

UMA COMPARAÇÃO ENTRE O MÉTODO DE MÁXIMA VEROSSIMILHANÇA GAUSSIANA E UMA REDE NEURAL ARTIFICIAL COM BACKPROPAGATION NA CLASSIFICAÇÃO DE ESPÉCIES VEGETAIS

Viviane Todt¹, Paulo M. Engel², Pedro R. de A. Madruga³

Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM)
Universidade Federal do Rio Grande do Sul (UFRGS)
Av. Bento Gonçalves, 9500 - Campus do Vale - Caixa Postal 15044
CEP: 91501-970 - Porto Alegre - RS - Brasil
Tel. (051) 339-1355 R: 6221
E-mail: {vivi,engel}@inf.ufrgs.br

¹ Bacharel em Informática, PUCRS 1994; aluna de Mestrado do CEPSRM/UFRGS

² Doutor Engenheiro (Dr. Ing), Munique, Alemanha 1986; Professor do CPGCC/UFRGS e do CEPSRM/UFRGS

³ Doutor Engenheiro, Curitiba, Brasil 1992; Professor do CEPSRM/UFRGS e do Depto da Geodésia/Instituto de Geociências; Especialista da área de Engenharia Florestal

RESUMO

Este trabalho apresenta uma comparação entre o método de Máxima Verossimilhança Gaussiana e uma Rede Neural Artificial Multinível com BackPropagation na classificação de espécies vegetais em imagens multiespectrais. A área de estudo situa-se no estado do Rio Grande do Sul, Brasil, a cerca de 290 Km da capital do estado - Porto Alegre. A classificação realizada por ambos os métodos, utilizando-se imagens do satélite Landsat 5-TM, identifica as espécies vegetais: *Pinus*, *Eucalyptus*, *Acácia Negra* e *Mata Nativa*, que predominam na região.

ABSTRACT

This paper shows a comparison between the Gaussian Maximum Likelihood method and a BackPropagation Neural Network in classification of vegetable kinds in multiespectral images. The study area is within Rio Grande do Sul state, Brazil, about 181 miles of city of state - Porto Alegre. The classification accomplished for both methods, using satellite Landsat 5-TM images, recognizes the vegetable kinds: *Pinus*, *Eucalyptus*, *Acácia Mearnsii* and *Native Forest*, that predominate in the region.

1. INTRODUÇÃO

Atualmente, grande parte da superfície terrestre encontra-se imageada por satélites, como o Landsat 5-TM (americano) ou o SPOT (francês). As imagens obtidas por estes satélites podem ser processadas em computadores e, posteriormente, analisadas para o monitoramento de áreas da superfície terrestre. Através destas imagens, podemos identificar áreas de vegetação, água, solo exposto, ou áreas com cultivo de trigo e soja, ou até mesmo, podemos reconhecer tipos de vegetação ou tipos de rochas.

Os satélites mais recentes, como o Landsat 5-TM, fornecem imagens multiespectrais de cada área imageada. Isto ocorre, pois o Landsat possui um conjunto de 7 sensores (7 bandas), cada qual imageando a superfície terrestre em um determinado intervalo de comprimento de onda. Como cada alvo comporta-se diferentemente em cada região do espectro-eletromagnético, resultando em um comportamento diferente em cada banda, ao analisarmos as diversas bandas do satélite, podemos classificar os diversos alvos em classes que sejam de nosso interesse. A figura 1.1 mostra o comportamento de alvos como água, vegetação e solo exposto nos diversos comprimento de onda do espectro-eletromagnético e nas bandas do Landsat 5-TM.

