

CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO BASEADA EM TEXTURA POR REDES NEURAIAS

ADRIANO BELUCO¹
ALEXANDRE BELUCO²
PAULO MARTINS ENGEL³

¹CEPSRM - Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia
UFRGS - Universidade Federal do Rio Grande do Sul
Av. Bento Gonçalves, 9500 - 91501-970 - Porto Alegre - RS, Brasil
limiar@logic.com.br

²IPH – Instituto de Pesquisas Hidráulicas - UFRGS
Av. Bento Gonçalves, 9500 Cx. Postal 15029 - 91501-970 - Porto Alegre - RS, Brasil
abeluco@iph.ufrgs.br

³CPGCC - Curso de Pós-Graduação em Ciências da Computação - UFRGS
Av. Bento Gonçalves, 9500 - 91501-970 - Porto Alegre - RS, Brasil
engel@inf.ufrgs.br

Resumo. Este artigo descreve um método de classificação de imagens de sensoriamento remoto que integra a importância de atributos de textura na seleção de feições com a eficiência das redes neurais artificiais no processo de classificação. O processo de classificação consiste em uma filtragem por Gabor seguida de uma classificação com a aplicação de redes neurais. A classificação é baseada em uma rede neural artificial multi nível com algoritmo “backpropagation”. Alguns resultados de experimentos com imagem sintética e com imagem de sensoriamento remoto são apresentados e discutidos.

Palavras chave: sensoriamento remoto, redes neurais, filtro de Gabor, textura, processamento de imagens, classificação de imagens.

Abstract. This paper describes a method for classification of remote sensing images integrating the importance of texture with the efficiency of the artificial neural networks. The classification process consists of applying Gabor filters followed by neural network classification. This classification is based on a multi-layer perceptron neural network with backpropagation algorithm. Some results of experiments with synthetic and remote sensing images are presented and discussed.

Keywords: remote sensing, neural network, gabor filtering, texture, image processing, image classification.

1. Introdução

O objetivo deste trabalho é propor uma metodologia de classificação de imagens de sensoriamento remoto que integre a importância de atributos de textura na seleção de feições com a eficiência das redes neurais artificiais no processo de classificação. A seleção das características texturais é realizada através da utilização de frequências espaciais de cada classe textural e sua direção por um processo de filtragem da imagem com um banco de filtros de Gabor. A classificação da imagem é realizada pela rede neural artificial multinível com algoritmo Backpropagation, num processo pixel a pixel. Para tanto, o treinamento da Rede neural foi realizada com dados retirados de amostras de cada textura da imagem original. A rotulação feita pela rede neural, e baseada nas texturas, gera a imagem classificada.

O processo de filtragem é realizado pela convolução da imagem original com cada filtro, gerando um número de imagens filtradas igual ao número de filtros existentes. Tal processo é realizado por uma janela que faz a varredura da imagem. As dimensões da janela são específicas de cada filtro. Cada imagem filtrada identifica uma determinada frequência

espacial, podendo ser designada como uma banda textural. Dessa forma, é montada uma imagem formada pelas "bandas texturais" obtidas na filtragem.

A classificação da imagem é realizada pela rede neural artificial num processo pixel a pixel. Para tanto, fez-se necessário o treinamento da RNA com dados retirados de amostras de cada textura da imagem original. A rotulação feita pela rede neural, e baseada nas texturas, gera a imagem classificada.

A metodologia desenvolvida nesta dissertação está baseada fundamentalmente nos trabalhos de Jain e Farroukhnia (1991), Raghu et al (1995) e Angelo (2000).

Jain e Farroukhnia (1991) propõem um algoritmo inspirado na técnica de filtragem multicanal para a segmentação de textura que usa um banco de filtros de Gabor para caracterizar os canais texturais. Para tal, utilizam um esquema sistemático de seleção de filtro baseado na reconstrução da imagem de entrada através das imagens filtradas. Raghu et al (1995) apresentam uma estrutura de rede neural de dois estágios, combinando as características de um mapa auto-organizável (SOM) a um perceptron multi-camadas (MLP). Numa etapa anterior, utilizam uma técnica de filtragem multicanal para a extração de características texturais. Os canais são constituídos por um banco de filtros de Gabor com diferentes dimensões, orientações e frequências. Angelo (2000) utilizou a técnica de filtragem multicanal, através de filtros de Gabor, juntamente com o método de Máxima Verossimilhança Gaussiana, para propor um método de classificação supervisionado em imagens digitais com base em atributos de textura.

