caso 3 (**Tabela 4**) foram obtidos com o uso do modelo de MSV, com desempenho semelhante para os conjuntos 3 e 1. A seleção de atributos não provou melhoria no desempenho dos classificadores, neste caso. A não utilização dos atributos meteo-oceanográficos provocou uma diminuição entre 11 e 15% no desempenho dos modelos.

Tabela 4 - Resultados dos modelos classificatórios para o Caso 3.

CASO 3 - 5 CLASSES						
Atributos	AD		RN		MSV	
	AUC1 (%)	GSS2 (%)	AUC1 (%)	GSS2 (%)	AUC1 (%)	GSS2 (%)
1- TOTVAR S/E&P LOC	81	69	78	70	87	83
2- TOTVAR S/E&P LOC e METEO	66	57	69	67	79	73
3- VAR+ S/E&P LOC	84	76	82	79	90	86
4- VAR+ S/E&P LOC e METEO	64	51	75	70	78	72

TOTVAR= todas as variáveis, VAR+ = melhores variáveis; S/METEO= sem os atributos meteo-oceanográficos; S/E&P LOC= sem os atributos de localização relativa às unidades petrolíferas.

4. Discussão e conclusões

Foram gerados classificadores capazes de identificar sete tipos de eventos ambientais costeiros e oceânicos, detectáveis em imagens de radares orbitais. O processo envolve duas etapas: primeiro os eventos são separados em duas categorias - Poluentes ou Meteo-oceanográficos. Na segunda etapa os eventos são classificados de acordo com as classes específicas de cada categoria. Diversos atributos foram avaliados e diferentes subconjuntos de variáveis foram testados. Também, considerou-se a indisponibilidade de dados contextuais meteo-oceanográficos.

O uso de todos os atributos obteve melhores resultados na primeira etapa, enquanto os conjuntos de variáveis selecionadas obtiveram os melhores valores na etapa seguinte.

Os modelos baseados em MSV apresentaram os melhores resultados para todos os casos avaliados. As RN (do tipo MLP) apresentaram também bons resultados.

A não utilização dos dados meteo-oceanográficos causou redução da ordem de 3% (**Figura 2**) no desempenho do classificador, na primeira etapa. Na segunda etapa, verificou-se uma redução maior no desempenho para a identificação dos quatro tipos de eventos meteo-oceanográficos.

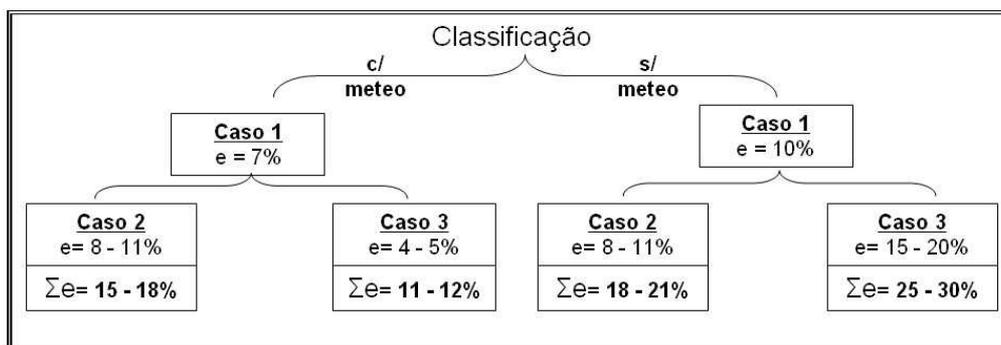


Figura 2 – Erros (e) estimados com os valores de AUC e GSS para a classificação dos diferentes casos, com e sem a utilização dos atributos meteo-oceanográficos. Σe = Somatório dos erros.

O desempenho dos classificadores poderá ser melhorado com novos treinamentos, na medida em que mais exemplos forem gerados. O uso de comitês de classificadores é outra opção para o aumento no desempenho do processo de classificação.

A disponibilidade de dados como os do satélite ENVISAT, capaz de adquirir simultaneamente imagens em diferentes faixas do espectro, tem grande potencial para aumentar o número de atributos espectrais e melhorar a qualidade dos meteo-oceanográficos.

Os classificadores desenvolvidos têm bom potencial para uso operacional. No entanto, necessita-se avançar nos métodos de individualização automática das feições. Apesar da disponibilidade de diferentes procedimentos, esta etapa ainda necessita de supervisão humana para a obtenção de bons resultados.

4. Referências

Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, A., Hofmann, P., Lingenfelder, I., Mimler, M., Sohlbach, M., Weber, M. Willhauck, G. **eCognition User Guide 3**. Definiens Imaging. 2003.

Bentz, C.M.; Politano, A.T.; Genovez, P.C. Monitoramento ambiental de áreas costeiras e oceânicas com múltiplos sensores orbitais. In Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12. 2005, Goiânia.

Bentz, C.M. **Reconhecimento automático de eventos ambientais Costeiros e Oceânicos em Imagens de Radares Orbitais**. Tese de Doutorado - Universidade Federal do Rio de Janeiro, COPPE, D. Sc., Engenharia Civil, Rio de Janeiro, 2006.

Clemente-Colón P. and Yan X., 2000, Low-Backscatter Ocean Features in Synthetic Aperture Radar Imagery, **Johns Hopkins Applied Technical Digest**, **21**, pp. 116-121, 2000.

Del Frate, F.; Petrocchi, A.; Lichtenegger, J.; and G. Calabresi, Neural Networks for oil spill detection using ERS-SAR data, **IEEE Transaction on Geoscience and Remote Sensing**, **3** (5), 2282-2287, 2000.

Espíndola, R.P. and Ebecken, N.F.F. On Extending F-Measure and G-Mean metrics to multi-class problems, **Data Mining VI**, WITPress, ,6,25-34,2005.

Espedal H.A. and T. Wahl, Satellite SAR oil spill detection using wind history information, **International Journal of Remote Sensing**, **20** (1), 49-65, 1999.

Kubat, M. Holte, C. and S. Matwin, Machine learning for detection of oil spills in satellite radar images, **Machine Learning**, vol.30, n° 2-3, 195-215, 1998.

Miranda F.P., Mendoza A., Pedroso E. A., Beisl C.A. Methodological design for the use of RADARSAT-1 data to monitor offshore petroleum activities in the Campeche Bay, Gulf of México, Seventh International Conference on Remote Sensing for Marine and Coastal Environments, FL./USA, May 20-22., 2002.

Pedersen, J.P., Seljelv, L.G., Bauma T., Strøm G.D., Follum, O.A., Andersen, J.H, Wahl T. and Skøelv Å., Towards an operational oil spill detection service in the Mediterranean - The Noerwegian experience: A preoperational early warning detection service using ERS SAR data. *ERS Thematic Workshop: Oil Pollution Monitoring in the Mediterranean*, 25-26 March, ESRIN, Frascati, Italy, 1996.

Solberg, A. H. S.; Storvik, G.; Solberg, R. and E. Volden, Automatic detection of oil spills in ERS SAR images, **IEEE Transaction on Geoscience and Remote Sensing**, **37** (4), July, 1999.