

BRUNO DE CARVALHO RESCK

**Avaliação de diferentes métodos de classificação de imagem IKONOS
para mapeamento do uso e cobertura terrestre**

VIÇOSA
MINAS GERAIS – BRASIL
2009

UNIVERSIDADE FEDERAL DE VIÇOSA
CENTRO DE CIÊNCIAS HUMANAS, LETRAS E ARTES
DEPARTAMENTO DE GEOGRAFIA

BRUNO DE CARVALHO RESCK

**Avaliação de diferentes métodos de classificação de imagem IKONOS
para mapeamento do uso e cobertura terrestre**

Monografia apresentada ao
Departamento de Geografia,
Universidade Federal de Viçosa, como
requisito parcial para a obtenção do
título de Bacharel em Geografia.

Orientador: Prof. Elpídio Inácio F. Filho

Co-orientador: Prof. André Luis Lopes
de Faria.

VIÇOSA
MINAS GERAIS – BRASIL
2009

BRUNO DE CARVALHO RESCK

**Avaliação de diferentes métodos de classificação de imagem IKONOS
para mapeamento do uso e cobertura terrestre**

Monografia apresentada ao
Departamento de Geografia,
Universidade Federal de Viçosa, como
requisito parcial para a obtenção do
título de Bacharel em Geografia.

Orientador: Prof. Elpídio Inácio F. Filho

Co-orientador: Prof. André Luis Lopes
de Faria.

Aprovada: 30 de julho de 2009.

Elpídio Inácio Fernandes Filho (Orientador)

André Luis Lopes de Faria

Rafael de Ávila Rodrigues

*À Maria Eduarda, minha filha, amor de
minha vida, fonte de inspiração e motor
que impulsiona minha vida.*

*Aos meus pais, Antônio Carlos Resck e
Dalva de Carvalho Resck.*

Aos meus irmãos Marcela e Flávio.

À todos meus familiares.

Dedico.

AGRADECIMENTOS

À Universidade Federal de Viçosa em especial ao Departamento de Geografia pela oportunidade de realizar este curso.

Ao Departamento de Solos.

Ao Prof. Elpídio Inácio Fernandes Filho, pela oportunidade no LabGeo, pelos ensinamentos e pela orientação.

Ao Prof. André Faria por participar da banca e pelas contribuições.

Ao Prof. Rafael por aceitar de pronto participar da banca e pelas contribuições.

Ao prof. Eduardo Maia, pela paciência e atenção na resolução dos problemas burocráticos.

Ao casal de amigos, Diogo e Raquel, pela amizade e pela paciência e pelo acolhimento no laboratório.

À Marla Carolina, pelo carinho, pela atenção e pelos ótimos momentos juntos.

Aos meus pais pelo apoio emocional e material e pela paciência.

Aos meus irmãos que mesmo longe estão sempre presentes no meu coração.

À Nilcéia de Freitas por me apresentar a cidade de Viçosa.

Aos amigos da República Canguição, apartamento 2322 e apartamento 2111, pelo convívio e pelos momentos de descontração.

Aos colegas de trabalho do LabGeo, pelo constante aprendizado e pelos bons momentos.

SUMÁRIO

RESUMO	vii
INTRODUÇÃO.....	8
1. REFERENCIAL TEÓRICO.....	10
1.1 Sensoriamento Remoto	10
1.2 Comportamento espectral do uso e ocupação do solo.....	11
1.2.1 Comportamento espectral da Vegetação.....	12
1.2.2 Comportamento espectral dos solos	12
1.2.3 Comportamento espectral da água.....	13
1.2.4 Índice de Vegetação por Diferença Normalizada	14
2.2 Classificação Digital de Imagens	15
2.1 Classificação Supervisionada	16
2.2 Classificação Não-Supervisionada	17
2.3 Algoritmo de Máxima Verossimilhança	17
2.4 Redes Neurais Artificiais	18
2.5 Avaliação das imagens classificadas	19
2.6 O satélite IKONOS II	21
3. MATERIAL E MÉTODOS	23
3.1 Localização da área de estudo	23
3.2 Trabalho de Campo.....	24
3.3 Material Utilizado	25
3.4 Classificação da Imagem IKONOS	25
3.5 Validação da Classificação	28
3.6 Pós Classificação	30
4. RESULTADOS E DISCUSSÃO	31
4.1 Análise Quantitativa das classificações.....	31
4.2 Análise Qualitativa das classificações	38
5. CONCLUSÕES E RECOMENDAÇÕES.....	45
REFERÊNCIA BIBLIOGRÁFICA.....	46
ANEXO I	49

RESUMO

RESCK, Bruno de Carvalho. **Avaliação de diferentes métodos de classificação de imagem IKONOS para mapeamento do uso e cobertura.** 2009. 45 f. Monografia (Bacharelado em Geografia) – Universidade Federal de Viçosa, Viçosa-MG, 2009.

O trabalho teve como objetivo a avaliação de diferentes métodos de classificação de imagens IKONOS para o mapeamento do uso e cobertura terrestre. Foram utilizados os algoritmos de Máxima Verossimilhança e Rede Neural (*Backpropagation*) em uma imagem do sensor IKONOS com resolução espacial de 1m. Para cada algoritmo foram utilizadas as mesmas amostras de treinamento. A validação das imagens geradas pelos classificadores foi feita através da geração de uma malha de pontos aleatórios sobreposta sobre a imagem considerada como verdade de campo. Esta mesma malha de pontos foi sobreposta sobre as imagens temáticas geradas. Após este procedimento foi gerada a matriz de confusão, de onde pode-se calcular os índices Kappa para cada classificação. O índice calculado para o algoritmo de Máxima Verossimilhança foi de 79%, considerado Muito Bom, e para o algoritmo de Rede Neural foi de 80%, considerado Excelente. Dentre os resultados obtidos, podem ser destacados: Os métodos de classificação utilizados neste trabalho não apresentaram grande diferença, sendo a Rede Neural que obteve melhor desempenho; as classes mais homogêneas espectralmente foram melhores classificadas, apresentando menos sobreposição às outras classes; A alta resolução espectral da imagem IKONOS dificultou a distinção entre as classes, influenciando na precisão final; Os resultados obtidos pelos algoritmos de Máxima Verossimilhança e Rede Neural não diferenciam estatisticamente ao nível de significância de 95%; Recomenda-se para este estudo a utilização do classificador por Máxima Verossimilhança, devido ao fato deste algoritmo exigir menor esforço computacional e pessoal, e se encontra implementado na maioria dos softwares de classificação de imagens; Recomenda-se a utilização de informações texturais, diferentes números de amostras e arquiteturas de Redes Neurais para o aprimoramento das pesquisas com classificação de imagens de alta resolução espacial.

INTRODUÇÃO

A atividade desordenada de uso e ocupação da terra impulsionado pelo modelo econômico vigente e o crescimento populacional tem resultado na degradação, fragmentação e esgotamento dos recursos florestais (NASCIMENTO, 2006). O ambiente e os recursos terrestres vem sofrendo grande pressão e transformação constante frente à evolução natural e às atividades humanas. Para entender a complexidade destas transformações é necessário que se faça uma série de observações ao longo do tempo e do espaço a fim de agrupar um grande número de informações . As observações feitas à partir do sensoriamento remoto são meios efetivamente econômicos para reunir grande volume de dados para monitorar e modelar esses fenômenos (VIEIRA, 2000).

Segundo Blaschke *et al* (2005) dados espaciais confiáveis e parâmetros de ecologia da paisagem são de grande importância para as tarefas de proteção do meio ambiente e da natureza. O sensoriamento remoto é uma importante ferramenta para obtenção destes dados, sobretudo pela capacidade de obtenção de dados atuais e cada vez com custos reduzidos.

Sensoriamento remoto é a utilização de modernos sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, aeronaves, espaçonaves etc., com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas mais diversas manifestações (NOVO, 1989).

Embora a interpretação visual seja uma técnica considerada superior, chegando a um nível de detalhes não alcançado por uma classificação computacional, a viabilidade tende para a classificação computacional, pela rapidez e facilidade em obter resultados (COSTA, 1999).

Com os avanços tecnológicos dos recursos de geoprocessamento tem-se buscado a utilização dessas ferramentas em várias áreas, sobretudo na área ambiental. As ferramentas de geoprocessamento quando comparadas aos recursos tradicionais utilizados, proporcionam enorme economia de tempo e recursos, bem como a sua adequação às mais diversas propostas de pesquisa

levando a resultados mais precisos (VALENTE, 2005).