A aplicação de técnicas de filtragem multicanal para extração de características texturais vem sendo amplamente utilizada na classificação de imagens digitais provenientes de Sensoriamento Remoto. Da mesma forma, as Redes Neurais têm se mostrado de grande utilidade no processo de classificação destas imagens.

2. Filtros de Gabor

Os filtros de Gabor são um conjunto de funções senoidais complexas, bidimensionais, moduladas por uma função Gaussiana também bidimensional e que apresentam certas propriedades extremamente úteis para fins de classificação de imagens. Neste processo, são criados bancos de filtros de Gabor com a finalidade de extrair as feições texturais presentes numa imagem. Daugman(1988) mostra que os filtros de Gabor são adequados à análise textural, no sentido em que minimizam a incerteza conjunta, nos domínios espacial e no domínio de frequências espaciais, permitindo, desta forma, selecionar feições cujas características ficam determinadas por frequências espaciais diretamente no domínio espacial, sem a necessidade de desenvolver operações no domínio de Fourier ou das frequências.

A estrutura local da textura, nos vários canais utilizados, é descrita pela frequência e pela orientação, que são definidas pela função senoidal no filtro de Gabor. O envelope Gaussiano define as resoluções espaciais com que as estruturas de textura são caracterizadas. A forma geral da Função de Gabor bidimensional é dada através da equação:

$$g(x, y, \sigma_x, \sigma_y, k_x, k_y) = A \cdot \exp \left\{ -\frac{1}{2} \left[\left(\frac{x}{\sigma_x} \right)^2 + \left(\frac{y}{\sigma_y} \right)^2 \right] + 2\pi i (k_x x + k_y y) \right\}$$

onde A é um fator de escala e (σ_x, σ_y) definem a extensão espacial da função de Gabor. A orientação da grade senoidal é fornecida por $\text{tg}^{-1} \left(\frac{k_y}{k_x} \right)$. A frequência da onda senoidal é dada

por $k = (k_x, k_y)$, onde k_x, k_y são suas componentes ao longo dos eixos x e y, respectivamente. O módulo de k é dado por $|k| = \sqrt{k_x^2 + k_y^2}$.

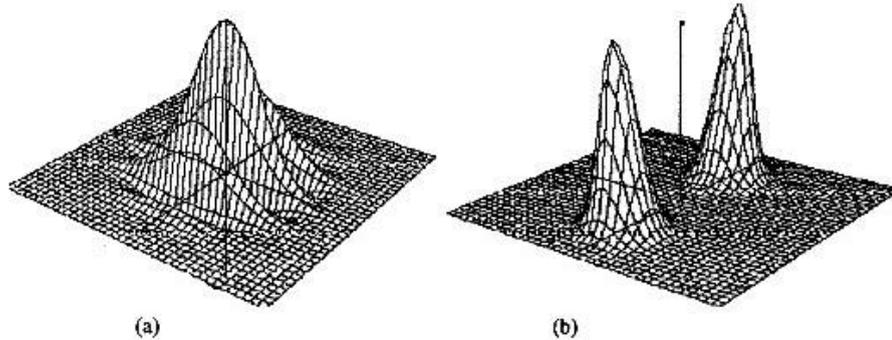


Figura 1. Componente real do filtro de Gabor bidimensional no domínio espacial (a); resposta de frequência do filtro definido em a (b). Adaptado de Angelo (2000).

A imagem processada por um filtro de Gabor é obtida através da convolução da imagem com a função de Gabor, que pode ser implementada tanto no domínio das frequências como no domínio espacial (Raghu, 1995). Após o processo de convolução obtém-se uma imagem filtrada formada por valores imaginários. A imagem assim formada, por conter uma componente imaginária, não pode ser diretamente representada. Segundo Angelo, uma alternativa consiste na representação através de valores absolutos ou o quadrado deste, conhecido como energia. A energia de cada pixel é dada por:

$$f(x, y) = |I(x, y) * g(x, y)|^2$$

onde * significa convolução, $I(x, y)$ representa a imagem original e $g(x, y)$ o filtro de Gabor, tomado com os parâmetros $k_x, k_y, \sigma_x, \sigma_y$.

3. Perceptron Multi-camadas com algoritmo Backpropagation

As redes neurais podem ser interpretadas como transformadoras de dados (Pao, 1989), onde o objetivo é associar os elementos de um grupo de dados com os elementos de um segundo conjunto. Quando aplicado à classificação, por exemplo, existe o interesse na transformação de dados do espaço de características para o espaço de classes. Por pertencerem à mesma classe de técnicas que o reconhecimento de padrões e a regressão linear, e visto a sua importância, as Redes Neurais Artificiais têm sido frequentemente utilizadas no sensoriamento remoto, principalmente por permitir o manuseio de grandes quantidades de dados.

