

Classificação supervisionada de imagens SAR do SIVAM pré-filtradas

Orlando Alves Máximo^{1,2}
David Fernandes²

¹Instituto de Estudos Avançados – IEAv
Rodovia dos Tamoios Km 5,5 – 12228-840 – São José dos Campos – SP, Brasil
oamaximo@ieav.cta.br

²Instituto Tecnológico de Aeronáutica (ITA) – Centro Técnico Aeroespacial (CTA)
Praça Mal. Eduardo Gomes, 50 – 12228-900 - São José dos Campos - SP, Brasil
{david, maximo}@ele.ita.br

Abstract. This paper evaluates the accuracy of multidimensional supervised classifiers using SAR images preprocessed by noise speckle reduction filters. Three filters were applied: Lee, Frost and Mean. Five supervised classifiers were compared: Minimum Distance, Mahalanobis Distance, Maximum Likelihood, Cascade and Global Membership Function with reliability factors (GMF). Two images processed by the Brazilian Air Force SAR Processor (PROSAR-BR) were used in the comparison. The results indicate that the classifiers were sensitive to the filtering and to the type of filtering applied. The Mahalanobis classifier achieved the lower accuracy results in all cases. For the original image, and all windows filtering for the Lee and Frost filters, the best results were achieved by the GMF classifier. For the Mean filter, the best results were achieved by the Maximum Likelihood Classifier.

Palavras-chave: SIVAM, SAR, supervised classification, reliability factors; speckle reduction filters, classificação supervisionada, graus de confiança, filtros redutores de speckle.

1. Introdução

Nos últimos anos, tem aumentado o número de sensores que operam na faixa das microondas em atividade, fornecendo uma variada gama de produtos para comunidade científica.

No Brasil, a entrada em operação das aeronaves de sensoriamento remoto do Projeto SIVAM (operadas pela Força Aérea Brasileira – FAB) constituiu um significativo incremento na disponibilidade de imagens de sensoriamento remoto na faixa das microondas. Equipadas com dois sensores SAR, as aeronaves podem gerar imagens nas Bandas X (HH) e L (HH, VV, HV, VH), em vários modos de imageamento e em várias resoluções.

Durante o processo de implantação das aeronaves, uma equipe da FAB participou de um grupo de absorção de tecnologias SAR em Vancouver, Canadá. Ao retornar ao Brasil, o grupo foi incorporado à Divisão de Sensoriamento Remoto (ESR), IEAv/CTA.

Após esta incorporação, a ESR, aproveitando os resultados da parceria com o ITA e contando com o apoio da Comissão para Coordenação do Projeto SIVAM (CCSIVAM), desenvolveu um processador SAR para as imagens geradas pelos sensores a bordo das aeronaves de sensoriamento remoto, no intuito de suprir algumas deficiências do processador adquirido junto à empresa fornecedora dos sensores (Veiga, 2004). Este processador recebeu o nome de PROSAR-BR, e já está em uso no Centro Regional de Vigilância de Manaus e na cidade de Anápolis, sede dos aviões de sensoriamento remoto.

Este artigo tem como objetivo utilizar um par de imagens geradas pelo PROSAR-BR em um experimento que compara a influência das técnicas de filtragem do speckle e da inclusão de pesos controladores de influência (graus de confiança) num processo de classificação supervisionada bidimensional.

Na Seção 2 é feita uma descrição das técnicas de classificação supervisionada com e sem a inclusão dos graus de confiança em classificadores estatísticos. Na Seção 3 é realizada uma

descrição sumária das principais características do PROSAR-BR. O experimento é descrito na Seção 4 e os resultados são analisados na Seção 5.

2 Classificação Supervisionada

Segundo Campbell (1996), a classificação supervisionada pode ser informalmente definida como o processo no qual amostras de identidade conhecida são utilizadas para classificar pixels de identidade desconhecida.

Neste processo, um analista identifica na imagem as classes de informação de seu interesse e separa regiões que melhor representem estas classes. Dentro destas regiões ele separa áreas de treinamento que contêm os pixels que serão usados como representantes da classe. A partir destes pixels são extraídas determinadas características das classes, que serão usadas para a classificação dos demais pixels.

Ainda segundo Campbell (1996), o processo de classificação supervisionada apresenta vantagens e desvantagens em relação à classificação não-supervisionada.