Com o lançamento de plataformas e sensores de alta resolução espectral e espacial, como o IKONOS II, os resultados das classificações digitais ganham novos paradigmas. O satélite IKONOS II foi lançado em 1999 sendo o primeiro satélite comercial com a capacidade de coletar imagens pancromáticas com 1 metro de resolução e imagens multiespectrais com 4 metros de resolução espacial.

A alta resolução deste sensor permite ao intérprete identificar pequenos objetos na superfície terrestre, mas no entanto, existe uma grande variação espectral dentro de uma mesma classe, ocasionando confusão entre classes quando utilizado métodos automáticos de classificação (SUGUMARAM e ZERR, 2001 apud RIBEIRO, 2003).

Neste sentido, a realização de pesquisas sobre diferentes métodos de classificação de imagens orbitais de alta resolução torna-se necessárias.

O objetivo deste trabalho de pesquisa é a avaliação de métodos de classificação em imagens orbitais de alta resolução espacial para mapeamento de uso e cobertura.

1. REFERENCIAL TEÓRICO

1.1 Sensoriamento Remoto

O Sensoriamento Remoto é definido como a ciência e a arte de aquisição de dados a respeito de um objeto, área ou fenômeno por meio de análise de informações obtidas por um sensor que não esteja em contato com o objeto, área ou fenômeno em investigação (LILLESAND e KIEFER, 1987).

As radiações refletidas e emitidas da superfície terrestre são armazenadas nos sensores e transformadas em informações sobre essa área imageada. Essas informações representam a interação da energia eletromagnética emitida, na maioria das vezes pelo sol, e os objetos sensoriados. Com base em técnicas de processamento digital de imagens é possível inferir algo sobre este objeto e, devido às suas características, eventualmente discriminá-los (MENDONÇA, 2006).

A ciência do sensoriamento remoto compreende a análise e interpretação das medições das radiações eletromagnéticas que são refletidas ou emitidas pelos corpos que se encontram a uma determinada distância do sensor. Todos os corpos presentes na superfície da terra, com temperatura superior a zero absoluto (0° K), podem emitir, refletir, transmitir ou absorver radiação eletromagnética (REM), e por meio dessa características é possível discriminar espectralmente objetos distintos (MATHER, 2004).

A REM ao penetrar na atmosfera atinge diferentes alvos na superfície terrestre e pode se comportar de três maneiras: parte é absorvida, parte é transmitida e parte é refletida para o espaço, como o próprio objeto emite sua própria energia conforme figura 1.

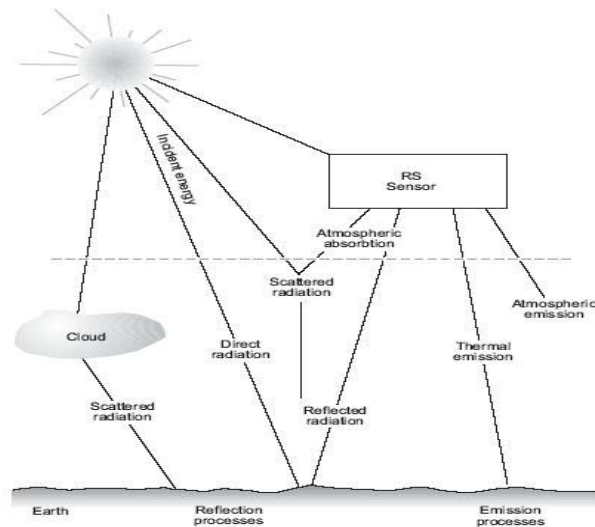


Figura 1. Interação da energia eletromagnética na atmosfera com a superfície. (Fonte: Woldai, 2004)

A faixa do espectro eletromagnético está relacionado à distribuição da intensidade da REM relativo ao comprimento de onda. São exemplos de fontes de radiação eletromagnética: as ondas de rádio, microondas, radiação infravermelha, raios ultravioleta, raios-X e raios gama. A Figura 2 mostra as principais regiões do espectro eletromagnético.




Figura 2. O espectro eletromagnético. (Fonte: Woldai, 2004 - Adaptado).

1.2 Comportamento espectral do uso e ocupação do solo

O mapeamento dos diversos tipos de uso e ocupação da superfície terrestre sempre foi uma importante ferramenta para subsidiar planos de preservação e conservação dos recursos naturais. As características espectrais dos objetos estão diretamente ligadas às interações da radiação

eletromagnética que atua no alvo existente na superfície terrestre refletindo, absorvendo e transmitindo essa mesma radiação em diferentes intensidades de acordo com suas propriedades bio-físico-químicas (RODRIGUEZ apud VILELA, 2009).

Os levantamentos do uso e cobertura do solo são de grande valia na medida em que os efeitos do uso desordenado causam deterioração do ambiente (MENDONZA ROJAS, 2004).

1.2.1 Comportamento espectral da Vegetação

Dos elementos da vegetação, as folhas são as que mais contribuem para o sinal detectado pelos sensores. As características de uma folha estão relacionados à sua composição química, morfológica e estrutura interna (IBGE, 2001).

De acordo com a figura 3, nota-se que a curva de espectral média de uma folha sadia apresenta alta reflectância devido à interferência da estrutura celular da folha, enquanto até a faixa de 0,7 μm a reflectância é baixa devido à absorção causadas pelos pigmentos da folha. Já na faixa de 1,3 μm a 2,5 μm a influência maior é do conteúdo de água da folha, existindo dois máximos de absorção em 1,4 μm e 1,95 μm .




Figura 3. Assinatura espectral média de uma folha sadia. (Fonte: IBGE, 2001. Adaptado).

1.2.2 Comportamento espectral dos solos

As características dos solos que influenciam a radiação refletida da

superfície são vários, no entanto os mais importantes são os óxidos de ferro, umidade, material orgânico, granulometria, mineralogia da argila e o material de origem. A rigor, a quantidade de energia refletida por uma determinada classe de solos é função de todos esses fatores que, conjuntamente, se encontram no solo. Em determinadas condições a influência de um parâmetro, na energia refletida pelo solo, sobrepõe a de outros, resultando num espectro característico daquele parâmetro. (MOREIRA, 2003).

A energia refletida apresenta valores menores nas regiões do azul, aumentando sucessivamente nas regiões do vermelho, do infravermelho próximo e do infravermelho próximo médio. Os óxidos e hidróxidos de ferro diminuem a reflexão no comprimento de onda do azul, aumentando no intervalo espectral do verde ao infravermelho próximo. Os altos teores de umidade no solo ocasionam redução da reflectância, em todos os comprimentos de onda. O aumento de matéria orgânica gera redução da reflectância. O nível de matéria orgânica é melhor discriminado nas regiões do visível e infravermelho próximo até o comprimento de onda igual a 1,2 μm . Quanto a granulometria os solos argilosos apresentam menor reflectância do que os arenosos, isso acontece devido os solos argilosos possuírem maior quantidade em matéria orgânica, óxidos de ferro e minerais opacos (IBGE, 2001).

1.2.3 Comportamento espectral da água

De acordo com a figura 4, nota-se que a água possui comportamento espectral diferentes, de acordo com o estado físico em que se encontra. No estado líquido, a água apresenta baixa reflectância na faixa compreendida entre 0,38 e 0,7 μm . No entanto, esta reflectância sofre influencia dos processos de absorção e espalhamento causados por objetos dissolvidos e em suspensão. O comportamento espectral das nuvens apresenta elevada reflectância ao longo do espectro com picos de absorção em 1, 1,3, e 2 μm (IBGE, 2001).

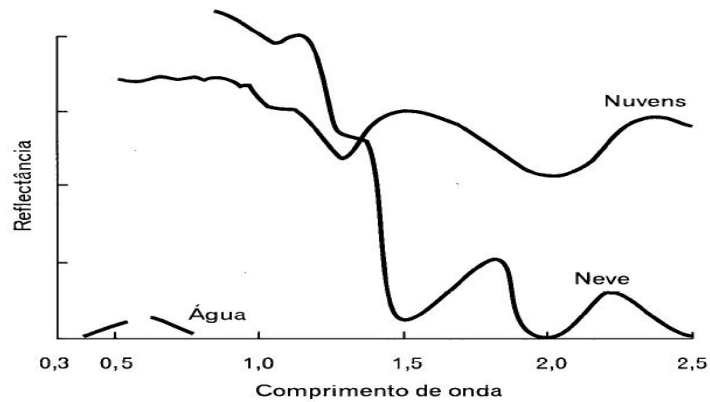


Figura 4. Comportamento espectral da água. (Fonte: IBGE, 2001 – Adaptado).

