

CAPÍTULO 18

TÉCNICAS DE CLASSIFICAÇÃO DE IMAGENS PARA ANÁLISE DE COBERTURA VEGETAL

Adriano Venturieri
João Roberto dos Santos

18.1 Apresentação

Nos capítulos anteriores, além da apresentação das bases do Geoprocessamento, foram mostradas algumas aplicações em diferentes escalas. Na maior parte dos casos, os dados de sensoriamento remoto foram essenciais no cumprimento dos objetivos propostos. Neste sentido, é intenção deste capítulo apresentar, ainda que de forma expedita, os métodos de classificação digital de imagens de satélite, cujos resultados geram um grande número de informações temáticas que podem ser aplicadas diretamente à agricultura. São discutidos os métodos de classificação não supervisionada, a classificação supervisionada, a classificação híbrida e as técnicas de segmentação, além de experiências na utilização de redes neurais artificiais. Espera-se assim que os leitores tenham uma compreensão maior do uso das imagens de satélite e de como a partir delas são gerados planos de informações espaciais, posteriormente transferidos para sistemas de informações geográficas (SIGs).

18.2 Introdução

O monitoramento da paisagem de uma dada região é fator primordial no planejamento racional de utilização da terra, face principalmente à velocidade de ocupação do espaço físico e ao pouco conhecimento dos recursos naturais nela existentes. Diante deste quadro, os produtos de sensoriamento remoto orbital têm sido importantes não só na aquisição primária de informações como no inventário e gerenciamento da paisagem agroflorestal em países de dimensões continentais, como o Brasil.

Em décadas recentes, a capacidade fotointerpretativa dos analistas dos

produtos orbitais de sensoriamento remoto permitiu uma evolução no processo de desenvolvimento metodológico para extrair informações de produtos fotográficos, explorando os aspectos tonais (ou de cores), texturais, geométricos e contextuais das imagens. Até hoje, a significância dos resultados alcançados na análise visual destes produtos fotográficos continua baseada na experiência do fotointérprete, o qual usa critérios subjetivos no delineamento de classes temáticas. Esta capacidade interpretativa do fotointérprete tem também sido aproveitada para avaliar os resultados das classificações digitais das imagens orbitais. A classificação via computador é baseada em determinados parâmetros estatísticos, ou seja, a identificação e a discriminação dos alvos são feitas sem a subjetividade da análise visual.

Existem diversas técnicas de classificação digital para levantamento, análise e monitoramento da paisagem agroflorestal, todas procurando extrair um máximo de informações temáticas das imagens, num tempo computacional mínimo. Antes de iniciar qualquer tipo de tratamento digital, o usuário deve refletir sobre os objetivos do trabalho e estabelecer qual tipo de produto é o mais adequado, relacionando-o prioritariamente com o nível de estratificação temática e com o tipo de algoritmo classificatório.

O *nível de estratificação temática* a ser obtida com os produtos orbitais está diretamente relacionado com a complexidade das *classes de uso da terra* da região de estudo. Utilizando-se sensores de resolução espacial relativamente “grosseira”, como as imagens do NOAA/AVHRR (pixel ~ 1 km), pode-se discriminar áreas cobertas com florestas, áreas desflorestadas e/ou queimadas, e talvez áreas agrícolas, principalmente se os alvos adjacentes forem bem contrastantes. Imagens multitemporais do NOAA/AVHRR, realçadas para discriminação de vegetação (técnica conhecida como índice de vegetação), são utilizadas para o acompanhamento fenológico da cobertura vegetal natural e do estágio de desenvolvimento de cultivos agrícolas extensos, compatíveis com a resolução deste tipo de sensor. Com sensores na faixa óptica de resolução espacial mais “fina”, do tipo Landsat/TM (pixel de 30 m) e SPOT/HRV (pixel de 10 e 20 m), têm-se conseguido significativos resultados na caracterização da paisagem agrícola e florestal, ou na análise da dinâmica de ocupação da terra. Imagens de radar em órbita (ERS-2, JERS-1 e RADARSAT), de operacionalidade mais recente, têm sido investigadas para avaliação de seus potenciais nesta tarefa de estratificação temática, bem como para o estabelecimento de algoritmos classificatórios adequados às imagens oriundas da faixa de microondas.

Com relação ao tipo de algoritmo classificatório, o usuário deve somente conduzir o trabalho após conhecer os mecanismos que regem as classificações temáticas e o tempo computacional a ser gasto no processamento da imagem em estudo. Conceituação e procedimentos de uso destes algoritmos são descritos em itens a seguir. Tem sido muito comum, inclusive em análise multitemporal das imagens orbitais para estudos de dinâmica de ocupação da terra, o processo classificatório híbrido, resultante de combinação da *classificação não-supervisionada*, utilizada para a extração dos atributos e visualização geográfica prévia das classes de interesse e da

classificação supervisionada, utilizada quando já se dispõe de informações de campo, para dar maior confiabilidade às amostras de treinamento necessárias a uma adequada classificação.

Em complementação a estes aspectos mencionados, é relevante lembrar que o produto resultante da classificação temática deve ser editado segundo as convenções e padrões de precisão cartográfica, quando se quer associar a classificação obtida com outros planos de informação tais como mapas de drenagem, rede viária, e limite político-administrativo num sistema de informações geográficas.

18.3 Métodos de classificação de imagens de sensoriamento remoto

A classificação de imagens consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe. Neste sentido, os sistemas computacionais auxiliam o usuário na interpretação das imagens orbitais.

Os métodos de classificação digital podem ser agrupados em função da presença ou não de uma fase de treinamento onde o analista interage com o computador. O método é dito *não-supervisionado* quando o classificador não utiliza a priori nenhum conhecimento sobre as classes existentes na imagem e define, sem a interferência do analista, a estratificação da cena, atribuindo a cada pixel uma determinada classe. Tal abordagem corresponde à técnica de segmentação de imagens, onde as mesmas são divididas em certas classes sem conhecimento prévio. O algoritmo define estas classes com base em regras estatísticas pré-selecionadas (Richards, 1986).

O método de classificação é dito *supervisionado* quando existe um conhecimento prévio de algumas áreas em que se deseja trabalhar, o que permite a seleção de amostras de treinamento confiáveis. O algoritmo classificador opera com base na distribuição de probabilidade de cada classe selecionada (Adeniyi, 1985). Numa linguagem mais popular, o analista inicialmente treina o classificador, para depois associar os demais pixels a uma determinada classe (previamente definida), através de regras estatísticas preestabelecidas.

