

Classificação de imagens SAR de Machadinho d'Oeste – RO em ambiente distribuído

Thalita Biazzuz Veronese¹
Maurício Pozzobon Martins²
Lamartine Nogueira Frutuoso Guimarães²

¹Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil
thalita@lac.inpe.br

²Instituto de Estudos Avançados - IEAv
Caixa Postal 6044 – 12228-001 - São José dos Campos - SP, Brasil
{mauricio, guimarae}@ieav.cta.br

Abstract. In this paper, we evaluate the efficiency of a Kohonen's Map for classifying SAR-SIVAM images, based on Gabor texture features (Manjunath e Ma, 1996). In the feature extraction phase, techniques of distributed processing were implemented in low cost computer network, in order to analyze the real performance improvement. The images for testing were obtained in 2004 September 13, by the SAR sensor of SIVAM's remote sensing aircraft, kindly given by Remote Sensing Division of Advanced Studies Institute (IEAv/CTA). As reference for the visual identification of texture classes, SPOT optical images, given by EMBRAPA, are used.

Palavras-chave: SAR images, texture classification, distributed processing, imagens SAR, classificação de texturas, processamento distribuído.

1. Introdução

Ao longo das últimas décadas, diversas técnicas têm sido desenvolvidas para classificação de imagens obtidas através de sensores ópticos. Entretanto, no caso de imagens geradas por sensores que atuam na faixa de microondas (radar), novas pesquisas ainda são necessárias, já que muitas vezes técnicas consagradas para imagens ópticas não produzem resultados satisfatórios quando aplicadas a imagens radar, devido às características peculiares deste tipo de imagem – efeito *speckle*, por exemplo. Na região amazônica, as condições climáticas frequentemente são caracterizadas por coberturas de nuvens, o que se apresenta como fator restritivo à utilização de sensores ópticos. Assim, os sensores SAR têm se tornado os principais responsáveis pela obtenção de dados, contribuindo para suprir a falta de informação disponível sobre esta região.

Localizado dentro da Amazônia Legal Brasileira, o município de Machadinho d'Oeste – RO foi escolhido como objeto de um estudo a longo prazo, a fim de auxiliar no suporte a projetos de sustentabilidade agrícola na Amazônia. Fruto de uma cooperação técnica entre a Embrapa Monitoramento por Satélite e o Instituto de Estudos Avançados (IEAV/CTA - Comando Geral de Tecnologia Aeroespacial), cujo objetivo é intensificar os trabalhos de pesquisa que utilizem imagens de radares de abertura sintética (SAR) no monitoramento territorial, as imagens utilizadas no classificador em estudo foram obtidas pelo sensor SAR-SIVAM sobre Machadinho d'Oeste – RO, adquiridas em 13 de Setembro de 2004 e gentilmente cedidas pela Divisão de Sensoriamento Remoto do IEAv.

Neste trabalho, avalia-se a eficiência de um mapa de Kohonen na classificação de imagens SAR obtidas sobre Machadinho d'Oeste, utilizando medidas de textura obtidas por filtros Gabor (Manjunath e Ma, 1996). Na fase de extração de atributos, foram implementadas técnicas de processamento distribuído em rede de computadores de baixo custo, a fim de avaliar o real ganho em desempenho. Como referência para a identificação visual de classes

de texturas, foram utilizadas imagens ópticas SPOT, cedidas pela Embrapa. Dados de uso do solo e cobertura de terra verificados em campo foram utilizados como amostras de treinamento, a fim de verificar a validade dos métodos propostos na geração de um mapa temático da região.

2. Área de Estudo

Localizado a aproximadamente 400 km de Porto Velho – RO, Machadinho d’Oeste originou-se do Projeto de Assentamento Machadinho, implantado em 1982 pelo INCRA, como parte do Programa POLONORDESTE. O município foi escolhido pela Embrapa Monitoramento por Satélite como objeto de um estudo de longo prazo, que envolve a caracterização e o monitoramento dos sistemas de produção praticados pelos pequenos agricultores na região, com o objetivo de obter informações que proporcionem suporte aos projetos de sustentabilidade agrícola na Amazônia.