O perceptron multicamadas (*Multi Layer Perceptron*), que é uma das redes neurais artificiais mais utilizadas no sensoriamento remoto, pode separar dados que são não-lineares e, geralmente, consiste de 3 ou mais tipos de camadas. Para o início do processo de aprendizado da rede neural faz-se necessária a seleção de um conjunto de amostras das classes de padrões (conjunto de treinamento) a serem aprendidos e as saídas desejadas correspondentes. Para cada classe, devem ser selecionadas amostras representativas e em número suficiente.

Basicamente, esta rede apresenta três ou mais camadas de neurônios: uma de entrada (input layer), uma ou mais intermediárias (hidden layer) e uma de saída (output layer). A sua topologia é completamente interconectada para frente (feedforward), com retroalimentação, onde nenhuma conexão passa diretamente por sobre uma outra mais a frente (figura 2).

A definição do número de neurônios das camadas de entrada e saída é realizada de acordo com o problema ao qual a rede solucionará. O número de neurônios intermediários, ou

mesmo o número de camadas intermediárias, é definido de forma intuitiva, não havendo, portanto, uma regra que defina o seu número. Se o número de neurônios definido for muito alto, isto pode fazer com que apenas alguns neurônios especializem-se em características úteis, porém, se o contrário ocorrer e o número de neurônios for insuficiente, pode acontecer da rede não conseguir aprender os padrões desejados.

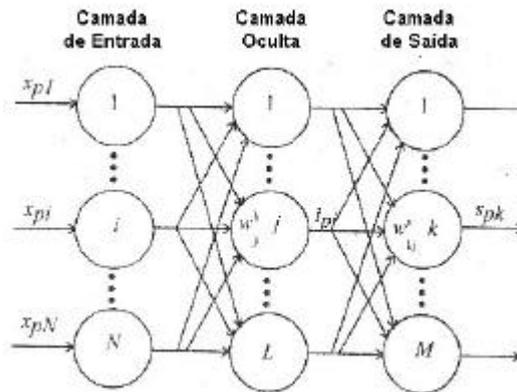


Figura 2. Topologia de uma RNA Multinível com Backpropagation (Lieberman, 1997).

A característica de grande importância deste modelo é o aprendizado supervisionado baseado em duas etapas: propagação e adaptação.

O treinamento (*supervised-learning*) consiste em fornecer à rede um conjunto de estímulos (padrões de entrada) e a saída desejada correspondente, onde o primeiro padrão de entrada é propagado até a saída (fase de propagação). Já na fase de adaptação, um sinal de erro na saída é computado e transmitido de volta para cada neurônio da camada intermediária que contribuiu para a saída obtida. Sendo assim, cada neurônio da camada intermediária recebe somente uma parte do erro total, conforme a contribuição relativa que o neurônio teve na saída gerada. Este processo repete-se, camada por camada, até que cada neurônio da rede receba o seu correspondente. Tal processo recebe o nome *Backpropagation*, pois o aprendizado baseia-se na propagação retrógrada do erro para níveis superiores da rede.

De acordo com o erro recebido pelo neurônio associado, os pesos existentes nas conexões entre os neurônios são atualizados. Esta regra de aprendizado é uma generalização da regra LMS (Least Mean Square Error), também conhecida como Regra Delta (Todt, 1998).

Com as devidas alterações de pesos, o processo de aprendizado permanece até o momento em que a saída obtida pela rede neural, para cada um dos padrões de entrada, seja próxima o bastante da saída desejada, de forma que a diferença entre ambas seja aceitável. Esta diferença é obtida através do cálculo do Erro Médio Quadrado. Considera-se diferença aceitável aquela que for menor ou igual a um erro previamente estipulado (1% ou 0,5%, em média).

4. Classificação de imagens obtidas por sensoriamento remoto com redes neurais

O processo de filtragem e classificação de imagens por redes neurais baseado em características texturais, proposto neste trabalho, foi testado em imagens sintéticas e reais. Os experimentos envolvendo as imagens sintéticas têm o objetivo de determinar a acurácia do processo. Já a utilização de imagens reais permite avaliar o comportamento da metodologia quando aplicada a imagens obtidas por sensoriamento remoto.

A imagem sintética usada no primeiro experimento foi obtida a partir de texturas reais extraídas do álbum fotográfico de Brodatz (Brodatz, 1966). Numa segunda etapa, utiliza-se uma imagem digitalizada em formato raster da região metropolitana do município de Porto Alegre (RS), caracterizada por classes de textura distintas.