As principais vantagens são: a) O analista tem maior controle sobre o processo (escolhe o número e o tipo de classes, as regiões de amostragem e o número de amostras). Esta característica é importante principalmente quando a classificação visa a um objetivo específico; b) a classificação supervisionada é balizada pelas classes pré-definidas pelo analista, desta forma, não é necessário concatenar a imagem classificada com as classes de interesse; e c) o analista tem condições de identificar possíveis imprecisões graves pela análise das áreas de treinamento.

As principais desvantagens são: a) O analista impõe uma determinada estrutura de classificação aos dados, através da definição prévia das classes de informação. Estas classes podem não corresponder às classes reais existentes na cena imageada, ou não ser separáveis no espaço n-dimensional; e b) As áreas de treinamento selecionadas podem não apresentar todas as características das classes que representam. Esta característica pode ter muita influência, principalmente quando a área a ser classificada é grande, complexa ou inacessível.

Técnicas de classificação supervisionada

a) Maxver

Segundo Richards (1986) a classificação Maxver é a técnica de classificação mais utilizada em imagens de sensoriamento remoto. A regra de decisão utilizada pode ser definida como:

$$x \in w_i \Leftrightarrow \ln p(x/w_i) + \ln p(w_i) = \max_j (\ln p(x/w_j) + \ln p(w_j)) \quad (1)$$

onde $w_i \in \{w_1, \dots, w_m\}$, que é o conjunto de classes selecionadas pelo analista.

Considerando que as classes são normalmente distribuídas e equiprováveis, a Equação (1) pode ser reescrita como:

$$x \in w_i \Leftrightarrow -\ln|\Sigma_i| - (x - m_i)^T \Sigma_i^{-1} (x - m_i) = \max_j (-\ln|\Sigma_j| - (x - m_j)^T \Sigma_j^{-1} (x - m_j)) \quad (2)$$

onde Σ_i e m_i são, respectivamente, a matriz de covariância e o vetor média da classe i , obtidas através das amostras de treinamento.

b) Distância Mínima

Nesta técnica, as áreas de treinamento definem regiões no espaço de dados n-dimensional. Cada uma das regiões pode ser representada por um ponto, denominado centróide. O processo de classificação baseia-se na projeção de cada pixel neste espaço n-dimensional e no cálculo

da distância n-dimensional entre ele e os centróides. O pixel será classificado na classe que corresponder à menor distância calculada.

Muito embora seja de implementação simples, esta técnica é bastante influenciada pela sobreposição de classes e pela variabilidade dentro de cada classe. É possível construir modelos sofisticados deste classificador usando diferentes técnicas para medição de distâncias e para a definição dos centróides.

c) Classificador Mahalanobis

Efetuada uma inversão de sinais na Equação (2), a função discriminante da regra de decisão pode ser considerada como uma medida de distância, definida como (Richards, 1986):

$$d(x; m_i, \Sigma_i)^2 = \ln|\Sigma_i| + (x - m_i)^t \Sigma_i^{-1} (x - m_i) \quad (3)$$

Considerando o caso onde as matrizes de covariância são iguais, isto é, $\Sigma_i = \Sigma \forall i$, a Equação (3) pode ser reescrita como:

$$d(x; m_i)^2 = (x - m_i)^t \Sigma^{-1} (x - m_i) \quad (4)$$

O classificador construído com base nesta distância é conhecido como Classificador Mahalanobis.

d) Classificador em Cascata

Em determinadas situações nos casos n-dimensionais, cada conjunto de informação (cada banda da imagem, por exemplo) pode ser considerado como uma fonte independente. Neste caso, Swain (1978) utilizou a abordagem Bayesiana do MaxVer para definir o Classificador em Cascata, que tem como regra de decisão:

$$x \in w_i \Leftrightarrow p(w_i)^{1-n} \prod_{k=1}^n p(x_k | w_i) = \max_j p(w_j)^{1-n} \prod_{k=1}^n p(x_k | w_j) \quad (5)$$

onde $k = 1, \dots, n$, representa o número de fontes independentes e x_k é o valor do pixel na fonte k e $x = \{x_1, \dots, x_k\}$.

e) Função de Adesão com graus de confiança

Uma outra abordagem para o caso n-dimensional onde cada conjunto de informação é considerado como uma fonte independente considera a qualidade de cada uma das fontes. O objetivo é minimizar a influência das fontes consideradas com menor qualidade. Benediktsson et al. (1990) introduziram a Função de Adesão com graus de confiança como sendo:

$$F_j(x) = p(w_i) \prod_{k=1}^n \left[\frac{p(w_i | x_k)}{p(w_i)} \right]^{\alpha_k} \quad (6)$$

onde α_k é o grau de confiança da fonte k , com valores no intervalo $[0,1]$ e $x = \{x_1, \dots, x_k\}$.