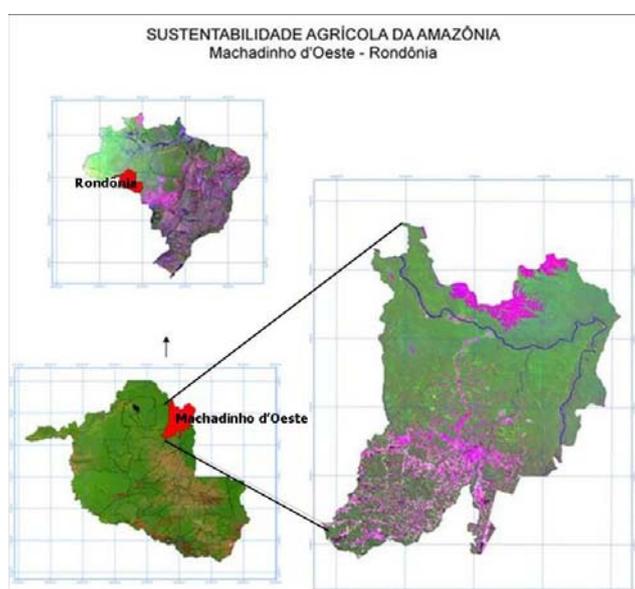


Figura 1 – Localização da Área de Estudo. Fonte: Embrapa.

Para o presente trabalho, dados de uso do solo e cobertura de terra verificados em campo foram utilizados como amostras de treinamento, a fim de avaliar a eficiência dos métodos propostos na geração de um mapa temático da região.

3. O Sensor do SIVAM

O sensor SAR, que equipa as aeronaves R99-B do SIVAM, fornece imagens captadas na faixa de microondas do espectro eletromagnético e possui, além de outras características, capacidade de imageamento em dois comprimentos de onda (bandas X e L), multipolarização na banda L (HH, VV, HV e VH), modo interferométrico na banda X e resolução espacial variando de 1.8 a 18 m. As três aeronaves de SR são administradas pela Força Aérea Brasileira e encontram-se na Base Aérea de Anápolis-GO. Uma vez coletadas, as imagens são processadas no Centro Técnico Operacional do SIPAM (Sistema de Proteção da Amazônia) em Manaus (AM). As imagens R99-SAR são comumente utilizadas em estudos hidrológicos, geológicos, monitoramento ambiental, entre outros.

As imagens utilizadas foram adquiridas nas bandas L (combinações polarimétricas HH, VV e HV) e X (polarização HH), em 13 de setembro de 2004, todas com resolução espacial de 3 metros, tomadas simultaneamente com ângulo de incidência de 30°, a uma distância

média de 18 km entre a plataforma e a cena imageada, a uma altitude de vôo de 10 km em relação ao nível do mar.

4. Atributos de Textura

O conceito de textura está relacionado à variabilidade espacial de tonalidades dentro de uma região da imagem. Em termos visuais, a textura é descrita como a impressão de aspereza ou suavidade criada pela variação de tonalidade ou repetição de padrões através de uma superfície (Tso e Mather, 2001). Com a consolidação da teoria da transformada Wavelet, muitos pesquisadores passaram a estudar a aplicação de Wavelets à representação de texturas. Este trabalho baseia-se na metodologia proposta por Manjunath and Ma (1996), segundo a qual os padrões de textura são caracterizados utilizando a transformada *Wavelet* de Gabor e medidas estatísticas.

Dada uma imagem I e o banco de filtros Gabor g_{mn} , a transformada Gabor em (x, y) é definida por:

$$W_{mn}(x, y) = \int \int I(x, y) g_{mn}^*(x - x_1, y - y_1) dx_1 dy_1.$$

Onde $*$ indica o complexo conjugado. Com a aplicação de filtros Gabor sobre padrões de textura, a geração dos vetores de atributos é realizada através do cálculo de medidas estatísticas da imagem filtrada. As medidas estatísticas utilizadas são a média (μ_{mn}) e o desvio padrão (σ_{mn}) da magnitude dos coeficientes da transformada definidas por:

$$\mu_{mn} = \int \int |W_{mn}(xy)| dx dy,$$

$$\sigma_{mn} = \sqrt{\int \int (|W_{mn}(xy)| - \mu_{mn})^2 dx dy}.$$

Para cada filtro aplicado, os dados estatísticos de média e desvio padrão são calculados e concatenados para a formação do vetor de atributos daquela textura. Num experimento usando um filtro Gabor de quatro escalas e seis orientações, por exemplo, os vetores de atributos resultantes teriam a seguinte forma:

$$\bar{f} = [\mu_{11} \sigma_{11} \mu_{12} \sigma_{12} \dots \mu_{46} \sigma_{46}].$$