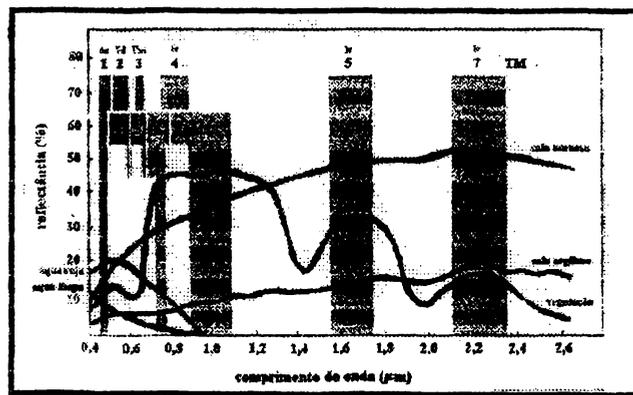


Figura 1.1 - Relação das faixas espectrais dos sensores do Landsat TM e reflectância espectral de alvos da superfície terrestre

A análise destas imagens multiespectrais pode ser executada manualmente, o que é extremamente custoso e um tanto subjetivo, pois depende de como o analista enxerga a área a ser classificada, ou pelo uso de técnicas computacionais.

Tradicionalmente, a análise de imagens multiespectrais tem sido executada, em computadores, pelo uso de classificadores que baseiam-se no Teorema de Bayes.

Mais recentemente, as Redes Neurais Artificiais (RNA's) têm sido utilizadas como uma opção para a análise multiespectral. Conforme Milidiú (1995), "as RNA's são de inspiração biológica, pois possuem forte analogia com os comprovadamente eficientes sistemas biológicos" e são adequadas para a resolução de problemas complexos, como é o caso da classificação de padrões em imagens multiespectrais.

Desta forma, surge a seguinte questão: até que ponto os classificadores tradicionais são satisfatórios na identificação de alvos em imagens multiespectrais? As RNA's podem vir a contribuir no aumento do índice de uma classificação correta?

Este artigo é parte de uma dissertação de mestrado, intitulada "Avaliação de Desempenho de Classificadores Neurais para Aplicações em Sensoriamento Remoto", e que está sendo desenvolvida no Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, na Universidade Federal do Rio Grande do Sul.

2. REVISÃO BIBLIOGRÁFICA

Tradicionalmente, a análise de imagens multiespectrais é realizada por classificadores que baseiam-se no Teorema de Bayes.

Os classificadores Bayesianos são, teoricamente, ideais quando as hipóteses sobre as distribuições de probabilidade são corretas para as diversas classes existentes na imagem. Entretanto, a necessidade em obter-se um modelo probabilístico específico é a maior limitação desta abordagem. Assim, resultados ruins de classificação podem ser obtidos, se as probabilidades de densidade são diferentes daquelas assumidas pelo modelo.

Usualmente, utiliza-se o modelo de Máxima Verossimilhança Gaussiana que é um classificador Bayesiano com distribuição de probabilidade gaussiana. Desta forma, consideramos que as distribuições internas de cada classe da imagem a ser classificada possui distribuição normal.

Entretanto, conforme Seibert (1992) os dados das imagens multiespectrais não apresentam distribuição de probabilidade gaussiana e, portanto, classificadores gaussianos não seriam a melhor técnica de classificação para estas imagens.

As RNA's são uma alternativa para uma variedade de problemas de classificação. Publicações recentes, como Bischof et al. (1992), Machado (1993) e An et al. (1995), têm mostrado o sucesso das aplicações de Redes Neurais para a classificação de imagens multiespectrais de satélites de Sensoriamento Remoto.

Classificações de tipos de rochas por BP, na região do norte do Canadá, são apresentadas em An et al. (1995). Além dos resultados da classificação, este estudo apresenta uma análise sobre a importância de obter-se uma quantidade suficiente de amostras significativas, para as etapas de treinamento e reconhecimento de uma RNA, com a finalidade de obter-se uma classificação satisfatória.

Heermann et al. (1992) apresenta um estudo focalizado na classificação de tipos de vegetação dos arredores de Chernobyl, enquanto que Machado (1993) utiliza BP para classificar áreas na Amazônia. Neste estudo, imagens do Landsat-TM que cobrem a região da Amazônia são classificadas em: floresta, cerrado, água, área desflorestada, nuvem, sombra e bruma.

De maneira semelhante, Bischof et al. (1992) realiza a aplicação de uma rede BP, de três níveis, para a classificação de imagens de satélite em uma base pixel-a-pixel. Cenas do Landsat-TM, dos arredores de Viena, foram classificadas em: área urbana, área agrícola, floresta e água.