Uma regra de decisão para o classificador utilizando esta Função de Adesão pode ser escrita como:

$$x \in w_i \Leftrightarrow F_i(x) = \max_j F_j(x) \quad (7)$$

3 O PROSAR-BR

Dentre os diversos sensores e sistemas de coleta de dados adquiridos para compor o SIVAM, o Radar Imageador de Abertura Sintética (SAR), que equipa três aeronaves operadas pela FAB, destaca-se como sendo o de maior potencial para uso na comunidade científica.

Após a sua entrada em operação, embora estes Sistemas tenham sido concebidos como uma solução completa e sejam capazes de cumprir todo o seu ciclo operacional, desde a coleta, processamento, distribuição e análise de dados, foram identificadas algumas limitações onde era possível e/ou necessária uma adequação.

Dentre outras podem ser citadas: a) A arquitetura de hardware para o processador SAR adquirido possui alto custo de manutenção e atualização; b) O processador também não permite o agendamento de tarefas, exigindo a presença constante do operador do sistema; c) Não havia domínio nacional sobre o código fonte, o que impedia a sua modificação, adaptação e/ou melhoria por técnicos brasileiros; e d) Não existia um sistema de catálogo eletrônico capaz de armazenar os metadados mais significativos dos vôos de imageamento e seus produtos finais (imagens), que permitisse a consulta parametrizada sobre o histórico dos dados coletados, bem como a visualização preliminar dos mesmos.

Em virtude desta situação, e aproveitando os resultados promissores da parceria com o ITA, a ESR sugeriu o desenvolvimento de um sistema que pudesse solucionar/minimizar estas limitações. O PROSAR-BR foi proposto com as seguintes características principais: a) Ser um Sistema baseado em plataformas de baixo custo, do tipo PC, dotados de sistema operacional Windows®; b) Possibilitar a paralelização do processamento, bem como seu agendamento; c) Possuir um sistema de catálogo de missões e produtos que permita a clientes remotos, selecionados e identificados, efetuar consultas sobre a disponibilidade de dados, pré visualização de imagens já processadas, bem como apresentar e acompanhar pedidos de missão de coleta de dados através da Internet; e d) Possuir um sistema de armazenamento de dados brutos do SAR em discos de DVD-R ou fitas DLT, de baixo custo e alta confiabilidade.

A arquitetura final do Sistema contemplou três módulos ou subsistemas:

a) SPSAR (Subsistema de Processamento SAR) – inteiramente implementado em linguagem IDL, este subsistema é o responsável pelo processamento dos dados brutos obtidos pelo SAR (Bandas X e L) e a conseqüente geração de imagens no modo “strip” (Veiga, 2004).

b) PRODIS (Subsistema de Processamento Distribuído) – responsável por estabelecer a estratégia de distribuição de tarefas com o intuito de “paralelizar” o processamento das imagens. Para isso, efetua a divisão dos dados brutos em blocos de 1000X1000 pixels e os distribui para uma matriz de computadores que possuem o SPSAR instalado. Atualmente, trabalha com uma matriz de 16 computadores, que pode ser ampliada.

c) CATCON (Subsistema de Catalogação e Controle) – é responsável pela coleta, catalogação, armazenamento e recuperação de dados sobre as missões de imageamento utilizando todos os sensores a bordo da aeronave. Incorpora também uma interface com o usuário que permite a consulta de imagens já coletadas, solicitação de pedidos de imagens já coletadas e de missões de imageamento, bem como o acompanhamento destes pedidos.

Este Sistema já foi concluído e está em operação no CRV Manaus e na sede do esquadrão que opera as aeronaves de sensoriamento remoto. Seu desempenho está sendo considerado superior ao do processador adquirido originalmente.