Os experimentos foram desenvolvidos através de fases bem definidas: extração de frequências características a cada classe textural; formação dos filtros de Gabor correspondentes a cada frequência espacial selecionada; convolução da imagem com cada filtro de Gabor; treinamento da rede neural artificial para a constituição do classificador baseado em redes neurais; e, finalmente, a classificação da imagem.

4. Experimento utilizando imagem sintética

A imagem mosaico está ilustrada na figura 3. Visto que o processo de filtragem se trata de uma abordagem supervisionada, é necessária a extração de amostras da cada classe.

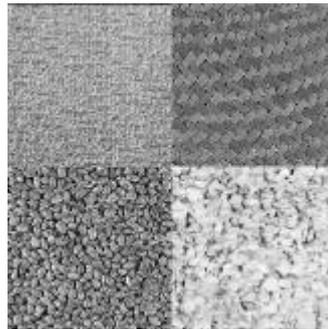


Figura 3. Imagem mosaico sintética de 256 x 256 pixels composta por microtexturas de Brodatz.

A seleção de frequências para a determinação dos filtros de Gabor em cada experimento é realizada através do conhecimento de um "especialista", a partir das frequências de cada amostra que apresentem os maiores níveis de energia. Este processo de seleção de frequências é feito com base no espectro de Fourier de cada amostra de cada classe da imagem.

Neste experimento, foram empregadas como parâmetros de entrada as 25 imagens filtradas de através dos filtros de Gabor. A rede neural artificial utilizada para a classificação da imagem sintética neste experimento usa 25 neurônios na camada de entrada, 28 neurônios na camada intermediária e 4 neurônios na camada de saída.

A figura 4 ilustra a imagem obtida após a classificação através da RNA, pixel a pixel, da imagem sintética (figura 3).

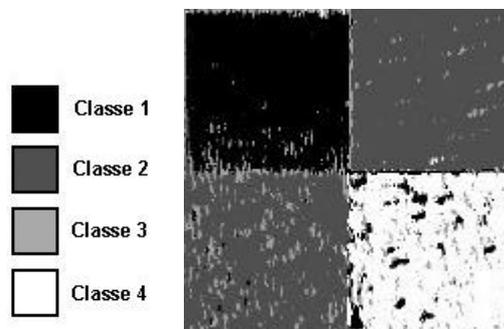


Figura 4. Imagem classificada referente ao experimento utilizando a imagem sintética da figura 3.

Para a avaliação do processo de classificação utilizou-se a Matriz de Erro, forma padrão para informar o erro local específico (Angelo, 2000). Segundo a matriz de erro, a

imagem classificada da figura 4 obteve sucesso na classificação de 89,05 % dos pixels da imagem sintética original (figura 3).

5. Experimento utilizando imagem obtida por sensoriamento remoto

A imagem digital utilizada neste experimento abrange parte da cidade de Porto Alegre (RS - Brasil) e região metropolitana, como pode ser visto na figura 5. As dimensões desta imagem são de 256 x 256 pixels e o fator preponderante de seu uso para o experimento é a existência de três classes texturais distintas: água, urbana e vegetação. A região urbana é caracterizada pela região da cidade de Porto Alegre, a classe de água é representada pela região da laguna do Guaíba e a vegetação refere-se à área composta pelas ilhas do delta do Jacuí.

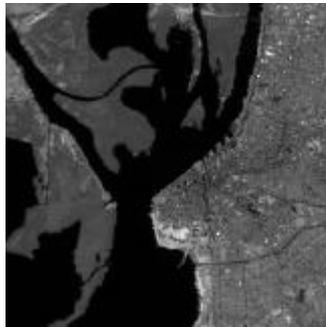


Figura 5. Imagem digital de parte da cidade de Porto Alegre (RS - Brasil) e entorno.

Os filtros necessários para a seleção de feições na imagem acima foram baseados nas amostras das classes água, urbana e vegetação. As dimensões das janelas utilizadas para a coleta das amostras devem ser suficientes para caracterizarem as texturas de cada classe presente na imagem. A seleção de frequências para a determinação dos filtros de Gabor em cada experimento é realizada através do conhecimento de um "especialista", a partir das frequências de cada amostra que apresentem os maiores níveis de energia. Este processo de seleção de frequências é feito com base no espectro de Fourier de cada amostra de cada classe da imagem.

Os 18 filtros de Gabor geram 18 imagens filtradas. A classificação da imagem pela RNA no experimento ocorrerá através de um processo pixel a pixel onde os parâmetros de entrada da RNA serão os valores do contador digital (CD) de um pixel nas 18 "bandas texturais" (imagens filtradas).