As classificações não-supervisionada e supervisionada podem ser utilizadas simultaneamente para minimizar as desvantagens inerentes de cada método, obtendo-se, assim, uma maior eficiência na caracterização dos alvos agrícolas e florestais nas imagens. Tal método é conhecido como *classificação híbrida* e uma breve discussão desse procedimento é também dedicada neste capítulo.

18.3.1 Classificação não-supervisionada

Neste tipo de classificação, o algoritmo baseia-se na análise de agrupamentos onde são identificadas no espaço de atributos as nuvens (clusters) formadas por pixels com características espectrais similares. Neste tipo de classificador, é comum

especificar o número destas nuvens, isto é, o número de classes possíveis de serem encontradas na área de estudo, mesmo não sendo este o número ideal destas classes. Define-se então, através de um limiar estabelecido pelo analista, quais as concentrações de pixels que devem ser tratadas como grupos distintos (Richards, 1986).

Comumente utilizado dentre os algoritmos de classificação não-supervisionada, o K-Médias agrupa os dados em K dimensões no espaço, onde K refere-se ao número de bandas espectrais e/ou imagens envolvidas (Schowengerdt, 1983). A premissa é de que cada nuvem de pixels gerada representa a distribuição de probabilidade de uma determinada classe. Este algoritmo define um vetor média para cada classe e no procedimento subsequente, os pixels da amostragem são individualmente avaliados com relação a cada uma destas médias. O objetivo deste procedimento é agrupar os pixels de características espectrais mais similares, a partir de medidas da menor distância euclidiana entre um pixel e os centros de gravidade das classes definidas anteriormente. Uma vez iniciada esta fase de agrupamento, a conclusão da avaliação por agrupamento encerra-se quando não mais ocorre mudança significativa nos vetores de média das classes ou atinja um determinado número de iterações preestabelecidas. A seguir é mostrado como a distância Euclidiana é calculada.

Sejam $X_{i1}, X_{i2}, \dots, X_{ip}$ os valores de p variáveis contínuas observadas no indivíduo i ; e $X_{j1}, X_{j2}, \dots, X_{jp}$ os valores observados no indivíduo j . A distância euclidiana entre os indivíduos i e j é dada por:

$$d(i, j) = \sqrt{\sum_{k=1}^p (X_{ik} - X_{jk})^2}$$

ou se

$$\underline{x}_i = [X_{i1}, X_{i2}, \dots, X_{ip}]^1 \text{ e } \underline{x}_j = [X_{j1}, X_{j2}, \dots, X_{jp}]^1$$

então

$$d(i, j) = \sqrt{(\underline{x}_i - \underline{x}_j)^1 (\underline{x}_i - \underline{x}_j - \underline{x}_j)}$$

onde \underline{x}_{-j} significa o transporte de \underline{x}_j .

Se $p = 2$ ou $p = 3$, a distância euclidiana é a distância em linha reta entre os dois indivíduos, seja no plano ($p = 2$) ou no espaço de 3 dimensões ($p = 3$).

Para $p > 3$, a interpretação física fica mais difícil. Entretanto, à medida que $d(i, j)$ se afasta de zero, maior é a diferença entre os indivíduos i e j . Se acreditarmos que existe um espaço de dimensão $p > 3$, e que nesta dimensão existem dois pontos i e j , a interpretação física vista para $p = 2$ continua válida.

Diferente do classificador pixel a pixel que é o K-Médias, outro algoritmo de classificação não-supervisionado é o Ioseg, baseado em um conjunto de regiões definido pela técnica de segmentação de imagens. Segundo Bins et al. (1993), esse algoritmo envolve uma primeira etapa de particionamento da imagem em regiões com diferentes atributos estatísticos (média, matriz de covariância e área) e uma segunda etapa de classificação de regiões, fundamentada na teoria de agrupamentos (clustering).

Em uma descrição sucinta deste algoritmo de classificação, tem-se como primeira tarefa a definição do limiar de aceitação (em porcentagem), referente à distância entre os centros iniciais dos “clusters”. Com isto, gera-se uma relação de regiões ordenada de forma decrescente por área. De um modo geral, as regiões de maior área são aquelas de maior representatividade da classe. Atributos estatísticos como a média e a matriz de covariância da primeira região (maior área) são tomados como parâmetros iniciais de uma dada classe. Aquelas regiões constantes da relação onde a distância de Mahalanobis ao “cluster” é inferior ao limiar de aceitação, são removidas em um processo iterativo, recalculando-se os novos atributos da classe. Este processo é contínuo até que não haja mais nenhuma remoção de regiões e todas as classes na imagem sejam reconhecidas. A seguir é mostrado como se calcula a distância de Mahalanobis.

$$\text{Seja } \underline{V} = \begin{bmatrix} \text{Var}(X_{i1}), \text{Cov}(X_{i1}, X_{i2}) \dots \text{Cov}(X_{i1}, X_{ip}) \\ \text{Cov}(X_{i2}, X_{i1}), \text{Var}(X_{i2}) \dots \text{Cov}(X_{i2}, X_{ip}) \\ \dots \\ \text{Cov}(X_{ip}, X_{i1}), \text{Cov}(X_{ip}, X_{i2}) \dots \text{Var}(X_{ip}) \end{bmatrix}$$

a matriz de variância e covariâncias de $x_{i1}, x_{i2}, \dots, x_{ip}$ (e também de $x_{j1}, x_{j2}, \dots, x_{jp}$) A distância de Mahalanobis entre os indivíduos i e j é dada por:

$$d(i, j) = \sqrt{\begin{pmatrix} X_i - X_j \\ -i & -j \end{pmatrix}^t V^{-1} \begin{pmatrix} X_i - X_j \\ -i & -j \end{pmatrix}}$$

A interpretação física desta distância não é clara. Entretanto, se considerarmos que $\text{Cov}(x_{ih}, x_{jh})$ é zero para todos os pares (h, h') , o resultado é a divisão de cada diferença pelo desvio padrão da variável em questão, retirando o efeito da escala (tão necessária em alguns casos). Se as covariâncias não são nulas, além do efeito da escala, também é retirado o efeito da correlação entre as variáveis (duas a duas).

Para os usuários interessados na caracterização de feições agroflorestais por intermédio das imagens orbitais, muitos são os trabalhos a serem consultados. Por exemplo, Corr et al. (1989) testaram a precisão dos algoritmos de classificação que usam as técnicas de segmentação. Estes algoritmos mostraram desempenho superior em relação aos processos convencionais, permitindo inclusive a caracterização de mudanças de uso da terra. Idêntica conclusão foi obtida por Belaid et al. (1992) na discriminação de pequenos cultivos agrícolas. Dentre os algoritmos de classificação por pós-segmentação testados por estes últimos autores, aqueles baseados em regra de decisão e análise discriminante tiveram melhor desempenho por se basearem em métodos mais representativos da distribuição espectral e espacial de segmentos. Venturieri (1996), utilizando o classificador Ioseg com os limiares 99,9, 99, 95 e 75%, concluiu que na discriminação das classes Floresta, Sucessão Secundária “Inicial”, Sucessão Secundária “Avançada”, Pasto Sujo, Pasto Limpo e Áreas de Cultivos Agrícolas, o limiar de 75% representou melhor a distribuição espectro-contextual destas formas de ocupação da terra.