Onde μ_{op} e σ_{op} denotam a média e o desvio padrão, respectivamente, no estágio (escala) o e orientação p . Um banco de filtros Gabor de quatro escalas e seis orientações possui vinte e quatro filtros para cada medida. Como a informação textural é representada por duas medidas, então o vetor de atributos possui quarenta e oito elementos: dois parâmetros para cada filtro.

5. Processamento Distribuído

Devido ao alto tempo de execução gasto para realizar a extração de atributos de textura das imagens, torna-se imprescindível a integração de técnicas de processamento de alto desempenho a esta etapa. Assim, através do paralelismo de dados, as amostras e imagens a serem analisadas são divididas entre os processadores, que calculam os vetores de atributos independentemente. Este trabalho está sendo desenvolvido em um *cluster* baseado no conceito de máquinas *Beowulf*. O ambiente utilizado faz parte do projeto *Believe*, desenvolvido no Laboratório de Engenharia Virtual do Instituto de Estudos Avançados (IEAv).

Amostras de 17.500, 52.500 e 87.500 pixels foram usadas a fim de avaliar o efeito da paralelização e do número de máquinas sobre o tempo de execução. No gráfico da **Figura 3a**,

observam-se as medidas de *speedup* obtidas, enquanto na **Figura 3b** estão representadas as medidas de eficiência para até sete processadores. É possível perceber que o impacto da estratégia de paralelização se mostrou proporcional ao tamanho da amostra, sendo que para a imagem de 87.500 pixels, os valores de eficiência se mostraram mais estáveis, mostrando um alto ganho em desempenho, independente do número de processadores.

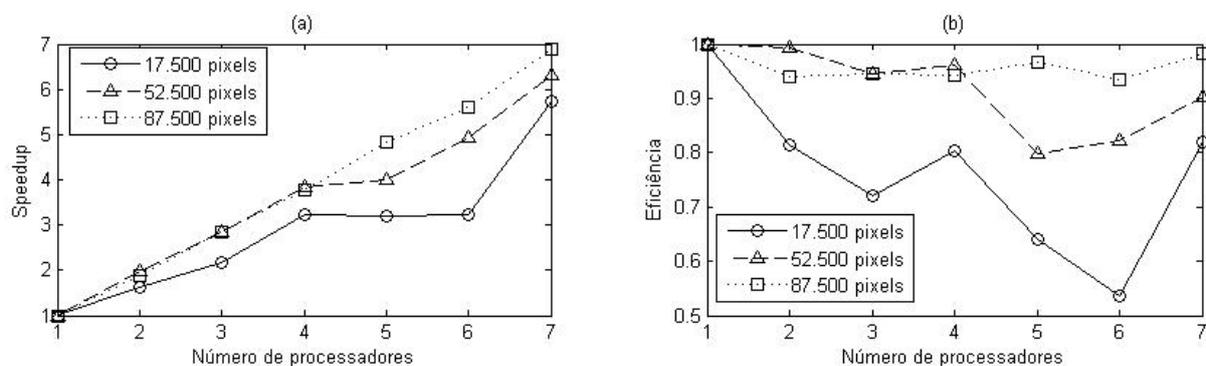


Figura 2 – Análise de *speedup* (a) e eficiência (b) para diferentes tamanhos de imagens.

6. Classificação

Por mais de uma década, o reconhecimento de padrões em imagens de sensoriamento remoto tem se baseado principalmente em técnicas estatísticas convencionais, como os procedimentos de máxima probabilidade e distância mínima. Embora as abordagens tradicionais possam apresentar bom desempenho, sua habilidade geral para resolver confusões inter-classes é limitada. Nos últimos anos, estratégias alternativas têm sido propostas, como o uso de redes neurais artificiais, árvores de decisão e métodos derivados da teoria dos conjuntos nebulosos *Fuzzy Set Theory* (Tso e Mather, 2001). A capacidade de reconhecer padrões, mesmo ao lidar com informações ruidosas ou incompletas (Haykin, 2001), contribui para que as redes neurais artificiais possam atuar como ferramentas nos mais diversos tipos de problemas (Fausett, 94). No contexto de sensoriamento remoto, seu uso vem crescendo nos últimos dez anos, principalmente para classificação de imagens (Tso e Mather, 2001).

