

REGIANE MARIA PAES RIBEIRO

**AVALIAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS
IKONOS II PARA O MAPEAMENTO DA COBERTURA TERRESTRE**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2003

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

R484a
2004

Ribeiro, Regiane Maria Paes, 1978-
Avaliação de métodos de classificação de imagens
IKONOS II para o mapeamento da cobertura terrestre /
Regiane Maria Paes Ribeiro. – Viçosa : UFV, 2004.
ix, 53f. : il. ; 29cm.

Orientador: Vicente Paulo Soares
Dissertação (mestrado) - Universidade Federal de
Viçosa.

Referências bibliográficas: 51-53

1. Imagens multiespectrais - Classificação. 2. Mapeamen-
to do solo. 3. Satélites artificiais em sensoriamento remoto.
4. Solo - Uso. 5. Redes neurais (Computação). I. Univer-
sidade Federal de Viçosa. II.Título.

CDO adapt. CDD 634.9585

REGIANE MARIA PAES RIBEIRO

**AVALIAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS
IKONOS II PARA O MAPEAMENTO DA COBERTURA TERRESTRE**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

APROVADA: 17 de dezembro de 2003

Prof. Carlos Antônio Oliveira Vieira
(Conselheiro)

Prof. Carlos Antônio A. Soares Ribeiro
(Conselheiro)

Prof. Guido Assunção Ribeiro

Prof. Elpídio Inácio Fernandes Filho

Prof. Vicente Paulo Soares
(Orientador)

Aos meus pais, Roberto e Eliza.

Aos meus irmãos, Ricardo e Rúbia.

A todos os amigos e familiares.

A Deus.

AGRADECIMENTOS

À Universidade Federal de Viçosa, em especial ao Departamento de Engenharia Florestal, pela oportunidade de realizar o curso.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa concedida.

Ao Prof. Vicente Paulo Soares, pelos ensinamentos, pela confiança e orientação.

Ao conselheiro Prof. Carlos Antônio Oliveira Vieira, pelas contribuições, pelas sugestões e pelos ensinamentos.

Ao conselheiro Prof. Carlos Antônio Álvares Soares Ribeiro, pela colaboração e pelos ensinamentos.

Ao Prof. Carlos Cardoso Machado, pelo incentivo.

À minha família, pela confiança, pelo apoio e pela paciência.

A Jean, pelo amor, pelo companheirismo, pela confiança e ajuda constante.

Aos amigos e colegas de curso, pela convivência.

Aos funcionários do Departamento de Engenharia Florestal, em especial a Ritinha e Frederico.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

BIOGRAFIA

REGIANE MARIA PAES RIBEIRO, filha de Roberto José Ribeiro e Eliza Jannotte Paes Ribeiro, nasceu em 6 de janeiro de 1978, em Viçosa, Minas Gerais.

Em 1996, iniciou o curso de Engenharia de Agrimensura na Universidade Federal de Viçosa, graduando-se em agosto de 2001.

Ainda em agosto de 2001, iniciou o curso de Mestrado em Ciência Florestal, submetendo-se à defesa de tese em dezembro de 2003.

ÍNDICE

| | Página |
|--|--------|
| RESUMO | vii |
| ABSTRACT | ix |
| 1. INTRODUÇÃO | 1 |
| 1.1. Justificativa | 2 |
| 1.2. Objetivo | 3 |
| 2. REVISÃO DE LITERATURA | 4 |
| 2.1. Classificação de imagens digitais | 4 |
| 2.1.1. Classificação por pixel | 7 |
| 2.1.2. Classificação por regiões | 7 |
| 2.1.3. Redes neurais artificiais | 8 |
| 2.1.4. Algoritmos de classificação | 11 |
| 2.1.4.1. O algoritmo da Mínima Distância | 11 |
| 2.1.4.2. O algoritmo da Máxima Verossimilhança | 12 |
| 2.1.4.3. O algoritmo <i>backpropagation</i> | 13 |
| 2.1.5. Avaliação das imagens classificadas | 14 |
| 2.2. Imagens digitais de alta resolução | 18 |
| 2.3. O Satélite IKONOS II | 20 |
| 2.4. Aplicações de imagens de alta resolução | 22 |
| 3. MATERIAL E MÉTODOS | 25 |
| 3.1. Localização e caracterização da área | 25 |
| 3.2. Materiais utilizados | 25 |
| 3.2.1. Imagem IKONOS II | 27 |
| 3.2.2. Sistemas computacionais e equipamentos utilizados | 27 |
| 3.3. Classificação da imagem IKONOS II | 27 |

| | Página |
|--|--------|
| 4. RESULTADOS E DISCUSSÃO..... | 31 |
| 4.1. Avaliação quantitativa das imagens classificadas..... | 31 |
| 4.1.1. Matrizes de erros..... | 31 |
| 4.1.2. Índices kappa | 39 |
| 4.1.3. Significância entre os índices kappa..... | 41 |
| 4.2. Avaliação qualitativa das imagens classificadas..... | 42 |
| 5. RESUMO E CONCLUSÕES | 49 |
| REFERÊNCIAS BIBLIOGRÁFICAS | 51 |

RESUMO

RIBEIRO, Regiane Maria Paes, M.S., Universidade Federal de Viçosa, dezembro de 2003. **Avaliação de métodos de classificação de imagens IKONOS II para o mapeamento da cobertura terrestre.** Orientador: Vicente Paulo Soares. Conselheiros: Carlos Antônio Oliveira Vieira e Carlos Antônio Álvares Soares Ribeiro.

O trabalho consistiu na avaliação de métodos de classificação de imagens IKONOS II para o mapeamento da cobertura terrestre. Foram utilizados os algoritmos da Mínima Distância, da Máxima Verossimilhança e de Redes Neurais Artificiais (*backpropagation*), em uma imagem do satélite IKONOS II com 4 metros de resolução espacial. Para cada algoritmo foi realizada uma classificação por pixel e uma por regiões, gerando seis métodos: Mínima Distância por pixel, Mínima Distância por regiões, Máxima Verossimilhança por pixel, Máxima Verossimilhança por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel e Redes Neurais Artificiais (*backpropagation*) por regiões, que apresentaram níveis de aceitação dos índices kappa iguais a razoável, razoável, razoável, excelente, razoável e excelente, respectivamente. Dentre os resultados obtidos, podem ser destacados: a) os métodos que mostraram melhor desempenho foram Redes Neurais Artificiais (*backpropagation*) e Máxima Verossimilhança, ambos por regiões, não apresentando diferença

estatística significativa a 95% de probabilidade pelo teste Z entre eles; b) os seguintes métodos não apresentaram diferenças significativas a 95% de probabilidade: Máxima Verossimilhança por pixel em relação à Mínima Distância por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel em relação à Mínima Distância por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel em relação à Máxima Verossimilhança por pixel e Redes Neurais Artificiais (*backpropagation*) por regiões em relação à Máxima Verossimilhança por regiões; c) as classes mais homogêneas espectralmente foram melhor classificadas, apresentando menos sobreposição às outras classes; d) a baixa resolução espectral da imagem dificultou a distinção entre classes durante o processo de classificação; e) o algoritmo de classificação da Mínima Distância, que até então era utilizado com êxito para classificar imagens de média resolução espacial, apresentou desempenho inferior ao dos algoritmos de Máxima Verossimilhança e Redes Neurais Artificiais (*backpropagation*) na classificação de imagens de alta resolução espacial; f) apesar de os resultados obtidos com os algoritmos de Máxima Verossimilhança e Redes Neurais Artificiais (*backpropagation*), ambos por regiões, não diferirem estatisticamente, recomenda-se, pelo menos para este estudo, o uso do algoritmo de Máxima Verossimilhança. Essa recomendação se deve ao fato de que este exige um menor esforço computacional e se encontra implementado na maioria dos *softwares* de processamento de imagens.

ABSTRACT

RIBEIRO, Regiane Maria Paes, M.S., Universidade Federal de Viçosa, December 2003. **Evaluation of IKONOS II imagery classification methods for land cover mapping.** Adviser: Vicente Paulo Soares. Committee Members: Carlos Antônio Oliveira Vieira and Carlos Antônio Álvares Soares Ribeiro.

This work evaluated the methods of classification of IKONOS II imagery for land cover mapping. The algorithms Minimal Distance, Maximum Likelihood and Artificial Neural Networks (backpropagation) were used to classify a satellite IKONOS II image measuring 4 m of spacial resolution. A pixel – based and a region- based classification were performed for each algorithm, generating six methods : Minimal Distance per pixel, Minimal Distance per regions, Maximum Likelihood per pixel, Maximum Likelihood per regions, Artificial Neural Nets (backpropagation) per pixel, and Artificial Neural Nets (backpropagation) per regions, which presented Kappa index acceptance levels equal to reasonable, reasonable, reasonable, excellent, reasonable and excellent, respectively. Some of the most outstanding results obtained were: a) the approaches Artificial Neural Nets (backpropagation) and Maximum Likelihood, both by regions, presented the best results, with no significant statistical difference at 95% probability by the test Z between them; b) the following methods did not present significant

differences at 95% of probability: Maximum Likelihood per pixel in relation to Minimal Distance per regions, Artificial Neural Nets (backpropagation) per pixel in relation to Minimal Distance per regions, Artificial Neural Nets (backpropagation) per pixel in relation to Maximum Likelihood per pixel and Artificial Neural Nets (backpropagation) by regions in relation to Maximum Likelihood per regions; c) the most spectrally homogeneous classes were better classified, presenting less superposition to the other classes; d) the low spectral resolution of the imagery made it difficult to distinguish between classes during the classification process; e) the algorithm Minimal Distance, which was until then successfully used to classify medium spatial resolution imagery had a performance inferior to that of the algorithms Maximum Likelihood and Artificial Neural Nets (backpropagation) in the classification of imagery of high spatial resolution; f) despite the fact that the results obtained with the algorithms Maximum Likelihood and Artificial Neural Nets (backpropagation), both by regions, did not differ statistically, the use of the algorithm Maximum Likelihood is recommended, at least for this study. Such recommendation is due to the fact that this algorithm demands less computing effort and has been implemented in most imagery - processing softwares.

1. INTRODUÇÃO

O ambiente e os recursos terrestres estão sofrendo mudanças constantemente em resposta à evolução natural e às atividades humanas. Para entender a complexa inter-relação dos fenômenos que causam essas mudanças, é necessário fazer diversas observações com uma série de dados do espaço e escalas no tempo. A observação terrestre feita do espaço é o meio mais efetivo e econômico de unir os dados necessários para monitorar e modelar esses fenômenos (VIEIRA, 2000).

Nas últimas décadas, os sistemas de sensoriamento remoto têm sido amplamente utilizados no mapeamento da cobertura terrestre e no monitoramento dos recursos naturais. Os dados obtidos a partir de satélites propiciam coberturas repetitivas da superfície terrestre em intervalos relativamente curtos. Esses dados podem ser processados rapidamente, através de técnicas de análise associadas aos sistemas computacionais (VILELA et al., 2000).

No entanto, os dados de sensores remotos necessitam ser analisados para que sejam extraídas informações necessárias ao planejamento, manejo e monitoramento dos recursos. Essa análise torna-se possível pelo fato de os fenômenos e materiais superficiais apresentarem comportamentos específicos ao longo do espectro eletromagnético (VILELA, 1998), os quais podem, portanto, ser usados para identificá-los (CRÓSTA, 1992).

O método mais freqüentemente utilizado para analisar dados e extrair informações refere-se à classificação digital fundamentada em dados multiespectrais (JENSEN, 1996).

Nos grandes projetos de mapeamento, a técnica de interpretação visual é ainda muito utilizada, mesmo com diversos algoritmos de classificação de imagens já desenvolvidos. Entretanto, há uma tendência de utilização cada vez maior da classificação computacional, pela rapidez e facilidade em obter resultados (COSTA, 1999).

Com o advento de plataformas e sensores que apresentam melhor resolução espacial, como o IKONOS II, esses resultados podem ser obtidos também de forma mais detalhada. O satélite IKONOS II, lançado em setembro de 1999, foi o primeiro satélite comercial a coletar imagens pancromáticas (preto e branco) com 1 metro de resolução espacial e imagens multiespectrais com 4 metros.

A alta resolução espacial do satélite IKONOS II permite ao usuário identificar e mapear pequenos objetos na terra (SUGUMARAN e ZERR, 2001), porém ocasiona muita variação espectral em algumas feições, gerando dificuldades na classificação.

A realização de pesquisas visando avaliar métodos de classificação em imagens digitais multiespectrais de alta resolução torna-se, portanto, imprescindível.

1.1. Justificativa

Um dos principais interesses em dados de sensores remotos é a geração de mapas temáticos da superfície terrestre. Tradicionalmente, os métodos de mapeamento usando dados de sensores remotos têm sido apoiados por fotografias aéreas de grande escala, adquiridas por métodos convencionais. Essa abordagem é efetiva em áreas relativamente pequenas e convenientemente localizadas. Entretanto, em locações remotas, onde o mapeamento deve cobrir áreas extensas, necessita-se da adoção de métodos que apresentem custo reduzido, como aqueles provenientes de sensores remotos orbitais. Neles a visão sinóptica, obtida por

satélites, propicia mapeamento rápido de áreas extensas, permitindo, ainda, monitoramento destas, dada a repetitividade na aquisição dos dados (VILELA, 1998).