1.2.4 Índice de Vegetação por Diferença Normalizada

Os índices de vegetação são medidas quantitativas que visam medir a biomassa ou o vigor da vegetação. Normalmente são formados a partir da combinação de vários valores espectrais que são somados, divididos ou multiplicados de acordo a produzir um único valor que indica a quantidade ou vigor da vegetação dentro de um pixel (CAMPBELL, 1987).

Para a composição do Índice de Vegetação por Diferença Normalizada (NDVI), é realizada um operação matemática entres as bandas da região espectral do Infravermelho Próximo e da região do Vermelho. Na análise da vegetação quanto maior o vigor da vegetação, maior será o contraste entre as bandas. O NDVI é calculado a partir da seguinte equação:

$$NDVI = \frac{IVP - V}{IVP + V} \tag{01}$$

Os índices de vegetação foram criados para tentar minimizar o trabalho de análise dos dados, através da maximização de informações espectrais da vegetação no menor número de bandas de operação dos sensores (MOREIRA, 2003).

2.2 Classificação Digital de Imagens

Segundo Novo (1992), as técnicas de classificação digital consiste na aplicação de regras de decisão para que o computador possa atribuir uma identidade a um certo número de pixels da imagem. Desta forma o mapeamento ou reconhecimento da superfície terrestre poderia tornar-se um processo menos subjetivo e com maior poder de repetição.

As imagens orbitais destinam-se à confecção de mapas dos mais diversos tipos, que são gerados a partir da transformação das categorias espectrais, presentes nelas, em categorias ou classes informacionais, mediante processos de classificação. Estes mapas servem de base a diversas atividades que variam em suas utilizações, desde simples ilustrações até produtos de alta qualidade final, que servirão de base a atividades críticas de planejamento e monitoramento de recursos. (BRITES, 1996).

Segundo Janssen & Gorde (2004) o processo de classificação de imagens envolve cinco passos:

- 1- Seleção e preparação da imagem: Dependendo do tipo de cobertura a ser classificado, o sensor mais apropriado, data de aquisição da imagem mais apropriada, e o comprimento de onda mais apropriado;
- 2- Definição de classes com características comuns no espaço: aqui duas abordagens são possíveis: classificação supervisionada e classificação não-supervisionada. Na classificação supervisionada, o operador define as classes durante o processo de treinamento. Na classificação não-supervisionada um determinado algoritmo procura e define classes de identidade semelhante automaticamente.
- 3- Seleção do algoritmo de classificação: uma vez criada as classes com características espectrais definidas, o operador precisa decidir sobre a forma de atribuir os valores nos pixels da imagem;
- 4- Execução da classificação: uma vez escolhido o algoritmo a ser utilizado, será atribuído a cada pixel da imagem, de acordo com seu valor de reflectância, uma classe predeterminada pelo operador.
- 5- Validação do resultado: após classificada a imagem, a qualidade do produto é avaliada comparando o resultado com os dados de referência (verdade de campo). Este requer a seleção de amostras, geração de matriz de erro e cálculo dos parâmetros de erro.

A classificação de imagens é dividida basicamente em supervisionada e não-supervisionada, de acordo com a forma como esta classificação será conduzida.

2.1 Classificação Supervisionada

De acordo com Campbell (1987), a classificação supervisionada pode ser definida como o processo de usar amostras de identidade conhecida para classificar pixels de identidade desconhecida. A identidade e a localização de algumas feições são reconhecidas através de análise de campo, fotografias aéreas, mapas e experiência pessoal. O operador identifica áreas específicas, comumente denominadas de amostras de treinamento, que representem exemplos homogêneos destas feições específicas.

O processo de atribuição de um rótulo a um determinado conjunto de pixels é chamado de treinamento. Nesta fase, o analista identifica áreas representativas na imagem e desenvolve uma descrição numérica (estatísticas) dos atributos espectrais de cada tipo de cobertura apresentada na imagem.

O objetivo do processo de treinamento é levantar um conjunto de valores estatísticos que possam descrever os padrões de respostas espectrais de cada tipo de cobertura a ser classificada. A qualidade no processo de treinamento é um fator importante no sucesso na fase de classificação de imagens orbitais (LILLESAND *et al* 2004 *apud* MENDONÇA, 2006).

Crósta citado por Ribeiro (2003) salienta que alguns algoritmos utilizados na classificação supervisionada se baseiam em premissas estatísticas das áreas de treinamento, e, no caso de o operador não consegue definir áreas de treinamento bastante representativas, corre o risco de que a imagem classificada contenha imprecisões sérias.

Um dos grandes problemas no processo paramétrico de classificação de imagens está na dificuldade do operador em selecionar amostras de treinamento 'puros', representativos de cada classe espectral. A resposta espectral de um determinado alvo nem sempre é homogênea e mesmo dentro de diferentes classes, como a vegetação, existem diferentes tipos de resposta espectral em função da época da obtenção da imagem, época do plantio, ataque de pragas ou deficiência nutricional (CAMPBELL, 1987).

2.2 Classificação Não-Supervisionada

A classificação não-supervisionada requer somente o mínimo de informação de dados de entrada pelo analista, uma vez que as identidades das feições que são apresentadas como classes dentro da imagem não são conhecidas a priori. Neste processo, o computador agrupa os pixels em diferentes classes espectrais, agrupando 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 (RIBEIRO, 2003).

Na classificação não-supervisionada não são utilizadas amostras de treinamento como fundamento para a classificação. Os algoritmos examinam os pixels desconhecidos e associam à determinadas classes baseando nos agrupamentos naturais presentes nos valores da imagem. A lógica deste tipo de classificação é a de que valores de um mesmo tipo de cobertura devem estar próximos num mesmo espaço de medida, considerando que as classes diferentes devem estar comparativamente separados. Neste caso o operador tem pouco controle sobre a separação de classes, não necessitando de atenção no que se refere à homogeneidade das amostras (NOVO, 1992; LILLESAND, 1992 *apud* MENDONÇA, 2006).

2.3 Algoritmo de Máxima Verossimilhança

Dentre os algoritmos mais utilizados para classificação de imagens orbitais está o de Máxima Verossimilhança (CAMPBELL, 1987).

Este algoritmo utiliza a média e a covariância das amostras de treinamento para assinalar a um pixel desconhecido uma classe identificada. De acordo com esses parâmetros, é computado a probabilidade estatística de um pixel pertencer a uma determinada classe. Depois de analisada a probabilidade para cada classe, o pixel é assumido a uma classe cuja a probabilidade tenha sido a mais alta, ou se for o caso, em nenhuma delas (RIBEIRO, 2003; EASTMAN, 2006).

O classificador por máxima verossimilhança define o diagrama de dispersão das classes em torno de uma média e suas distribuições de

probabilidades, considerando a distribuição normal (MOREIRA, 2005).

A função de densidade de probabilidade é assim descrita:

$$P_c = [-0,5\log_e(\text{Det}(V_c))]-[0,5(X - M_c)^T(V_c)^{-1}(X - M_c)] \quad (2)$$

Em que:

P_c = probabilidade do vetor X ser assinalado na classe c ;

X = vetor de medidas dos pixels desconhecidos;

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

$\text{Det}(V_c)$ = Determinante da matriz de covariância V_c ;

M_c = Vetor das médias para cada classe c ; e

T = matriz transposta.

2.4 Redes Neurais Artificiais

As redes neurais artificiais são modelos matemáticos inspirados no sistema nervoso, ou seja, semelhante a alguns procedimentos humanos. Aprendem pela experiência, generalizam exemplos através de outros e abstraem características (RIBEIRO, 2005; DREYFUS, G. 2005).

De acordo com Vieira (2000), uma rede neural artificial consiste em um conjunto de unidades computacionais conectadas segundo uma topologia específica. Cada unidade representa 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 é transformada por uma função de ativação, a fim de produzir uma saída para a unidade.

O treinamento do comportamento de uma rede neural artificial pode ser sintetizado como sendo 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 (RIBEIRO, 2005; VIEIRA, 2000).

A arquitetura (Figura 5) de uma rede neural mais utilizada, segundo Vieira (2000) é construída seguindo uma estrutura conceitual hierárquica. A entrada de uma unidade vem somente das unidades que precedem a camada. O fluxo dentro da rede não é circular, ou seja, as informações seguem um fluxo unidirecional e são chamadas de redes *feed-forward* com camadas

completamente interligadas usando o algoritmo de treinamento *back-propagation* (DREYFUS, 2005; VIEIRA, 2000).