Embora exista uma facilidade de aplicação destes classificadores não-supervisionados nas imagens orbitais, em se tratando do tempo computacional, há a formação de um elevado número de classes temáticas, principalmente em regiões agroflorestais mais complexas, o que faz aumentar o custo homem/máquina quando se deseja realizar simplesmente a edição do mapa temático.

18.3.2 Classificação supervisionada

Conforme Lillesand & Kiefer (1987), dentre os métodos iterativos de classificação, os mais comuns são a classificação por paralelepípedo (Single Cell) e a classificação por máxima verossimilhança (Maximum Likelihood).

No método do paralelepípedo, a mais simples das classificações supervisionadas e de maior rapidez computacional, as “assinaturas” das classes são estabelecidas pelo exame dos histogramas, que compõem os atributos espectrais individuais dos dados contidos nas amostras de treinamento. Os limites inferior e superior do histograma são identificados e utilizados para descrever a amplitude dos valores de brilho característica de cada componente temática na imagem orbital. Para Crósta (1992), no paralelepípedo definido pelo nível de cinza mínimo e máximo do conjunto de treinamento, os lados desta figura geométrica constituem os limites de decisão de determinada classe. Assim, todos os pixels contidos neste intervalo serão rotulados como pertencentes a esta classe específica. Um aspecto que afeta o desempenho deste método é a correlação existente entre as bandas ópticas dos sensores atualmente disponíveis, principalmente aquelas na região do visível.

O método de classificação por máxima verossimilhança (Maxver) baseia-se no cálculo da distância estatística entre cada pixel e a média dos níveis de cinza da classe previamente definida a partir de amostras de treinamento (Dutra et al., 1981).

É oportuno comentar que a seleção destas amostras de treinamento deve refletir a variabilidade de cada categoria dentro da área estudada, não existindo contudo um número ideal destas amostras para representar a classe de interesse. Richards (1986) indicou um mínimo de $(N+1)$ amostras para cada classe, sendo N o número de bandas que integram a imagem utilizada na classificação. No entanto, a experiência adquirida na classificação supervisionada de temas agrícolas e florestais em regiões tropicais nos permite indicar um valor mínimo de $3N$ amostras.

Face à complexidade temática e, às vezes, à ocorrência de classes com áreas diminutas e espacialmente espalhadas em toda a imagem, torna-se necessário reduzir a dimensão de cada uma destas amostras de treinamento para quatro pixels no máximo. Com isto, evita-se o efeito de bordas e torna o conjunto de valores espectrais que define a classe mais fidedigno. Nos casos de classes agroflorestais que normalmente ocupam contínuas e largas extensões nas imagens, sem variações radiométricas significativas, o analista pode coletar os parâmetros estatísticos (vetor média e matriz de covariância) a partir de várias amostras de treinamento com valor pouco superior a 16 pixels cada. Assim, para uma adequada classificação de imagens, respeitando é claro todo um conjunto de variações espectrais, deve-se fazer uso do programa *Análise de Amostras* que permite avaliar o desempenho de cada amostra de treinamento em relação às demais e ao conjunto de classes estudadas. Neste programa, pode-se adicionar ou subtrair áreas até conseguir uma representação temática coerente com a estabelecida pelo usuário.

Neste tipo de classificação supervisionada, a probabilidade de um dado pixel pertencer a uma das classes predefinidas é calculada por uma função de probabilidade $P(x)$. O cálculo é realizado para o conjunto de classes que intervêm na classificação temática. Em resumo, o pixel é atribuído àquela classe que maximiza a função de probabilidade. A regra de decisão deste método de máxima verossimilhança pressupõe que as várias classes têm a mesma probabilidade de ocorrência, fato que na prática nem sempre ocorre. Um ponto x será pertencente à classe ω_i , se:

$$P(x / \omega_1) > P(x / \omega_2) \dots > P(x / \omega_n), \text{ e}$$

$$P(x / \omega_1) > L.$$

O limiar L é utilizado com o intuito de evitar que pixels com pequenas probabilidades de pertencer a determinada classe sejam classificados nesta classe (Figura 18.1).

Dentro desta consideração probabilística de cada classe, um novo fator no critério de decisão passa a ser introduzido, baseado na probabilidade bayesiana (Chuvieco & Congalton, 1988). É comum a imagem resultante deste tipo de classificação Maxver apresentar excessiva fragmentação de áreas, função da presença de pixels isolados dentro de classes, o que ocasiona uma perda de uniformidade da imagem. De acordo

com Pardi Lacruz (1996), esta fragmentação de áreas dificulta a interpretação temática, sendo necessária a aplicação de um filtro de moda sobre a imagem classificada. Este procedimento é realizado através do uso do algoritmo denominado *Uniformização de Temas*. No entanto, convém salientar que o uso deste programa pode provocar uma modificação nas bordas dos polígonos classificados corretamente.

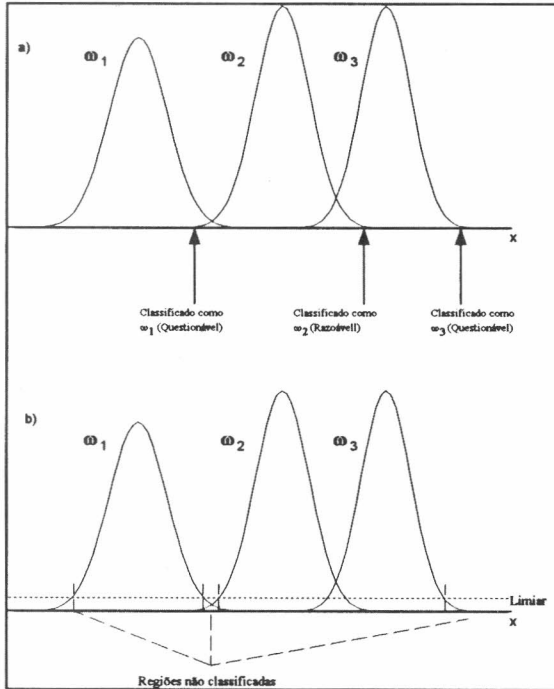


Figura 18.1 - Função de distribuição espectral antes (a) e depois (b) da utilização do limiar. Fonte: Richards (1986), adaptada pelos autores.

