

AMBIGÜIDADE ENTRE CLASSES DE VEGETAÇÃO RESULTANTES APLICAÇÃO DE UMA REDE NEURAL ARTIFICIAL

Maria de Lourdes B. Trindade Galo¹

Evlyn M. L. de Moraes Novo²

Mauricio Galo¹

¹ UNESP – Universidade Estadual Paulista - FCT – Faculdade de Ciências e Tecnologia
Rua Roberto Simonsen, 305 – Caixa Postal 467 - 19060-900 – Presidente Prudente – SP – Brasil
{mlourdes, galo}@prudente.unesp.br

² INPE – Instituto de Nacional Pesquisas Espaciais
Av. dos Astronautas, 1758 – Caixa Postal 515 - 12201-970 – São José dos Campos – SP – Brasil
evlyn@ltd.inpe.br

RESUMO

Alguns modelos de redes neurais artificiais permitem classificar dados multiespectrais e temáticos usando um conjunto de pesos ajustados durante a fase de treinamento, atribuindo cada pixel da cena à classe de maior valor de saída. Uma arquitetura de rede foi treinada para mapear os tipos de vegetação natural em uma área de proteção ambiental localizada no Pontal do Paranapanema, SP, cuja aplicação resultou em um conjunto de valores de ativação calculados para cada classe. Considerando que essas classes apresentam certa ambigüidade nas áreas de transição entre tipos de vegetação foi implementado um aplicativo computacional que identifica a classe com maior valor de ativação para um dado pixel de entrada e, se o resultado é ambíguo (valores de saída igualmente altos para as duas classes de maior resposta), o pixel em questão não é classificado. Para verificar quais classes de vegetação natural apresentam maior grau de confusão, foram adotados diferentes níveis de tolerância à ambigüidade. Como era esperado, a ocorrência de regiões de transição entre classes vizinhas, onde estão presentes elementos representativos de dois tipos florestais, fica bem caracterizada nas classificações resultantes. A estratégia usada permitiu identificar quais tipos de vegetação são similares em relação às características consideradas na classificação e pode auxiliar tanto na definição de novas classes representadas pelas áreas de transição, como indicar quais classes podem ser fundidas, visto que representam tipos florestais com características muito similares.

ABSTRACT

An artificial neural network was applied to classify multispectral and thematic data set into classes of natural types in an environmental protection area. Considering that transitions between natural forestry types are gradual and the classes mapped usually have boundary vagueness, it was implemented and applied a computational tool to verify this ambiguity condition. The ambiguity is measured by a factor that considers the two most significant response of the output vector, produced by the neural network, for each pixel. Its application verified the classes output values to a specific pixel and, if the result is ambiguous (according some threshold) the pixel is not classified. The approach adopted allowed a neighborhood characterization of the classes boundary and shows with natural vegetation types are more similar.

INTRODUÇÃO

A natureza multiespectral dos dados de sensoriamento remoto têm conduzido, via de regra, à utilização de métodos estatísticos de classificação automática. Entretanto, conforme ressaltam BENEDIKTSSON et al. (1990), as abordagens convencionais de classificação

multivariada, que implicam na definição prévia da distribuição estatística das classes, não foram concebidas para a utilização de dados obtidos por diferentes fontes, os quais não podem ser descritos por um modelo multivariado único. Nesse sentido, a aplicação de redes neurais artificiais em classificação tem se mostrado promissora, uma vez que não requerem que a natureza paramétrica da distribuição dos dados seja explicitada.

Existem, atualmente, vários modelos de redes neurais desenvolvidos para diversas aplicações, entre elas a rede neural *perceptron multicamadas*, a qual assume regiões de decisão semelhantes àquelas formadas por um classificador estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados (LIPPMAN, 1987). Na descrição da arquitetura básica dessas redes, GONZALEZ & WOODS (1993) referem-se a uma configuração que consiste de camadas de elementos de processamento ou nós, estruturalmente idênticos, arranjados de modo que a saída de cada nó em cada camada alimente a entrada de cada um dos nós da camada seguinte. O número desses elementos de processamento da primeira camada corresponde à dimensionalidade do vetor de atributos dos dados de entrada. A camada de saída terá tantos nós quantas forem as classes a serem separadas. A definição do número de camadas escondidas e do número de nós que as compõem, porém, tem sido feita por tentativa e erro, ou pela experiência prévia no domínio de uma dada situação.