No entanto, um dos problemas enfrentados na utilização de imagens de satélite é a resolução espacial das imagens até então disponíveis para uso civil. Segundo COUTINHO (1997), os produtos mais conhecidos e utilizados são as imagens do satélite Landsat-TM. Estas imagens apresentam problemas relacionados à perda de definição em abordagens envolvendo escalas superiores a 1:100.000, exigindo sua complementação com fotografias aéreas.

As imagens digitais de alta resolução possuem informações mais detalhadas, que não eram disponíveis nos produtos de satélites imageadores tradicionais. Contudo, com a melhoria da resolução espacial e espectral das imagens produzidas por esta nova série de sensores, há um aumento na variação interna das classes e, conseqüentemente, uma sobreposição das classes no espaço característico, segundo KURY e VIEIRA (2002).

Embora imagens de alta resolução possam prover informações detalhadas importantes, é necessário avaliar os dados e desenvolver métodos para lidar com suas características únicas (MYEONG et al., 2001).

Pesquisas têm sido realizadas em todo o mundo com o intuito de minimizar as dificuldades encontradas na classificação de imagens digitais de alta resolução, porém estudos ainda são necessários para que as características destas imagens sejam melhor compreendidas e para que sua utilização alcance resultados mais precisos.

Diante desse contexto, decidiu-se desenvolver este trabalho visando comparar diferentes métodos de classificação em imagens digitais multiespectrais de alta resolução para o mapeamento da cobertura terrestre.

1.2. Objetivo

O objetivo deste trabalho foi o de comparar diferentes métodos de classificação em imagens digitais multiespectrais de alta resolução do sensor IKONOS II, para o mapeamento da cobertura terrestre.

2. REVISÃO DE LITERATURA

2.1. Classificação de Imagens Digitais

As técnicas de classificação digital implicam a implementação de uma regra de decisão para que o computador possa atribuir uma determinada classe a um certo conjunto de pontos da imagem (pixels). Essas técnicas teriam, dessa forma, o objetivo de tornar o processo de mapeamento ou reconhecimento de características da superfície terrestre menos subjetivo e com maior potencial de repetição em situações subseqüentes (NOVO, 1992).

A distinção e identificação das composições de diferentes materiais superficiais, sejam eles tipos de vegetação, padrões de uso do solo, rochas e outros, tornam-se possíveis devido ao fato de os materiais superficiais terem comportamentos específicos ao longo do espectro eletromagnético – comportamentos estes que podem, portanto, ser usados para identificá-los (CRÓSTA, 1992).

Segundo CRÓSTA (1992), a classificação automática de imagens multiespectrais de sensoriamento remoto diz respeito a associar um "rótulo" descrevendo um objeto real (vegetação, solo, etc.) a cada pixel da imagem. Dessa forma, os valores numéricos associados a cada pixel, definidos pela reflectância dos materiais que compõem esse pixel, são identificados em termos de um tipo de cobertura da superfície terrestre imageada (água, tipo de vegetação, de solo, de

rocha, etc.), chamadas então de temas. Quando esse tipo de operação é efetuado para todos os pixels de uma determinada área, o resultado é um mapa temático, mostrando a distribuição geográfica de um tema, tal como vegetação ou uso do solo. Pode-se dizer então que uma imagem de sensoriamento remoto classificada é uma forma de mapa digital temático. Quando essa imagem é reorganizada para se ajustar a uma dada projeção cartográfica, torna-se um importante elemento para ser incorporado a um sistema de informações geográficas.

Divide-se a classificação de imagens basicamente em supervisionada e não-supervisionada, de acordo com a forma como esta classificação é conduzida.

A classificação supervisionada pode ser definida como o processo de usar amostras de identidade conhecida para classificar pixels de identidade desconhecida. Neste tipo de classificação, a identidade e a localização de algumas feições são conhecidas *a priori* através de análise de campo, fotografias aéreas, mapas e experiência pessoal. O analista tenta identificar áreas específicas, comumente denominadas amostras de treinamento, que representem exemplos homogêneos destas feições específicas. Algumas etapas estão envolvidas na classificação supervisionada (CAMPBELL, 1987):

- Seleção e coleta das amostras de treinamento – seleção, sobre a imagem, de áreas onde as identidades das feições são conhecidas, denominadas de amostras de treinamento, que devem ter algumas características observadas, como: número de pixels dentro das amostras, forma dos polígonos das amostras, número de amostras e uniformidade das amostras de treinamento.
- Extração das estatísticas das amostras de treinamento – as principais estatísticas são a média, o desvio-padrão, a variância, a covariância e a correlação.
- Manipulação das amostras de treinamento – purificação das estatísticas das amostras mediante fusão, eliminação, etc., tornando-as o mais homogêneas possível, de forma a propiciar uma classificação mais acurada.
- Classificação da imagem – esta etapa consiste na classificação propriamente dita, através de algoritmos de classificação.

Segundo CRÓSTA (1992), alguns dos algoritmos utilizados na classificação supervisionada se baseiam em premissas estatísticas das áreas de treinamento, e, se o usuário por algum motivo não consegue definir áreas de treinamento bastante representativas, corre o risco de que a imagem classificada contenha imprecisões sérias. Uma abordagem alternativa de classificação é então usada para se tentar evitar esses problemas, que é a classificação não-supervisionada.

A classificação não-supervisionada requer somente uma quantidade mínima de informação de dados de entrada pelo analista, uma vez que as identidades das feições que são especificadas como classes dentro da imagem não são conhecidas *a priori*. Nesse processo, o computador (algoritmo de classificação) agrupa os pixels em diferentes classes espectrais (agrupamento de pixels com características espectrais similares), de acordo com alguns critérios estatísticos predeterminados. Após a classificação, o analista tenta identificar as classes geradas pelo computador, as quais, depois de rotuladas, são denominadas classes informacionais – classes de interesse do analista (CAMPBELL, 1987).

A associação de algoritmos não-supervisionado e supervisionado no processamento das imagens é recomendada principalmente nas classificações que envolvem uma estratificação temática mais detalhada. Para obter desempenho significativo, o método supervisionado necessita do delineamento *a priori* das classes espectrais unimodais, o que nem sempre é possível. Por sua vez, o método não-supervisionado pode contornar essa limitação, estabelecendo na representatividade da imagem estudada os agrupamentos de pixels que podem ser convenientemente tratados como classes distintas, ainda que não se espere que este método realize por inteiro a classificação (VENTURIERI e SANTOS, 1998). Segundo esses autores, este método de classificação híbrida, na realidade, tem seu desempenho dependente do conhecimento temático do analista, devido, primeiramente, à 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.

2.1.1. Classificação por pixel

As classificações digitais tradicionais mencionadas anteriormente são conhecidas por classificações por pixel. Nesse método, um conjunto de amostras é utilizado para caracterizar cada classe temática a ser mapeada, e os pixels (elementos básicos constituintes da imagem) são comparados um a um às amostras fornecidas, decidindo assim a qual classe temática eles pertencem. Esses métodos de classificação desconsideram o contexto de inserção dos pixels e a textura da imagem (COUTINHO, 1997).

2.1.2. Classificação por regiões

A necessidade de criar métodos digitais de classificação de imagens reduzindo a subjetividade do processo de interpretação visual e ao mesmo tempo considerando algumas características do meio, e não exclusivamente o valor espectral do pixel, levou ao desenvolvimento de algoritmos de segmentação, visando considerar nas interpretações digitais de imagens de satélite, além do valor espectral dos pixels, as características da textura e o contexto de inserção destes (COUTINHO, 1997).

O processo de segmentação representa um passo no sentido de preparar as imagens de satélite para uma futura classificação temática, em que os elementos analisados e utilizados na classificação são as regiões resultantes da aplicação do segmentador usado para definição do espaço de atributos da classificação (VENTURIERI e SANTOS, 1998).

A segmentação de imagem é uma técnica de agrupamento de dados, na qual somente regiões espacialmente adjacentes podem ser agrupadas. Inicialmente, o processo de segmentação rotula cada pixel como uma região distinta. Em seguida, é utilizado um critério de similaridade para cada par de regiões espacialmente adjacentes. O critério de similaridade baseia-se em um teste de hipótese estatístico que testa a média entre regiões. Finalmente, a imagem é dividida em um conjunto de subimagens e, então, realiza-se a união entre elas, segundo um limiar de similaridade (SHIMABUKURO et al., 1999).

Para realizar a segmentação é necessário definir dois limiares: a) o limiar de similaridade – limiar mínimo, abaixo do qual duas regiões são consideradas similares e agrupadas em uma única região; e b) o limiar de área – valor de área mínima, dado em número de pixels, para que uma região seja individualizada (SHIMABUKURO et al., 1999).

Vários métodos de segmentação de imagens foram criados com o objetivo de fragmentar a imagem em regiões “homogêneas”, sobre as quais é processada a classificação. Esses métodos de classificação pós-segmentação, diferentemente dos anteriores, chamados de pixel, são conhecidos como classificação por regiões (COUTINHO, 1997).

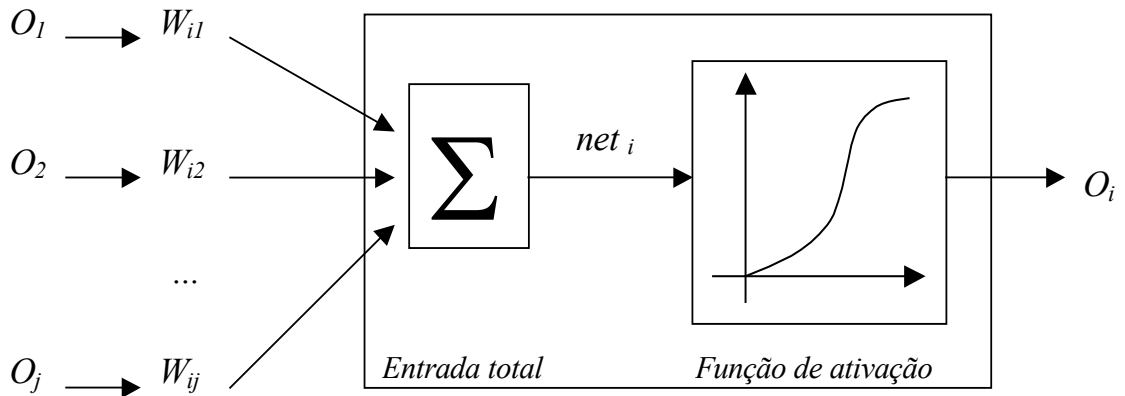
Os classificadores por regiões, supervisionados ou não, agrupam segmentos similares com base em distâncias de separabilidade (COSTA, 1999) e, em vez de considerar um pixel como unidade de medida, consideram um agrupamento de pixels.

Segundo MOREIRA (2001), os classificadores por regiões utilizam, além da informação espectral do pixel, a informação espacial desse pixel e de seus vizinhos, procurando simular o comportamento de um fotointérprete ao reconhecer áreas homogêneas dentro de uma imagem.

2.1.3. 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. Este método procura resolver problemas pela imitação do cérebro humano, utilizando de um grande número de neurônios interligados para processar os sinais de entrada (VENTURIERI e SANTOS, 1998).

A Figura 1 apresenta o modelo de um neurônio artificial simples.



Fonte: VIEIRA (2000).

Figura 1 – Modelo de um neurônio artificial u_i .

De forma sucinta, cada neurônio u_i é uma estrutura simples, que recebe a entrada O_j de muitos outros neurônios u_j , através dos pesos das conexões W_{ij} . Essas entradas com pesos são combinadas através de uma soma simples, que constitui a memória imediata da unidade. Em outras palavras, essa é a informação armazenada no neurônio a cada tempo t . Finalmente, a função de ativação aplicada à informação atual do neurônio fornece um nível discriminador no contexto do estímulo de entrada aplicado à rede (VIEIRA, 2000).

Segundo VIEIRA (2000), uma rede neural artificial é um conjunto de unidades computacionais conectadas segundo uma topologia específica. Cada unidade consiste em um número de conexões de entrada, uma função de ativação e uma conexão de saída. Os produtos das entradas e dos pesos são resumidos aos neurônios intermediários para derivar uma rede de entrada para aquela unidade. Essa rede de entrada é então transformada por uma função de ativação, a fim de produzir uma saída para a unidade. Isso pode ser expresso como:

$$net_i = \sum_j W_{ij} O_j \quad (1)$$

$$output = f(net_i) \quad (2)$$

em que W_{ij} é o peso associado com a conexão entre o neurônio corrente i e o neurônio anterior j ; e O_i é o estado de ativação ou a magnitude da i^{th} entrada (que é uma saída para o neurônio anterior). A função de ativação (f) empregada aqui é a mais utilizada: função *sigmóide*.

Treinamento em rede neural é uma resposta para o problema de ajustar os pesos da conexão entre neurônios de tal modo que a rede forneça um correto conjunto de valores de saída para um dado conjunto de valores de entrada. Uma maneira de se fazer isso é usar um conjunto de amostras de treinamento. Em síntese, o treinamento do comportamento de uma rede neural é a modificação do comportamento de saída em resposta ao estímulo de entrada. A rede aprende pela modificação dos pesos associados com as conexões entre neurônios (VIEIRA, 2000).

