

Aplicação de Redes Neurais Artificiais em Ambiente de Alto Desempenho para Classificação de Imagens SAR

Thalita Biazzuz Veronese
Instituto Nacional de
Pesquisas Espaciais – INPE
thalita@lac.inpe.br

Lamartine N. F. Guimarães
Instituto de Estudos
Avançados – IEAv
guimarae@ieav.cta.br

Maurício Pozzobon Martins
Instituto de Estudos
Avançados – IEAv
mauricio@ieav.cta.br

Resumo

Neste trabalho é proposto um modelo para estudo sobre a eficiência de métodos baseados em redes neurais artificiais na classificação de imagens SAR (Synthetic Aperture Radar), utilizando medidas de textura obtidas por filtros Gabor. Para isso, diferentes tipos de redes neurais artificiais devem ser incorporados, como SOM, Perceptron e ART. Serão implementadas técnicas de processamento distribuído em rede de computadores de baixo custo (PC), com o objetivo de avaliar o real ganho em desempenho. No desenvolvimento do projeto, será utilizado o método de Troca de Mensagens. O ambiente a ser utilizado para implementação é composto por computadores de processamento distribuído que integram o projeto B E L I E Ve, do Laboratório de Engenharia Virtual (L E V) do Instituto de Estudos Avançados (I E Av / Centro Técnico Aeroespacial) (<http://www.ieav.cta.br/efa/lev.htm>). As imagens a serem utilizadas foram obtidas do sensor SAR da aeronave de sensoriamento remoto do SIVAM, adquiridas em 13 de Setembro de 2004. A região de coleta situa-se no município de Machadinho d'Oeste – RO.

Palavras-chave: filtro Gabor, neurocomputação, classificação de texturas, SAR – Synthetic Aperture Radar, computação de alto desempenho.

1. Introdução

A classificação de imagens de sensoriamento remoto consiste em associar um rótulo de classe a cada pixel, com base em medidas extraídas da

imagem – geralmente do próprio pixel ou de seus vizinhos.

Uma imagem de sensoriamento remoto totalmente classificada é chamada de “Mapa Temático”, pois possibilita a identificação geográfica das classes sobre a superfície imageada [2]. Há diversas aplicações para a classificação de imagens de sensoriamento remoto, como, por exemplo, análise de culturas agrícolas, monitoramento e controle ambiental, planejamento urbano, etc.

Para classificação de imagens de sensoriamento remoto geradas a partir de sensores ópticos, várias técnicas têm sido desenvolvidas, aperfeiçoadas e utilizadas ao longo das últimas décadas. Entretanto, no caso das imagens obtidas a partir de sensores que atuam na faixa de microondas (radar), novas pesquisas são necessárias, já que muitas vezes técnicas de classificação consagradas para imagens ópticas não produzem resultados satisfatórios quando aplicadas a imagens radar, devido às características peculiares desse tipo de imagem – distorções causadas pela atmosfera, por exemplo.

Inaugurado em 25 de julho de 2002, o SIVAM (Sistema de Vigilância da Amazônia) (<http://www.sivam.gov.br>) tem o propósito de zelar pela Amazônia Legal Brasileira. Esta área, considerada a maior reserva natural do planeta, está sujeita a ações predatórias realizadas por madeireiras e garimpeiros ilegais, narcotraficantes e diversos tipos de ilícito.

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. O SIVAM dispõe de três aeronaves R-99B equipadas com sensores SAR (Synthetic Aperture Radar – Radar de Abertura Sintética) para gerar imagens radar da região. Em alguns minutos de voo é possível coletar dados de uma área de dezenas de quilômetros quadrados, a uma resolução espacial de 3 metros, resultando em uma imagem de mais de 1 gigabyte. Infelizmente, a facilidade em produzir esse grande volume de dados não é acompanhada pela velocidade de análise dos mesmos e a conseqüente geração de resultados aplicáveis ao propósito do SIVAM. Portanto, metodologias em Processamento de Alto Desempenho devem ser consideradas a fim de otimizar a manipulação dessa grande quantidade de dados.