Nos modelos de redes neurais, o conhecimento é distribuído através da rede e armazenado na estrutura topológica dos pesos definidos para as conexões, permitindo que as redes sejam organizadas através de métodos de treinamento automatizados que simplificam o desenvolvimento de aplicações específicas (ZELL et al., 1995). Nesse contexto, os algoritmos de aprendizagem, como o *backpropagation*, habilitam a rede a desenvolver um comportamento associativo correto, quando confrontada com situações com características similares. Após a aprendizagem da rede, ela passará a classificar os padrões usando o conjunto de pesos ajustados durante o treinamento, e reconhecendo um dado padrão como pertencente a uma determinada classe, quando a saída para essa classe for "alta", e "baixa" para as demais classes (GONZALEZ & WOODS, 1993). Em linhas gerais, o critério de decisão adotado estabelece que, para um dado padrão de entrada, o elemento de processamento da camada de saída (associado a uma classe específica) que produzir o maior resultado numérico definirá a classe à qual o padrão será atribuído. Para algumas implementações de rede neural, além dessa saída ser maior para uma das classes, ela deve ter um valor superior a um limite de tolerância, para que o padrão possa ser atribuído àquela classe.

O aspecto da representação da cena classificada assume especial importância face às feições da superfície terrestre que se pretende expressar e analisar. Nos estudos de vegetação, as descrições de como os indivíduos se distribuem em uma determinada área geográfica ou na paisagem, e sua interação com o ambiente, têm sido caracterizadas por duas abordagens distintas: uma delas considera os padrões de vegetação como unidades espaciais discretas e bem diferenciadas, e a outra defende que os padrões espaciais se dispõem ao longo de gradientes ambientais (*continuum*) (MATTEUCCI & COLMA, 1982). Essas diferentes caracterizações de unidades de vegetação demandam critérios, também diferenciados, para a sua análise. Nas classificações de tipologias florestais, o conceito de unidades espaciais com limites bem definidos tem prevalecido, muito embora alguns autores (como BROWN, 1998) considerem a necessidade de representar entidades espaciais, particularmente tipos de vegetação natural, como uma série contínua com limites pouco nítidos.

Para efeito de mapeamento temático e representação cartográfica das tipologias florestais, as mudanças graduais entre classes de vegetação natural têm sido geralmente desconsideradas,

tanto por questões de ordem prática, como pela própria tradição em estudos de vegetação. Além disso, ao considerar o conceito de *continuum*, outros atributos temáticos, relacionados com a ambigüidade e incerteza espacial em relação às áreas de transição entre as classes, devem ser levados em conta na análise espacial (BROWN, 1998).

Nesse contexto, objetivo do presente trabalho é apresentar a abordagem adotada para gerar a cena classificada mediante a aplicação de uma rede neural artificial, considerando diferentes graus de ambigüidade entre as classes de vegetação presentes em uma área de proteção ambiental.

MATERIAL E MÉTODOS

A abordagem de classificação adotada foi aplicada a uma área de proteção ambiental constituída pelo Parque Estadual Morro do Diabo (PEMD) que abrange uma área de 33.845 ha, situado no extremo Oeste de São Paulo e localizado entre as coordenadas 22°27' a 22°40' de latitude Sul e 52°10' a 52°22' de longitude Oeste. Para essa área de vegetação natural, razoavelmente preservada, dispõe-se de um mapa de vegetação elaborado por CAMPOS & HEINSDIJK (1970), cujas classes representam tipos florestais distintos, caracterizados segundo padrões fitofisionômicos, conforme apresentado na Tabela 1.

TABELA 1 - Descrição dos tipos de vegetação mapeados em 1970.

| Denominação | Descrição dos tipos de vegetação |
|-------------|--|
| TIPO I | - Corresponde à vegetação mais densa da área, com árvores altas (15,0 metros de altura média). |
| TIPO II | - Vegetação menos densa que a anterior (13,0 metros de altura média) |
| TIPO III | - Vegetação mais heterogênea; dificuldade de uma avaliação de seu potencial. Constitui uma transição entre os tipos II e IV. |
| TIPO IV | - Desprovido de árvores de grande porte, que surgem esporadicamente e são sempre uma continuação do tipo III. |
| TIPO H | - Ocorre na margem do rio, sendo a maior parte nos meandros. Também ocorre junto às lagoas. Vegetação mais heterogênea, local mais úmido. Às vezes ocorrem grandes árvores. |
| TIPO S | - Conseqüência da ação do homem, pelo fogo ou extração de madeira. Heterogeneidade a maior possível, indo da mata raleada ao sapé, com grande incidência de palmeiras. Os contornos são pouco definidos. |
| MACEGA | - Vegetação que ocorre na margem do ribeirão Estreito, como também margeando as lagoas. Não há árvores, senão arbustos e certas gramíneas. |

Fonte: CAMPOS & HEINSDIJK, 1970.

Os dados multiespectrais usados refere-se a uma imagem TM/Landsat-5, órbita/ponto 223/75 quadrante D+ e bandas espectrais TM3 (região espectral do visível - vermelho), TM4 (infravermelho próximo) e TM5 (infravermelho médio), adquirida em 30 de julho de 1985 e obtida pela FCT - Faculdade de Ciências e Tecnologia da Unesp, Campus de Presidente Prudente, junto ao INPE - Instituto Nacional de Pesquisas Espaciais. Foi utilizada uma imagem de 1985 por se tratar da cena disponível mais próxima época da elaboração do mapa de vegetação usado como referência para a classificação. Além disso, foram usados dados espaciais de natureza não-espectral, resultantes de mapeamentos anteriores realizados no PEMD, referentes a: cartas topográficas do IBGE na escala 1:50.000; cartas topográficas do IGC na escala 1:10.000 e carta de geomorfologia, escala original 1:200.000, elaborada pela CESP.