A rede neural artificial utilizada para a classificação da imagem obtida por sensoriamento remoto neste experimento usa 18 neurônios na camada de entrada, 20 neurônios na camada intermediária e 3 neurônios na camada de saída.

A figura 6 ilustra a imagem obtida após a classificação através da RNA, pixel a pixel, da imagem. Com base na matriz de erro, a imagem classificada dessa figura obteve sucesso na classificação de 85,15 % dos pixels da imagem real original (figura 5).



Figura 6. Imagem classificada referente ao experimento utilizando uma imagem real (figura 5).

6. Considerações finais

A filtragem através dos filtros de Gabor, bem como a classificação das imagens filtradas decorrentes pelas redes neurais artificiais, foi processada no software MATLAB for Windows, desenvolvido pela Math Works, Inc., versão 5.3.

No âmbito geral da aplicação dos filtros de Gabor na imagem original, este processo gera um número de imagens filtradas igual ao número de filtros aplicados. Portanto, cada pixel passa a ser descrito por um vetor cuja dimensionalidade é igual ao número de filtros utilizados. Da mesma forma que em imagens multi-espectrais, as imagens resultantes da filtragem podem ser denominadas de "canais ou bandas texturais" (ANGELO, 2000).

A função de ativação selecionada para as RNAs utilizadas foi a função tangente hiperbólica, pois converge mais rapidamente. O algoritmo de BackPropagation utilizado nas RNAs baseia-se no Gradiente descendente do Erro (minimização do erro médio quadrado). O processo de classificação realizado pelas RNAs é feito diretamente a partir dos níveis de cinza dos pixels de cada uma das imagens decorrentes do processamento pelos filtros de Gabor, que extraíram as frequências espaciais associadas às diferentes classes presentes nas imagens. Portanto, cada neurônio da camada de entrada recebe a informação do mesmo pixel referente a cada uma das imagens filtradas de Gabor. O número de neurônios da camada de saída da rede será igual ao número de classes existentes na imagem. Havendo 4 classes definidas, teremos uma camada de saída com quatro neurônios.

De uma forma geral, a metodologia composta por uma etapa de extração de frequências espaciais de cada classe presente na imagem (filtragem de Gabor), aliada a um processo de classificação baseado em redes neurais multi-layer perceptron com algoritmo backpropagation obteve bons resultados, instigando a continuidade de pesquisas envolvendo o uso de redes neurais artificiais na classificação de imagens obtidas por sensoriamento remoto.

Referências

- Angelo, N. P. Aplicação de filtros de Gabor no processo de classificação de imagens digitais com base em atributos de textura. (Dissertação de mestrado) Universidade Federal do Rio Grande do Sul - *Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia*, 2000, 137p.
- Beluco, A. Classificação de imagens de sensoriamento remoto baseada em textura por redes neurais. (Dissertação de mestrado) UFRGS - CEPSRM, 2002, 127p.
- Brodatz, P. T. Textures: a photogrametric album for artists and designers. New York: Dover, 1966. 143 p.
- Daugman, J. D. Complete discrete 2-d Gabor transforms by neural networks for image analysis and compression. In: IEEE Trans. Acoustics, Speech and Signal Processing. V. 36, p. 1169 - 1179, 1988.
- Freeman, J. A., Skapura, D. M. Neural networks, algorithms, applications and programming techniques. New York: Addison-wesley, 1991. 360 p.

Jain, A. K., Farrokhnia, F. Unsupervised texture segmentation using Gabor filters. In: Pattern Recognition, v. 24, n. 12, p. 1167-1186, 1991.

Kanellopoulos, I.; Wilkinson, G. G. Strategies and best practice for neural network image classification. In: International Journal of Remote Sensing, v. 18, n 4, p. 711-726, 1997.

Lieberman, F. Classificação de imagens digitais por textura usando redes Neurais. (Dissertação de mestrado) Universidade Federal do Rio Grande do Sul - CPGCC, 1997, 86 p.

Pao, Y. H. Adaptive pattern recognition and neural networks. New York: Addison-Wesley, 1989, 301 p.

Raghu, P. P., Poongodi, R., Yegnanarayana, B. A combined neural network approach for texture classification. In: Neural Networks, v. 8, n. 6, p. 975-987, 1995.

Todt, V. Avaliação do desempenho de classificadores neurais para aplicações em sensoriamento remoto. (Dissertação de mestrado) UFRGS - CEPSRM, 1998, 274p.