Além disto, é possível utilizar-se BP para a classificação de imagens multiespectrais para supervisionar e interpretar danos em florestas, contribuindo de forma destacada na área de proteção ambiental (Engel, 1993).

A habilidade de aprendizado em RNA's fornecem um interesse alternativo aos classificadores Bayesianos. Por não ser necessário definir um modelo de probabilidade, as RNA's são ditas universais.

Algumas desvantagens da classificação por técnicas convencionais em relação às técnicas de Redes Neurais são relatadas em Vasconcelos (1995). Entre elas, pode-se dizer que um classificador Bayesiano necessita de suposições teóricas a respeito da distribuição de probabilidade das classes de padrões, o que dificilmente é observada na prática.

Em contrapartida, as RNA's são técnicas não-paramétricas, que podem ser utilizadas para estimar uma função de mapeamento entre padrões de entrada e classes (padrões de saída) associados, com o uso de um conjunto de pares de treinamento (An et al., 1995).

Trabalho encontrado em Seibert (1992), cujo objetivo era diferenciar áreas arborizadas intactas de áreas devastadas devido a tempestades, expõe alguns bons resultados de classificadores neurais sobre métodos convencionais. Neste trabalho, o autor relata que "resultados obtidos com Redes Neurais, como BackPropagation e Mapas de Características de Kohonen, mostraram ser mais favoráveis do que classificações por Máxima Verossimilhança e outros classificadores convencionais. Isto se deve ao fato de que o método clássico de Máxima Verossimilhança é baseado em condições matemáticas inflexíveis, quando em geral, BP é apta a determinar áreas no espaço de características com boa exatidão"

Huang et al. (1987) e Benediktsson et al. (1990) também apresentam resultados de comparação entre um classificador neural BP e métodos estatísticos de classificação.

Devido a grande viabilidade e utilidade das Redes Neurais Artificiais na classificação de imagens multiespectrais, o presente trabalho empregou esta técnica em uma situação real no estado do Rio Grande do Sul (RS), Brasil. Pretendia-se identificar espécies vegetais (*Pinus*, *Eucalyptus*, *Acácia Negra* e *Mata Nativa*) de grande interesse econômico para a região.

3. ÁREA DE ESTUDO

A área de estudo localiza-se no estado do Rio Grande do Sul, Brasil, em uma região que compreende Montenegro, Charqueadas e parte do Rio Guaíba até Arroio dos Ratos (cerca de 290 Km de Porto Alegre - capital do estado).

A imagem do satélite Landsat 5-TM utilizada é a de órbita 221/81, quadrante A, adquirida em 28/08/89.

A área possui aproximadamente 42 x 42 Km e pode ser geograficamente localizada nas seguintes coordenadas UTM: 6699,000 - 406,000 e 6657,000 - 448,000.

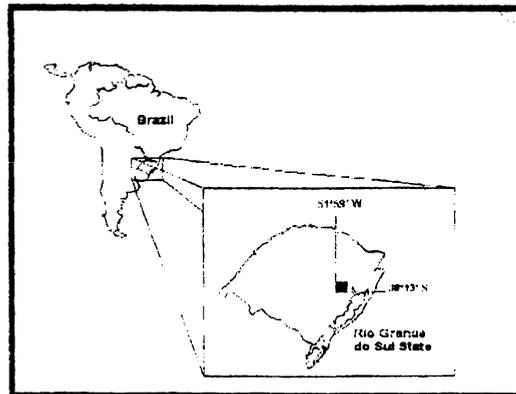


Figura 3.1 - Localização da Área de Estudo. Fonte: (Deppe,1995)

Esta região foi selecionada por ser significativa em termos de reflorestamento, por ter uma boa variação de espécies vegetais, por ser de fácil acesso (é uma região bem servida de rodovias, o que facilitou idas a campo) e por ser de grande interesse econômico às empresas de celulose, tanino, postes, energia e de madeiras do centro de Porto Alegre que estão interessadas em comprar determinadas espécies vegetais.