18.3.3 Classificação híbrida

A associação de algoritmo não-supervisionado e supervisionado no processamento das imagens é recomendada principalmente nas classificações que envolvem uma estratificação temática mais detalhada. Segundo Richards (1986), o método supervisionado, para ter desempenho significativo, necessita o delineamento a priori das classes espectrais unimodais, o que nem sempre é possível. Por sua vez, o método não-supervisionado pode contornar tal limitação, estabelecendo na representatividade da imagem estudada os agrupamentos de pixels (nuvens) que podem ser convenientemente tratados como classes distintas, ainda que não se espere que este método realize por inteiro a classificação. Este método de classificação híbrida, na realidade, tem seu desempenho dependente do conhecimento temático do analista. Primeiro, pela definição e análise das classes estatísticas produzidas pelo procedimento

não-supervisionado, que numa fase seguinte orientam a seleção de amostras mais homogêneas e espectralmente representativas de cada classe, como base de treinamento supervisionado.

O conhecimento de campo e as informações de relações de aspectos de cada alvo, em cada banda, trazem suporte à regra de decisão na escolha das amostras de treinamento a ser feita pelo analista. Uma vez aplicado o algoritmo classificatório supervisionado (Maxver, por exemplo), a rotulação final dos pixels na classificação é feita em associação com os tipos de cobertura do solo existentes na área de estudo. Exemplos de aplicação deste procedimento híbrido é relatado por Moran et al. (1993), que estudaram nove classes de uso da terra sujeitas a diferentes processos de manejo na Amazônia Oriental, integrando inclusive a classificação híbrida de imagens Landsat/TM com dados etnográficos e fitofisionômicos. Watrin (1994) estudou diferentes padrões de uso da terra (cultivos agrícolas, estádios de sucessão secundária, florestas remanescentes, etc.) na Amazônia Oriental, também fazendo uso da classificação híbrida (K-médias subsidiando o algoritmo Maxver), com o intuito de verificar os níveis de dinâmica da paisagem em uma determinada série temporal (Figura 18.2).



Figura 18.2 - Imagem temática parcial do município de Igarapé-Açu (PA).
Fonte: Watrin (1994).

18.4 Análise conceitual, estrutural e de aplicação da técnica de segmentação de imagens

Os sistemas de classificação vistos até este momento estão baseados no menor elemento de resolução de uma imagem, isto é, o pixel. Porém, observa-se na literatura que alguns usuários têm descrito certas limitações nesta abordagem de classificação pixel a pixel. Pequenas variações de relevo ou simplesmente alguns pixels de comportamento radiométrico não conseqüente (devido a escala de trabalho), apresentam-se como problema em um processo classificatório, visto que o algoritmo considera cada unidade radiométrica para sua análise. O resultado do processo classificatório é um mapa temático onde, geralmente, pode ocorrer uma série de pixels não classificados ou ainda classificados incorretamente.

Uma alternativa para este problema é a utilização da técnica de segmentação de imagem, descrita a seguir, que tem como abordagem agrupar pixels com características similares em termos tonais e texturais, formando regiões homogêneas, sendo estas, então, submetidas ao processo de classificação.

O processo de segmentação representa um passo no sentido de preparar as imagens de satélite para uma futura classificação temática, onde os elementos analisados e utilizados na classificação são as regiões resultantes da aplicação do segmentador utilizado para definição do espaço de atributos da classificação.

Alguns autores definem a segmentação como um processo que subdivide uma imagem em suas partes constituintes ou objetos (regiões), de acordo com algumas propriedades intrínsecas da cena, isto é, nível de cinza, contraste ou propriedades texturais (Moigne & Tilton, 1992). O objetivo é particionar a imagem em um conjunto de regiões que correspondam às feições da superfície terrestre, que irão servir de base para a análise e cartografia temática. O ato de segmentar uma imagem corresponde à formação de áreas compostas por determinado número de pixels unidos por um critério de similaridade. O resultado desse processo são áreas com aspecto contínuo e uniforme, onde cada área possui características espectrais bem diferentes das vizinhas que a cercam.

Existem várias técnicas para segmentar uma imagem, incluindo-se os métodos por agrupamento espectral, por bordas e aqueles baseados em regiões homogêneas (Hautakoski, 1989). O método baseado em agrupamento espectral torna os pixels da imagem pertencentes a uma determinada região com a definição de superfícies de borda em um espaço de medida n -dimensional, considerando, para este agrupamento, os valores em torno de uma média. No caso do método de borda, a imagem é “varrida”, procurando-se descontinuidades espectro-texturais e efetuando-se o cálculo da probabilidade de cada pixel pertencer a uma determinada borda; posteriormente, ligam-se esses pixels para a formação de bordas contínuas. No método baseado em regiões, discutido de forma mais detalhada a seguir, o critério de homogeneidade testado para rotular o(s) pixel(s) como pertencente(s) à determinada região pode utilizar como


abordagem operacional o crescimento de regiões, a junção de regiões e a separação de regiões.

A seguir, abordaremos o método baseado em crescimento de regiões, que encontra-se implementado no Sistema de Processamento de Imagens Georreferenciadas (Spring), desenvolvido no Instituto Nacional de Pesquisas Espaciais (Inpe).

Nessa abordagem por crescimento de regiões, o interesse do algoritmo são os pixels interiores de regiões homogêneas definidas por um determinado critério de similaridade, ou seja, de proximidade radiométrica. Neste método, o princípio básico é o agrupamento de pixels com características similares em regiões contínuas, formadas pela junção adequada de pixels vizinhos (Schoenmakers et al., 1991).

O algoritmo de crescimento de regiões gera, a partir de um pixel (i, j) , uma região que contém (i, j) e possui um valor médio de nível de cinza próximo ao de (i, j) . O grau de similaridade é determinado por um parâmetro de tolerância t , representado pela distância euclidiana entre os vetores associados a cada segmento. Assim, devem-se estabelecer, segundo Liporace (1994), uma distância (R_i, R_j) e um limiar A (número de pixels). A distância (R_i, R_j) indica a similaridade entre as regiões R_i e R_j , aumentando à medida que R_i e R_j se tornam mais distintas. O limiar A refere-se ao tamanho mínimo de cada região. Logo, a operacionalização do algoritmo de crescimento de regiões considera que:

- (a) no início do processo de segmentação, cada pixel da imagem é uma região. Por exemplo, os vizinhos de R_1 são R_2, R_3, R_4 e R_5 , conforme representação abaixo:



- (b) sendo R_i e R_j duas regiões tais que R_i é o vizinho mais próximo de R_j e vice-versa, a região R_i é dita vizinha mais próxima de R_j quando a distância $(R_j, R_i) < \text{distância}(R_j, R_k)$, para todo R_k vizinho de R_j ;
- (c) se a distância $(R_j, R_i) < t$, é necessário criar uma região $R_i = R_j \cup R_i$, voltando ao passo (b);
- (d) para cada região R_j cujo tamanho em pixels é menor que A , é

necessário criar um segmento $R_k = R_j \cup R_i$ onde R_i é o vizinho mais próximo de R_j , repetindo esse procedimento até que nenhuma região tenha tamanho inferior que A .