Neste trabalho, é sugerida a implementação de um modelo para estudo sobre a eficiência de métodos baseados em redes neurais artificiais (RNA) na classificação de imagens SAR, utilizando medidas de textura obtidas por filtros Gabor [11]. Para isso, diferentes modelos de RNA devem ser incorporados, como SOM (Self-Organizing Map), Perceptron e ART. Nas diversas etapas de extração de atributos, treinamento e classificação, serão implementadas técnicas de processamento distribuído em rede de computadores de baixo custo (PC), a fim de avaliar o real ganho em desempenho. Serão utilizadas imagens obtidas pelo sensor SAR – SIVAM sobre Machadinho d'Oeste – RO, adquiridas em 13 de Setembro de 2004, gentilmente cedidas pela Divisão de Sensoriamento Remoto do Centro Técnico Aeroespacial (CTA). Como referência para a identificação visual de classes de texturas, serão utilizadas imagens ópticas SPOT, cedidas pela EMBRAPA.

2. Materiais e Métodos

2.1. Imagens obtidas por Radar de Abertura Sintética

A utilização de imageamento por radiação eletromagnética (REM) na faixa de microondas (radar) pelo setor civil é relativamente recente, iniciativa formalizada apenas em 1960. Graças ao seu poder de penetração em determinados tipos de materiais (como nuvens e chuvas), os radares imageadores são considerados ferramentas importantes para o sensoriamento remoto de áreas onde as condições meteorológicas se apresentam como fator restritivo à utilização de sistemas de sensores ópticos. Outra motivação para o uso do

imageamento por radar é que, por se tratar de um sistema ativo, isto é, independente da iluminação solar, ele pode ser empregado no período diurno ou noturno, sem perda de desempenho [15].

Entretanto, a informação gerada pelo radar é diferente da obtida por sensores ópticos. Imagens SAR apresentam um ruído do tipo multiplicativo específico conhecido como *speckle*, e condições geométricas especiais, que requerem estudos e desenvolvimentos especializados [3]. Características clássicas, como momento e borda, são freqüentemente comprometidas pelo *speckle*, sendo necessário um pré-processamento (filtragem) da imagem a fim de eliminar o ruído.

O sensor SAR que equipa as aeronaves de sensoriamento remoto R99B 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, W, HV e VH), modo interferométrico na banda X e resolução espacial variando de 1.8 a 18m.




Figura 1 – Imagem SAR gerada pelo sensor do SIVAM

2.2. Atributos de textura

A textura é um dos mais significativos atributos visuais utilizados como base para sistemas de classificação de imagens. Nos últimos anos, sua importância e utilidade em reconhecimento de padrões e visão computacional tem crescido significativamente, como é possível observar pela grande quantidade de trabalhos desenvolvidos nesta área [13]. Neste contexto, a eficiência na representação dos atributos de textura é essencial

para garantir o bom desempenho da busca e recuperação dos padrões.

Com a consolidação da teoria da transformada Wavelet, muitos pesquisadores passaram a estudar a aplicação de Wavelets à representação de texturas [13], [1], [8], [14], e [5].

Ao avaliar o desempenho de atributos de textura extraídos por várias transformadas Wavelet, incluindo transformadas ortogonais e bi-ortogonais, tipo árvore-estruturada e de Gabor, Manjunath e Ma [9] obtiveram melhor representação para os padrões de teste quando aplicada a transformada Wavelet de Gabor. A partir dos estudos de Manjunath e Ma, foram desenvolvidas metodologias robustas de busca e recuperação de padrões, incorporadas a projetos como a Biblioteca Digital Alexandria (ADL) e o sistema Netra.

Apesar de existir uma grande quantidade de pesquisas em recuperação de imagens baseada em conteúdo, poucas dedicam-se ao contexto das imagens de sensoriamento remoto [16]. Dentre estas, apenas uma pequena parte utiliza a abordagem baseada em conteúdo-atributo. Os classificadores a serem utilizados neste trabalho baseiam-se na metodologia proposta por Manjunath e Ma [10].

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

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

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:

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

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.

2.3. Classificadores baseados em Redes Neurais Artificiais

Uma das características mais importantes das RNA's é sua capacidade de reconhecer padrões, até mesmo ao lidar com informações ruidosas ou incompletas. Segundo Haykin [6], o reconhecimento de padrões é formalmente definido como o processo pelo qual um padrão recebido é atribuído a uma classe dentre um número predeterminado de classes (ou categorias).