Figura 05. Arquitetura de uma Rede Neural.

Um dos pontos favoráveis à utilização das redes neurais artificiais para classificação de imagens orbitais está na sua estrutura de processamento, tolerância crítica e flexibilidade estatística. O processamento das redes neurais são inerentemente paralelos, eminentemente mais rápidos do que as estruturas seriais usados na maioria dos classificadores. Outro ponto favorável é que as redes neurais artificiais são mais robustas com respeito a informações perdidas ou com ruído. Por fim, redes neurais não passam por suposições estatísticas, ou seja, são classificadores não paramétricos (VIEIRA, 2000; MATHER & TSO, 2001 apud MENDONÇA, 2006).

2.5 Avaliação das imagens classificadas

No formato digital, a imagem pode ser interpretada utilizando os programas computacionais, no intuito de aproximar o máximo possível a representação digital da cena à realidade. Neste sentido, o resultado do processo de classificação da imagem deve ser testado, a fim de verificar sua precisão, indicando seu nível de confiabilidade. (MENDONÇA, 2006).

Entre os métodos mais utilizados para a avaliação da confiabilidade de uma classificação está o índice Kappa, que é uma técnica de medida de exatidão que pode ser utilizada para determinar se uma matriz de erro é significativamente diferente da outra. Este índice é baseado na diferença entre a exatidão global (indicada pela diagonal da matriz) e a exatidão do risco do produtor e do consumidor, que é indicada pela soma das linhas e colunas da matriz de confusão.

O Índice Kappa é dado pela seguinte equação:

$$\hat{k} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} x_{+i}} \quad (3)$$

onde:

r = número de linhas e colunas da matriz;

x_{ii} = número de observações na linha i e coluna i;

x_{i+} = total de observações da linha i;

x_{+i} = total de observações na coluna i;

N = número total de observações.

A confiabilidade é a principal limitação em classificações de imagens orbitais geralmente com menos de 90% de exatidão (índice Kappa). Dentre os fatores que interferem na exatidão estão os pixels de mistura, a superposição entre dados de reflectância de alvos diferentes no espaço, a baixa representatividade das amostras de treinamento e a própria capacidade do classificador em lidar com inconstâncias no processo (COSTA, 1999).

Em geral é empregado testes estatísticos para avaliar a exatidão das imagens geradas à partir de classificações automáticas. A operação consiste na determinação de um limiar de unidades amostrais representativas dos dados de referência, e compará-los às imagens temáticas, assumindo uma margem de erro permissível. Se a imagem estiver dentro da faixa de valores aceitáveis ela pode ser considerada como precisa dentro de um intervalo de confiança (JANSEN & GORDE, 2004).

A comparação entre a imagem classificada e os dados de referência é expressa numa tabela denominada de matriz de contingência ou matriz de erro (CONGALTON & GREEN, 1998 *apud* MENDONÇA, 2006). A Matriz de erro é construída a partir de pontos amostrados no mapa. As amostras de referência são representadas nas colunas da matriz, e é comparada com os pixels classificados representados pelas linhas da matriz. Em alguns esquemas de amostragem, os dados de referência são obtidos à partir de inspeções no campo (SKIDMORE, 2005; DREYFUS, 2005; BRITES, 1996).

Congalton & Green (1998) citados por Ribeiro (2005) estabeleceram

intervalos de valores dos índices Kappa para representar o nível de exatidão obtido através de uma classificação. Os resultados obtidos através do cálculo do coeficiente Kappa são comparados pelos valores da tabela de avaliação de qualidade de classificação, proposto por Landis e Koch (1977) citado por Mendonza Rojas (2004). O quadro 1 apresenta os intervalos do coeficiente Kappa associados a critérios de concordância e seus valores distribuídos entre 0 e 1, onde 1 representa o valor de concordância máximo e quando multiplicado por 100, dá a porcentagem da medida da exatidão da classificação.

Quadro 1. Nível de aceitação dos resultados das classificações segundo o índice Kappa.

Kappa (\hat{k})	Qualidade
0.00	Péssima
0.01 – 0.20	Ruim
0.21 – 0.40	Razoável
0.41 – 0.60	Boa
0.61 – 0.80	Muito Boa
0.81 – 1.00	Excelente

2.6 O satélite IKONOS II

O programa IKONOS (do grego *icon*, imagem) prevê o lançamento de uma série de satélites. O primeiro deles, o IKONOS I, por problemas técnicos, não chegou a ser colocado em órbita (MOREIRA, 2005).

O satélite IKONOS II foi lançado no dia 24 de setembro de 1999, com a previsão de uma vida operacional de aproximadamente 8 anos e meio. Possui a bordo de sua plataforma sensores capazes de gerar imagens pancromáticas e multispectrais, de 1 e 4 metros de resolução espacial, respectivamente, havendo a possibilidade de combiná-las, produzindo imagens coloridas com resolução de 1 metro (SPACE IMAGING, 2006 *apud* MENDONÇA, 2006).

A alta resolução espacial muda até o modo de se utilizarem as imagens geradas pelos satélites. Se anteriormente um *pixel* continha vários objetos, agora um objeto é composto de vários *pixels*, aumentando o nível de detalhamento da cena. Uma das características do satélite IKONOS é que, além de efetuar visadas no sentido de sua órbita, captam imagens no sentido perpendicular a esta, o que aumenta a frequência de revisita e a possibilidade

de aquisição de pares estereoscópicos, utilizados na restituição de mapas (MOREIRA, 2005).

As principais características do satélite IKONOS II estão apresentadas no quadro 2.

Quadro 2. Principais 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: 1m / Multiespectral: 4m			
Bandas espectrais	Pancromática 0,45 – 0,90 µm Azul 0,45 – 0,52 µm Verde 0,52 – 0,60 µm Vermelho 0,63 – 0,69 µm Infravermelho próximo 0,76 – 0,90 µm			
Imageamento	13 km na vertical (cenas de 13 km x 13 km)			
Capacidade de aquisição de imagens	Faixas de 11 km x 100 km até 11 km x 1000 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 <i>Obs.: Esses valores valem para latitude de +/- 40°. A frequência de revisita para latitudes maiores será menor, e maior para as latitudes perto do Equador.</i>			
Banda	Faixa (µm)	Reg. espectral	Resolução (m x m)	Larg de faixa (km)
MS1	0,45 a 0,52	Azul	4	11
MS2	0,52 a 0,60	Verde	4	11
MS3	0,63 a 0,69	Vermelho	4	11
MS4	0,76 a 0,90	Infravermelho	4	11
Pan	0,45 a 0,90	Visível e IV	1	11

Fonte: Moreira (2005).

3. MATERIAL E MÉTODOS

3.1 Localização da área de estudo

A área de estudo está localizada na bacia hidrográfica do ribeirão São Bartolomeu, no município de Viçosa, MG, compreendida entre as coordenadas UTM 720.200E, 7.699.200N, e 721.600E, 7.698.000N. (Figura 6)

O clima da área é caracterizado, segundo a classificação de Köppen, como Cwa – clima mesotérmico – com verões quentes e úmidos e invernos frios e secos, precipitação média anual de 1.200mm e temperatura do mês mais frio inferior a 18°C e do mês mais quente superior a 22°C (ORLANDINI, 2002).




FIGURA 06. Localização da Bacia do São Bartolomeu.

Segundo Correa (1984) a área está embasada sobre rochas de idades pré-cambrianas inferior ou indiviso, compreendendo gnaisses e migmatitos. Sedimentos do Quaternário ocorrem ao longo dos vales, constituindo depósitos aluviais de caráter argiloso, argilo-arenoso ou arenoso, representados por terraços e leitos maiores de deposição recente.

O relevo predominante da região é forte ondulado e montanhoso, com encostas de perfil convexo-côncavo embutidos em vales de fundo chato, formados por terraços e leitos maiores. A altimetria da bacia do Ribeirão São Bartolomeu varia entre 614m a 902m com elevação média de 758m. A

cobertura vegetal original era constituída por Mata Atlântica, sendo intensamente substituída por pastagem e café. (CORREA, 1984).

A bacia do Ribeirão São Bartolomeu é uma importante fonte de água para o abastecimento público, atendendo 65% da população de Viçosa e 100% da Universidade Federal de Viçosa (FONTES, 2006).