Segundo VIEIRA (2000), a arquitetura de rede mais freqüentemente utilizada é construída seguindo uma estrutura conceitual hierárquica. A entrada em uma unidade vem somente das unidades que precedem a camada. Pelo fato de haver um fluxo unidirecional de informação dentro da rede, elas são chamadas de redes neurais *feed-forward*. Entre esses modelos, o mais popular em uso é a arquitetura *feed-forward* com multicamadas completamente conectadas usando o algoritmo de treinamento *backpropagation*.

Esse método de treinamento é talvez o mais conhecido no contexto de sensoriamento remoto. A primeira vantagem do uso de redes neurais artificiais para classificação de cobertura terrestre diz respeito à estrutura de processamento, tolerância crítica e flexibilidade estatística. Em termos de processamento, redes neurais artificiais são inerentemente paralelas, e o processamento paralelo é mais rápido (isto é, depois de definir a estrutura interna da rede) do que as estruturas seriais usadas na maioria dos classificadores. Secundariamente, redes neurais tendem a ser mais robustas com respeito a informações perdidas ou com ruído. Finalmente, redes neurais artificiais não passam por suposições estatísticas; elas são completamente não-paramétricas (VIEIRA, 2000).

Segundo VENTURIERI e SANTOS (1998), 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. Ressalta-se a robustez do sistema de inteligência artificial, que oferece um grande potencial na discriminação das classes de cobertura terrestre em comparação com os sistemas de classificação convencionais.

2.1.4. Algoritmos de classificação

2.1.4.1. O algoritmo da Mínima Distância

Este algoritmo utiliza a média das amostras de treinamento para assinalar um pixel desconhecido a uma dada classe.

Regra de decisão

O algoritmo calcula a distância de cada pixel desconhecido a ser classificado até a média de cada classe em cada banda envolvida na classificação. O pixel será atribuído à classe que apresentar a menor distância entre eles. Esta distância é geralmente calculada usando a distância euclidiana mínima baseada no teorema de Pitágoras, cuja equação geral é dada a seguir:

$$D_{AB} = \sqrt{\sum_{i=1}^n (a_i - b_i)^2} \quad (3)$$

em que:

D_{AB} = distância do pixel desconhecido até a média de cada classe em cada banda;

a_i = valor numérico do pixel desconhecido; e

b_i = média dos valores numéricos dos pixels dentro da classe numa dada banda.

2.1.4.2. O algoritmo da Máxima Verossimilhança

Um dos algoritmos de classificação supervisionada por pixel mais utilizados, segundo CAMPBELL (1987), é o Algoritmo da Máxima Verossimilhança.

Este algoritmo utiliza a média e a covariância das amostras de treinamento para assinalar um pixel desconhecido a uma dada classe. Dados esses parâmetros, pode ser computada a probabilidade estatística de um pixel desconhecido pertencer a uma ou outra classe. Funções de densidade de probabilidade são utilizadas para classificar um pixel desconhecido, computando a probabilidade de que aquele pixel venha a pertencer a uma dada categoria. Depois de avaliar a probabilidade para cada categoria, o pixel é assinalado na classe cuja probabilidade tenha sido a mais alta, ou em nenhuma delas, no caso de os valores de probabilidade estarem abaixo de um determinado limite estipulado pelo analista.

Regra de decisão

Seja:

M_c = vetor das médias para cada classe c ;

V_c = matriz de covariância da classe c contemplando todas as bandas (K, \dots, L); e

X = vetor de medidas dos pixels desconhecidos.

$$X = \begin{bmatrix} VN_{ij1} \\ VN_{ij2} \\ VN_{ij3} \\ \dots \\ VN_{ijn} \end{bmatrix} \quad (4)$$

em que n é o número de bandas

Assinale X na classe c se e somente se $P_c \geq P_i$, sendo:

$i = 1, 2, 3, \dots, m$ possíveis classes;

P_c = probabilidade de o vetor X ser assinalado na classe c ; e

P_i = probabilidade de o vetor X ser assinalado em qualquer outra classe.

A função de densidade de probabilidade é dada a seguir:

$$P_c = [-0,5 \log_e (\det (V_c))] - [0,5 (X - M_c)^T (V_c)^{-1} (X - M_c)] \quad (5)$$

em que $\det (V_c)$ = determinante da matriz de covariância V_c .

Assim, para classificar o vetor X , a regra de decisão computa o valor P_c para cada classe e atribui o pixel à classe que possua o maior valor.

A equação anterior considera que as classes sejam equiprováveis no terreno. No entanto, em muitas aplicações, existe uma alta probabilidade de encontrar algumas classes mais freqüentemente do que outras. É possível incluir esta informação *a priori* no processo de decisão atribuindo pesos a cada classe c , de acordo com a sua apropriada probabilidade *a priori*, a_c . Assim, a equação torna-se:

$$P_c(a_c) = \log_e (a_c) - [-0,5 \log_e (\det (V_c))] - [0,5 (X - M_c)^T (V_c)^{-1} (X - M_c)] \quad (6)$$

Deve-se assinalar X na classe c se e somente se $P_c(a_c) \geq P_i(a_c)$, em que: $i = 1, 2, 3, \dots, m$ possíveis classes.

A probabilidade *a priori* tem sido usada com sucesso como um meio de incorporar os efeitos de deslocamento e outras características do terreno na melhoria da exatidão da classificação.

2.1.4.3. O algoritmo *backpropagation*

O modelo *backpropagation* é um algoritmo de classificação supervisionada que, segundo VIEIRA (2000), minimiza iterativamente uma função de erro através das saídas da rede e de um conjunto de saídas desejadas derivadas de um conjunto de dados de treinamento. O processo continua até o erro convergir para um nível baixo e aceitável. Convencionalmente, a função de erro é dada pela equação:

$$E = \frac{1}{2} \sum_i (T_i - O_i)^2 \quad (7)$$

em que T_i é o vetor de saídas desejadas para o conjunto de treinamento e O_i é o vetor de saída da rede para o conjunto de treinamento dado.

Em cada iteração, o algoritmo *backpropagation* computa recursivamente o gradiente ou a mudança no erro no que diz respeito a cada peso na rede, e esses valores são usados para modificar os pesos entre unidades da rede. Somar uma fração do gradiente negativo para cada peso é equivalente a realizar uma minimização descendente excessiva do erro com respeito a cada peso na rede.

Segundo VIEIRA (2000), treinar uma rede neural *feed-forward* usando treinamento supervisionado consiste nos seguintes passos:

- A rede começa em um estado inicial, com alocação aleatória de pesos entre neurônios. Os pesos devem ser inicializados com valores aleatórios pequenos, o que evita o problema de a rede ficar saturada com valores grandes ou a dificuldade de ela não treinar, devido à presença de valores de pesos homogêneos.
- Um padrão de entrada é apresentado à rede. A entrada é transmitida na rede até que a ativação alcance a camada de saída.
- A saída gerada pela rede neural é então comparada com o valor desejado, correspondente a uma amostra de treinamento particular. O erro (equação 4), isto é, a diferença entre a saída gerada e a saída desejada, é então usado para computar a mudança na conexão. Desse modo, os erros são propagados no sentido inverso.
- Este processo se repete para o restante das amostras de treinamento, submetendo interativamente o conjunto de treinamento até que o erro alcance um nível baixo e aceitável.

2.1.5. Avaliação das imagens classificadas

Gong e Howard (1990), citados por BRITES (1996), sugerem o índice kappa como um dos procedimentos mais utilizados para mensurar a exatidão das classificações temáticas, por representar inteiramente a matriz de erros, que identifica o erro global da classificação para cada categoria, mostrando também como se deram as confusões entre as categorias. Para Rosenfield e

Fitspatrick-Lins, também citados por BRITES (1996), o índice kappa é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância, além da casualidade, e a discordância esperada. A estimativa do índice kappa é a proporção de concordância desconsiderando-se a concordância em virtude da casualidade.

O cálculo do índice kappa é efetuado por meio da seguinte relação (CONGALTON e GREEN, 1998):

$$K = \frac{x \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{x^2 - \sum_{i=1}^r x_{i+} x_{+i}} \quad (8)$$

em que:

x = elemento da matriz de erros;

r = número de categorias presente na matriz de erros;

x_{ii} = elementos da diagonal principal;

x_{i+} = total da linha para uma dada categoria informacional; e

x_{+i} = total da coluna para uma dada categoria informacional.

Em se tratando da maioria das aplicações em sensoriamento remoto, é necessário que a classificação apresente um nível de exatidão satisfatório. CONGALTON e GREEN (1998) caracterizaram os intervalos de valores nos quais o índice kappa determina o nível de aceitação dos resultados das classificações. Esses intervalos são apresentados no Quadro 1.

Quadro 1 – Nível de aceitação dos resultados das classificações segundo o índice kappa

| Índice kappa (K) | Característica |
|----------------------|----------------|
| $K \leq 0,4$ | Pobre |
| $0,4 < K \leq 0,8$ | Razoável |
| $K \geq 0,8$ | Excelente |

A determinação da significância do índice kappa é feita utilizando-se o teste estatístico Z , conforme equação a seguir (CONGALTON e GREEN, 1998):

$$Z = \frac{K}{\sqrt{\text{var}(K)}} \quad (9)$$

em que:

K = coeficiente kappa; e

$\text{var}(K)$ = variância do coeficiente kappa.

A variância do índice kappa é obtida através da seguinte equação (CONGALTON e GREEN, 1998):

$$\text{var}(K) = \frac{1}{n} \left\{ \frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right\} \quad (10)$$

em que:

$$\theta_1 = \frac{1}{X} \sum_{i=1}^r x_{ii} \quad (11)$$

$$\theta_2 = \frac{1}{X^2} \sum_{i=1}^r x_{i+} x_{+i} \quad (12)$$

$$\theta_3 = \frac{1}{X^2} \sum_{i=1}^r x_{ii} (x_{i+} + x_{+i}) \quad (13)$$

e

$$\theta_4 = \frac{1}{X^3} \sum_{i=1}^r \sum_{j=1}^r x_{ij} (x_{j+} + x_{+i})^2 \quad (14)$$

sendo:

x = elemento da matriz de erros;

r = número de categorias presente na matriz de erros;

x_{ji} = elementos da diagonal principal;

x_{i+} = total da linha para uma dada categoria informacional;

x_{+j} = total da coluna para uma dada categoria informacional;

x_{ij} = número de amostras classificadas em uma categoria i na classificação e categoria j nos dados de referência; e

x_{j+} = número de amostras classificadas na categoria j nos dados de referência .

O valor de Z calculado, se maior do que o Z tabelado (1,96, para 95% de probabilidade), indica que o resultado da classificação é significativo e significativamente melhor do que o resultado de uma classificação aleatória.

Para testar se duas matrizes de erros independentes são significativamente diferentes, utiliza-se o teste Z , conforme especificado na equação apresentada na seqüência (CONGALTON e GREEN, 1998):

$$Z = \frac{(K_1 - K_2)}{\sqrt{\text{var}(K_1) + \text{var}(K_2)}} \quad (15)$$

em que:

K_1 = coeficiente kappa do método 1;

K_2 = coeficiente kappa do método 2;

$\text{var}(K_1)$ = variância do coeficiente kappa do método 1; e

$\text{var}(K_2)$ = variância do coeficiente kappa do método 2.

Uma matriz de significância apresenta os resultados comparando classificações duas a duas e mostrando em quais comparações há diferença significativa entre as duas classificações (VIEIRA, 2000).

Segundo CONGALTON e GREEN (1998), se o teste mostrar que não existe diferença significativa entre as duas, então pode-se usar a opção mais barata, mais rápida ou mais eficiente.

2.2. Imagens digitais de alta resolução

Com os recentes avanços na tecnologia do sensoriamento remoto, imagens de alta resolução espacial e espectral tornam-se disponíveis comercialmente e para pesquisa. Muitos usuários esperam fazer uso desses novos dados de imagens para obter soluções com um custo menor do que aquele gerado com a utilização de fotografias aéreas e interpretação visual (FISHER e GOETZ, 2001).

Imagens de alta resolução trazem consigo, no entanto, um novo conjunto de questões associadas à resolução de elementos individuais da cena, que devem ser consideradas. Essas imagens possuem uma vantagem significativa: identificação de feições espaciais a partir de informação textural. Considerando previamente que imagens com resolução mais grosseira têm sua utilização dificultada sem o conhecimento *a priori* das feições terrestres, o acréscimo da informação textural disponível em imagens de alta resolução permite melhorar a interpretação, com base na forma e textura dessas feições. Por exemplo, edifícios se tornam feições identificáveis representados em múltiplos pixels, em lugar de um único pixel. Campos com vegetação escassa aparecem como parcelas de solo exposto com traços de vegetação, em lugar de uma complexa mistura de assinaturas espectrais. Métodos anteriormente utilizados com o propósito de delinear feições em fotografias aéreas pancromáticas podem ser utilizados em imagens digitais para apoiar, por exemplo, classificações de tipos de uso e cobertura terrestre (FISHER e GOETZ, 2001).