4. MÁXIMA VEROSSIMILHANÇA GAUSSIANA

Sendo X um vetor de componentes cujos valores são os níveis de cinza de um pixel, em cada uma das bandas consideradas, e W_i sendo a classe i , uma das "n" possíveis classes pré-definidas; como classificar um pixel X em uma classe W_i ?

No método de Máxima Verossimilhança, um pixel X pertence a uma classe W_i se

$$P(W_i/X) > P(W_j/X), \forall j \neq i \quad [1]$$

Nota-se que $P(W_i/X)$ é a probabilidade de X pertencer a classe W_i , ou pode-se dizer que é a verossimilhança de X em relação à classe W_i .

Desta forma, a questão principal é determinar a $P(W_i/X)$, sendo $i=1..n$. Para tanto, temos pelo Teorema de Bayes que:

$$P(W_i/X) = \frac{P(X/W_i) \cdot P(W_i)}{P(X)} \quad [2]$$

$P(W_i)$ é a probabilidade de ocorrência da classe i na imagem. É a probabilidade considerada “a priori”, pois é obtida pelos conhecimentos que o especialista tem sobre a região. $P(X)$ é a probabilidade de encontrarmos um pixel de qualquer classe na posição X . $P(X/W_i)$ é a distribuição de probabilidade de X dado uma classe W_i , ou seja, é a probabilidade interna da classe i . Esta probabilidade é obtida através de amostras das diversas classes.

Substituindo $P(W_i/X)$ da relação [1], conforme o Teorema de Bayes, temos:

$$X \in W_i, \text{ se } \frac{P(X/W_i) \cdot P(W_i)}{P(X)} > \frac{P(X/W_j) \cdot P(W_j)}{P(X)}, \quad \forall j \neq i \quad [3]$$

Sendo $P(X)$ um termo comum, este pode ser eliminado de [3]. Assim:

$$X \in W_i, \text{ se } P(X/W_i) \cdot P(W_i) > P(X/W_j) \cdot P(W_j), \quad \forall j \neq i \quad [4]$$

Algumas vezes, dependendo da aplicação, assume-se que as probabilidades de ocorrência das “n” classes são iguais, o que simplifica ainda mais a relação obtida em [4]. Desta forma obtemos:

$$X \in W_i, \text{ se } P(X/W_i) > P(X/W_j), \quad \forall j \neq i$$

Para o método de Máxima Verossimilhança **Gaussiana**, assume-se que as amostras possuem distribuição normal de probabilidade nas diversas classes. Logo, $P(X/W_i)$ é dada por:

$$P(X/W_i) = [(2\pi)^{-n/2} \cdot |\Sigma_i|^{-1/2}] \cdot \exp\left\{-1/2 \cdot (X-\mu_i)^T \cdot \Sigma_i^{-1} \cdot (X-\mu_i)\right\} \quad [5]$$

Sendo

- n número de bandas, o que corresponde ao número de componentes de X
- Σ_i : matriz de covariância da classe i , para as “n” bandas
- μ_i : vetor que contém o valor médio de nível de cinza, da classe i , em cada banda

Conforme Nunes (1995), por questões de simplificação matemática, aplica-se logaritmo natural à equação [5], obtendo a função de discriminação:

$$G_i(X) = -\ln |\Sigma_i| - (X-\mu_i)^T \cdot \Sigma_i^{-1} \cdot (X-\mu_i)$$

Logo:

$$X \in W_i, \text{ se } G_i(X) > G_j(X), \quad \forall j \neq i$$

sendo esta a **Regra de Decisão** utilizada na classificação por Máxima Verossimilhança Gaussiana.

Mais detalhes sobre classificação por Máxima Verossimilhança podem ser obtidos em Richards (1986) e Nunes (1995).

5. RNA MULTINÍVEL COM BACKPROPAGATION

5.1. Características do Modelo

Este modelo de RNA foi apresentado por Rumelhart et al., em 1986. É um modelo capaz de resolver problemas de reconhecimento de padrões complexos, através de funções que mapeiam valores de entrada da rede com valores de saída desejados.