3.2 Trabalho de Campo

Foi feita uma visita a campo para a identificação do uso e cobertura da terra em diversos pontos da área de estudo, visando produzir as amostras de treinamento e validação.

Os pontos foram coletados utilizando um aparelho GPS de navegação Garmim Etrex HCx.

No quadro 3 são apresentadas as classes identificadas assim como o padrão apresentado na imagem.

Quadro 3. Classes utilizadas para classificação.

Classe	Padrão	Descrição
Lavoura		Áreas com lavouras anuais, e áreas preparadas para plantio
Eucalipto		Áreas de plantio de eucalipto.
Café		Áreas com plantio de café.
Solo		Áreas com solos expostos, estradas, terraplanagens.
Área Inundável		Leito maior dos cursos d'água, solos hidromórficos e sujeitos à inundação periódica.
Pastagem		Áreas sob pastagem em diferentes níveis de degradação.
Água		Águas com diferentes profundidades.
Mata		Áreas de mata em diferentes estágios de sucessão.

3.3 Material Utilizado

Os dados utilizados para a realização deste trabalho foram derivados de parte de uma imagem IKONOS, obtida em 29/10/2007, bandas azul, verde, vermelho e infravermelho próximo. No quadro 4 são relacionadas as principais características referentes à imagem utilizada.

Quadro 4. Características das imagens utilizadas.

Banda	Comprimento de onda (μm)	Resolução espacial (m)
Azul	0,45 – 0,52	4
Verde	0,52 – 0,60	4
Vermelho	0,63 – 0,69	4
Infravermelho	0,79 – 0,90	4
Próximo		

3.4 Classificação da Imagem IKONOS

Para a classificação da imagem IKONOS foi utilizado o programa IDRISI Andes (EASTMAN, 2006) e os algoritmos utilizados para efetuar as classificações foram o da Máxima Verossimilhança, e Rede Neural Artificial. Optou-se por utilizar o programa IDRISI pelo fato deste software congregar diversos algoritmos para classificação de imagens, tornando o trabalho mais dinâmico e rápido.

Não foi necessária a realização de correção radiométrica sobre as imagens, assim como optou-se por não fazer correção geométrica pois a imagem utilizada foi ortorretificada quando adquirida.

Após a visita de campo e a identificação dos diferentes tipos de uso e cobertura da terra, foram digitalizados em tela polígonos sobre as classes identificadas, utilizando o programa ArcGis 9.2 (ESRI, 2006) como mostrado na figura 7.

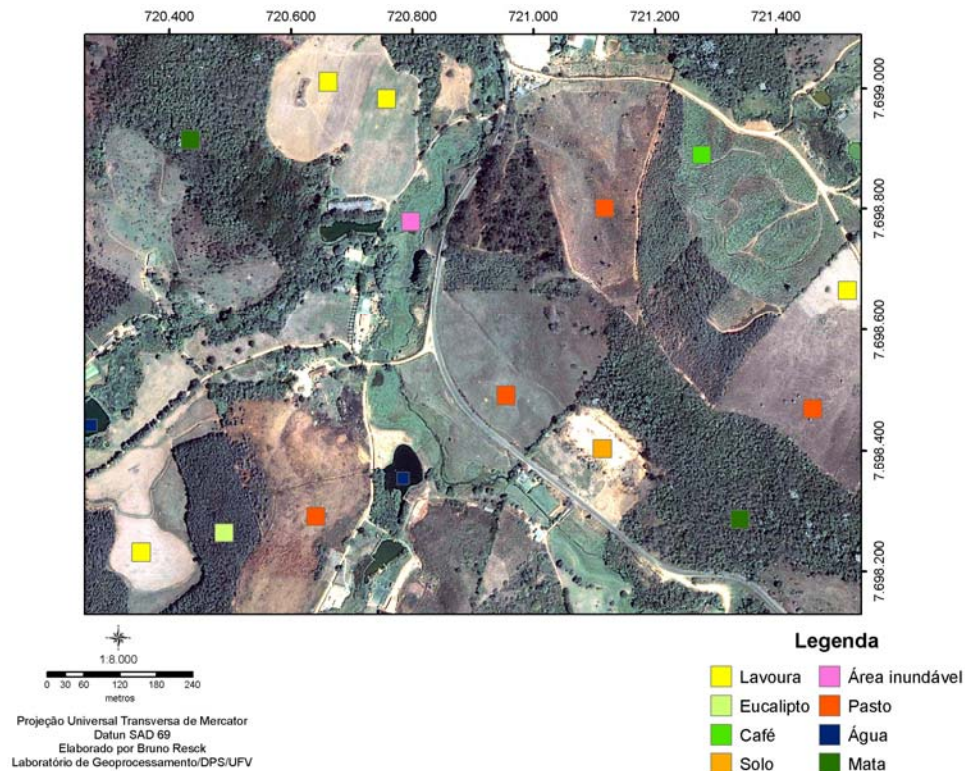


FIGURA 7. Polígonos sobre as classes utilizadas para treinamento.

Para o treinamento de ambos classificadores foram utilizadas as seguintes bandas:

- 1 Banda Azul;
- 2 Banda Verde;
- 3 Banda Vermelha;
- 4 Banda Infravermelho próximo e,
- 5 NDVI.

Para a aquisição da banda NDVI foi utilizada o módulo *VEGINDEX* do programa IDRISI. Neste módulo é realizada uma operação matemática entre as bandas da região do Infravermelho Próximo e a da região do Verde, de acordo com a equação 1.

O treinamento do algoritmo de Máxima Verossimilhança consiste em criar um arquivo de assinaturas para as classes informacionais. A entrada para a criação do arquivo de assinatura no módulo *MAKESIG* do programa IDRISI Andes é o arquivo de polígonos criados sobre cada classe identificada. Durante o processo de criação do arquivo de assinatura é calculada a média e a covariância dos pixels de cada polígono.

No módulo *MAXLIKE* do IDRISI é realizada a classificação por Máxima Verossimilhança (Figura 08). Os parâmetros de entrada são o arquivo de assinaturas e a probabilidade do pixel pertencer a alguma determinada classe. Neste trabalho optou-se pela utilização da equiprobabilidade para cada assinatura.

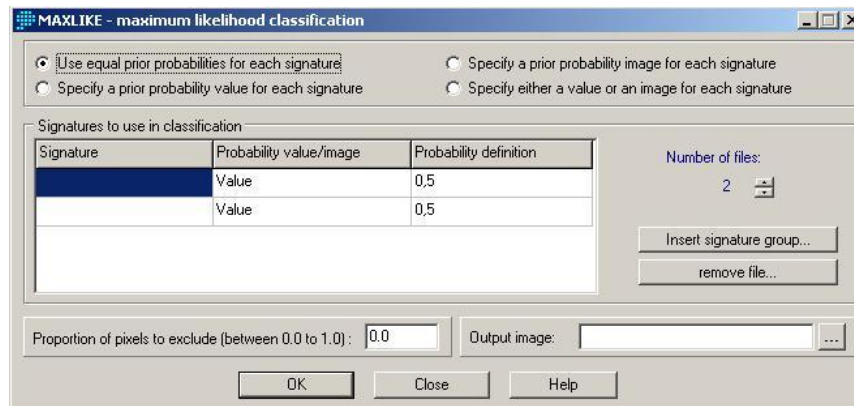


Figura 08. Módulo MAXLIKE do IDRISI.

No módulo *Multi-Layer-Perceptron* (MLP) do IDRISI é realizada a classificação por Redes Neurais Artificiais (Figura 09). Este módulo utiliza o algoritmo *backpropagation* para treinamento e classificação da imagem.

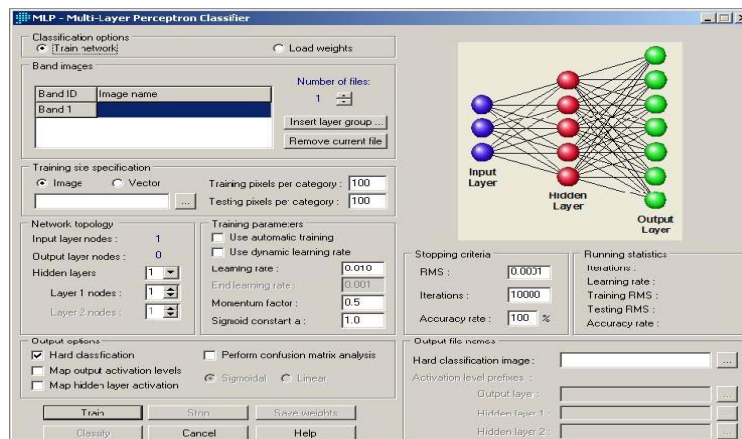


Figura 09. Módulo MLP do IDRISI.