Neste trabalho, diferentes metodologias de redes neurais artificiais serão testadas como classificadores de textura em imagens de radar. Para isso, amostras de textura pré-processadas (filtradas) extraídas de imagens SAR serão utilizadas para treinamento das redes. Na etapa de classificação, a imagem passa pelo processo de extração de atributos e é então submetida à rede já treinada, que gera como saída o mapa temático. A fim de garantir a verdade terrestre do modelo, serão utilizadas, para efeito de comparação com os resultados do classificador, imagens ópticas georreferenciadas cedidas pela EMBRAPA.

2.3.1. Perceptron

A teoria das redes *Perceptron* foi introduzida no final da década de 1950 por Frank Rosenblatt. Basicamente, o *Perceptron* de múltiplas camadas consiste em uma rede de neurônios artificiais dispostos em pelo menos três camadas: camada de entrada, camada oculta (uma ou mais) e camada de saída. Assumem-se pesos fixos entre as camadas de entrada e oculta, correspondendo ao padrão de entrada em treinamento, enquanto os pesos das conexões entre as unidades ocultas e de saída são ajustáveis através do processo de treinamento da rede.




Figura 2 – Perceptron de múltiplas camadas

Os pesos entre as unidades ocultas e de saída são ajustados através da regra de aprendizagem do algoritmo *backpropagation*. Para cada padrão de entrada apresentado no treinamento, a rede calcula a resposta da unidade de saída. A saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado. O processo se repete até que se atinja a saída desejada (alvo) ou um número máximo predeterminado de iterações.

A aprendizagem neste caso é do tipo supervisionada, ou seja, são conhecidos pela rede os padrões de saída associados a cada padrão de entrada. Finalizado o treinamento, é esperado que padrões de entrada similares aos padrões de treinamento produzam resultados semelhantes. A isso chama-se de capacidade de generalização da rede neural.

2.3.2. Mapas auto-organizáveis de Kohonen (SOM)

Proposto por Kohonen [7], o Mapa Auto-Organizável (SOM) é um modelo de RNA baseada em competição, isto é, na qual a rede deve escolher uma única unidade para responder a um dado padrão de entrada. A arquitetura consiste em uma estrutura alimentada adiante com uma única camada computacional de unidades arranjadas em linhas e colunas, como mostra a Figura 3.




Figura 3 - Grade bidimensional de neurônios [6]

Após inicializados os parâmetros da rede, o próximo passo é retirar uma amostra x do espaço de entrada; a amostra representa o padrão de ativação que é aplicado à grade. Encontra-se então a unidade vencedora, isto é, aquela que apresenta o melhor “casamento” com o vetor de entrada dado, o que

pode ser calculado pelo índice $i(x)$, usando o critério da mínima distância euclidiana.

Os vetores de peso sináptico de todos os neurônios são então ajustados usando a fórmula de atualização:

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x(n) - w_j(n)),$$

onde $h_{j,i(x)}(n)$ é a função de vizinhança centrada em torno da unidade vencedora $i(x)$.

A vizinhança topológica $h_{j,i}$ é uma função unimodal da distância $d_{j,i}$ (distância lateral entre a unidade vencedora i e a unidade excitada j), desde que ela satisfaça duas exigências:

- $h_{j,i}$ é simétrica em relação ao ponto máximo definido por $d_{j,i}=0$; em outras palavras, ela alcança seu valor máximo na unidade vencedora i para a qual a distância $d_{j,i}$ é zero;
- A amplitude de $h_{j,i}$ decresce monotonicamente com o aumento da distância lateral $d_{j,i}$, decaindo a zero para $d_{j,i} \rightarrow \infty$, esta é uma condição necessária para a convergência.

2.3.3. Aprendizagem por quantização vetorial (LVQ)

A Aprendizagem por Quantização Vetorial (LVQ – Learning Vector Quantization) é um método de classificação de padrões que visa refinar a definição das superfícies de decisão entre as classes, explorando informações conhecidas sobre os padrões de treinamento. Desta maneira, é possível aplicar o mapa auto-organizável de Kohonen para fazer um arranjo inicial dos pesos para a classificação dos padrões, e, em uma etapa posterior, o LVQ para fazer um ajuste fino e melhorar a capacidade de classificação da rede. O esquema do classificador neural baseado em atributos de textura resultante da integração das redes SOM + LVQ é mostrado na Figura 4.