Dificuldades associadas com pixels misturados (pixels que sobrepõem duas ou mais superfícies diferentes e, assim, mostram propriedades espectrais das duas) podem ser reduzidas com imagens de alta resolução, pois os pixels cobrirão superfícies distintas na maioria dos casos. O aumento da resolução espacial também significa que parcelas individuais, como edifícios e rodovias, tornam-se claramente visíveis e interpretáveis pelo olho humano. Esse mesmo atributo

permite que áreas mais heterogêneas sejam distinguidas, sendo possível identificar a localização exata de culturas infestadas ou estressadas em fazendas e avaliar a extensão da invasão biológica (crescimento de plantas daninhas) ou mudanças na umidade da terra em ecossistemas de menor escala. Além disso, imagens de alta resolução são freqüentemente úteis na interpretação de imagens com menor resolução espacial e podem ser utilizadas em estratégias de amostragem (FISHER e GOETZ, 2001).

Uma dificuldade adicional é apresentada na iluminação dos elementos da cena. Um ângulo de elevação solar alto reduz sombras, que são mais proeminentes em imagens de alta resolução do que naquelas de menor resolução espacial. Essas sombras podem ser difíceis de ser identificadas e classificadas, constituindo fontes de erros em interpretação de imagens. Além do mais, pelo fato de objetos tridimensionais interceptarem a luz diferentemente, eles aparecem com iluminação e reflectância espectral não-uniformes (FISHER e GOETZ, 2001).

Até o advento do satélite IKONOS II e de sistemas orbitais de imageamento de alta resolução similares, o método mais usual de obtenção de imagens de alta resolução de pequenas áreas era o uso de sistemas aerotransportados. Para FISHER e GOETZ (2001), as maiores dificuldades para aquisição dos dados nesses sistemas são aquelas que afetam o voo propriamente dito. Mapear uma área extensa em um avião de voo baixo pode levar várias horas. Nesse mesmo tempo, ocorrem mudanças no tempo e na iluminação. Também é difícil obter imagens múltiplas consistentes em cima de uma mesma área para comparação direta.

Os sistemas de imageamento de alta resolução espacial também produzem grande volume de dados para serem pré-processados durante ou após a aquisição destes, antes que eles possam ser usados para alguma aplicação. São ainda freqüentemente limitados em sua capacidade para registrar dados com boa resolução espectral. Assim, o potencial para identificar emissões específicas e espectro de absorção pode ser limitado (FISHER e GOETZ, 2001).

2.3. O Satélite IKONOS II

A seguir, apresenta-se a ficha técnica do satélite IKONOS II (ENGESAT, 2002).

O satélite IKONOS II foi lançado no dia 24 de setembro de 1999 e encontra-se em operação desde o início de janeiro de 2000. É operado pela SPACE IMAGING, que detém os direitos de comercialização em nível mundial.

As imagens geradas pelo IKONOS II possuem grande resolução espacial, apresentando 1 metro no modo pancromático e 4 metros no modo multiespectral, aliada a uma grande precisão cartográfica, que é obtida através do processo de georreferenciamento das imagens.

Para se conseguir a alta resolução espacial, as bandas espectrais dos sensores no visível são mais largas dentro do espectro eletromagnético, permitindo maior penetração na atmosfera e maior poder de discriminação dos alvos terrestres, principalmente de cobertura vegetal, áreas sombreadas e corpos d'água.

As imagens geradas pelo IKONOS II permitem discriminar objetos de 1 m² de área ou maiores.

As imagens adquiridas no modo pancromático, com 1 metro de resolução espacial, podem ser combinadas com as imagens multiespectrais, com 4 metros de resolução espacial, gerando imagens multiespectrais coloridas com 1 metro de resolução espacial, combinando então as vantagens dos dois tipos de imagem.

Além da alta resolução espacial, as imagens possuem uma resolução radiométrica de 11 bits (2.048 níveis de cinza), aumentando o seu poder de discriminação, inclusive nas áreas de sombra. Outras imagens de satélites, como SPOT, CBERS, IRS ou LANDSAT, possuem resolução radiométrica de 8 bits (1 byte) ou 256 níveis de cinza.

O IKONOS II tem capacidade de efetuar visadas no sentido de sua órbita e perpendicularmente a ela, aumentando a frequência de revisita e possibilitando a aquisição de pares estereoscópicos, utilizados para trabalhos de restituição de altimetria.

As principais características técnicas do satélite IKONOS II e de seus produtos estão resumidas no Quadro 2.

Quadro 2 – Características técnicas do satélite IKONOS II

| | |
|---|--|
| Altitude | 680 km |
| Inclinação | 98,1° |
| Velocidade | 7 km/s |
| Sentido da Órbita | Descendente |
| Duração da Órbita | 98 minutos |
| Tipo de Órbita | Sol-síncrona |
| Resolução Espacial | Pancromática: 1 metro - Multiespectral: 4 metros |
| Bandas Espectrais | Pan: 0,45 – 0,90 μ Azul: 0,45 – 0,52 μ Verde: 0,52 – 0,60 μ Vermelho: 0,63 – 0,69 μ Infravermelho próximo: 0,76 – 0,90 μ |
| Imageamento | 13 km na vertical (cenas de 13 x 13 km) |
| Capacidade de Aquisição de Imagens | Faixas de 11 x 100 km até 11 x 1.000 km Mosaicos de até 12.000 km ² 20.000 km ² de área imageada numa passagem |
| Frequência de Revisita | 2,9 dias no modo Pancromático 1,5 dia no modo Multiespectral Esses valores valem para latitude de $\pm 40^\circ$. A frequência de revisita para latitudes maiores é menor, e maior para as latitudes perto do Equador. |

Fonte: ENGESAT (2002).

São inúmeras as aplicações potenciais que podem se tornar reais utilizando as imagens IKONOS II, em quase todos os ramos que utilizam imagens de satélites e em muitos outros que sofrem com a limitação da resolução dos sistemas convencionais, desde a gestão do espaço geográfico complexo e extenso até a análise pontual:

- SIG (redes, telecomunicações, planejamento, meio ambiente);
- Elaboração de mapas urbanos;
- Mapas de arruamentos e cadastro;
- Cadastros urbano e rural;
- Apoio em GPS;
- Uso e ocupação do solo (urbano sobretudo);
- Meio ambiente em escalas grandes;

- Arquitetura/urbanismo/paisagismo;
- Fundiário (regularização de propriedades, demarcação de pequenas glebas);
- Engenharia (simulações mais realistas) em escalas da ordem de 1:5.000 até 1:2.500;
- Agricultura convencional e agricultura de precisão;
- Florestal (estimativa de potencial econômico, projetos de desenvolvimento sustentável, censo de árvores);
- Turismo (identificação de locais específicos, mapas de localização de atrativos turísticos);
- Trabalhos até então realizados com fotos aéreas;
- Perícias em questões ambientais.

2.4. Aplicações de imagens de alta resolução

A seguir são apresentados alguns estudos realizados com imagens de alta resolução, apontando seu potencial de utilização, bem como as dificuldades encontradas ao lidar com suas características únicas.

Imagens digitais de alta resolução do sensor Emerge foram usadas para classificação da cobertura urbana em Syracuse, New York, por MYEONG et al. (2001). O estudo tentou identificar cinco classes: árvores, grama, solo exposto, água e superfícies impermeáveis. Algumas classes apresentaram respostas espectrais semelhantes, resultando em confusão. Dificuldades na classificação ocorreram para água e superfícies impermeáveis negras, concreto e solo exposto, grama e árvores. Com o intuito de melhorar a classificação, foi avaliada a incorporação de textura, para diferenciar árvores e estrutura de floresta urbana da grama, e também uma relação entre bandas (NDVI), para distinguir vegetação de outras classes. A água foi separada das outras classes usando uma máscara baseada em dados de mapa e interpretação de imagens. Foi utilizado um filtro de moda 3x3 duas vezes, a fim de reduzir o número de pequenas aglomerações na classificação e melhorar o resultado final. A precisão global da classificação foi de 81,75%.

Um estudo comparativo foi realizado por FISHER e GOETZ (2001) no Public Park do município de Montgomery, Maryland. Foram utilizados para comparação: um mapa planimétrico da área derivado de interpretação de fotos aéreas, uma imagem multiespectral de alta resolução do Airbone Imaging Spectrometer (AISA), com 2 metros de resolução, uma imagem Landsat Thematic Mapper (TM) e uma imagem do satélite IKONOS II, com 4 metros de resolução. Estatísticas indicaram que, embora o mapa obtido da imagem AISA tenha concordado mais com o mapa planimétrico por pixel, ocorreu um erro global maior do que o mapa obtido a partir da imagem IKONOS II. O mapa derivado da imagem Landsat alcançou a menor taxa de sucesso, em razão de a resolução da imagem TM não ter sido suficiente para discriminar as menores feições presentes na cena, fazendo com que casas isoladas e estradas estreitas fossem completamente perdidas. Embora o IKONOS II possua uma resolução espacial melhor do que a do Landsat, houve dificuldade em discriminar algumas classes de solos e superfícies pavimentadas, devido à menor resolução espectral. Os sistemas AISA e IKONOS II foram mais precisos do que o Landsat, por causa de sua habilidade em distinguir feições sutis e elementos individuais na cena.

SUGUMARAN e ZERR (2001) estudaram o potencial das imagens do satélite IKONOS II na cidade de Columbia, Missouri, para uso pela administração e pelo governo local. A exatidão global da imagem classificada utilizando diferentes métodos estatísticos variou entre 87 e 91%. Ocorreu confusão entre algumas classes, o que influenciou a precisão da classificação. Áreas de floresta decídua foram classificadas como milho. Áreas urbanas com presença de sombras foram classificadas como água, bem como áreas de bordas de floresta com presença de sombras, que também foram classificadas erroneamente. Concluiu-se que muitos dos problemas encontrados durante a classificação podem ser minimizados na fase de aquisição dos dados, especificando o azimute de aquisição dos dados para reduzir sombras e adquirindo imagens da mesma área em datas diferentes. Os mesmos autores citam como principal problema do uso de imagens do satélite IKONOS II sua baixa resolução espectral. Sugerem ainda que estudos sejam realizados com o intuito de comparar diferentes métodos de classificação aplicados às imagens IKONOS II.

Outro estudo foi realizado por KURY e VIEIRA (2002), que desenvolveram uma metodologia para classificação automática de imagens de alta resolução espacial utilizando regiões como unidades de classificação, sendo usada uma imagem do satélite IKONOS II de uma área localizada próximo à cidade de Lascano, no Uruguai. A imagem foi dividida em várias regiões espectralmente homogêneas e foi realizada a classificação automática por regiões, utilizando-se o algoritmo da Máxima Verossimilhança. Algumas regiões foram classificadas incorretamente, devido à semelhança entre os dois tipos de vegetação. Obteve-se um Índice de Exatidão Global igual a 96,4%.

PAOLA et. al. (1997) utilizaram redes neurais para classificação da cobertura do solo e concluíram que o desempenho da rede é melhor que dos algoritmos tradicionais de classificação.

3. MATERIAL E MÉTODOS

3.1. Localização e caracterização da área

A área de estudo está localizada no município de Serra do Salitre, Estado de Minas Gerais, compreendida entre as coordenadas geográficas 19°14' S e 19°20' de latitude sul e 46°43' S e 46°37' de longitude oeste.

Segundo VILELA (2002), a área apresenta clima temperado chuvoso, com precipitação média anual de 1.600 mm e temperaturas médias mínima e máxima de 14,5 e 24,8 °C, respectivamente. A altitude da área varia de 850 a 970 m e a vegetação predominante é o cerrado, com suas diversas fitofisionomias já bastante antropizadas.

Na Figura 2 é mostrada a localização da área de estudo.

3.2. Materiais utilizados

Os materiais utilizados foram uma imagem IKONOS II, um computador e *softwares*, conforme descrições a seguir.




Figura 2 – Localização da área de estudo.

3.2.1. Imagem IKONOS II

Os dados utilizados no presente estudo foram derivados de uma imagem obtida pelo satélite IKONOS II, bandas azul, verde, vermelho e infravermelho próximo, obtida em 2 de março de 2002. No Quadro 3 são apresentadas a porção do espectro eletromagnético (λ) e a resolução espacial referentes a cada banda utilizada.

Quadro 3 – Resolução espectral (λ) e espacial das bandas azul, verde, vermelho e infravermelho próximo do satélite IKONOS II

| Banda | λ (μm) | Resolução Espacial (m) |
|-----------------------|-----------------------------|------------------------|
| Azul | 0,45 – 0,52 | 4 |
| Verde | 0,52 – 0,60 | 4 |
| Vermelho | 0,63 – 0,69 | 4 |
| Infravermelho Próximo | 0,76 – 0,90 | 4 |

3.2.2. Sistemas computacionais e equipamentos utilizados

Na realização do trabalho utilizou-se um microcomputador AMD Athlon 950 Mhz, com HD de 40 GB e memória RAM de 256 MB, e os seguintes *softwares*: CartaLinx 1.2, Idrisi 32, MatLab 6.0, SNNS (simulador de redes neurais), Max_Like_cof (VIEIRA, 2000), Funcpow (VIEIRA, 2000), Erdas Imagine 8.5 e MSEXcel.