Podemos observar, pelas considerações acima, que este método procura os pixels com características similares aos segmentos adjacentes, fazendo a junção desses segmentos se o critério de similaridade for satisfeito. Toda vez que um novo pixel é adicionado ao segmento, as características deste, tais como a média e a variância, são redefinidas. O crescimento de regiões continua até que uma zona problema seja alcançada, onde as características dos pixels não correspondem mais aos critérios fornecidos para inclusão no segmento, cessando assim, o processo segmentador (Figura 18.3).

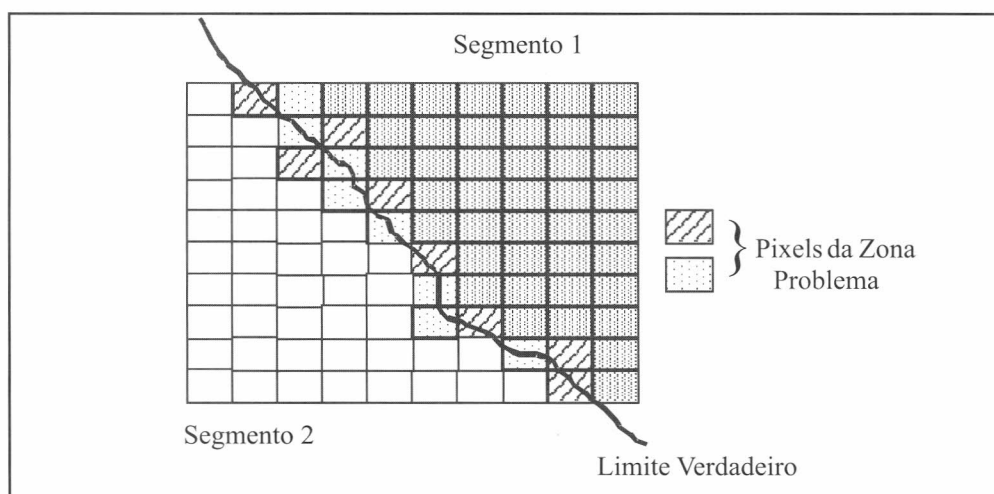


Figura 18.3 - Segmentação de imagem com uma zona problema.

Fonte: Schoenmakers et al. (1991), adaptada pelos autores.

Os pixels internos à zona problema podem ser agrupados nas regiões mais próximas ou permanecer como pixels isolados, não sendo associados a nenhuma região. No contexto da segmentação de imagens para o estudo da paisagem agroflorestal, pode-se citar como exemplo prático de zona problema o efeito de ruídos do sensor na cena imageada ou, ainda, irregularidades nas características homogêneas de classes de uso do solo (e.g., manchas de solo exposto sob o dossel de vegetação em uma pequena área). Isto favorece a ocorrência de segmentos anômalos, ou seja, pixels isolados no meio de segmentos homogêneos. Segundo Benie et al. (1989), este problema ocorre com frequência nas imagens de sensoriamento remoto.

No processo de crescimento de regiões, conforme mencionado anteriormente,

o algoritmo de agregamento tem como referência um limiar de área que define o tamanho mínimo que cada segmento deve possuir. Regiões com áreas inferiores a um tamanho preestabelecido e que não são de interesse do usuário, serão desconsideradas, sendo absorvidas por uma outra de média espectral mais próxima.

A experiência no tratamento destes dados segmentados tem indicado que se o limiar de similaridade preestabelecido for elevado, o processo de crescimento de regiões deixará muitos pixels espectralmente diferentes compondo uma única região. Por outro lado, se for definido um limiar muito baixo, qualquer classe representando, por exemplo, uma fâcie de cobertura vegetal ou de uso agrícola com pequena variância espectral apresentará uma fragmentação excessiva, dificultando assim sua interpretação e delineamento de contornos. Ao final do processo de segmentação, obtém-se uma descrição da imagem com as características vetoriais, uma lista de regiões com seus respectivos atributos e, segundo Fonseca et al. (1990), uma relação de arcos (fronteira entre regiões) com seus atributos (força e orientação média das bordas) e uma lista de nós (ponto de encontro entre três ou mais regiões). Com isso, pode-se visualizar e analisar a imagem de uma forma compacta, com o traçado das regiões, sem a necessidade de dispor da cena original anteriormente armazenada (Figura 18.4).



Figura 18.4 - Imagem segmentada da região de Tucuruí, PA. A - Floresta; B - Capoeira Avançada; C - Capoeira Inicial; D - Água.

Fonte: Venturieri (1996).

A importância das técnicas de segmentação de imagens é efetiva, conforme registra a literatura. Corr et al. (1989) utilizaram várias técnicas de segmentação de imagens objetivando um avanço no processo de análise automática de dados multitemporais. Belaid et al. (1992) realizaram a classificação digital de pequenas áreas agrícolas após o processo de segmentação de imagens, sendo constatada uma melhor precisão global na classificação quando comparado aos métodos convencionais onde o objeto pictórico é o pixel. Vários trabalhos recentes também foram desenvolvidos, explorando essa técnica de segmentação em estudos de áreas tropicais, quer para estratificação florestal (Bernardes, 1996; Pardi Lacruz, 1996) quer para identificação e monitoramento da dinâmica de uso da terra (Watrin, 1994; Santos et al., 1996a; Venturieri, 1996).

A conceituação acerca de segmentação de imagens se fez necessária para poder apresentar alguns algoritmos que utilizam regiões como fundamento no processo classificatório, em vez do método de pixel a pixel, como visto até o momento. É o caso dos classificadores de regiões não-supervisionados, como o Isoseg citado anteriormente e aqueles supervisionados como o Maxver por regiões e os que trabalham a partir de redes neurais artificiais, este último descrito mais adiante.

O Maxver por regiões, implementado no Spring versão 2.0, utiliza os mesmos princípios do modelo classificatório pixel a pixel, contudo, com um significativo aprimoramento em relação ao modelo tradicional, uma vez que se utiliza das regiões geradas na segmentação como amostras de treinamento.