No processamento e análise digital dos dados espaciais foram usados aplicativos, que funcionam em sistema operacional Windows ou Linux. O Linux foi necessário para viabilizar o

uso do simulador de redes neurais artificiais SNNS na classificação dos dados, o que implicou, ainda, na necessidade de desenvolver e implementar programas computacionais para converter os dados a serem classificados em um arquivo padrão que pudesse ser compreendido pelo simulador, assim como, para a conversão dos valores de saída da rede neural artificial para o formato de uma imagem classificada. Os softwares utilizados foram: Idrisi for Windows, versão 2.0 e simulador de redes neurais artificiais SNNS (*Stuttgart Neural Network Simulator*), versão 4.1 para sistema operacional Linux. Esse último trata-se de um ambiente de simulação eficiente e flexível para pesquisa e aplicação de redes neurais artificiais que vem sendo desenvolvido pelo *Institute for Parallel and Distributed High Performance Systems* da *University of Stuttgart*, desde 1989 (ZELL et al., 1995).

Para compatibilizar os dados espaciais visando sua utilização conjunta pela rede neural aplicou-se uma série de processamentos prévios, tanto à imagem orbital, quanto aos dados temáticos. Nesse sentido, a imagem multiespectral TM/Landsat foi georreferenciada e usada na geração de um plano de textura, enquanto os dados de natureza temática foram submetidos a procedimentos específicos, definidos em função de seu formato original, e que possibilitaram a elaboração das imagens representando as classes de hipsometria e geomorfologia. O mapa de vegetação do PEMD no formato digital, usado para orientar a definição das classes no processo de treinamento da rede, foi produzido a partir da digitalização das classes representadas no mapa analógico de vegetação e compatibilizado aos demais dados apresentados à rede.

Com base nas considerações feitas por HUSH & HORNE (1993) e outros autores que descreveram os aspectos teóricos ou a aplicação de redes neurais artificiais na classificação de dados de sensoriamento remoto, e tendo em vista a abordagem de classificação supervisionada pretendida, foi adotado um modelo de rede neural com estrutura de múltiplas camadas e alimentação progressiva (*feed-forward*), treinada com algoritmo *backpropagation*. Na Figura 1 é apresentado um fluxograma que resume as atividades relacionadas com a aplicação da rede neural na classificação dos dados. Na seqüência de operações, mostrada nesse fluxo, são discriminadas as atividades baseadas em sistema operacional Windows e Linux, assim como os aplicativos ou programas computacionais implementados para o seu desenvolvimento.

Como a definição da arquitetura de uma rede neural multicamadas implica na determinação prévia da dimensionalidade dos dados de entrada e das classes de ocorrência, à medida que se estabeleceu como planos de entrada as três bandas espectrais TM/Landsat, a imagem de textura e as imagens representando classes hipsométricas e de geomorfologia, o número de elementos de processamento da primeira camada ficou dimensionado em seis nós. Da mesma forma, o número de elementos de processamento da camada de saída foi definido em consonância com as tipologias florestais usadas como referência, as quais foram extraídas do mapa de vegetação de 1970. Para dimensionar o número de camadas escondidas e o número de nós que constituem cada camada intermediária foram realizadas simulações com diferentes arquiteturas de redes neurais. Essas simulações constaram, na verdade, do treinamento e análise do desempenho da rede treinada sobre uma amostra de validação, para cada arquitetura testada.

O procedimento de aquisição de dados amostrais para treinamento e validação constou da extração de pequenos segmentos de imagem, em cada um dos planos de entrada da rede e da geração de imagens na mesma dimensão desses segmentos representando apenas as classes desejadas sobre um fundo preto (que caracteriza ausência de informação, pelo fato de estar fora da região delimitada para a amostra). Feita a aquisição das áreas de treinamento e validação foi necessário, inicialmente, transferir cada arquivo de dados para o sistema operacional Linux e, então, gerar os arquivos de padrões no formato aceito pelo SNNS. Para isso, foi implementado

um programa computacional que permite montar esses arquivos de padrões a partir dos planos que compõem cada segmento de imagem. Esse programa é flexível o suficiente para permitir que sejam definidos vários padrões em um único arquivo, o que possibilitou criar um arquivo de padrões com as três áreas de treinamento adquiridas.