4 Descrição do Experimento

O experimento constituiu na comparação da precisão dos classificadores descritos na Seção 2 (quais sejam: MaxVer, Distância Mínima, Mahalanobis, Cascata e Função de Adesão com

graus de confiança) para avaliar a influência da manipulação estatística e da inclusão de graus de confiança no processo de classificação.

Foram selecionadas duas imagens SAR amplitude (Banda X, polarização HH; e Banda L polarização VV) de uma região próxima à cidade de São José dos Campos – SP, que foram coletadas pelos sensores a bordo das aeronaves do 2º Esquadrão do 6º Grupo de Aviação (2º/6º GAv) da Força Aérea Brasileira (FAB), que opera as aeronaves do Projeto SIVAM.

Os dados brutos foram processados pelo PROSAR-BR e as imagens são apresentadas na **Figura 1**.




Figura 1 – a) Imagem Banda L, pol. VV; b) Imagem Banda X, pol. HH.

Após a sintetização das imagens, elas foram entregues a três analistas para a seleção/definição das classes e das regiões de coleta de dados. Essas regiões foram utilizadas para a coleta de dados de treinamento e para o teste do classificador.

Para a avaliação da precisão do classificador, foi utilizado o Índice de Precisão, definido por Máximo e Fernandes (2002). Os autores definiram o Índice de Precisão como: $D(X) = 1 - |P - P(X)| / \sqrt{5}$, onde $P(X)$ é um vetor de precisão composto pelos seguintes coeficientes: Precisão Global, Precisão Média por Classes, Coeficiente Kappa, e os Coeficientes de Kullback-Leibler com distribuição uniforme e proporcional. As formulações para estes coeficientes podem ser encontradas em Nishii (1999).

Para a aplicação dos classificadores MaxVer, Distância Mínima e Mahalanobis, foram utilizados os algoritmos disponibilizados no software ENVI, versão 3.6.

O classificador em Cascata e o Classificador da Função de Adesão com graus de confiança foram implementados em linguagem IDL (“Interactive Data Language”), versão 5.6. Nesta implementação, o grau de confiança de cada conjunto de dados variou entre zero (0) e um (1), com intervalos de 0,1, totalizando 121 combinações em cada classificação.

Todo o processo de classificação foi repetido para a imagem original e para imagens processadas com os filtros de Lee, de Frost e da média, com janelas de filtragem de tamanho 3x3, 7x7 e 11x11.

5 Análise dos Resultados

Os resultados obtidos pelos classificadores foram analisados em duas etapas distintas. Na primeira, todos os classificadores foram comparados entre si, de acordo com o Índice de Precisão definido na seção anterior. Para representar o resultado do uso da Função de Adesão

com graus de confiança, foram seleccionadas as combinações que obtiveram o maior e o menor Índice, respectivamente.

Ainda na primeira etapa, os classificadores foram avaliados com relação ao seu comportamento em função da aplicação dos filtros utilizados.

Na segunda etapa, foi avaliado o comportamento da Função de Adesão em função da variação da combinação de graus de confiança.

A **Figura 2** apresenta um sumário dos resultados obtidos no experimento.

Pode-se perceber que o resultado da classificação é bastante dependente do tipo de classificador e do pré-processamento. O intervalo de variação do Índice de Precisão no experimento foi de $[0,28 - 0,97]$, correspondendo, respectivamente, ao desempenho do classificador Mahalanobis com a imagem original e ao desempenho do classificador MaxVer com a imagem processada pelo filtro da média, janela 11. A **Figura 3** apresenta o resultado da classificação para estes casos.




Figura 2 – Índice de Precisão em função dos classificadores e da janela de filtragem.




Figura 3 – a) Classificação com o Classificador Mahalanobis, imagem original; b) Classificação com o MaxVer, imagem processada com filtro da média, janela 11.

Analisando o desempenho dos classificadores, observa-se que o Classificador Mahalanobis apresentou resultados inferiores aos demais em todas as situações.

No geral, a aplicação dos filtros provocou um incremento no Índice de Precisão em relação ao obtido com a imagem original. Este incremento está relacionado diretamente com o tamanho da janela de filtragem, havendo sinais de estabilização a partir da janela 11 para os filtros de Lee e de Frost.