Esta rede apresenta três ou mais níveis de neurônios: um nível de entrada (*input layer*), um ou mais níveis intermediários (*hidden layer*) e um nível de saída (*output layer*). É totalmente interconectada para frente (*feedforward*), não existindo conexões retroalimentadas, e onde nenhuma conexão passa diretamente por sobre uma outra mais a frente.

O número de neurônios do nível de entrada e de saída é definido de acordo com o problema ao qual a rede tentará solucionar. Entretanto, não existe uma regra que defina o número de neurônios intermediários, ou até mesmo o número de camadas intermediárias, de maneira que isto deve ser definido de forma intuitiva. Inicialmente, se o número de neurônios definido for muito alto, isto pode fazer com que alguns neurônios especializem-se em um determinado padrão. Porém, se o contrário ocorrer e o número de neurônios for muito baixo, pode acontecer da rede não conseguir aprender os padrões desejados.

Outra característica deste modelo é o **aprendizado supervisionado** baseado em duas fases: propagação e adaptação.

O treinamento ou aprendizado supervisionado (*supervised-learning*) consiste em fornecer à rede um conjunto de estímulos (padrões de entrada) e a saída desejada correspondente. Inicialmente, o primeiro padrão de entrada é propagado até a saída (fase de **propagação**). Após, 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. Desta forma, 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 erro correspondente. Daí o nome BackPropagation, pois o aprendizado baseia-se na propagação retrógrada do erro para níveis superiores da rede.

Em seguida, os pesos existentes nas conexões entre os neurônios são atualizados de acordo com o erro recebido pelo neurônio associado.

Esta regra de aprendizado é uma generalização da **Regra LMS** (*Least Mean Square Error*), também conhecida como **Regra Delta**.

O processo de aprendizado, com as devidas alterações de pesos, permanece até o momento em que a saída obtida, pela RNA, seja próxima o bastante da saída desejada, de forma que a diferença entre ambas seja aceitável. Considera-se diferença aceitável aquela que for menor ou igual a um erro previamente estipulado, em geral, 0.1 ou 1%.

5.2. Algoritmo BackPropagation

Considerando X_p como um vetor de entrada que representa o padrão p , W_{ji} como o peso de conexão entre o neurônio j e o neurônio i , Y_{pk} como sendo a saída desejada e O_{pk} , a saída obtida pela rede para o padrão p , podemos descrever o algoritmo de BP nos seguintes passos:

1. Aplicar o vetor de entrada X_p à Rede Neural.
2. Calcular os valores internos (net) dos neurônios (j) da camada escondida (h):

$$net_{pj}^h = \sum_{i=1}^N W_{ji}^h X_{pi}^h + \theta_j^h$$

sendo N o número de neurônios da camada de entrada e θ_j^h um valor de limiar do neurônio j . θ_j^h , conhecido por bias, tem a função de contribuir na convergência da rede.

3. Calcular as saídas (ativação) dos neurônios da camada escondida:

$$i_{pj}^h = f_j^h (net_{pj}^h)$$

sendo f_j^h a aplicação de uma função limiar. Em geral, utiliza-se a função sigmoideal dada por:

$$f(x) = 1 / (1 + e^{-x})$$

Desta forma, os neurônios da camada h geram valores de ativação dentro do intervalo $[0;1]$.

4. Calcular os valores internos (net) para os neurônios (k) da camada de saída (o):

$$net_{pk}^o = \sum_{j=1}^L W_{kj}^o i_{pj}^h + \theta_k^o$$

sendo L o número de neurônios da camada de saída.

5. Calcular as ativações dos neurônios de saída:

$$O_{pk}^o = f_k^o (net_{pk}^o)$$

6. Calcular os termos de erro para as unidades de saída:

$$\phi_{pk}^o = (Y_{pk} - O_{pk}^o) \cdot O_{pk}^o \cdot (1 - O_{pk}^o)$$

7. Calcular os termos de erro para as unidades escondidas:

$$\varphi_{pj}^h = i_{pj} (1 - i_{pj}) \sum_{k=1}^o \varphi_{pk} W_{kj}$$

8. Atualizar pesos na camada de saída:

$$W_{kj}^o(t+1) = W_{kj}^o(t) + \eta \varphi_{pk}^o i_{pj}$$

sendo η o coeficiente que determina a velocidade do aprendizado.