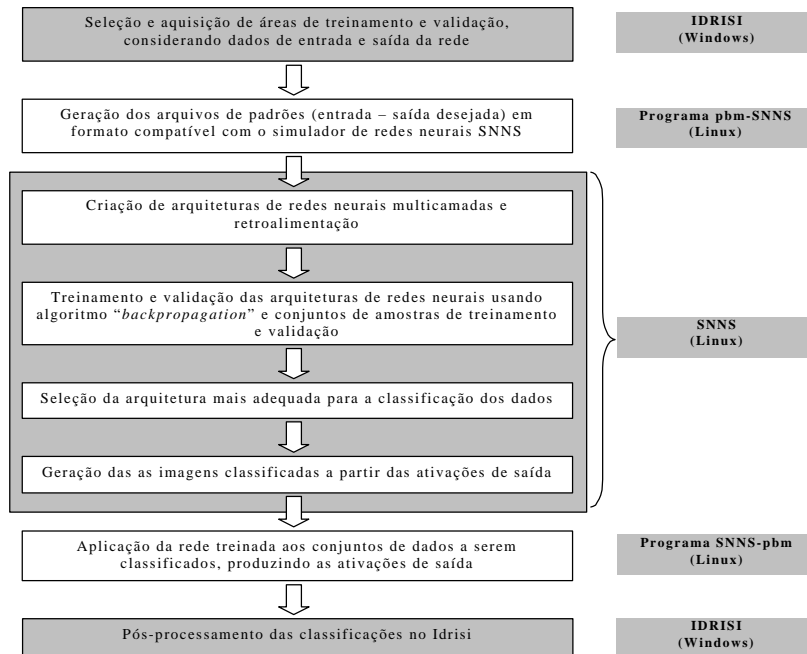


Figura 1 - Fluxograma genérico das atividades relacionadas com a aplicação de redes neurais para a classificação dos dados espaciais.

As simulações, realizadas durante a etapa de treinamento, constaram da aplicação de diferentes arquiteturas de rede aos dados de validação, a fim de selecionar a melhor arquitetura. Nesse processo os dados de treinamento e validação foram estruturados em um formato compatível com o SNNS e o treinamento foi realizado adotando-se o algoritmo padrão de aprendizagem *backpropagation*. Como esse algoritmo implica na definição prévia da taxa de aprendizagem (α) e do termo de erro (d), partiu-se da recomendação da literatura especializada e de resultados de testes preliminares de convergência para definir tais parâmetros (GALO, 2000), o mesmo ocorrendo quando da especificação das funções de ativação e inicialização. Para verificar se um elemento de processamento era ou não ativado por uma entrada específica, foi usada uma função sigmóide; o modo de atualização foi definido segundo uma estrutura topológica de organização das camadas na rede; e a inicialização do treinamento foi desenvolvida a partir de pequenos valores de pesos aleatórios para os elementos da camada de entrada. Como critério de término das iterações do algoritmo de aprendizagem foi monitorada a queda do erro médio quadrático (EMQ) para o conjunto de validação, durante a fase de treinamento, e finalizado o processo quando esse atingir um valor mínimo (ZELL et al., 1995).

Do mesmo modo que os dados de treinamento e validação, as imagens a ser classificadas foram combinadas a fim de constituírem um único arquivo de padrões no formato aceito pelo SNNS. A diferença foi quanto à definição dos planos de saída que, nesse caso, não constituíam mais os planos representando as amostras adquiridas para cada uma das classes, mas uma imagem vazia (atributo identificador igual a zero) e iguais para todas as classes de saída. Esse artifício foi necessário para que, durante a aplicação da rede treinada, houvesse compatibilidade entre o número de elementos de processamento da camada de saída da rede e o número de planos

do arquivo de padrões gerado para a classificação. Para a geração desses arquivos de padrões foi utilizado o mesmo programa de conversão de dados *pbm-SNNS* e a rede neural cuja arquitetura de pesos ajustados apresentou melhor desempenho sobre o conjunto de validação durante o processo de treinamento. Essa rede neural foi, então, aplicada para a classificação dos planos de entrada.

O simulador SNNS produz um arquivo de saída que indica os valores de saída calculados para cada elemento de processamento da última camada da rede, arranjados em uma estrutura seqüencial para cada um dos vetores de entrada. Assim, os arquivos de saída resultantes da aplicação da rede treinada aos dados de entrada foram convertidos para um formato matricial, de modo a constituírem uma imagem da cena classificada. Para produzir a imagem classificada foi implementado um aplicativo computacional com a finalidade de, para um dado vetor de entrada, identificar a unidade de processamento que forneceu o maior valor de ativação no vetor de saída, associá-lo à classe correspondente e estabelecer a posição desse pixel na matriz bidimensional que representa a imagem classificada.

Em termos genéricos, esse aplicativo permite atribuir um pixel a uma classe de saída, o que é feito pela seguinte regra de decisão:

Seja \vec{S} o vetor de saída correspondente a um dado vetor de entrada, então:

$\vec{S} = [S_1 \quad S_2 \quad \dots \quad S_M]^T$ a resposta será i , desde que S_i seja máximo de \vec{S} .