3.3. Classificação da imagem IKONOS II

Não foi necessária a realização de nenhum tipo de correção radiométrica sobre as imagens, tendo-se ainda optado por não realizar a correção geométrica, pois utilizou-se apenas uma imagem da mesma área.

A partir de levantamentos de campo, foram coletadas amostras utilizadas no treinamento dos classificadores, as quais foram coletadas de duas maneiras:

por pixels e por regiões. As amostras por regiões foram coletadas digitalizando-se polígonos sobre as classes de interesse na imagem.

As amostras coletadas por pixels são amostras nas quais os valores numéricos dos pixels amostrados são os dados que compõem o arquivo de treinamento. Já as amostras coletadas por regiões são amostras nas quais os valores médios dos pixels presentes nos polígonos amostrados são os dados que compõem o arquivo de treinamento.

Obteve-se, assim, um arquivo de treinamento com os valores numéricos dos pixels e outro arquivo de treinamento com os valores médios das regiões amostradas.

Foram definidas as seguintes classes informacionais presentes na área:

- | | |
|---------------------|----------------------|
| 1- Mata ciliar | 9- Milho |
| 2- Cerrado | 10- Restos culturais |
| 3- Braquiária | 11- Campo pedregoso |
| 4- Pasto | 12- Solo exposto |
| 5- Campo limpo/sujo | 13- Rio |
| 6- Café maduro | 14- Rodovia |
| 7- Café jovem | 15- Ferrovia |
| 8- Reforma de café | |

Encontra-se no Quadro 4 o número de amostras de treinamento coletadas para cada classe informacional presente na área.

Os algoritmos utilizados para efetuar a classificação foram o da Mínima Distância, através do *software* Funcpow (VIEIRA, 2000); o da Máxima Verossimilhança, por meio do *software* Max_Like_cof (VIEIRA, 2000); e o de Redes Neurais Artificiais (*Backpropagation*), através do simulador de redes neurais SNNS.

As formulações matemáticas desses algoritmos são descritas no item 2.1.4.

Quadro 4 – Número de amostras de treinamento coletadas para cada classe informacional

| Classe informacional | Nº de pixels | Nº de regiões |
|----------------------|--------------|---------------|
| Mata ciliar | 60 | 30 |
| Cerrado | 60 | 30 |
| Braquiária | 60 | 29 |
| Pasto | 60 | 30 |
| Campo limpo/sujo | 60 | 30 |
| Café maduro | 60 | 30 |
| Café jovem | 60 | 29 |
| Reforma de café | 60 | 24 |
| Milho | 60 | 30 |
| Restos culturais | 60 | 30 |
| Campo pedregoso | 60 | 30 |
| Solo exposto | 60 | 30 |
| Rio | 60 | 30 |
| Rodovia | 60 | 18 |
| Ferrovia | 60 | 18 |
| Total | 900 | 418 |

Foram realizadas classificações por pixel e por regiões para cada algoritmo, totalizando seis análises:

- MinDist P = Mínima Distância por pixels;
- MinDist R = Mínima Distância por regiões;
- MaxVer P = Máxima Verossimilhança por pixels;
- MaxVer R = Máxima Verossimilhança por regiões;
- RNAs P = *Backpropagation* (redes neurais artificiais) por pixels;
- RNAs R = *Backpropagation* (redes neurais artificiais) por regiões.

A exemplo das amostras de treinamento, foi gerado um arquivo de referência para cada um dos métodos utilizados, por pixels e por regiões.

Obteve-se então um arquivo de teste com os valores numéricos dos pixels e outro com os valores médios das regiões amostradas.

No Quadro 5 é apresentado o número de amostras de teste coletadas para cada classe informacional presente na área.

Quadro 5 – Número de amostras de teste coletadas para cada classe informacional

| Classe informacional | Nº de pixels | Nº de regiões |
|----------------------|--------------|---------------|
| Mata ciliar | 40 | 20 |
| Cerrado | 40 | 20 |
| Braquiária | 40 | 20 |
| Pasto | 40 | 20 |
| Campo limpo/sujo | 40 | 20 |
| Café maduro | 40 | 20 |
| Café jovem | 40 | 20 |
| Reforma de café | 40 | 17 |
| Milho | 40 | 20 |
| Restos culturais | 40 | 19 |
| Campo pedregoso | 40 | 20 |
| Solo exposto | 40 | 20 |
| Rio | 40 | 20 |
| Rodovia | 40 | 12 |
| Ferrovia | 40 | 12 |
| Total | 600 | 280 |

Depois de realizadas as classificações e obtidos os dados de referência, procedeu-se à validação das imagens temáticas geradas, com a obtenção das matrizes de erros e o cálculo dos índices kappa para cada método empregado, através da equação (8).

A significância da diferença entre os índices kappa Ka_1 e Ka_2 quaisquer foi verificada pela aplicação do teste estatístico Z a 95% de probabilidade, por meio da equação (10).

Após concluídas as etapas anteriores, as imagens temáticas resultantes dos processos de classificação foram geradas, sendo apresentadas no item 4 – Resultados e Discussão.

4. RESULTADOS E DISCUSSÃO

4.1. Avaliação quantitativa das imagens classificadas

A análise quantitativa das imagens classificadas foi realizada tendo como parâmetros as matrizes de erros e os índices kappa obtidos a partir destas.

O cálculo do índice kappa é efetuado por meio da equação (8).

4.1.1. Matrizes de erros

Nos Quadros 6, 7, 8, 9, 10 e 11 são apresentadas as matrizes de erros de cada método de classificação. As colunas representam os dados de referência (verdade de campo), enquanto as linhas, a classificação gerada.

A linha Producer's Accuracy (Produ.) indica a porcentagem de pixels classificados corretamente em cada classe. Esta linha é calculada dividindo-se o número total de pixels classificados corretamente como uma dada classe pelo número total de amostras.

A coluna User's Accuracy (Users) indica a porcentagem de pixels classificados como uma dada classe e que realmente pertencem àquela classe em campo. Ela é calculada dividindo-se o número total de pixels classificados corretamente como uma dada classe pelo número total de pixels classificados como pertencendo a esta mesma classe.

Quadro 6 – Matriz de erros referente ao método da Mínima Distância por pixels

| Class. | Dados de referência | | | | | | | | | | | | | | | Total | Users |
|--------|---------------------|------|------|------|------|------|------|-----|------|------|------|-------|-------|------|------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | | |
| 1 | 26 | 11 | 0 | 0 | 0 | 2 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 40 | 65,0 |
| 2 | 9 | 29 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 5 | 0 | 0 | 0 | 1 | 45 | 64,4 |
| 3 | 0 | 0 | 36 | 8 | 1 | 0 | 5 | 7 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 57 | 63,2 |
| 4 | 0 | 0 | 1 | 16 | 1 | 0 | 13 | 1 | 0 | 4 | 0 | 0 | 0 | 0 | 5 | 41 | 39,0 |
| 5 | 0 | 0 | 0 | 0 | 12 | 0 | 0 | 0 | 0 | 7 | 9 | 0 | 0 | 1 | 3 | 32 | 37,5 |
| 6 | 4 | 0 | 0 | 0 | 0 | 28 | 0 | 0 | 14 | 0 | 0 | 0 | 0 | 0 | 0 | 46 | 60,9 |
| 7 | 0 | 0 | 3 | 3 | 0 | 0 | 13 | 0 | 7 | 0 | 0 | 0 | 0 | 0 | 4 | 30 | 43,3 |
| 8 | 0 | 0 | 0 | 5 | 3 | 0 | 5 | 0 | 1 | 8 | 0 | 0 | 0 | 0 | 5 | 27 | 0,0 |
| 9 | 1 | 0 | 0 | 5 | 0 | 10 | 4 | 1 | 17 | 0 | 0 | 0 | 0 | 0 | 1 | 39 | 43,6 |
| 10 | 0 | 0 | 0 | 2 | 5 | 0 | 0 | 4 | 0 | 21 | 2 | 0 | 0 | 1 | 1 | 36 | 58,3 |
| 11 | 0 | 0 | 0 | 0 | 10 | 0 | 0 | 0 | 0 | 0 | 22 | 0 | 0 | 2 | 2 | 36 | 61,1 |
| 12 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 24 | 0 | 0 | 0 | 40 | 0 | 1 | 1 | 67 | 59,7 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 40 | 0 | 0 | 40 | 100,0 |
| 14 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 3 | 0 | 0 | 1 | 0 | 0 | 33 | 9 | 48 | 68,8 |
| 15 | 0 | 0 | 0 | 1 | 4 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 2 | 8 | 16 | 50,0 |
| Total | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 600 | |
| Prod. | 65,0 | 72,5 | 90,0 | 40,0 | 30,0 | 70,0 | 32,5 | 0,0 | 42,5 | 52,5 | 55,0 | 100,0 | 100,0 | 82,5 | 20,0 | | |

Kappa = 0,537 Variância = 0,000461 Z estatístico = 25,026*

1- Mata ciliar

2- Cerrado

3- Braquiária

4- Pasto

5- Campo limpo/sujo

6- Café maduro

7- Café jovem

8- Reforma de café

9- Milho

10- Restos culturais

11- Campo pedregoso

12- Solo exposto

13- Rio

14- Rodovia

15- Ferrovia

Quadro 7 – Matriz de erros referente ao método da Mínima Distância por regiões

| Class. | Dados de referência | | | | | | | | | | | | | | | Total | Users |
|--------|---------------------|------|------|------|------|------|------|------|------|------|------|------|-------|------|------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | | |
| 1 | 14 | 1 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 16 | 87,5 |
| 2 | 6 | 19 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 26 | 73,1 |
| 3 | 0 | 0 | 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 12 | 100,0 |
| 4 | 0 | 0 | 3 | 10 | 0 | 0 | 5 | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 20 | 50,0 |
| 5 | 0 | 0 | 0 | 1 | 4 | 0 | 1 | 0 | 0 | 5 | 3 | 0 | 0 | 0 | 3 | 17 | 23,5 |
| 6 | 0 | 0 | 0 | 0 | 0 | 12 | 0 | 0 | 7 | 0 | 0 | 0 | 0 | 0 | 0 | 19 | 63,2 |
| 7 | 0 | 0 | 3 | 0 | 0 | 1 | 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 18 | 77,8 |
| 8 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 16 | 0 | 0 | 0 | 8 | 0 | 0 | 0 | 26 | 61,5 |
| 9 | 0 | 0 | 0 | 2 | 0 | 6 | 0 | 0 | 11 | 0 | 0 | 0 | 0 | 0 | 0 | 19 | 57,9 |
| 10 | 0 | 0 | 0 | 6 | 2 | 0 | 0 | 0 | 0 | 13 | 0 | 0 | 0 | 0 | 0 | 21 | 61,9 |
| 11 | 0 | 0 | 0 | 1 | 10 | 0 | 0 | 0 | 0 | 0 | 17 | 0 | 0 | 0 | 4 | 32 | 53,1 |
| 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 12 | 0 | 0 | 0 | 13 | 92,3 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 20 | 0 | 0 | 20 | 100,0 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 11 | 0 | 11 | 100,0 |
| 15 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 5 | 10 | 50,0 |
| Total | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 17 | 20 | 19 | 20 | 20 | 20 | 12 | 12 | 280 | |
| Prod. | 70,0 | 95,0 | 60,0 | 50,0 | 20,0 | 60,0 | 70,0 | 94,1 | 55,0 | 68,4 | 85,0 | 60,0 | 100,0 | 91,7 | 41,7 | | |

Kappa = 0,655 Variância = 0,000892 Z estatístico = 21,940*

1- Mata ciliar

2- Cerrado

3- Braquiária

4- Pasto

5- Campo limpo/sujo

6- Café maduro

7- Café jovem

8- Reforma de café

9- Milho

10- Restos culturais

11- Campo pedregoso

12- Solo exposto

13- Rio

14- Rodovia

15- Ferrovia

Quadro 8 – Matriz de erros referente ao método da Máxima Verossimilhança por pixels

| Class. | Dados de referência | | | | | | | | | | | | | | | Total | Users |
|--------|---------------------|------|------|------|------|------|------|------|------|------|------|-------|------|------|------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | | |
| 1 | 18 | 9 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 28 | 64,3 |
| 2 | 16 | 27 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 45 | 60,0 |
| 3 | 0 | 0 | 32 | 5 | 0 | 0 | 2 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 41 | 78,0 |
| 4 | 0 | 0 | 5 | 26 | 1 | 0 | 8 | 4 | 5 | 2 | 0 | 0 | 3 | 1 | 5 | 60 | 43,3 |
| 5 | 0 | 0 | 0 | 0 | 12 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 15 | 80,0 |
| 6 | 3 | 0 | 0 | 0 | 0 | 26 | 0 | 0 | 9 | 0 | 0 | 0 | 0 | 0 | 0 | 38 | 68,4 |
| 7 | 0 | 0 | 2 | 1 | 0 | 0 | 22 | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 2 | 29 | 75,9 |
| 8 | 1 | 3 | 1 | 2 | 10 | 1 | 2 | 27 | 0 | 7 | 2 | 0 | 2 | 0 | 5 | 63 | 42,9 |
| 9 | 2 | 0 | 0 | 3 | 0 | 12 | 4 | 1 | 25 | 0 | 0 | 0 | 0 | 0 | 0 | 47 | 53,2 |
| 10 | 0 | 0 | 0 | 0 | 1 | 0 | 2 | 2 | 0 | 30 | 2 | 0 | 0 | 0 | 1 | 38 | 78,9 |
| 11 | 0 | 0 | 0 | 0 | 11 | 0 | 0 | 0 | 0 | 0 | 28 | 0 | 0 | 0 | 0 | 39 | 71,8 |
| 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 40 | 0 | 0 | 0 | 43 | 93,0 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 35 | 0 | 0 | 35 | 100,0 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 32 | 2 | 35 | 91,4 |
| 15 | 0 | 1 | 0 | 3 | 4 | 0 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 7 | 25 | 44 | 56,8 |
| Total | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 600 | |
| Prod. | 45,0 | 67,5 | 80,0 | 65,0 | 30,0 | 65,0 | 55,0 | 67,5 | 62,5 | 75,0 | 70,0 | 100,0 | 87,5 | 80,0 | 62,5 | | |