Individualmente, alguns classificadores apresentaram comportamento específico para cada tipo de filtro. Em relação ao seu desempenho com a imagem original, o Classificador em Cascata teve seu desempenho bastante deteriorado pela aplicação dos filtros de Lee e de Frost, tanto em termos absolutos quanto em comparação com os demais classificadores. Esta tendência foi revertida com a aplicação do filtro da média, que provocou um incremento na precisão do classificador.

O Classificador da Distância Mínima teve seu desempenho incrementado com a aplicação dos filtros, tanto em termos absolutos quanto em comparação com os demais. Neste último caso, a influência do filtro de Lee foi discreta, a do filtro de Frost foi mais acentuada e a do filtro da média foi bastante acentuada, chegando a um desempenho de 0,969, praticamente igual ao maior desempenho obtido em todo o experimento, que foi de 0,974.

O Classificador da Função de Adesão apresentou os maiores Índices de Precisão entre todos os classificadores utilizados na imagem original e com a aplicação dos filtros de Lee e de Frost. Com a aplicação do filtro da média, o seu desempenho foi superado pelo Classificador da Distância Mínima e pelo MaxVer a partir da janela 7.

O comportamento da Função de Adesão com graus de confiança será analisado com mais detalhe. De maneira geral, não há uma combinação única que maximize o desempenho do classificador. Esta característica já havia sido notada em Máximo e Fernandes (2002, 2003). A **Figura 4a** apresenta o comportamento do Índice de Precisão em função dos graus de confiança para as imagens, para o caso do filtro da média, janela 7.




Figura 4 – Índice de Precisão em função dos graus de confiança para as imagens a) filtro da média, janela 7; b) filtro de Lee, janela 7; e c) filtro de Frost, janela 7.

Dos dados da **Figura 2**, pode-se calcular, usando todas as janelas, uma diferença média de seis pontos percentuais entre os valores mínimo e máximo dos Índices de Precisão obtidos.

A análise da Equação 6 revela que, quando os graus de confiança são iguais, a Função de Adesão fica equivalente ao Classificador em Cascata. Este fato acarreta um baixo Índice de Precisão na classificação das imagens pré-processadas com o filtro de Lee (**Figura 4b**) e com o filtro de Frost (**Figura 4c**). Não foi possível, até o momento, estabelecer uma relação determinística para calcular a combinação de graus de confiança que maximizam o desempenho do classificador.

Conclusão

A análise dos dados revelou que os classificadores têm seu comportamento alterado de acordo com o pré-processamento das imagens. De maneira geral, o filtro da média proporcionou os maiores valores para a medida de precisão utilizada.

Com relação à Função de Adesão, não foi possível estabelecer uma combinação de graus de confiança que maximizasse o desempenho do classificador.

Agradecimentos

Os autores agradecem à Comissão para Coordenação do Projeto SIVAM (CCSIVAM), ao Instituto Tecnológico de Aeronáutica (ITA) e ao Instituto de Estudos Avançados (IEAv) pelo apoio na realização deste experimento.

Referências

- Benediktsson, J.A.; Swain, P.H.; Ersoy, O.K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 4, p. 540-552, 1990.
- Campbell, J. B. **Introduction to remote sensing**. New York: The Guilford Press, 1996. 622 p.
- Máximo, O.A.; Fernandes, D. The use of data set reliability factors in a multidimensional Bayesian classifier. In: International Geoscience and Remote Sensing Symposium, Toronto, CA, June 2002. **Proceedings**. Publicação em CD.
- Máximo, O.A.; Fernandes, D. Uso de graus de confiança das classes em classificadores Bayesianos. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., 2003, Belo Horizonte. **Anais...** São José dos campos: INPE, 2003. p. 2083-2090. Disponível na biblioteca digital URLib: < tid.inpe.br/sbsr/2002/11.17.11.53>.
- Nishii .R, Tanaka S., "Accuracy and inaccuracy assessment in land-cover classification". **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 1, p. 491-498, 1999.
- Richards, J. A. "**Remote sensing digital image analysis**". Berlin:Springer Verlag, 1986. 375p.
- Swain, P.H. "Bayesian classification in a time-varying environment". **IEEE Trans. Syst., Man, Cybern**, v. SMC-8, p. 879-883, 1978.
- Veiga, R. Q. **Processador SAR com compensação de movimento para o SAR-SIVAM**. 2004. 90p. Dissertação (Mestrado em Engenharia Eletrônica) – Instituto Tecnológico de Aeronáutica, São José dos Campos. 2004.