Previendo a possibilidade, muito comum, de ocorrer ambigüidade entre as classes, foi incorporado no aplicativo um fator de não-ambigüidade (*Fna*), que refina o critério de decisão considerando os dois maiores valores de ativação.

Sejam S_a a maior ativação de \vec{S} e S_b a segunda maior ativação de \vec{S} , então:

O fator de não ambigüidade *Fna* é calculado por:

$$Fna = 1 - \left(\frac{S_b}{S_a} \right)$$

de modo que para $S_a = S_b \Rightarrow Fna = 0$ o resultado é totalmente ambíguo. Para o caso em que $S_b = 0 \Rightarrow Fna = 1$ não ocorre ambigüidade entre as classes.

Como os extremos de *Fna* são 0 e 1 e dependendo da razão entre o segundo maior valor de ativação (S_b) e o maior valor (S_a), o fator *Fna* vai assumir um valor real neste intervalo. Desse modo, pode-se admitir que, quanto mais próximo de 1 for o fator *Fna* menor será a ambigüidade na classificação. Assim pode-se estabelecer uma regra que classifica apenas os pixels cujo fator de não ambigüidade esteja acima de um certo limiar. Caso contrário o pixel não é classificado.

Essa estratégia de considerar a ambigüidade na geração das imagens classificadas permite refinar o processo de classificação. Por isso, o resultado da aplicação da rede neural foi convertido para o formato imagem inicialmente desconsiderando a ambigüidade entre as classes, e aplicando diferentes limiares ao *Fna*, acima dos quais as classes são consideradas não ambíguas. Para verificar quais classes apresentavam um comportamento mais ambíguo e confuso em relação aos tipos de vegetação definidos, o resultado foi convertido para o formato imagem utilizando limiares definidos em intervalos de 10%, de modo a reduzir gradativamente a tolerância para a ambigüidade entre duas classes.

RESULTADOS

A arquitetura completa da rede neural aplicada na classificação dos dados ficou definida como [6-15-12-9] ou seja, 6 nós na camada de entrada, 15 nós na primeira camada escondida, 12 na segunda e 9 nós na camada de saída da rede (8 classes + fundo). Como o comportamento esperado para a rede durante o treinamento é uma redução gradativa do EMQ ao término de cada iteração (ciclo de treinamento), isso só foi conseguido com uma taxa de aprendizagem pequena ($\alpha=0,01$). Para ajustar um conjunto de pesos que fosse adequado para a classificação dos planos de entrada, essa arquitetura foi treinada em 400 iterações, resultando em um valor de EMQ de 0,04927, para os dados de treinamento, e 0,04851, para a amostra de validação.

A cena classificada resultante da aplicação da arquitetura anterior da rede neural treinada é apresentada na Figura 3, para uma situação de não ambigüidade entre as classes, além das classes de vegetação mapeadas a partir da interpretação visual de fotografias aéreas de 1970.

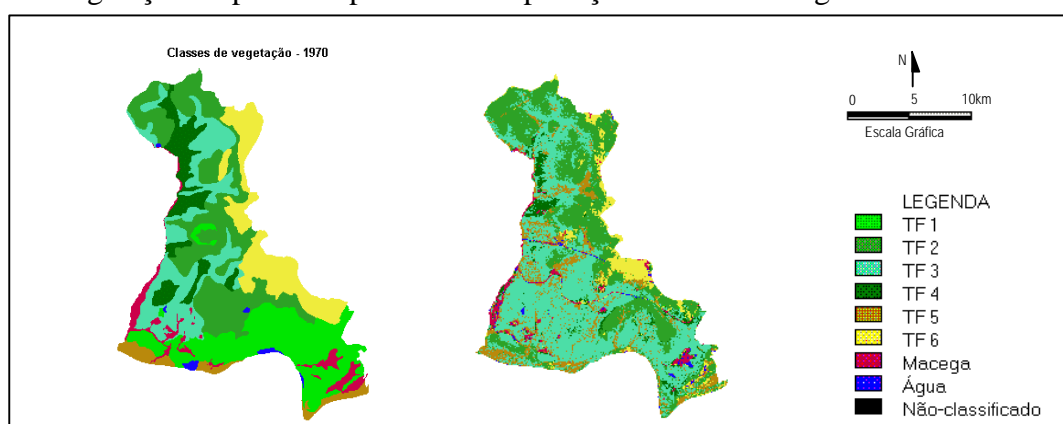


Figura 2 - Representação espacial das classes de vegetação, desconsiderando a ocorrência de ambigüidade entre as classes.

Uma análise, mesmo preliminar da Figura 2 mostra que a rede treinada têm uma relativa facilidade em identificar classes espectralmente bem definidas. Entretanto, como ocorre nas classificações supervisionadas, se a classe não estiver adequadamente caracterizada nos dados de treinamento, dificilmente ela estará representada na classificação resultante da aplicação da rede neural. Isso ocorreu com TF 1, classe cuja discriminação visual está relacionada com uma maior variação textural, determinada pela presença de alguns indivíduos de grande porte.