9. Atualizar pesos na camada escondida:

$$W_{ji}^h(t+1) = W_{ji}^h(t) + \eta \varphi_{pj}^h X_{pi}$$

10. Repetir de 1 a 9 para os M padrões.

O processo encerra quando o erro médio quadrado ($\langle E \rangle$), dos M padrões, for menor ou igual a um erro previamente estipulado, ou ao atingir-se um número determinado de iterações.

$$\langle E \rangle = 1 / M \sum_{p=1}^M (Y_{pk} - O_{pk})^2$$

Mais detalhes sobre o funcionamento de uma RNA multinível com BP podem ser encontrados no capítulo 3 de Freeman (1991).

5.3. Considerações Gerais

Para o início do processo de aprendizado da RNA é necessário selecionar um conjunto de amostras de treinamento que contenha as classes de padrões e as saídas desejadas correspondentes. Amostras representativas e em número suficiente devem ser selecionadas para cada classe.

Em um segundo momento, os pesos, que representam as conexões entre neurônios, devem ser inicializados com valores aleatórios pequenos (± 0.5).

O valor do coeficiente de aprendizado tem efeito significativo sobre o desempenho da rede. Deve ser um valor pequeno, como 0.05 ou 0.25, para garantir que a rede atinja uma solução. Em contrapartida, um valor pequeno para este parâmetro implica em um elevado número de iterações.

Entretanto, para acelerar a convergência pode-se utilizar a técnica do momento. Esta técnica consiste em acrescentar um termo adicional à atualização dos pesos. Isto tende a manter as mudanças dos pesos na mesma direção.

Desta forma, temos para os pesos da camada escondida:

$$W_{ji}^h(t+1) = W_{ji}^h(t) + \eta \varphi_{pj}^h X_{pi} + \alpha \Delta_p W_{ji}^h(t-1)$$

sendo α um valor entre 0 e 1 que representa uma proporção da variação do peso em um tempo $t-1$. De forma semelhante:

$$W_{kj}^o(t+1) = W_{kj}^o(t) + \eta \cdot \phi_{pk} \cdot i_{pj} + \alpha \Delta_p W_{kj}^o(t-1)$$

6. MATERIAL E MÉTODOS

Esta pesquisa utilizou-se das bandas 1, 2, 3, 4, 5 e 7 do satélite Landsat 5-TM. Inutilizou-se a banda 6, da área de estudo, por corresponder a banda termal, que é energia emitida pela superfície terrestre e não refletida, como ocorre com as demais bandas. Além disto, a resolução espacial da banda 6 é de 120m x 120m diferindo das demais cuja resolução é de 30m x 30m.

Este trabalho de pesquisa pode ser sintetizado nas seguintes etapas: pré-processamento das imagens de satélite, inclusão de módulos de Backpropagation ao sistema IRENE, criação de uma RNA e classificação das espécies vegetais da área de estudo pelo método de Máxima Verossimilhança Gaussiana e pela RNA multinível com Backpropagation.

6.1. Pré-Processamento

Como etapa inicial, foi necessário tratar as imagens de satélite (bandas) de forma a corrigi-las geometricamente. A correção geométrica nos permite associar um pixel da imagem a uma posição do terreno. Esta pode ser obtida através de coordenadas fornecidas por um GPS (*Global Position System*) ou até mesmo por cartas que nos indiquem as coordenadas UTM da área de estudo. Este procedimento é essencial para uma posterior verificação de campo e avaliação do desempenho dos classificadores.

Nota-se que tanto o sistema SITIM (Sistema de Tratamento de Imagens), desenvolvido pelo INPE (Instituto Nacional de Pesquisas Espaciais), quanto um SIG(Sistema de Informações Geográficas), nos permite corrigir geometricamente imagens de satélite.