18.5 Fundamentos e experiências de utilização de redes neurais artificiais

As redes neurais artificiais são modelos computacionais inspirados no sistema nervoso biológico, cujo funcionamento é semelhante a alguns procedimentos humanos, ou seja, aprendem pela experiência, generalizam exemplos através de outros e abstraem características (Wasserman, 1989). Esse método procura resolver problemas pela imitação do cérebro humano, através da utilização de um grande número de neurônios interligados para processar os sinais de entrada (Emaruchi et al., 1994). No delineamento de classes de uso da terra, a abordagem de tratamento de imagens a partir de redes neurais tem apresentado expressivos resultados, se comparados com os métodos tradicionais de classificação. Kim et al. (1995) ressaltaram a robustez do sistema de inteligência artificial, que oferece um grande potencial na discriminação das classes de cobertura da terra em comparação com os sistemas de classificação convencionais.

As redes neurais são constituídas por um conjunto de elementos de entrada, interligados a outros elementos que fazem o processamento, constituindo desta maneira os neurônios artificiais, cujo conjunto é conectado por sinapses. Segundo Liporace (1994), o processamento dos neurônios artificiais consiste na aplicação de uma função não linear G (denominada função de ativação) sobre o somatório das informações de

entrada que chegam a este elemento, gerando um resultado de saída (Figura 18.5). A complexidade temática pode exigir um aumento no número de neurônios para uma melhor definição estrutural de um determinado alvo na imagem, com obtenção de resultados classificatórios mais significativos. No entanto, este aumento no conjunto de neurônios está associado com o aumento no tempo de processamento (Freitas, 1993). Pode-se citar como algumas das características básicas de redes neurais, a capacidade de aprendizado através de simples observação de um conjunto de exemplos representativos de um dados alvo, a robustez do sistema com queda gradual do desempenho perante um mal funcionamento, e a capacidade de controle paralelo da rede e de forma distribuída.

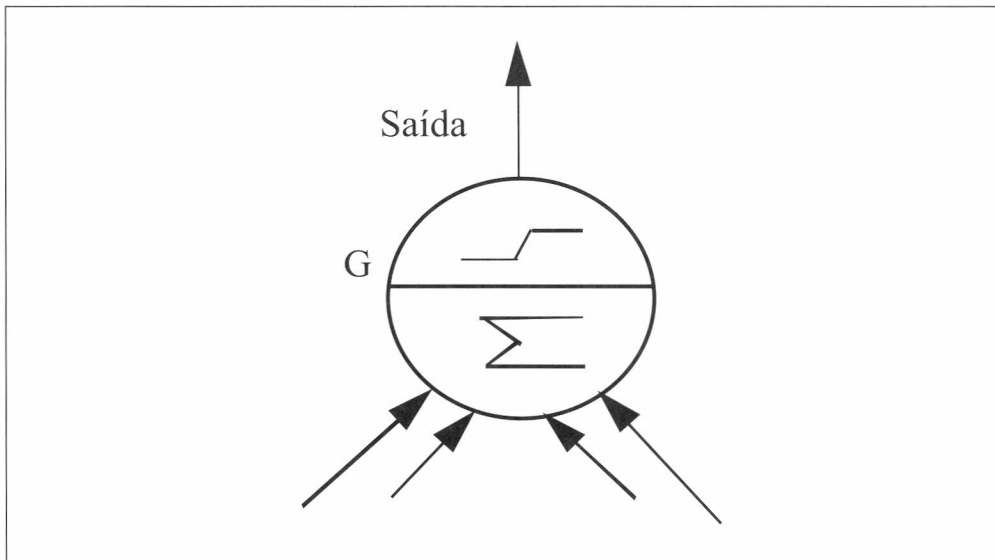


Figura 18.5 - Diagrama esquemático de neurônio artificial.

Fonte: Liporace (1994).

As redes são organizadas de acordo com o número de camadas que compõem a sua estrutura tipológica. Assim sendo, existem as redes neurais de camada simples, constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes multicamadas, formadas pela combinação de várias redes de camada simples. A Figura 18.6 apresenta um modelo de rede neural com três camadas, sendo uma escondida (camada de entrada E), outra camada escondida V e uma terceira camada de saída S.




Fig. 18.6 - Esquema de rede neural com uma camada escondida.

Fonte: Liporace (1994).

Na organização estrutural de rede, não existem regras para a definição do número de camadas escondidas. Contudo, recentes pesquisas têm mostrado que, muitas vezes, uma camada escondida é suficiente para resolver a maioria dos problemas de classificação em imagens multiespectrais. Desta forma, algumas normas são utilizadas para a determinação do número de camadas em uma rede neural, onde muitos neurônios podem levá-la facilmente ao processo de memorização (Liporace, 1994):

- Realizar experimentos com uma camada escondida inicialmente, analisando o desempenho classificatório e, caso seja necessário, utilizar uma segunda camada escondida e assim sucessivamente;
- Observar que, quanto maior for o número de entradas na rede, maior deverá ser o número de neurônios e concomitantemente, maior o conjunto de treinamento.

Outro aspecto a considerar é que a rede neural pode aceitar diferentes dados de entrada e não somente valores espectrais dos pixels. Assim, dados coletados em campo tais como condições e medidas topográficas, parâmetros edáficos, valores de fitomassa, estágio de desenvolvimento de culturas agrícolas, etc., também podem ser utilizados como fonte de definição espectro-textural e de contexto de determinado alvo, importante na tarefa de memorização de característica temática. Com isto, aumenta-se a precisão da classificação de classes agrícolas e florestais.

Para o treinamento das redes neurais, que é um sistema de classificação supervisionado, é necessário um agente externo que direcione o sistema. Esse direcionamento é realizado através do algoritmo de treinamento denominado backpropagation (retropropagação de erro), que consiste na apresentação de um conjunto de amostras, o qual é comparado com uma imagem de saída desejada

(Schlünzen et al., 1993). Desta forma, o algoritmo necessita de um conjunto de amostras com pares de entradas e saídas, ou padrões corretos, a partir do qual o algoritmo constrói uma configuração capaz de realizar o mapeamento desejado (Liporace, 1994).

Wilkinson et al. (1995), integrando imagens Landsat/TM com imagens radar de abertura sintética (satélite ERS-1), fizeram uso de redes neurais de multicamadas (MPL) treinadas pelo algoritmo de backpropagation, para mapear em primeira ordem nove classes de uso da terra (incluindo culturas agrícolas, pastagem, área urbana e uma área genérica de floresta, dentre outras classes) e em segunda ordem, oito diferentes tipos de florestas (incluindo áreas de Pinus, Carvalho, Eucalyptus, formações mistas, etc.) na região centro-oeste de Portugal. A acurácia no processo de classificação foi de 92,6 e 77,7%, respectivamente.