Figura 4 – Classificador neural SOM+LVQ

O LVQ é uma rede supervisionada que requer uma coleção de exemplos de treinamento associados a classes ou categorias conhecidas. O número de unidades na camada de saída deve ser igual ao número de classes no conjunto de dados de treinamento.

2.3.4. Teoria da ressonância adaptativa (ART)

A Teoria de Ressonância Adaptativa (ART – Adaptive Resonance Theory), uma das mais complexas teorias de RNA's em uso atualmente, foi desenvolvida no final da década de 1980 por Carpenter e Grossberg.

As redes ART foram projetadas com o intuito principal de permitir ao usuário controlar o grau de similaridade de padrões associados a uma mesma categoria. A arquitetura básica de uma rede ART consiste em três grupos de unidades: um campo para processamento de entrada (camada *F1*), as unidades *cluster* (camada *F2*), e um mecanismo de reinicialização, responsável por controlar o grau de similaridade dos padrões associados a um mesmo *cluster*. A camada *F1* é composta de duas partes: entrada e interface. A porção interface combina sinais da porção entrada e da camada *F2*, para uso na comparação da similaridade entre o sinal de entrada e o vetor de pesos da unidade *cluster* candidata [4].

2.4. Processamento paralelo e distribuído

Um computador paralelo consiste basicamente em um computador – ou uma coleção de computadores – com múltiplos processadores capazes de trabalhar juntos na resolução de um problema.

Um sistema paralelizado deve ser organizado de forma a cumprir as seguintes etapas no processamento de suas tarefas [12]:

- Implementação da rede de interconexão entre processadores e módulos de memória;
- Projeto e implementação do software;
- Desenvolvimento dos algoritmos e estruturas de dados para a resolução do problema;
- Divisão dos algoritmos e estruturas de dados em subproblemas;
- Identificação das comunicações necessárias entre os subproblemas;
- Designação dos subproblemas aos processadores e módulos de memória.

Sistemas paralelos são tradicionalmente classificados de acordo com a notação de Flynn, que estabelece uma hierarquia cujos níveis variam entre SISD (single-instruction single-data) e MIMD (multiple-instruction multiple-data).

Este trabalho será desenvolvido em um ambiente composto por dois *clusters* baseados no conceito de

máquinas da classe *Beowulf*. O sistema *Beowulf*, do tipo MIMD, é composto por processadores autônomos (nós) interligados por meio de uma rede privada, com bibliotecas de comunicação por mensagem entre cada nó.

Neste sistema, a memória é distribuída, ou seja, cada processador tem uma memória local. Porém, todos os processadores têm acesso a essa memória fisicamente distribuída, utilizando um único espaço de endereçamento de memória, ou seja, como num sistema compartilhado. Isso é permitido através de um sistema de troca de mensagens (*message-passing*), que possibilita a transferência de dados entre memória e processador de forma automática.

A troca de mensagens é o método mais comumente utilizado para programação de sistemas MIMD. Basicamente, os processadores coordenam suas atividades enviando e recebendo mensagens explicitamente. Ambientes em forma de bibliotecas são responsáveis pela comunicação e sincronização dos processos, permitindo que algumas linguagens específicas de sistemas sequenciais possam ser utilizadas em ambientes paralelos.

O ambiente utilizado integra o projeto *BELIEVe*, do Laboratório de Engenharia Virtual (LEV) do Instituto de Estudos Avançados (IEAv/CTA) (<http://www.ieav.cta.br/efa/lev.htm>). Este projeto conta com dois *clusters beowulf*, conectados por uma rede de 100 Mb, sob o sistema operacional Linux. O primeiro *cluster* é composto por nove computadores com processadores Athlon de 1,3 GHz, 256 Mb de RAM, 20 Gb de disco; o segundo possui doze computadores com processador Athlon 2500+, 1 Gb de RAM e 40Gb de disco. O sistema de troca de mensagens utilizado é o *Message Passing Interface* (MPI). O MPI possui grupos de processos e rotinas para gerenciamento de tarefas, que podem ser utilizados em duas funções: especificação dos processos envolvidos em uma operação de comunicação e utilização dos grupos criados no processo de comunicação para introduzir o paralelismo dentro da aplicação.