Kappa = 0,652 Variância = 0,000418 Z estatístico = 31,877*

- | | |
|---------------------|----------------------|
| 1- Mata ciliar | 9- Milho |
| 2- Cerrado | 10- Restos culturais |
| 3- Braquiária | 11- Campo pedregoso |
| 4- Pasto | 12- Solo exposto |
| 5- Campo limpo/sujo | 13- Rio |
| 6- Café maduro | 14- Rodovia |
| 7- Café jovem | 15- Ferrovia |
| 8- Reforma de café | |

Quadro 9 – Matriz de erros referente ao método da Máxima Verossimilhança por regiões

| Class. | Dados de referência | | | | | | | | | | | | | | | Total | Users |
|--------|---------------------|------|-------|------|------|------|------|------|------|------|------|------|------|------|------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | | |
| 1 | 19 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 22 | 86,4 |
| 2 | 1 | 17 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 18 | 94,4 |
| 3 | 0 | 0 | 20 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 22 | 90,9 |
| 4 | 0 | 0 | 0 | 14 | 0 | 1 | 3 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 20 | 70,0 |
| 5 | 0 | 0 | 0 | 0 | 12 | 0 | 0 | 1 | 0 | 0 | 2 | 0 | 0 | 0 | 1 | 16 | 75,0 |
| 6 | 0 | 0 | 0 | 1 | 0 | 15 | 0 | 0 | 8 | 0 | 0 | 0 | 0 | 0 | 0 | 24 | 62,5 |
| 7 | 0 | 0 | 0 | 2 | 0 | 0 | 16 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 18 | 88,9 |
| 8 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 15 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 15 | 100,0 |
| 9 | 0 | 0 | 0 | 2 | 0 | 4 | 0 | 0 | 12 | 0 | 0 | 0 | 0 | 0 | 0 | 18 | 66,7 |
| 10 | 0 | 0 | 0 | 1 | 1 | 0 | 1 | 0 | 0 | 18 | 0 | 0 | 0 | 0 | 0 | 21 | 85,7 |
| 11 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 18 | 0 | 0 | 0 | 0 | 22 | 81,8 |
| 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 19 | 0 | 0 | 0 | 19 | 100,0 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 19 | 0 | 0 | 19 | 100,0 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 9 | 0 | 9 | 100,0 |
| 15 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 11 | 17 | 64,7 |
| Total | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 17 | 20 | 19 | 20 | 20 | 20 | 12 | 12 | 280 | |
| Prod. | 95,0 | 85,0 | 100,0 | 70,0 | 60,0 | 75,0 | 80,0 | 88,2 | 60,0 | 94,7 | 90,0 | 95,0 | 95,0 | 75,0 | 91,7 | | |

Kappa = 0,824 Variância = 0,000564 Z estatístico = 34,696*

1- Mata ciliar

2- Cerrado

3- Braquiária

4- Pasto

5- Campo limpo/sujo

6- Café maduro

7- Café jovem

8- Reforma de café

9- Milho

10- Restos culturais

11- Campo pedregoso

12- Solo exposto

13- Rio

14- Rodovia

15- Ferrovia

Quadro 10 – Matriz de erros referente ao método de Redes Neurais Artificiais (*Backpropagation*) por pixels

| Class. | Dados de referência | | | | | | | | | | | | | | | Total | Users |
|--------|---------------------|------|------|------|------|------|------|------|------|------|------|-------|-------|------|------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | | |
| 1 | 30 | 12 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 43 | 69,8 |
| 2 | 5 | 26 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 2 | 35 | 74,3 |
| 3 | 0 | 0 | 36 | 5 | 0 | 0 | 2 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 45 | 80,0 |
| 4 | 1 | 0 | 0 | 22 | 2 | 0 | 5 | 2 | 1 | 2 | 0 | 0 | 0 | 1 | 7 | 43 | 51,2 |
| 5 | 0 | 1 | 0 | 0 | 15 | 0 | 0 | 2 | 0 | 1 | 4 | 0 | 0 | 0 | 1 | 24 | 62,5 |
| 6 | 3 | 0 | 0 | 0 | 0 | 28 | 0 | 0 | 10 | 0 | 0 | 0 | 0 | 0 | 0 | 41 | 68,3 |
| 7 | 0 | 0 | 1 | 2 | 0 | 0 | 24 | 2 | 4 | 3 | 0 | 0 | 0 | 0 | 2 | 38 | 63,2 |
| 8 | 0 | 0 | 1 | 0 | 4 | 0 | 2 | 23 | 2 | 0 | 1 | 0 | 0 | 0 | 1 | 34 | 67,6 |
| 9 | 1 | 0 | 2 | 6 | 11 | 5 | 1 | 23 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 49 | 46,9 |
| 10 | 0 | 0 | 0 | 1 | 0 | 0 | 2 | 4 | 0 | 34 | 1 | 0 | 0 | 0 | 1 | 43 | 79,1 |
| 11 | 0 | 0 | 0 | 0 | 16 | 0 | 0 | 0 | 0 | 0 | 30 | 0 | 0 | 2 | 0 | 48 | 62,5 |
| 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 40 | 0 | 0 | 0 | 42 | 95,2 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 40 | 0 | 0 | 40 | 100,0 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 29 | 5 | 35 | 82,9 |
| 15 | 0 | 1 | 0 | 4 | 2 | 0 | 0 | 1 | 0 | 0 | 3 | 0 | 0 | 8 | 21 | 40 | 52,5 |
| Total | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 40 | 600 | |
| Prod. | 75,0 | 65,0 | 90,0 | 55,0 | 37,5 | 70,0 | 60,0 | 57,5 | 57,0 | 85,0 | 75,0 | 100,0 | 100,0 | 72,5 | 52,5 | | |

Kappa = 0,680 Variância = 0,000400 Z estatístico = 34,038*

1- Mata ciliar

2- Cerrado

3- Braquiária

4- Pasto

5- Campo limpo/sujo

6- Café maduro

7- Café jovem

8- Reforma de café

9- Milho

10- Restos culturais

11- Campo pedregoso

12- Solo exposto

13- Rio

14- Rodovia

15- Ferrovia

Quadro 11 – Matriz de erros referente ao método de Redes Neurais Artificiais (*Backpropagation*) por regiões

| Class. | Dados de referência | | | | | | | | | | | | | | | Total | Users |
|--------|---------------------|------|------|------|------|------|------|------|------|------|------|------|-------|------|------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | | |
| 1 | 19 | 3 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 23 | 82,6 |
| 2 | 1 | 15 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 17 | 88,2 |
| 3 | 0 | 0 | 18 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 18 | 100,0 |
| 4 | 0 | 0 | 0 | 18 | 0 | 1 | 4 | 1 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 25 | 72,0 |
| 5 | 0 | 0 | 0 | 0 | 12 | 0 | 0 | 2 | 0 | 0 | 3 | 0 | 0 | 0 | 1 | 20 | 60,0 |
| 6 | 0 | 0 | 0 | 0 | 0 | 15 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 16 | 93,8 |
| 7 | 0 | 0 | 0 | 0 | 0 | 0 | 11 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 11 | 100,0 |
| 8 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 14 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 15 | 93,3 |
| 9 | 0 | 0 | 2 | 2 | 0 | 4 | 4 | 0 | 19 | 0 | 0 | 0 | 0 | 0 | 0 | 31 | 61,3 |
| 10 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 16 | 0 | 0 | 0 | 0 | 0 | 17 | 94,1 |
| 11 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 0 | 0 | 1 | 17 | 0 | 0 | 0 | 0 | 22 | 77,3 |
| 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 19 | 0 | 0 | 0 | 19 | 100,0 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 20 | 0 | 0 | 20 | 100,0 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 10 | 0 | 10 | 100,0 |
| 15 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 16 | 68,8 |
| Total | 20 | 20 | 20 | 20 | 20 | 20 | 20 | 17 | 20 | 19 | 20 | 20 | 20 | 12 | 12 | 280 | |
| Prod. | 95,0 | 75,0 | 90,0 | 90,0 | 60,0 | 75,0 | 55,0 | 82,4 | 95,0 | 84,2 | 85,0 | 95,0 | 100,0 | 83,3 | 91,7 | | |

Kappa = 0,824 Variância = 0,000563 Z estatístico = 34,722*

- | | |
|---------------------|----------------------|
| 1- Mata ciliar | 9- Milho |
| 2- Cerrado | 10- Restos culturais |
| 3- Braquiária | 11- Campo pedregoso |
| 4- Pasto | 12- Solo exposto |
| 5- Campo limpo/sujo | 13- Rio |
| 6- Café maduro | 14- Rodovia |
| 7- Café jovem | 15- Ferrovia |
| 8- Reforma de café | |

O Quadro 6, referente ao método da Mínima Distância por pixels, mostra que os maiores erros ocorreram nas classes mata ciliar e cerrado, pasto e braquiária, campo limpo/sujo e campo pedregoso, café maduro e milho, café jovem e pasto, reforma de café e solo exposto, por apresentarem características espectrais similares. A classe ferrovia apresentou alto erro de omissão, sendo a maioria dos pixels de teste assinalada na outra classe. A classe reforma de café obteve erro de omissão igual a 100%, sendo a maioria dos pixels assinalada na classe solo exposto. As classes que apresentaram os maiores acertos na classificação foram braquiária, solo exposto e rio.

No Quadro 7, referente ao método da Mínima Distância por regiões, nota-se que os maiores erros ocorreram nas classes mata ciliar e cerrado, campo limpo/sujo e campo pedregoso, café maduro e milho, café jovem e pasto, solo exposto e reforma de café, em razão de apresentarem características espectrais similares. As classes que apresentaram os maiores acertos na classificação foram cerrado e rio.

No Quadro 8, referente ao método da Máxima Verossimilhança por pixels, a análise permitiu observar que os maiores erros ocorreram nas classes mata ciliar e cerrado, campo limpo/sujo e campo pedregoso, café maduro e milho, café jovem e pasto, por apresentarem características espectrais similares. As classes que apresentaram os maiores acertos na classificação foram solo exposto e rio.

No Quadro 9, referente ao método da Máxima Verossimilhança por regiões, nota-se que os maiores erros ocorreram nas classes campo limpo/sujo e campo pedregoso, café maduro e milho, café jovem e pasto, rodovia e ferrovia, por apresentarem características espectrais similares. As classes que apresentaram os maiores acertos na classificação foram braquiária, solo exposto e rio.

Já no Quadro 10, referente ao método de Redes Neurais Artificiais (*backpropagation*) por pixels, os maiores erros ocorreram nas classes cerrado e mata ciliar, campo limpo/sujo e campo pedregoso, café maduro e milho, rodovia e ferrovia, por apresentarem características espectrais similares. As classes que apresentaram os maiores acertos na classificação foram solo exposto e rio.

No Quadro 11, referente ao método de Redes Neurais Artificiais (backpropagation) por regiões, a análise mostrou que os maiores erros ocorreram nas classes cerrado e mata ciliar, campo limpo/sujo e campo pedregoso, café maduro e milho, café jovem e milho, café jovem e pasto, rodovia e ferrovia, em razão de apresentarem características espectrais similares. As classes que apresentaram os maiores acertos na classificação foram mata ciliar, milho, solo exposto e rio.

Os problemas na separação das classes podem ser explicados pela semelhança nas respostas espectrais destas, pela baixa resolução espectral da imagem e pela grande variação dentro das classes.

Observou-se ainda que, em todos os métodos, as classes mais homogêneas, como rio, obtiveram altos índices de classificação correta, tendo poucos pixels classificados incorretamente.

A classe campo limpo/sujo obteve baixo índice de classificação correta em todos os métodos.

4.1.2. Índices kappa

No Quadro 12 são apresentados os índices kappa para cada método utilizado, bem como suas variâncias e valores do teste estatístico Z , a 95% de probabilidade.