Liporace (1994) utilizou informações espectrais, texturais e de vizinhança em segmentos obtidos pelo processo de crescimento de regiões para a identificação de áreas desflorestadas na região amazônica, considerando inclusive a distribuição e a forma de ocupação peculiares à região. A comparação com método bayesiano indicou que as redes neurais produziram resultados mais significativos, pois foram capazes de discriminar regiões de transição e com interferência, as quais não puderam ser identificadas com o algoritmo Maxver.

Comparando ainda os sistemas de classificação convencional (bayesiano) e de redes neurais no tratamento de imagens do Landsat/TM, sob as mesmas áreas de treinamento, Ritter & Hepner (1990) chegaram a um desempenho global de 59 e 70% respectivamente, demonstrando a capacidade potencial da abordagem por redes neurais. Utilizando imagens HRV/SPOT, Kanellopoulos et al. (1991) aplicaram a rede neural para classificar diversos tipos de cobertura da terra no sul da França. Conforme esses autores, a rede neural classificou um significativo número de tipos de cobertura do solo, com precisão superior às observadas pelos métodos tradicionais de classificação.

De acordo com Kim et al. (1995), na região de Daejon, Coréia do Sul, o método de classificação convencional por máxima verossimilhança apresentou uma menor capacidade de discriminar classes de uso do solo em relação ao sistema de classificação por redes neurais, especialmente quando o modelo de uso da terra era complexo.

Santos et al. (1996b), utilizando procedimentos estatísticos baseados em valores de distância entre pares de sensibilidade (capacidade de detecção do classificador) e especificidade (capacidade de rejeição), demonstraram o potencial da rede neural treinada pelo algoritmo de backpropagation na discriminação de classes de floresta primária, sucessão secundária inicial e avançada, pastagens bem ou mal implantadas, culturas agrícolas, dentre outras, em área da Amazônia Legal (Figura 18.7).

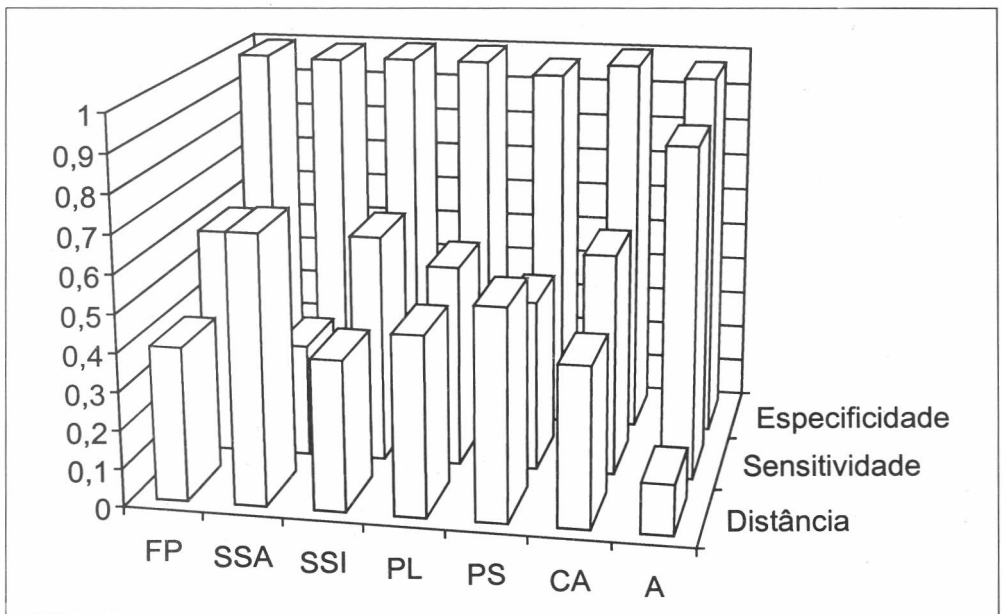


Figura 18.7 - Desempenho da rede neural relacionado com os índices de sensibilidade e especificidade na caracterização de classes de Floresta Primária (FP), Sucessão Secundária Avançada (SSA), Sucessão Secundária Inicial (SSI), Pasto Limpo (PL), Pasto Sujo (PS), Cultura Agrícola (CA), e Água (A).

Fonte: Santos et al. (1996b).

18.6 Conclusões

Na busca de uma melhor relação custo/benefício no tratamento de dados de satélite, o usuário espera dispor de uma série de dados confiáveis para a tomada de decisões. As técnicas de segmentação e classificação de dados de sensoriamento remoto, conjugadas com SIGs, têm se consolidado como ferramentas primordiais na obtenção e manipulação de informações espaciais e não-espaciais, gerando cartas temáticas como o de uso da terra que subsidiam planejamentos agrosilvopastoris de uma região.

As cartas temáticas geradas podem ser úteis no planejamento de amostragem de campo, no acompanhamento de propriedades agrícolas e florestais ou na avaliação do impacto ambiental resultante da instalação da agricultura ou da silvicultura. No entanto, o usuário deve entender o significado deste ou daquele tratamento digital de imagens orbitais, refletindo sobre o tempo computacional, a complexidade e o nível de estratificação dos temas envolvidos na análise, a facilidade de manuseio dos algoritmos e a oportunidade de transmitir conhecimentos, fazendo chegar na comunidade o retorno científico esperado e aplicável.