6.2. Inclusão de Módulo e criação da RNA

O sistema IRENE (Implementação de Redes Neurais) é um ambiente para a classificação de imagens de satélite. Atualmente, este sistema compõe-se de módulos de leitura e armazenamento de bandas, módulos de processamento de imagem em baixo nível (como extração de bordas, controle do nível de brilho e contraste, equalização de histogramas), módulos da Rede Neural Artificial conhecida por Kohonen e módulos dos classificadores LVQ. O ambiente IRENE foi desenvolvido na linguagem de programação "C" padrão, em plataforma SUN, rodando sob o sistema UNIX, com a versão 3.0 do sistema OpenWindows. É um sistema modular que permite extensões futuras (Nunes, 1995).

Desta forma, módulos do algoritmo de BackPropagation foram incluídos ao sistema IRENE, de maneira que uma RNA multinível com BackPropagation pôde ser criada e utilizada como classificador neural do tema de interesse.

6.3. Classificação por Máxima Verossimilhança Gaussiana

A classificação da área de estudo pelo Método de Máxima Verossimilhança Gaussiana foi realizada através do Projeto Piloto para a Classificação Digital de Florestas, desenvolvido entre a Riocell (empresa de celulose) e o Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM).

36 amostras, de 1 x 1 Km, da área de estudo foram verificadas em campo com o uso de um GPS. Desta forma, os resultados da classificação foram comparados com a verdade terrestre. Conforme Deppe (1994), a classificação da área em *Eucalyptus*, *Acácia*, *Mata Nativa*, *Pastagens*, *Corpos d'água* e *solos descobertos*, obteve uma exatidão de cerca de 76,7%, utilizando-se as seis bandas do satélite Landsat 5-TM.

6.4. Classificação por RNA

Estabeleceu-se uma RNA multinível com BP com seis neurônios de entrada, com cerca de dez neurônios em uma única camada escondida e com três neurônios de saída. Cada um dos neurônios de entrada foi associado a uma banda do satélite. Desta forma, as amostras para a rede consistiram de pixels de cada classe, de maneira que cada pixel era constituído de seis valores de níveis de cinza (um de cada banda). A opção por um resultado de classificação binário permitiu o uso de três neurônios de saída para a classificação das espécies: *pinus*, *eucalyptus*, *acácia negra* e *mata nativa* e para os demais pixels que representassem pastagens, solos descobertos e corpos d'água. Assim, a classe *eucalyptus* é identificada por 001, a classe *acácia* por 010 e assim por diante.

Cerca de 1% do número de pixels da imagem foram selecionados como amostras representativas de cada uma das classes. Esta seleção foi realizada com o auxílio dos especialistas da área de Engenharia Florestal que trabalharam no projeto Riocell e que, portanto, possuíam um bom conhecimento da área de estudo. Estas amostras de treinamento, com o uso do sistema IRENE, foram fornecidas à RNA para que ela pudesse ser treinada a identificar as diferentes espécies vegetais.

Na etapa de reconhecimento, os pixels da imagem foram propagados pela rede e os resultados da classificação foram obtidos.

Atualmente, esta pesquisa está em desenvolvimento e, portanto, ainda não se tem o valor quantitativo de exatidão com o qual a RNA classificou a área de estudo. Além disto, vários testes estão sendo realizados para a determinação ótima do número de neurônios intermediários, do coeficiente de aprendizado e do valor para o parâmetro do momento, considerando-se um erro médio quadrado de 1%.

7. CONCLUSÕES E TRABALHOS FUTUROS

Esta pesquisa, cumprindo com o compromisso da multidisciplinariedade, tem o intuito de utilizar RNA's para tentar aumentar o índice de classificação correta de espécies vegetais na área de estudo selecionada.

Com a RNA multinível com BP, espera-se atingir uma exatidão superior a 76,6% obtida com o Método de Máxima Verossimilhança, e que exista uma diferença significativa nos resultados de classificação entre ambas as técnicas, o que pode ser averiguada pelo uso de Métodos Estatísticos, como o teste "t"

Entretanto, observa-se que todo este processo de classificação está profundamente afetado por três erros aos quais não se pode fugir: erros de medida do GPS (5 metros), erros com a correção geométrica (15 metros) e erros do próprio sensor TM (calibração, flutuações).