Segundo critério estabelecido no item 2.1.5, o desempenho das classificações geradas foi apontado como:

- Razoável ($0,4 < K \leq 0,8$): algoritmos da Mínima Distância por pixels, da Mínima Distância por regiões, da Máxima Verossimilhança por pixels e *Backpropagation* por pixels; e
- Excelente ($0,8 < K \leq 1,0$): algoritmos da Máxima Verossimilhança por regiões e *Backpropagation* por regiões.

Analisando o Quadro 12, observa-se que as imagens classificadas pelo algoritmo da Máxima Verossimilhança apresentaram índices kappa superiores aos obtidos pelas imagens classificadas pelo algoritmo da Mínima Distância,

comparando-se os métodos por pixel e por regiões separadamente. Isso ocorre porque o algoritmo da Máxima Verossimilhança avalia a variância e a covariância dos padrões de resposta espectral ao classificar um pixel desconhecido, enquanto o da Mínima Distância avalia apenas a média.

Quadro 12 – Índices kappa, suas variâncias e valores de Z, para cada método utilizado

| Método | Kappa (%) | Variância do kappa | Z estatístico |
|-----------|-----------|--------------------|---------------|
| MinDist P | 53,7 | 0,000461 | 25,026* |
| MinDist R | 65,5 | 0,000892 | 21,940* |
| MaxVer P | 65,2 | 0,000418 | 31,877* |
| MaxVer R | 82,4 | 0,000564 | 34,696* |
| RNAs P | 68,0 | 0,000400 | 34,038* |
| RNAs R | 82,4 | 0,000563 | 34,722* |

Z* = significativo a 95% de probabilidade (Z estatístico $\geq 1,96$).

MinDist P = Mínima Distância por pixels; MinDist R = Mínima Distância por regiões; MaxVer P = Máxima Verossimilhança por pixels; MaxVer R = Máxima Verossimilhança por regiões; RNAs P = *Backpropagation* (redes neurais artificiais) por pixels; e RNAs R = *Backpropagation* (redes neurais artificiais) por regiões.

Observa-se também que a imagem classificada pelo algoritmo *Backpropagation* por pixels apresentou índice kappa estatisticamente igual ao obtido pela imagem classificada pelo algoritmo da Máxima Verossimilhança por pixels. Igualmente, as imagens classificadas pelos algoritmos *Backpropagation* e da Máxima Verossimilhança, ambos por regiões, apresentaram resultados estatisticamente iguais.

Pode-se constatar também que as classificações por regiões geradas pelos três algoritmos apresentaram índices kappa superiores àqueles das classificações por pixel. No entanto, não se pode afirmar categoricamente que os resultados das classificações por regiões foram melhores do que os das classificações por pixel, pois o número reduzido de amostras utilizado não permite que esta afirmação seja feita. Entretanto, as classificações por regiões consideram, além do valor numérico dos pixels, o contexto de inserção destes, melhorando o desempenho dos classificadores.

4.1.3. Significância entre os índices kappa

Por meio do teste de significância entre os índices kappa, verificou-se a existência ou não de diferenças significativas entre as classificações geradas.

No Quadro 13 é apresentada a matriz de significância entre os índices kappa das classificações geradas, a 95% de probabilidade, utilizando o teste Z.

A diagonal principal apresenta os valores do teste estatístico Z, a 95% de probabilidade, para cada método individualmente.

Quadro 13 – Matriz de significância entre os índices kappa

| | MinDist P | MinDist R | MaxVer P | MaxVer R | RNAs P | RNAs R |
|-----------|-----------|-----------|----------|----------|----------|----------|
| Kappa (%) | 53,7 | 65,5 | 65,2 | 82,4 | 68,0 | 82,4 |
| Variância | 0,000461 | 0,000892 | 0,000418 | 0,000564 | 0,000400 | 0,000563 |
| MinDist P | 25,026 | | | | | |
| MinDist R | 3,208 | 21,940 | | | | |
| MaxVer P | 3,879 | 0,083 | 31,877 | | | |
| MaxVer R | 8,964 | 4,429 | 5,489 | 34,696 | | |
| RNAs P | 4,873 | 0,696 | 0,979 | 4,638 | 34,038 | |
| RNAs R | 8,969 | 4,431 | 5,492 | 0,000 | 4,640 | 34,722 |

Z estatístico $\geq 1,96$: significativo a 95% de probabilidade.

MinDist P = Mínima Distância por pixels; MinDist R = Mínima Distância por regiões; MaxVer P = Máxima Verossimilhança por pixels; MaxVer R = Máxima Verossimilhança por regiões; RNAs P = *Backpropagation* (redes neurais artificiais) por pixels; e RNAs R = *Backpropagation* (redes neurais artificiais) por regiões.

Analisando o Quadro 13, verifica-se, pelo teste Z, que alguns métodos não mostraram diferenças significativas, ou seja, apresentaram resultados estatisticamente iguais a 95% de probabilidade. São eles: Máxima Verossimilhança por pixel em relação à Mínima Distância por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel em relação à Mínima Distância por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel em relação à Máxima Verossimilhança por pixel e Redes Neurais Artificiais (*backpropagation*) por regiões em relação à Máxima Verossimilhança por regiões.

O Quadro 13 permite observar também que as classificações geradas pelos algoritmos Redes Neurais Artificiais (*backpropagation*) e Máxima Verossimilhança, ambos por regiões, apresentaram melhores desempenhos que as demais.

4.2. Avaliação qualitativa das imagens classificadas

Com o intuito de melhorar a apresentação visual das imagens classificadas, utilizou-se um filtro de moda 3x3 para atenuar os ruídos (mistura de frequência).

Nas Figuras 3 e 4 é apresentada a imagem classificada pelo algoritmo da Mínima Distância por pixels e a mesma após a passagem do filtro de moda 3x3, respectivamente.

Pode-se observar nas Figuras 5 e 6 a imagem classificada pelo algoritmo da Mínima Distância por regiões e a mesma depois da passagem do filtro de moda 3x3, respectivamente.

Nas Figuras 7 e 8 pode-se ver a imagem classificada pelo algoritmo da Máxima Verossimilhança por pixels e a mesma após a passagem do filtro de moda 3x3, respectivamente.

Nas Figuras 9 e 10 é apresentada a imagem classificada pelo algoritmo da Máxima Verossimilhança por regiões e a mesma depois da passagem do filtro de moda 3x3, respectivamente.

Observa-se nas Figuras 11 e 12 a imagem classificada por Redes Neurais Artificiais (*backpropagation*) por pixels e a mesma após a passagem do filtro de moda 3x3, respectivamente.

Nas Figuras 13 e 14 é apresentada a imagem classificada por Redes Neurais Artificiais (*backpropagation*) por regiões e a mesma após a passagem do filtro de moda 3x3, respectivamente.




Figura 3 – Imagem temática resultante do método da Mínima Distância por pixels.

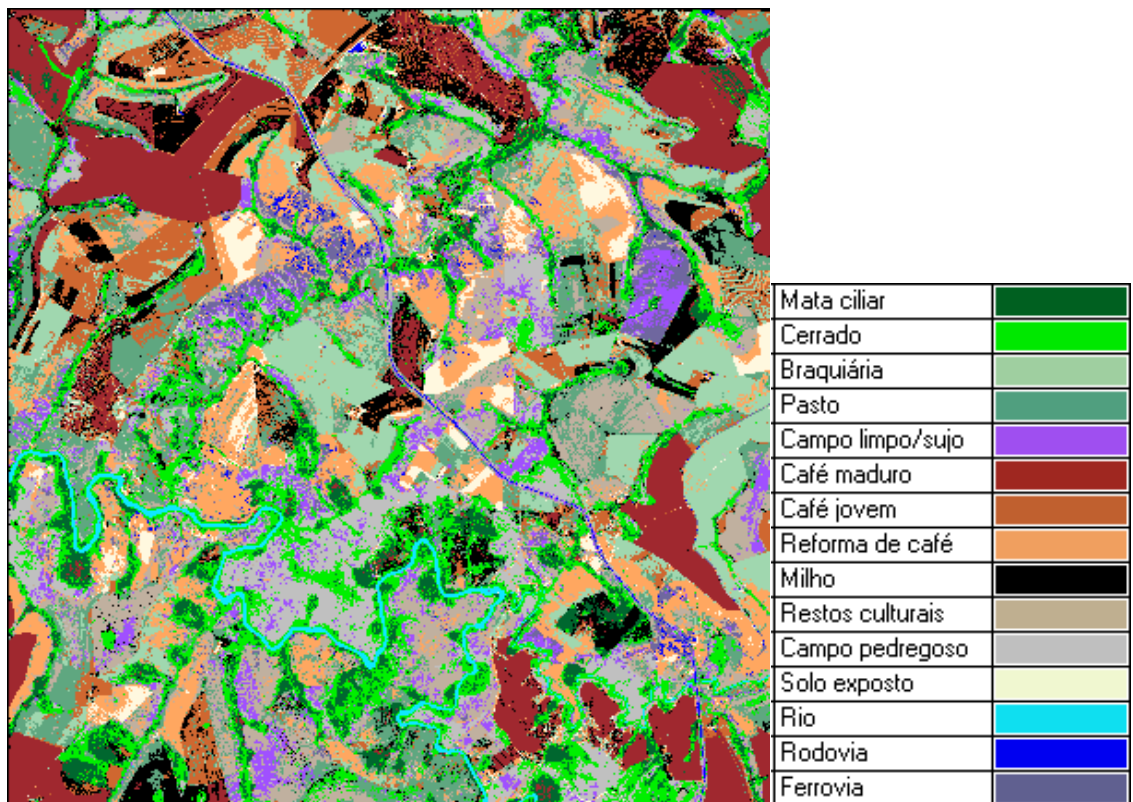


Figura 4 – Imagem temática resultante do método da Mínima Distância por pixels, filtrada.




Figura 5 – Imagem temática resultante do método da Mínima Distância por regiões.

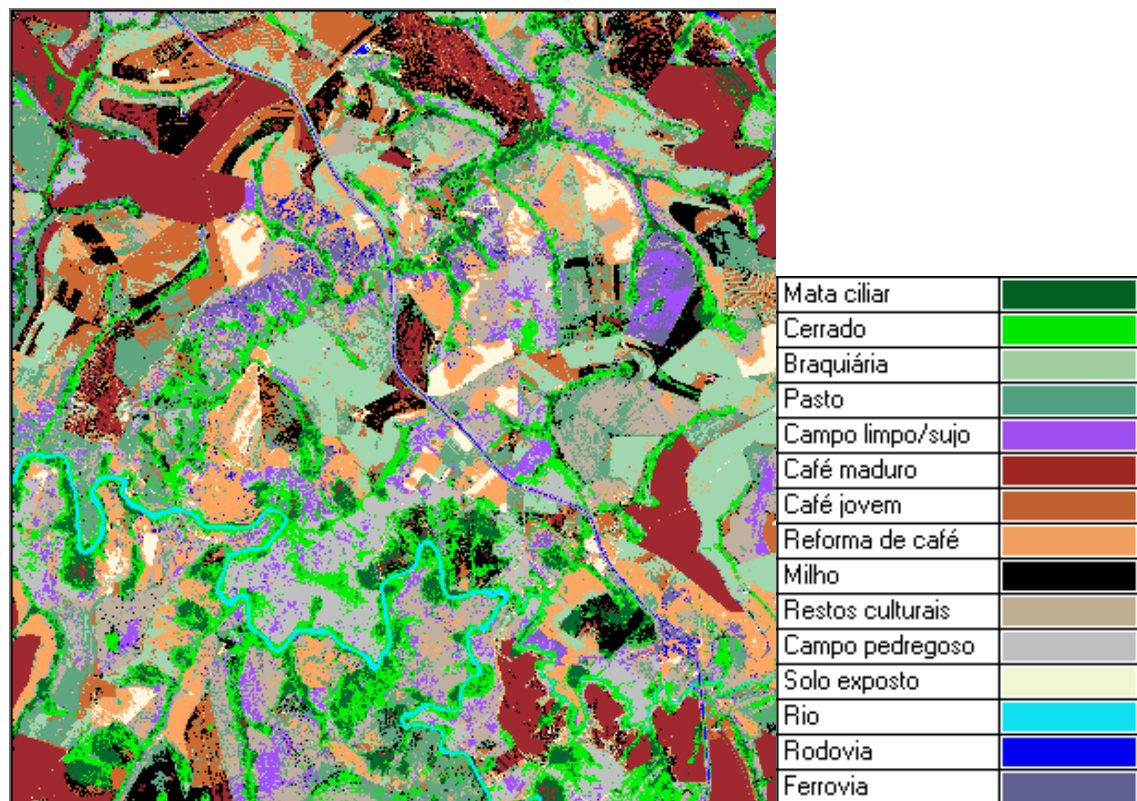


Figura 6 – Imagem temática resultante do método da Mínima Distância por regiões, filtrada.




Figura 7 – Imagem temática resultante do método da Máxima Verossimilhança por pixels.