O Mapa Auto-Organizável (SOM) desenvolvido por Kohonen é um modelo de rede neural artificial competitiva, representado por uma camada computacional de unidades dispostas em linhas e colunas, submetidas a um treinamento não-supervisionado baseado em regras de mínima distância euclidiana e uma função de vizinhança. A Aprendizagem por Quantização Vetorial (LVQ) consiste em um método supervisionado de classificação de padrões (LVQ) que visa refinar as superfícies de decisão entre as classes, com o objetivo de reduzir a taxa de erro observada. No presente trabalho, foi realizada a integração das redes SOM+LVQ a fim de melhorar os índices de acerto da classificação.

A imagem de onde foram extraídas as amostras para treinamento da rede, um pequeno recorte da área de estudo, é mostrada na **Figura 3a**. Os padrões de textura foram calculados para as bandas L (polarização VH) e X (polarização HH), bem como para as imagens resultantes da aplicação dos filtros Lee e Frost, com janelas 5x5. Com o objetivo de obter melhores índices de acerto, os vetores de entrada foram gerados através da combinação dos atributos destas seis diferentes imagens. Neste teste, foram selecionadas amostras de quatro classes: vegetação primária (verde), vegetação secundária (vermelho), pastagem (amarelo) e rio (azul). A imagem classificada (índice $Kappa = 0,6$) é mostrada na **Figura 3b**.

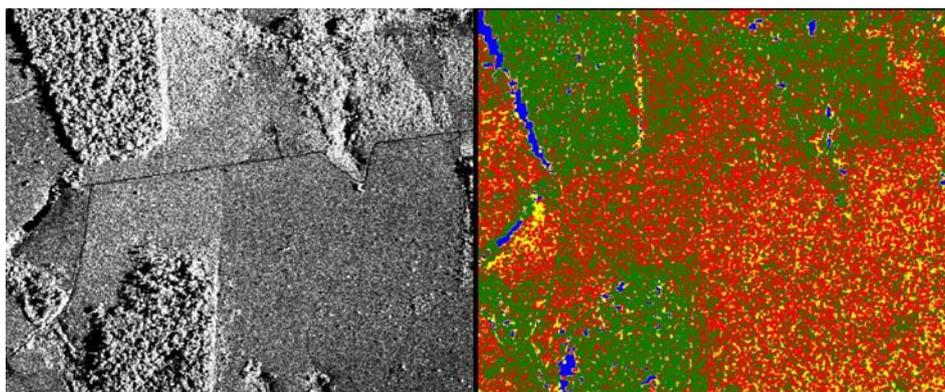


Figura 3 – (a) Imagem SAR (banda X, filtro Lee 5x5) e (b) o mapa temático resultante da aplicação da rede SOM+LVQ.

8. Conclusões

Os resultados obtidos até o momento refletem a viabilidade do método para o mapeamento da área em até quatro classes de uso do solo / cobertura da terra. Novos testes devem ser realizados a fim de avaliar a eficiência do método em distinguir outras classes ainda não incluídas, como áreas agrícolas. Devido ao alto custo computacional associado à grande quantidade de dados disponíveis, uma das maiores contribuições do trabalho consiste na possibilidade de diminuir os tempos de execução através do processamento distribuído. Por fim, observa-se a expectativa de obtenção de melhores índices através da incorporação de características não exploradas até o momento, como alguns parâmetros relativos à extração dos atributos de textura e ao treinamento da rede.

Referências

- Manjunath, B.S. and Ma, W.Y. Texture features for browsing and retrieval of image data, **IEEE Transactions on pattern analysis and machine intelligence**, vol. 18, pp. 837-842, 1996.
- Haykin, S. **Redes Neurais: Princípios e Prática**, 2 ed., Bookman, 2001.
- Fausett, L. V., **Fundamentals of Neural Networks: architectures, algorithms, and applications**, Prentice Hall, 1994.
- Tso, B. and Mather, P. **Classification Methods for Remotely Sensed Data**, Taylor & Francis, 2001.