18.7 Referências

- ADENIYI, P.O. Digital analysis of multitemporal Landsat data for land-use/land – cover classification in semi-arid area of Nigeria. *Photogrammetric Engineering and Remote Sensing*, v.51, n.11, p.1761-1774, 1985.
- BELAID, M.; EDWARDS, G.; JATON, A.; THOMSON, K.P.B.; BEAULIEU, J.M. Post-segmentation classification of images containing small agricultural fields. *Geocarto International*, v.7, n.3, p.53-60, 1992.
- BENIE, G.B.; THOMSON, K.P.B.; GOLDBAY, M. A comparison of four segmentation algorithms in the context of agricultural remote sensing. *Journal of Photogrammetry and Remote Sensing*, v.44, n.7, p.1-13, 1989.
- BERNARDES, S. *Índices de vegetação e valores de proporção na caracterização de floresta tropical primária e estádios sucessionais na área de influência da floresta nacional do Tapajós, Estado do Pará*. São José dos Campos: Inpe, 1996. 94p. Dissertação Mestrado.
- BINS, L.S.; ERTHAL, G.J.; FONSECA, L.M.G. Um método de classificação não supervisionada por regiões. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS, 6., 1993, Recife. *Anais do SIBGRAPI 93*. Recife: SBC/UFPE, 1993. v.2, p.65-68.
- CHUVIECO, E.; CONGALTON, R.G. Using cluster analysis to improve the selecting of training statistics in classifying remotely sensed data. *Photogrammetric Engineering and Remote Sensing*, v.54, n.9, p.1275-1281, 1988.
- CORR, D.J.; TAILOR, A.M.; CROSS, A.; HOGG, D.C.; LAWRENCE, D.H.; MANSON, D.C.; PETROU, M. Progress in analysis of multi-temporal remotely-sensed data. *International Journal of Remote Sensing*, v.10, n.7, p.1175-1195, 1989.
- CRÓSTA, A.P. *Processamento Digital de Imagens de Sensoriamento Remoto*. Campinas: UNICAMP, 1992. 170p.
- DUTRA, L.V.; SOUZA, R.C.M.; MITSUO, F.A.; MOREIRA, J.C. *Análise automática de imagens multiespectrais*. São José dos Campos: INPE, 1981. (INPE-2212-MD/009).
- EMARUCHI, B.; JIN, Y.; SAUCHYN, D.; KITE, G. Land cover mapping using an artificial neural networks. *ISPRS Mapping and Geographic Information Systems*, v.30, p.84-89, 1994.
- FONSECA, L.M.G.; BINS, L.S.; VELASCO, F.R.D.; MONTEIRO, A.M.V. Um sistema de segmentação baseado em conhecimento para imagens de satélite. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 6., 1990, Manaus. *Anais...* INPE/SELPER ISPRS/SBC, 1990. v.1, p.197-200.

- FREITAS, C.M. Reconhecimento de padrões utilizando rede neural. In: SIMPÓSIO BRASILEIRO DE CARTOGRAFIA, 16., 1993. Rio de Janeiro. *Anais...* (S.l.: s.n.), 1993. v.1, p.67-82.
- HAUTAKOSKI, M. Implementation of split-and-merge segmentation. *Photogrammetry Journal of Finland*, v.11, n.2, p.32-39, 1989.
- KANELLOPOULOS, I.; VARFIS, A.; WILKINSON, G.G.; MEGIER, J. *Classification of remotely-sensed satellite images using multilayer perceptron networks: artificial neural networks*. New York: (s.n.), 1991.
- KIM, K.; YANG, Y.; LEE, J.; CHOI, K.; KIM, T. Classification of multispectral image using neural network. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'95), 1995, Firenze. *Proceedings...* (S.l.: s.n.), 1995. v.1, p.446-448.
- LILLESAND, T.M.; KIEFER, R.W. *Remote Sensing and Image Interpretation*. New York: John Wiley & Sons, 1987. 612p.
- LIPORACE, F.S. *Um sistema neural para monitoração do desflorestamento na Região Amazônica utilizando imagens do Landsat*. Rio de Janeiro: UFRJ, 1994. 122p. Dissertação Mestrado.
- MOIGNE, J.L.; TILTON, J.C. Refining image segmentation by integration of edge region data. In: Proceedings of International Geoscience and Remote Sensing Symposium (IGARSS'92), 1992, Houston. *Proceedings...* (S.l.:s.n.), 1992. v.2, p.1406-1408.
- MORAN, E.F.; BRONDIZIO, E.; MAUSEL, P.; LI, Y.H. Assinaturas espectrais diferenciando etapas de sucessão secundária no leste amazônico. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 1993, Curitiba. *Anais...* São José dos Campos: INPE, 1993. v.2, p.202-209.
- PARDI LACRUZ, M.S. *Sensoriamento remoto e sistemas de informações geográficas como subsídio para levantamentos fisionômico-estruturais em floresta tropical úmida - estudo de caso: Estação Científica Ferreira Penna, PA*. São José dos Campos: INPE, 1996. 106p. Dissertação Mestrado.
- RICHARDS, J.A. *Remote sensing digital images analysis: an introduction*. Berlin: Springer-Verlag, 1986. 281p.
- RITTER, N.D.; HEPNER, G.F. Application of an artificial network to land-cover classification of thematic mapper imagery. *Computers & Geoscience*, v.16, n.6, p.837-880, 1990.
- SANTOS, J.R.; KUX, H.J.H.; KEIL, M.; PARDI LACRUZ, M.S.; SCALES, D. Interactive analysis of polarimetric SIR-C and Landsat-TM data for the spectral and textural characterization of the land cover in SW Amazonia, Brazil. In: INTERNATIONAL OF PHOTOGRAMMETRY AND REMOTE SENSING

- CONGRESS, 18., 1996a, Viena. *Proceedings...* (S.l.: s.n.), 1996a. v.31, Part B7, p.209-213. (Archives).
- SANTOS, J.R.; VENTURIERI, A.; MACHADO, R.J.; LIPORACE, F.S. Applicability of neural network architecture by a fuzzy model to identify natural vegetation regrowth in Brazilian Amazonia. In: INTERNATIONAL OF PHOTOGRAMMETRY AND REMOTE SENSING CONGRESS, 18., 1996b, Viena. *Proceedings...* (S.l.: s.n.), 1996b. v.31, Part B7, p.204-208. (Archives).
- SCHLÜNZEN, E.T.M.; TRINDADE, M.L.B.; SHIMABUKURO, M.H.; JÚNIOR, K.S.; NETO, M.L.A. Perspectiva da aplicação de redes neurais na classificação de dados multiespectrais de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 1993, Curitiba. *Anais...* São José dos Campos: INPE,1993. v.2, p.438-444.
- SCHOENMAKERS, R.P.H.M.; WILKINSON, G.G.; SCHOAUTEN, T.E. Segmentation of remotely-sensed images: a redefinition for operational applications. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'91), 1991 Espoo, Finland. *Proceedings...* (S.l.:s.n.), v.1, p.1087-1090.
- SCHOWENGERDT, R.A. *Techniques for image processing and classification in remote sensing*. New York: Academic, 1983. 249p.
- VENTURIERI, A. *Segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização do uso da terra na Região de Tucuruí (PA)*. São José dos Campos: INPE, 1996. 115p. Dissertação Mestrado.
- WASSERMAN, P.D. *Neural computing: theory and practice*. Van Nostrand Reinhold, 1989.
- WATRIN, O.S. *Estudo da dinâmica na paisagem da amazônia Oriental através de técnicas de geoprocessamento*. São José dos Campos: INPE,1994. 151p. Dissertação Mestrado.
- WILKINSON, G.G.; FOLVING, S.; KANELLOPOULOS, I.; McCORMICK, N.; FULLERTON, K.; MÉGIER, J. Forest mapping from multi-source satellite data using neural network classifiers - an experiment in Portugal. *Remote Sensing Reviews*, v.12, p.83-106. 1995.