Neste trabalho adotou-se a metodologia de treinamento da rede proposta por Vieira (2000), onde inicia-se utilizando valores baixos de taxa de aprendizagem e número de neurônios, até que a rede atinja uma taxa de aprendizagem satisfatória.

Foram feitas duas combinações de variáveis para o treinamento das redes: Combinação 01: B3-Vermelho, B2-Verde, B1-Azul e B4-Infravermelho Próximo. Combinação 02: B3-Vermelho, B2-Verde, B1-Azul, B4-Infravermelho Próximo e Índice NDVI.

Foram montadas várias arquiteturas para as redes, variando o número de neurônios, taxa de aprendizagem e número de interações. Utilizou-se para treinamento da rede os seguintes valores de taxa de aprendizagem: 0,003; 0,005; 0,007 e 0,01. Para o número de neurônios utilizou-se os seguintes valores: 06; 08; 10; 12; 14; 15; 25; 35 e 45. Foram testados diferentes números de interações: 10.000 e 20.000.

3.5 Validação da Classificação

Após realizadas as classificações procedeu-se a validação do mapa temático gerado, obtendo-se as matrizes de confusão e os respectivos Índices Kappa para cada método empregado.

Para a obtenção da matriz de confusão foi gerado uma malha de pontos aleatórios sobre a imagem IKONOS, totalizando 150 pontos (Figura 10). Para a determinação da quantidade de pontos a serem lançados sobre a imagem, adotou-se a metodologia de Jensen (1986) (Equação 02) que determina o número mínimo de pontos para que a validação da imagem classificada seja estatisticamente consistente.

$$N = [(4p)(q\sim)] / E^2 \quad (02)$$

Onde:

N = número de pontos amostrados;

p = percentual esperado de exatidão;

q~ = diferença entre 100 e p; e

E = erro permissível.




Figura 10. Malha de pontos lançadas de forma aleatória sobre a imagem.

Após lançada a malha de pontos foi realizada a identificação de cada ponto de acordo com a classe sobre a qual está localizado.

A mesma malha de pontos identificada foi lançada sobre a imagem temática gerada, e da mesma forma, cada ponto foi identificado.

Com os valores da imagem original e da imagem gerada pelos classificadores, foi possível criar a matriz de confusão e o cálculo do índice Kappa.

O índice kappa foi calculado a partir da matriz de confusão gerada pelo resultado das classificações, de acordo com a equação 03, utilizando o programa KAPPA de Vieira (2000).

A significância da diferença entre os índices Kappa Ka1 e Ka2 foi verificada aplicando-se o teste estatístico Z a 95% de probabilidade. Para testar se dois índices Kappa são significativamente diferentes utiliza-se o teste Z, conforme especificado pela equação apresentada a seguir:

$$Z = \frac{K1 - K2}{\sqrt{(VarK1) + (VarK2)}} \quad (04)$$

Onde:

K1 e K2 = índices Kappa calculados dos métodos 1 e 2;

VarK1 e VarK2 = variâncias dos índices Kappa do método 1 e 2.

3.6 Pós Classificação

Após realizadas as classificações com os diferentes algoritmos, as imagens geradas apresentam ruídos, no caso deste trabalho, pela alta resolução espacial da imagem e pela alta heterogeneidade espectral dentro de uma única classe.

Para melhorar a qualidade visual das imagens geradas, aplicou-se uma seqüência de operações no software ArcGis 9.2 (ESRI, 2006), que neste trabalho denominamos de Filtro.

O primeiro passo foi agrupar as células com valores iguais em regiões de identidade única, através do comando *Region Group*, onde um único valor é atribuído para cada região.

O passo seguinte é a seleção de um número de células que servirá como limiar no qual valores abaixo deste serão substituídos pelos valores das células vizinhas. Para este trabalho utilizou o valor de 50 células (50m²), ou seja, toda região que apresentar valor menor que o limiar determinado serão substituídas pelas células vizinhas.

Após esta etapa foi feita a quantificação de todas as classes

4. RESULTADOS E DISCUSSÃO

4.1 Análise Quantitativa das classificações

Os resultados das classificações geradas através dos métodos de Máxima Verossimilhança e Rede Neural foram comparados entre si de acordo com vários parâmetros, qualitativos e quantitativos. A avaliação dos resultados deu-se através da determinação do nível de confiança da classificação (índice Kappa) e da Exatidão Global das classificações através da análise da matriz de confusão.

Para a classificação por Redes Neurais, foram testadas duas combinações de bandas, sempre observando o resultado do teste (*Accuracy rate*), a saber: Combinação 1: B1, B2, B3 E B4; Combinação 2: B1, B2, B3, B4 E NDVI.

Foram utilizados 80 pixel por classe para treinamento e para teste, totalizando 640 pixels para o combinação 1, e 800 pixels para o combinação 2.

Na combinação 1, utilizando apenas as bandas multiespectrais do sensor IKONOS, variando de 6 a 45 neurônios, taxa de aprendizagem variando de 0,003 a 0,01, e 10.000 interações, a precisão do teste não ultrapassou o valor de 35%, como mostra a figura 11.




Figura 11. Resultados dos testes para o conjunto 1 de bandas com 10.000 interações.

Aumentando o número de interações para 20.000, e utilizando os

mesmos pesos, houve um aumento no resultado do teste, chegando a 47,19 (Figura 12) com 25 neurônios e taxa de aprendizagem de 0,01, apresentando nível de aceitação Bom, de acordo com Koch (1977).

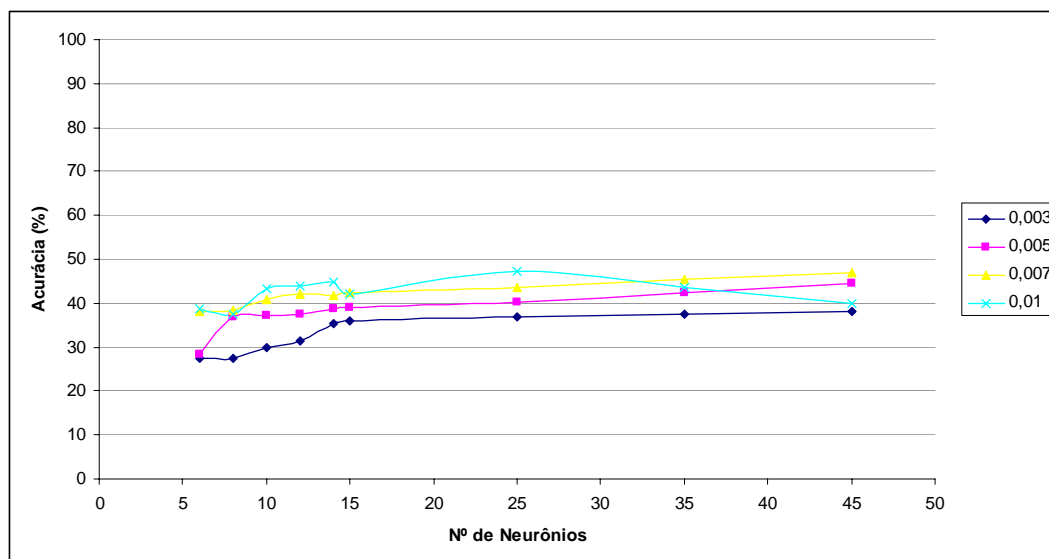


Figura 12. Resultados dos testes para o conjunto de 1 de bandas com 20.000 interações

Na combinação 2, foi utilizado além das bandas multiespectrais do sensor IKONOS, o índice NDVI, que indica o vigor da vegetação. Nesta série de testes de arquiteturas houve uma melhora nos resultados dos testes, chegando ao valor de 76,07% de precisão (Figura 13), com 12 neurônios na camada oculta, taxa de aprendizagem de 0,01 e 10.000 interações.

Na Figura 14 são apresentados os valores dos testes para treinamento da rede com 20.000 interações. Observa-se um aumento nos resultados na medida em que se aumenta o número de neurônios e a taxa de aprendizagem. Na combinação 2 de bandas, o melhor resultado encontrado foi de 80,54% com 15 neurônios na camada oculta, taxa de aprendizagem de 0,01 e 20.000 interações. Para este trabalho, esta arquitetura foi a utilizada para a classificação por Rede Neural.