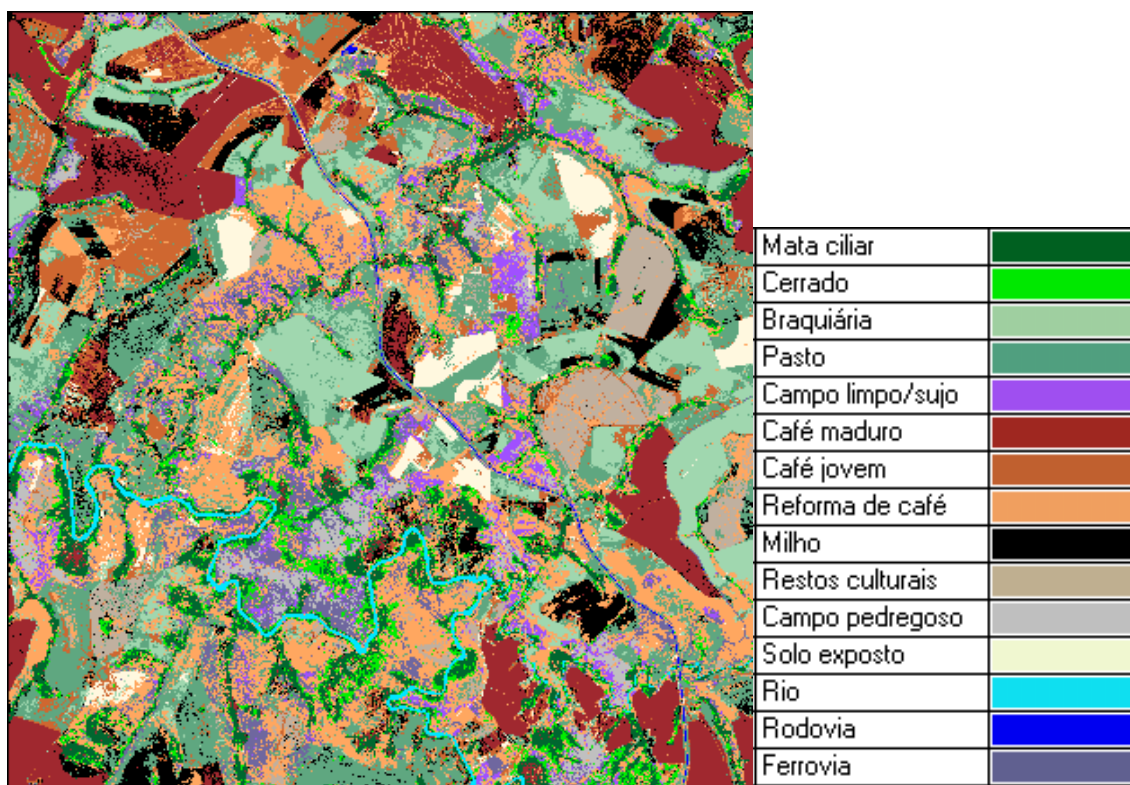


Figura 8 – Imagem temática resultante do método da Máxima Verossimilhança por pixels, filtrada.




Figura 9 – Imagem temática resultante do método da Máxima Verossimilhança por regiões.




Figura 10 – Imagem temática resultante do método da Máxima Verossimilhança por regiões, filtrada.




Figura 11 – Imagem temática resultante do método de Redes Neurais por regiões.




Figura 12 – Imagem temática resultante do método de Redes Neurais por regiões, filtrada.

As diferenças entre as imagens classificadas e as mesmas após a filtragem são bastante perceptíveis, atenuando a mistura de frequência (ruídos) e melhorando a qualidade visual.

As imagens classificadas pelo método da Mínima Distância por pixel (Figuras 3 e 4) e pelo método da Mínima Distância por regiões (Figuras 5 e 6) não apresentaram diferenças visuais significativas, apesar de este último método ter mostrado índice kappa superior ao primeiro. Em ambas, notou-se claramente que: áreas de campo limpo/sujo foram classificadas equivocadamente como campo pedregoso; áreas de café maduro foram classificadas como milho; áreas de restos culturais foram classificadas como campo limpo/sujo; áreas de solo exposto foram classificadas como reforma de café; e áreas de mata ciliar foram classificadas como cerrado.

Notou-se também que as imagens classificadas pelo algoritmo da Mínima Distância (Figuras 3, 4, 5 e 6) apresentaram qualidade visual inferior à das imagens classificadas pelo algoritmo da Máxima Verossimilhança (Figuras 7, 8, 9 e 10). Estas apresentaram boa qualidade visual, porém notou-se ainda que áreas de café maduro foram classificadas como milho, áreas de campo limpo/sujo foram classificadas como campo pedregoso, áreas de solo exposto foram classificadas como reforma de café e áreas de mata ciliar foram classificadas como cerrado, porém todas em menor proporção, se comparadas às imagens classificadas pelo algoritmo da Mínima Distância (Figuras 3, 4, 5 e 6).

A imagem classificada pelo método da Máxima Verossimilhança por regiões (Figuras 9 e 10) apresentou melhor qualidade visual do que aquela classificada pelo método da Máxima Verossimilhança por pixel (Figuras 7 e 8), tendo classificado corretamente uma maior área da imagem e apresentando regiões mais homogêneas.

A imagem classificada pelo algoritmo Redes Neurais Artificiais (*backpropagation*) por regiões (Figuras 11 e 12) também mostrou boa qualidade visual, tendo classificado corretamente boa parte da imagem, porém apresentou áreas de mata ciliar classificadas como cerrado, áreas de campo limpo/sujo classificadas como campo pedregoso e áreas de café maduro classificadas como milho. Apesar de essa classificação ter apresentado resultado estatisticamente igual ao resultado do método da Máxima Verossimilhança por regiões (Figuras 9 e 10), este último mostrou melhor qualidade visual, com áreas mais homogêneas.

5. RESUMO E CONCLUSÕES

O trabalho consistiu na comparação de métodos de classificação em imagens digitais multiespectrais de alta resolução para o mapeamento da cobertura terrestre.

Foram utilizados os algoritmos da Mínima Distância, da Máxima Verossimilhança e de Redes Neurais Artificiais (*backpropagation*), em uma imagem do satélite IKONOS II com 4 metros de resolução espacial. Para cada algoritmo foi feita uma classificação por pixel e uma classificação por regiões, gerando seis análises: Mínima Distância por pixel, Mínima Distância por regiões, Máxima Verossimilhança por pixel, Máxima Verossimilhança por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel e Redes Neurais Artificiais (*backpropagation*) por regiões, que apresentaram índices kappa iguais a 53,7, 65,5, 65,2, 82,4, 68,0 e 82,4%, respectivamente.

Os métodos que mostraram melhor desempenho foram Redes Neurais Artificiais (*backpropagation*) e Máxima Verossimilhança, ambos por regiões, não apresentando diferença estatística significativa a 95% de probabilidade pelo teste Z entre eles.

Os seguintes métodos não apresentaram diferenças significativas a 95% de probabilidade: Máxima Verossimilhança por pixel em relação à Mínima Distância por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel em

relação à Mínima Distância por regiões, Redes Neurais Artificiais (*backpropagation*) por pixel em relação à Máxima Verossimilhança por pixel e Redes Neurais Artificiais (*backpropagation*) por regiões em relação à Máxima Verossimilhança por regiões.

As classes mais homogêneas espectralmente foram mais bem classificadas, apresentando menos sobreposição às outras classes.

A seleção de amostras por regiões foi dificultada pelo fato de algumas classes apresentarem pequena área em relação à cena, impossibilitando a coleta de um número adequado de amostras.

Classes como rodovia e ferrovia podem ser excluídas da análise, por apresentarem dificuldades na obtenção de amostras, principalmente no método por regiões.

A baixa resolução espectral da imagem dificultou a distinção entre classes durante o processo de classificação, o que influenciou a precisão final. FISHER e GOETZ (2001) e SUGUMARAN e ZERR (2001), em seus estudos de classificação de imagens IKONOS II, encontraram as mesmas dificuldades devido à baixa resolução espectral das mesmas.

O algoritmo de classificação da Mínima Distância, que até então era utilizado com êxito para classificar imagens de média resolução espacial, apresentou desempenho inferior ao dos algoritmos da Máxima Verossimilhança e de Redes Neurais Artificiais (*backpropagation*) na classificação de imagens de alta resolução espacial.

Apesar de os resultados obtidos com os algoritmos de Máxima Verossimilhança e Redes Neurais Artificiais (*backpropagation*), ambos por regiões, não diferirem estatisticamente, recomenda-se, pelo menos para este estudo, o uso do algoritmo da Máxima Verossimilhança. Essa recomendação se deve ao fato de que este exige um menor esforço computacional e se encontra implementado na maioria dos *softwares* de processamento de imagens.

Recomenda-se, para o aprimoramento de pesquisas com classificação de imagens digitais multiespectrais de alta resolução, o teste desses algoritmos utilizando informação textural, um número maior de amostras e o teste de outros modelos de redes neurais.

REFERÊNCIAS BIBLIOGRÁFICAS

ANDRADE, A. F.; BOTELHO, M. F. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** Belo Horizonte: INPE, 2003. p. 265-272.

BRITES, R. S. **Verificação de exatidão em classificação de imagens digitais orbitais: Efeitos de diferentes estratégias de amostragem e avaliação de índices de exatidão.** 1999. 101 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 1999

CAMPBELL, J. B. **Introduction to remote sensing.** New York: The Guilford Press, 1987. 551 p.

CENTRO DE RECURSOS IDRISI PARA OS PAÍSES DE LÍNGUA PORTUGUESA. **Manual do usuário – Versão digital.** Disponível em: <<http://www.ecologia.ufrgs.br/idrisi>>. Acesso em: 27 jul. 2002.

COSTA, T.C.C. **Avaliação de estratégias para classificação de imagens orbitais em mapeamento de uso e cobertura da terra.** 1999. 109 f. Tese (Doutorado em Ciência Florestal, 1999) – Universidade Federal de Viçosa, Viçosa, 1999.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices.** New York: Lewis Publishers, 1998. 137 p.

COUTINHO, A. C. **Segmentação e classificação de imagens LANDSAT-TM para o mapeamento dos usos da terra na região de Campinas, SP.** 1997. 145 f. Dissertação (Mestrado em Ciências) – Universidade de São Paulo, São Paulo, 1997.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1992. 170 p.

ENGESAT. **Ficha técnica resumida**. Disponível em: <<http://www.engesat.com.br/satelites/ikonos.htm>>. Acesso em: 28 jul. 2002.

FISHER, J.; GOETZ, S. J. **Considerations in the use of high spatial resolution imagery: An applications research assessment**. In: ASPRS 2001 - GATEWAY TO THE NEW MILLENNIUM, 2001, St. Louis. **Proceedings...** St. Louis: 2001. p. 8

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2.ed. New Jersey: Prentice Hall, 1996. 316 p.

KURY, E. B.; VIEIRA, C. A. O. **Classificação automática de imagens de alta resolução**. In: NUGEO 2002 - WORKSHOP SOBRE GEOPROCESSAMENTO DA UFV, 2002, Viçosa. **Anais...** Viçosa: 2002. 4 p. Disponível em: <<http://www.ufv.br/nugeo>>. Acesso em: 24 ago. 2002.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 1.ed. São José dos Campos: INPE, 2001. 250 p.

MYEONG, S.; HOPKINS, P.; BROCK, R. H.; NOWAK, D. **Urban cover classification using digital, high resolution aerial imagery**. In: ASPRS 2001 - GATEWAY TO THE NEW MILLENNIUM, 2001, St. Louis. **Proceedings...** St. Louis: 2001. 10 p.

NOVO, E. M. L. M. **Sensoriamento remoto – princípios e aplicações**. 2.ed. São José dos Campos: INPE, 1992. 308 p.

PAOLA, J. D. **The effect of neural–network structure on a multispectral land–use/land–cover classification**. Photogrametric Engineering & Remote Sensing, v. 63, n. 5, p. 535-544, 1997.

SHIMABUKURO, Y. E.; DUARTE, V.; SANTOS, J. R.; MELLO, E. M. K.; MOREIRA, J. C. Levantamento de áreas desflorestadas na Amazônia através de processamento digital de imagens orbitais. **Floresta e Ambiente**, v. 6, n. 1, p. 38-44, 1999.

SUGUMARAN, R.; ZERR, D. **Potential role of high-resolution satellite images in local government planning and management**. In: ASPRS 2001 - GATEWAY TO THE NEW MILLENNIUM, 2001, St. Louis. **Proceedings...** St. Louis: 2001. 7 p.

VENTURIERI, A.; SANTOS, J. R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: **Sistemas de informações geográficas – aplicações na agricultura**. Brasília: Embrapa-SPI / Embrapa-CPAC. 1998. p. 351-371.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study.** 2000. 323 f. Thesis (Ph.D.) – University of Nottingham, Nottingham, 2000.

VILELA, M. F. **Uso de diferentes métodos de retificação geométrica e classificação digital de uma imagem TM/LANDSAT-5.** 1998. 118 f. Tese (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 1998.

VILELA, M. F. **Integração de técnicas de geoprocessamento e levantamento participativo de informações sócio-ambientais: um subsídio para a reforma agrária.** 2002. 135 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2002.

VILELA, M. F.; SOARES, V. P.; RIBEIRO, J. C.; BRITES, R. S. Avaliação de técnicas de realce e classificação digital na elaboração de um mapa de uso da terra mediante uma imagem TM/LANDSAT-5. **Revista Árvore**, v. 24, n. 2, p. 161-173, 2000.