Os resultados da aplicação de diferentes limiares ao Fna podem ser visualizados nas Figuras 3 e 4. No gráfico mostrado na Figura 3, que relaciona a proporção de pixels associados a cada classe de treinamento para os diferentes limiares incorporados ao fator de não-ambigüidade, as classes numeradas de 1 a 6 estão associadas aos diferentes tipos florestais (respectivamente I, I, II, IV, H e S, de acordo com a tabela I); 7 e 8 referem-se a Macega e Água, respectivamente; enquanto 9 está relacionado com a proporção de pixels não classificados.

Como se observa na Figura 3, a medida que se aumenta o limiar, a tolerância para a ambigüidade entre as classes diminui e, conseqüentemente a proporção de pixels associados a essas classes. Naturalmente, a situação se inverte em relação à quantidade de pixels não classificados, que aumenta diretamente com o limiar. Esse comportamento está claramente mostrado no gráfico, tanto pela redução sucessiva no número de pixels associados às classes treinadas, quanto pelo aumento proporcional em pixels não classificados. Porém, o aspecto mais relevante sugerido no gráfico está relacionado com a intensidade do decréscimo no número de

pixels para as diferentes classes, ou seja, a estabilidade das classes face à aplicação de diferentes limiares, fato que fica implícito para as classes de treinamento 2 (TF 2) e 3 (TF 3). O decréscimo no número de pixels associados à classe 3 exibe uma regularidade drástica, culminando em zero para um limiar de 90%, sugerindo que essa classe só é definida quando se usa uma alta tolerância à ambigüidade. Portanto, essa observação indica que TF 3 inclui representantes dos outros tipos florestais mapeados, em maior ou menor grau. Na prática, isso significa que essa classe poderia ser fundida a outras ocorrências que apresentam uma resposta espectral similar.

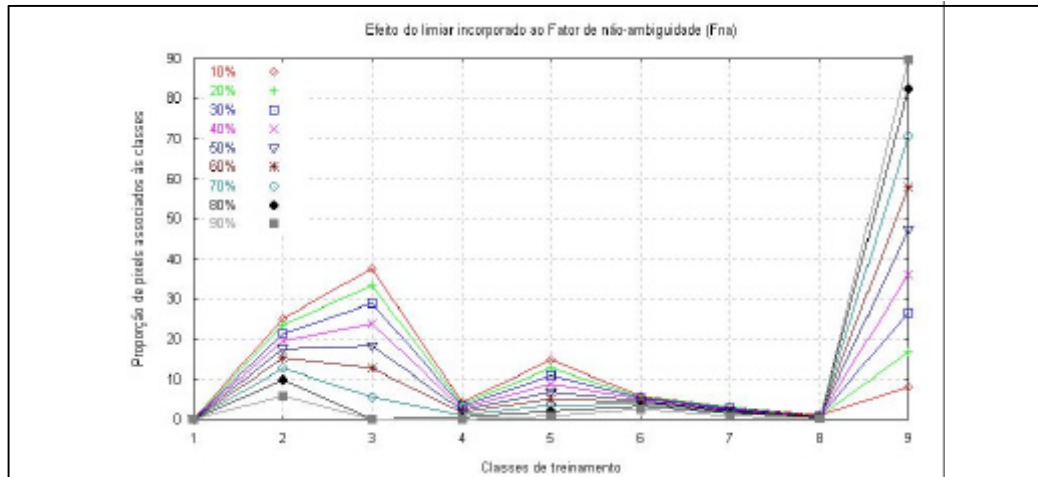


Figura 3 - Efeito da utilização de diferentes limiares aplicados ao *Fna* na geração das imagem classificada.

Por outro lado, mesmo com esse limiar de 90% (tolerância muito baixa à ambigüidade) a classe 2 ainda se faz representar na imagem e mesmo a redução na proporção de pixels associados a essa classe é comparativamente mais sutil. Quando se associa o grau de redução no número de pixels associados às classes com maior ou menor estabilidade na sua definição, percebe-se que as classes 6 (TF 6), 7 (Macega) e 8 (Água) são melhor definidas face às condições em que foi feita a classificação (dados de entrada incluindo imagens multiespectrais de 1985 e plano de textura), mesmo que sua representatividade espacial na cena seja pequena.

Assim, a ambigüidade comparativamente menor que caracteriza as classes 2, 6 e 8 pode também ser percebida através da representação espacial das classes na seqüência de imagens geradas com a aplicação de diferentes limiares ao Fator de não-ambigüidade, que compõe a Figura 4.