Oportunamente, classificações da área de estudo por outro tipo de RNA, conhecida por Mapas de Kohonen, que encontra-se disponível no Sistema IRENE, poderão ser realizadas. Isto permitirá uma avaliação de classificadores neurais para a classificação do tema de interesse, na área de estudo selecionada.

Ainda, posteriormente, será possível averiguar sobre quais as bandas do satélite Landsat 5-TM trazem informações relevantes para a classificação de espécies vegetais. Eventualmente, seis bandas talvez não sejam necessárias para um bom resultado de classificação, visto que a banda 1 (*blue*) apresenta grande ruído devido a interferência atmosférica.

8. REFERÊNCIAS BIBLIOGRÁFICAS

AN.P., CHUNG C.F. ; RENCZ A., 1995. Digital Lithology Mapping from Airborne Geophysical and Remote Sensing Data in the Melville Peninsula, Northern Canada, Using a Neural Network Approach. *IEEE Remote Sens. Environ.* V. 53. p. 76-84.

BENEDIKTSSON, J.A., SWAIN, P.H. & ERSOY, O.K., 1990. Neural Network Approach versus Statistical Methods in Classification of Multisource Remote Sensing Data. *IEEE Trans. Geosci. Remote Sensing.* V 28, N.4, p. 540-552.

BISCHOF, H., SCHNEIDER, W. & PINZ, A.J. , 1992. Multispectral Classification of Landsat - Images Using Neural Networks. *IEEE Trans. Geosci. Remote Sensing.* V. 30, N.3. p 482-490.

DEPPE, F. 1994. *Applications of Remote Sensing and Geographic Information Systems for Management and Planning Forestry Resources in Southern Brazil.* Cranfield University-Silsoe College. 330p.

ENGEL, P.M., 1993. *Inteligência Artificial e Redes Neurais em Prospecção Ambiental e Sensoriamento Remoto.* In: InfoBio'93. Simpósio de Aplicações da Informática em Biologia, I. Campinas, p 24-25.

- FREEMAN, J.A. & SKAPURA, D.M., 1991. **Neural Networks. Algorithms, Applications, and Programming Techniques.** Addison - Wesley.
- HEERMANN, P.D. & KHAZENIE N., 1992. Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network. **IEEE Trans. Geosci. Remote Sensing.** V. 30, N.1, p. 81-88
- HUANG, W.Y & LIPPMANN, R.P., 1987. Comparasion between neural net and convention classifiers. In **Proceedings of the IEEE First International Conference on Neural Networks.** San Diego, CA, p. 485-494, Junho
- MACHADO, R.J., 1993. **Interpretação de Imagens de Satélite da Amazônia Usando Redes Neurais.** In: InfoBio'93. Simpósio de Aplicações da Informática em Biologia. I. Campinas, p. 25-26.
- MILIDIÚ, R.L. 1995. **Fundamentos de Redes Neurais.** In: CNMAC95-Congresso Nacional de Matemática Aplicada e Computacional (Minicurso). Curitiba-PR. 44p.
- NUNES, R.V., 1995. **Uma Abordagem Neural para Tratamento de Imagens Multiespectrais.** CPGCC - UFRGS - Porto Alegre. 106p.
- RICHARDS, J.A. 1986. **Remote Sensing Digital Image Analysis - An Introduction.** Springer-Verlag, New York
- RUMELHART, D., HINTON, E. & WILLIAMS, R., 1986. **Learning Internal Representations by Error Propagation.** Parallel Distributed Processing: Explorations in the Microstructures of Cognition, MIT Press, Cambridge, MA, Vol. 1, p. 318-62
- SEIBERT, M.G.F., 1992. **Neural Network Image Analysis for Environmental Protection.**
- VASCONCELOS, G.C., 1995. **Redes Neurais e Reconhecimento de Padrões.** In: Simpósio Brasileiro de Redes Neurais.II., São Carlos - SP, (Tutorial 2)