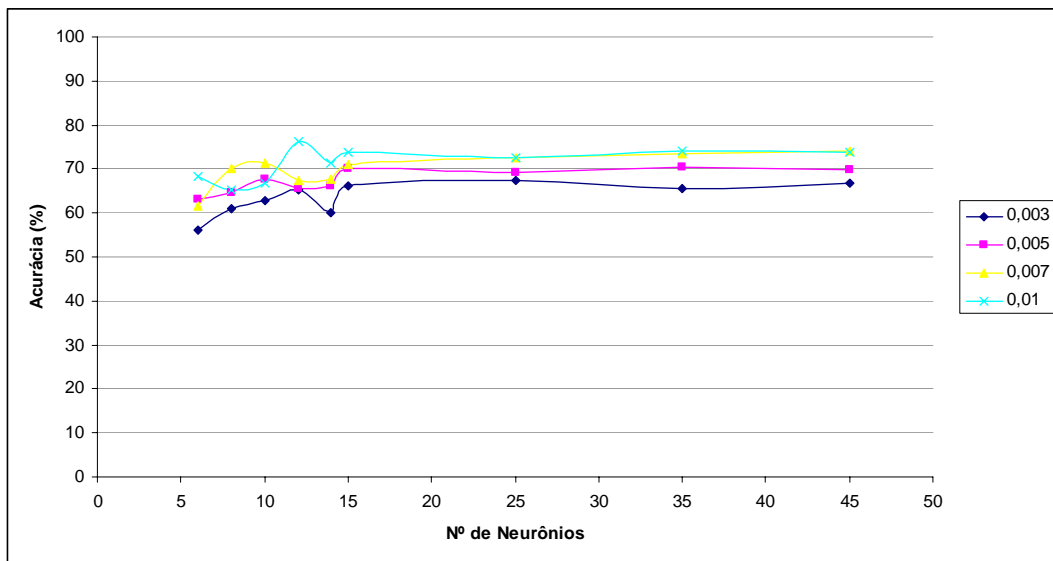


Figura 13. Resultados dos testes para a combinação 2 com 10.000 interações.

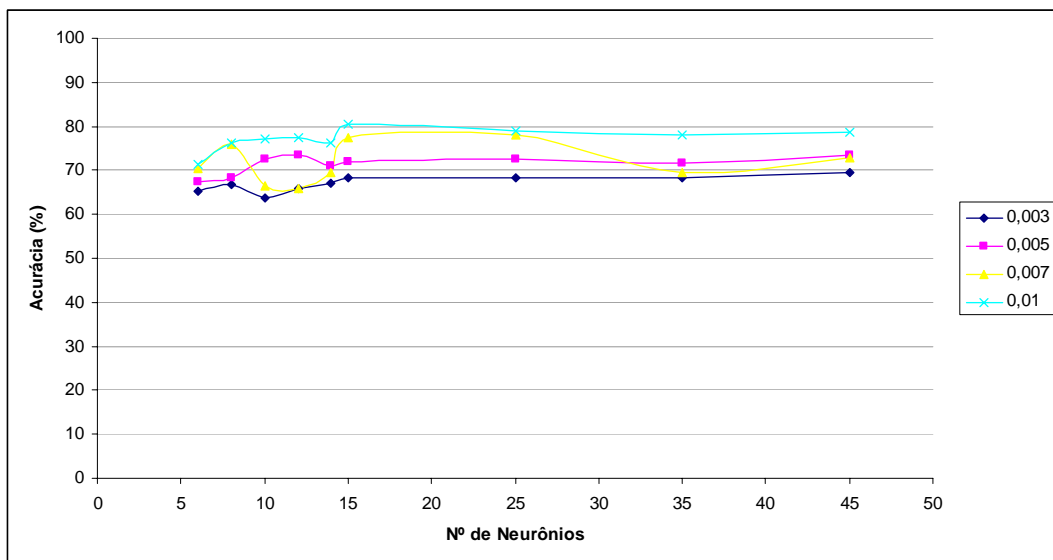


Figura 14. Resultados dos testes para a combinação 2, com 20.000 interações.

O quadro 9 apresenta a matriz de confusão obtida para a classificação das variáveis do Conjunto 2 pela Rede Neural. O Índice de Exatidão Global foi de 80 %, o Índice Kappa calculado foi de 75%.

Observa-se no quadro 9 que das oito classes, apenas três tiveram desempenho inferior a 80%, sendo eucalipto 75%, café 62% e área inundável 64%. A classe água teve 100% de acerto devido ao padrão homogêneo de sua assinatura espectral. As classes Mata e Lavoura foram as que obtiveram índices de exatidão global excelentes, 98% e 85% respectivamente.

A classe que teve a maior confusão foi o café com 38,5% de acerto, e 38,5% de confusão com a classe Área Inundável (5).

A segunda classe que teve maior confusão foi a classe Lavoura (1) tendo 61% de acerto dos pixels classificados nesta classe. A maior confusão entre a classe Lavoura foi com a classe Pasto (6), onde 25% dos pixels classificados nesta classe foram classificados como Lavoura. E também 11% dos pixels que deveriam ser classificados como classe Solos (4) foram classificados erroneamente como Lavoura.

As classes que apresentaram melhor desempenho de classificação foram as classes Água, com 100%; Mata, com 87% e Lavoura com 85% de exatidão. Acredita-se que a obtenção destes valores deve-se a distinção referente à resposta espectral (água e vegetação).

A classe eucalipto que obteve um índice de exatidão global muito bom com 75%, teve 20% dos pixels classificados confundidos com a classe Mata. A classe Solo (4) obteve um índice de exatidão global de 72%.

Quadro 09. Matriz de confusão e Índice Kappa para o classificador por Rede Neural.

Classes	1	2	3	4	5	6	7	8	Total
1	17	0	1	3	0	7	0	0	28
2	0	12	0	0	0	0	0	3	15
3	1	0	5	0	5	1	0	1	13
4	0	0	0	8	0	0	0	0	8
5	0	1	0	0	9	0	0	0	10
6	2	2	0	0	0	36	0	0	40
7	0	0	0	0	0	0	7	0	7
8	0	1	2	0	0	0	0	26	29
Prod.	0,85	0,75	0,62	0,72	0,64	0,81	1,00	0,87	
Total	20	16	8	11	14	44	7	30	150
Exatidão Global	0,80								
Índice Kappa	0,75								
Var.	0,001537								
Z calc.	19,1989								

Identificação das classes: 1-lavoura; 2-eucalipto; 3-café; 4-solo; 5-área inundável; 6-pasto; 7-água; 8-mata.

Para fins de comparação, objetivo deste trabalho, utilizou-se a mesma combinação de bandas (Combinação 2) para a classificação pelo algoritmo de

Máxima Verossimilhança. Foram utilizadas as mesmas classes, assim como os mesmos pixels utilizados na classificação por Rede Neural.

O quadro 10 apresenta a matriz de confusão obtida para a classificação das variáveis do Conjunto 2 pela Máxima Verossimilhança. O Índice de Exatidão Global foi de 89 %, o Índice Kappa calculado foi de 74%.

Observa-se no quadro 10 que das oito classes, quatro classes obtiveram desempenho inferior a 80% (Eucalipto 75%, café 63%, Área Inundável 57% e pasto 73%), duas classes entre 80% e 90% (Solo e Lavoura, respectivamente), e duas classes obtiveram índice de exatidão global superior a 90% (mata 97% e água 100%).

Assim como na Rede Neural, a classe água obteve o maior índice de exatidão global, com 100% de acerto. Os piores desempenhos foram das classes Área Inundável, com 57% e café, com 63%.

A classe que apresentou a maior confusão foi a classe Lavoura (1) que teve 26% classificados nesta classe, onde deveriam ter sido classificados como a classe Pasto (6).

A segunda maior confusão entre classes ocorreu com as classes café (3) e área inundável (5), onde 37,5% dos pixels atribuídos a classe 3 deveriam ser classificados como classe 5. A semelhança espectral das duas classes podem ter favorecido a confusão na classificação.

Outra classe onde houve maior confusão foi a classe mata (8) que teve 67% dos pixels classificados de forma correta, mas 12% classificados como classe pasto (6), e 21% com as classes eucalipto (2), Café (3) e área inundável (5). A grande confusão nesta classe deve-se à semelhança na resposta espectral desses tipos de vegetação.