Além de mostrar explicitamente que a classe 3 (TF 3) tem uma representação mais ambígua em relação às demais, uma vez que a medida que se aumenta o limiar (ou se reduz tolerância à ambigüidade) a proporção de pixels associados a essa classe diminui consideravelmente, e que os tipos florestais representados pelas classes 2 e 6 são menos ambíguos, já que se preservam ao longo da seqüência de imagens, a Figura 4 aponta também quais são e como ocorre a dispersão espacial das classes mais ambíguas. Assim, quando se verifica que os pixels não classificados com a aplicação de um limiar de 10% se concentram preferencialmente nos locais de transição entre as classes 2 e 3, ao norte do PEMD, é razoável supor que os pixels nessa situação apresentam características das duas classes. Com a redução sucessiva da tolerância à ambigüidade entre as classes, a distribuição espacial dos pixels não classificados se dispersa para outras regiões da imagem, mas preferencialmente ao longo dos limites estabelecidos para as classes até que, ao se aplicar um limiar de 90%, a classe 3 que era a

mais representativa quando não se impôs tolerância a ambigüidade, seja completamente suprimida. Essa situação ocorre, em menor grau, com as classes 4 e 5.

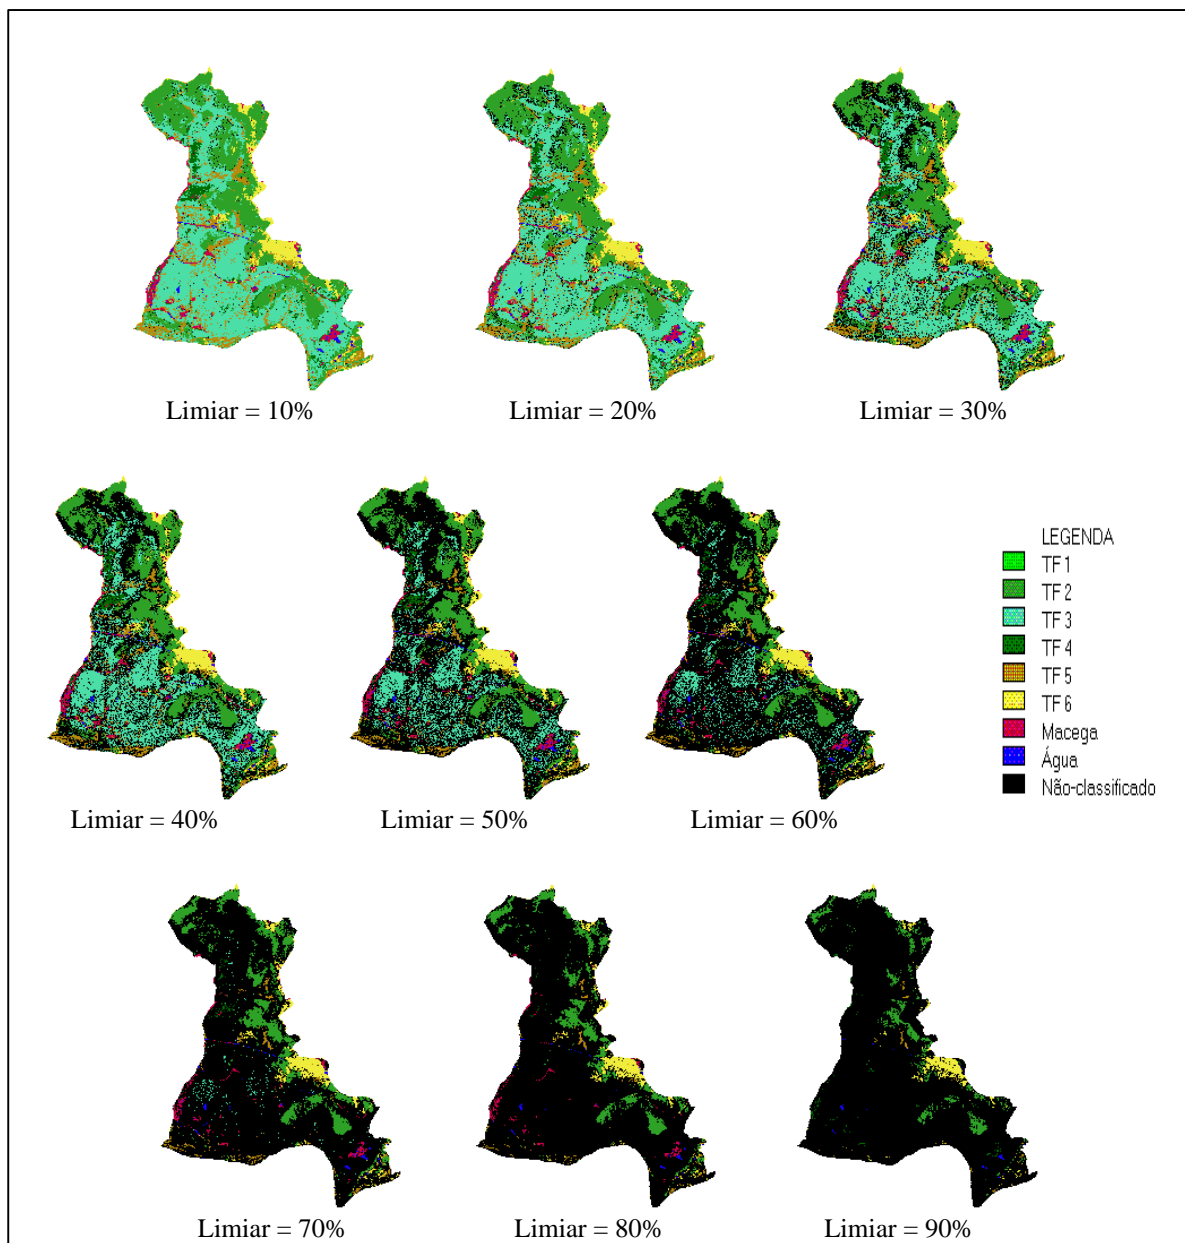


FIGURA 4 – Classificações resultantes da aplicação de diferentes limiares ao *Fna*

CONCLUSÃO

Uma aspecto relevante da abordagem desenvolvida com a utilização do simulador SNNS para a classificação dos tipos florestais presentes no PEMD foi a possibilidade de se realizar uma análise da ambigüidade entre as classes, no decorrer do processo de geração da imagem resultante da aplicação da rede neural. O simples procedimento de incorporar limiares gradativamente maiores ao fator de não-ambigüidade indicou os locais onde podem ser identificados elementos de duas tipologias florestais, ou seja, explicitou as classes que apresentam uma definição mais estável e aquelas que mais se confundem. A análise da ambigüidade, nesse contexto, pode ser considerada uma alternativa para avaliar classes

misturadas que ocorrem principalmente nas transições entre tipos de vegetação natural, onde podem ser identificadas características de dois tipos florestais vizinhos.

A disponibilidade do mapa de vegetação do PEMD (elaborado em 1970, na escala original 1:25000), permitiu avaliar o desempenho das redes neurais na classificação dos tipos florestais, resultante da integração das imagens multiespectrais de 1985 e outros dados geográficos. Esse mapa de vegetação foi, então, adotado como referência para a estimativa da exatidão da classificação usando dados multiespectrais adquiridos em 1985, desconsiderando as discrepâncias decorrentes da defasagem temporal entre as datas de aquisição dos dados de referência e as imagens multiespectrais e da qualidade do próprio mapeamento da vegetação.