A abordagem de programação adotada é o paralelismo de dados: uma estrutura de dados é distribuída entre os processadores, que executam as mesmas instruções, cada qual sobre sua parte da estrutura de dados. Assim, durante a etapa de extração de atributos, a imagem a ser processada é dividida entre os processadores, que executarão as tarefas de forma independente. Os dados gerados são, ao final do processo, convenientemente agrupados, constituindo a entrada para a próxima etapa.

3. Conclusão

Neste trabalho, descrevemos um projeto que visa construir um modelo de classificação de texturas imagens SAR, utilizando filtros Gabor e redes neurais artificiais. Ferramentas de processamento paralelo devem ser incorporadas a fim de avaliar o desempenho do modelo em redes de computadores de baixo custo. Espera-se, ao final do trabalho, obter um mapa temático sobre a região de coleta das imagens de Machadinho d'Oeste – RO, bem como uma avaliação do desempenho de diferentes classificadores neurais aplicados sobre imagens SAR, podendo futuramente estender o processo a alguns classificadores clássicos.

4. Referências

- [1] Chang, T. & Kuo, J. C. "Texture analysis and classification with tree-structured wavelet Transform", *IEEE Trans. Image Processing*, October 1993, vol. 2(4), pp. 429-441.
- [2] Crósta, A. P., *Processamento digital de imagens de sensoriamento remoto*, ed. rev., IG/UNICAMP, 1993.
- [3] Dutra, L. V., Mura, J. C., Freitas, C. C., Santos, J. R. dos & Elmiro, M. T., "Processamento de Imagens de Radar de Abertura Sintética – Princípios e Aplicações", *Anais do IV Workshop em Tratamento de Imagens*, 2003, pp. 4-13.
- [4] Fausett, L. V., *Fundamentals of Neural Networks: architectures, algorithms, and applications*, Prentice Hall, 1994.
- [5] Gross, M. H., Koch, R., Lippert, L. & Dreger, A. "Multiscale image texture analysis in wavelets spaces", *Proc. IEEE Int. Conf. on Image Processing*, 1994.
- [6] Haykin, S., *Redes Neurais, Princípios e Prática*, 2 ed., Bookman, 2001.
- [7] Kohonen, T. "Self-Organization and Associative Memory", *Springer-Verlag*, 1989, third edition.
- [8] Laine, A. & Fan, J. "Texture classification by wavelet packet signatures", *IEEE Trans. Pattern Recognition and Machine Intelligence*, 1993, vol. 15(11), pp. 1186-1191.
- [9] Manjunath, B. S., & Ma W. Y. "Image Indexing Using a Texture Dictionary", *In Proceedings of SPIE conference on Image Storage and Archiving System*, Oct. 1995, p. 288 – 298.
- [10] Manjunath, B. S., & Ma W. Y. "Browsing Large Satellite and Aerial Photographs", *International Conference on Image Processing*, Set. 1996, vol. 3.
- [11] Martins, M. P. "Classificador Neural de atributos de textura para busca e recuperação de imagens de Sensoriamento Remoto", 2003.
- [12] Pacheco, P. S., *Parallel Programming with MPI*, Morgan Kaufmann, 1997
- [13] Rui, Y., Huang, T. S. & Chang, S. "Image Retrieval: Current Techniques", *Promising Directions and Open Issues*, 1999.
- [14] Smith, R. J., & Chang, S. "Transform features for texture classification and discrimination in large image databases", *Proc. IEEE Int. Conf. on Image Processing*, 1994.
- [15] Ulaby, F. T., Moore, R. K. & Fung, A. K. *Microwave Remote Sensing: Active and Passive*, v. 2, Addison-Wesley, 1982.
- [16] Val Cura, L. M. del, N. J. Leite & Merdeiros, C. B. "An Architecture for Content-Based Retrieval of Remote Sensing Image", *IEEE*, 2000.