Enfim, uma aspecto que parece bastante promissor quando da aplicação das redes neurais em propostas de classificação da vegetação natural, é a análise da ambigüidade entre classes vizinhas. A medida que se incorpora um limiar que restringe a tolerância à ambigüidade entre as classes, pode-se identificar quais tipos de vegetação são similares em relação às características consideradas na classificação e facilitar uma etapa posterior de adequação das classes de treinamento às classes de informação, seja pela definição de novas classes representadas pelas áreas de transição, seja pela fusão das classes que apresentam características muito similares. No mais, a análise da ambigüidade pode se constituir um recurso valioso na tarefa de generalização de mapas temáticos. Sugere-se, assim, uma avaliação com esse enfoque a ser desenvolvida em regiões onde ainda ocorram extensas áreas de florestas naturais.

BIBLIOGRAFIA

- BENEDIKTSSON, J. A.; SWAIN, P. H.; ERSOY, O. K. (1990). Neural networks approaches versus statistical methods in classification on multisource remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, v.28, n.4, p.540-52.
- BROWN, D. G. (1998). Classification and boundary vagueness in mapping presettlement forest types. *International Journal of Geographical Information Science*, v.12, n.9, p.105-29.
- CAMPOS, J. C.; HEINSDIJK, D. (1970). A floresta do Morro do Diabo. *Silvicultura em São Paulo*, n.7, p.43-58.
- GALO, M. L. B. T. (2000). *Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo*. São Carlos, 205 p. Tese (Doutorado). Escola de Engenharia de São Carlos. Universidade de São Paulo.
- GONZALEZ, R. C.; WOODS, R. E. (1993). Recognition and Interpretation. In: *Digital Image Processing*. Reading, Addison-Wesley. Cap.9, p.571-661.
- HUSH, D. R.; HORNE, B. G. (1993). Progress in supervised neural networks: what's new since Lippmann. *IEEE Signal Processing Magazine*, v.1, p.8-37.
- LIPPMANN, R. P. (1987). An introduction to computing with neural nets. *IEEE ASSP Magazine*, v.4, p.4-22.
- MATTEUCCI, S. D.; COLMA, A (1982). *Metodologia para el estudio de la vegetacion*. Washington, D.C., Secretaria General de la Organización de los Estados Americanos, Programa Regional de Desarrollo Científico y Tecnológico. Monografía n° 22 (Serie de Biología).
- ZELL, A. et al. (1995). *SNNS: Stuttgart Neural Network Simulator*. User Manual, Version 4.1. Stuttgart, University of Stuttgart. (Report No. 6/95).