Quadro 10. Matriz de confusão e índice Kappa para o classificador por Máxima Verossimilhança.

Classes	1	2	3	4	5	6	7	8	Total
1	17	0	1	2	0	7	0	0	27
2	0	12	0	0	0	0	0	1	13
3	0	0	5	0	3	0	0	0	8
4	0	0	0	8	0	0	0	0	8
5	0	1	0	0	8	0	0	0	9
6	3	0	0	0	0	33	0	0	36
7	0	0	0	0	0	0	7	0	7
8	0	3	2	0	3	5	0	29	43
Prod.	0,85	0,75	0,63	0,80	0,57	0,73	1,00	0,97	
Total	20	16	8	10	14	45	7	30	150
Exatidão Global	0,79								
Índice Kappa	0,74								
Var.	0,001601								
Z calc.	18,57883								

Identificação das classes: 1-lavoura; 2-eucalipto; 3-café; 4-solo; 5-área inundável; 6-pasto; 7-água; 8-mata.

Na figura 15 são apresentados os índices de exatidão global calculados por classes após a classificação pelos classificadores por Máxima Verossimilhança e Rede Neural. Observa-se que o resultado das classificações foram parecidos, sendo a maior diferença entre a classe Área Inundável que teve índice do MaxVer inferior ao da Rede Neural, assim como a classe pasto. Já para a classe Mata o classificador por Máxima Verossimilhança obteve melhor resultado.

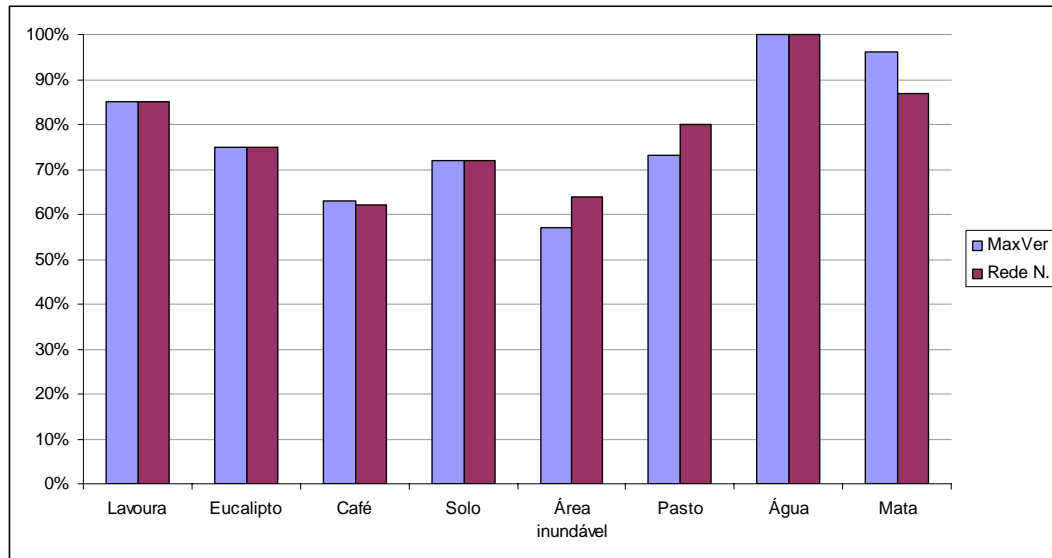


Figura 15. Índices de exatidão global por classes dos diferentes classificadores.

Foi realizado um teste de significância (Teste Z) para comparar as classificações feitas para a combinação de bandas 2, classificados pela Rede Neural e pela Máxima Verossimilhança.

O teste estatístico Z determina se dois ou mais valores independentes de Kappa, ou duas matrizes de confusão, são significativamente diferentes. Com este teste é possível comparar estatisticamente dois ou mais algoritmos de classificação, assim como dois ou mais conjunto de dados, tornando possível determinar qual produz melhor exatidão de classificação.

Para a realização do teste Z utilizou-se o índice Kappa e a variância de cada uma das classificações para observar a significância entre os classificadores (Quadro 12), de acordo com a equação 04.

Quadro 12. Índice Kappa e Variância de cada uma das classificações.

	Kappa	Variância	Z Calc.
Rede Neural	0,75	0,001537	19,1989
Maxver	0,74	0,001601	18,5788

Comparando o índice Kappa da classificação por Rede Neural com o índice Kappa da classificação por Máxima Verossimilhança, através do teste Z, encontrou-se o valor 0,2567. Para o teste Z ao nível de significância de 0,95 de probabilidade, qualquer valor encontrado menor do que 1,96 conclui-se que

não existe diferença significativa entre os valores testados. No caso deste trabalho, portanto, não existe diferença estatística entre os métodos de classificação por Rede Neural e por Máxima Verossimilhança.

Analisando os índices Kappa dos dois métodos utilizados para classificação neste trabalho, pode-se dizer que, de acordo com Landis e Koch (1977), a classificação por Redes Neurais apresenta índice Muito Bom, e a classificação por Máxima Verossimilhança apresenta índice Muito Bom.

4.2 Análise Qualitativa das classificações

Após as etapas de classificação da imagem pelo diferentes métodos de classificação, realizou-se uma filtragem da imagem para melhorar sua qualidade visual, e em seguida foi feita a quantificação da área de ocorrência de cada classe (quadro 13).

Quadro 13. Quantificação das classes mapeadas.

Classe	Área RN (ha)	Área MV (ha)	% RN	% MV
Lavoura	23,72	32,57	16,02	22,01
Eucalipto	16,84	9,71	11,38	6,56
Café	15,69	8,82	10,60	5,96
Solo	2,29	2,05	1,55	1,38
Área Inundável	8,84	5,37	5,98	3,63
Pastagem	47,60	34,59	32,17	23,37
Água	1,16	1,24	0,78	0,84
Mata	31,84	53,66	21,52	36,26
Total	147,98	148,01	100	100

RN = Rede Neural; MV = Máxima Verossimilhança.

Em termos de ocorrência observa-se que a classe que predomina no mapa classificado pela Rede Neural foi a classe Pasto com 47,60%, seguido da classe Mata com 31,84% e Lavoura com 23,72%.

Para o classificador por Máxima Verossimilhança, houve uma diferença entre a classe de maior ocorrência. Na imagem classificada por este classificador a classe de maior ocorrência foi a Mata com 36,26%, seguida por Pasto 23,37% e Lavoura 22,01%. Estes valores corroboram a diferença entre os valores de exatidão global encontrados para este classificador. A quantificação das áreas de cada classe é uma importante ferramenta para o

planejamento e manejo da área, uma vez que estudos temporais baseiam-se em dados qualitativos e quantitativos.

Na análise qualitativa pode-se observar mudanças espaciais ocorridas em determinadas classes, enquanto na análise quantitativa a informação numérica é representada através dos resultados das mudanças qualitativas.

Na figura 13 é apresentada a imagem temática gerada após a classificação por Máxima Verossimilhança. Nota-se que a imagem apresenta ruídos dentro das classes, apresentando uma qualidade visual inferior. Foi aplicado um filtro nesta imagem, obtendo uma melhoria na qualidade visual como apresentado na figura 14.

A imagem temática gerada pela Máxima Verossimilhança mostrou uma mistura entre as classes Pasto e Lavoura na parte superior central da imagem. As classes Mata, Eucalipto e Água foram caracterizadas de forma satisfatória. Na parte oeste central da imagem nota-se uma confusão entre as classes Área Inundável e Mata, devido à semelhança espectral destas classes. Houve confusão entre as classes Café e Área Inundável na parte central da imagem.

De modo geral a imagem temática gerada pelo classificador por Máxima Verossimilhança após aplicação do filtro apresenta qualidade visual satisfatória, apresentando as classes bem classificadas, corroborando o índice Kappa calculado.

A imagem temática gerada pelo classificador por Redes Neurais mostrou um grande número de ruídos entre as classes (Figura 15). Após aplicado um filtro nesta imagem, observa-se uma melhoria na qualidade, após eliminado pequenos pixels classificados de forma incorreta em cada classe como apresentado na figura 16.

De modo geral, a classificação por Redes Neurais apresentou-se satisfatória quando comparadas com a imagem original. As classes Mata, Eucalipto e Água foram bem classificadas, apresentando seus limites bem definidos. Houve confusão entre as classes Mata e Eucalipto, e Pasto e Lavoura devido à semelhança espectral entre estas classes.





Figura 13. Mapa temático gerado pela classificação por Máxima Verossimilhança sem aplicação do filtro.

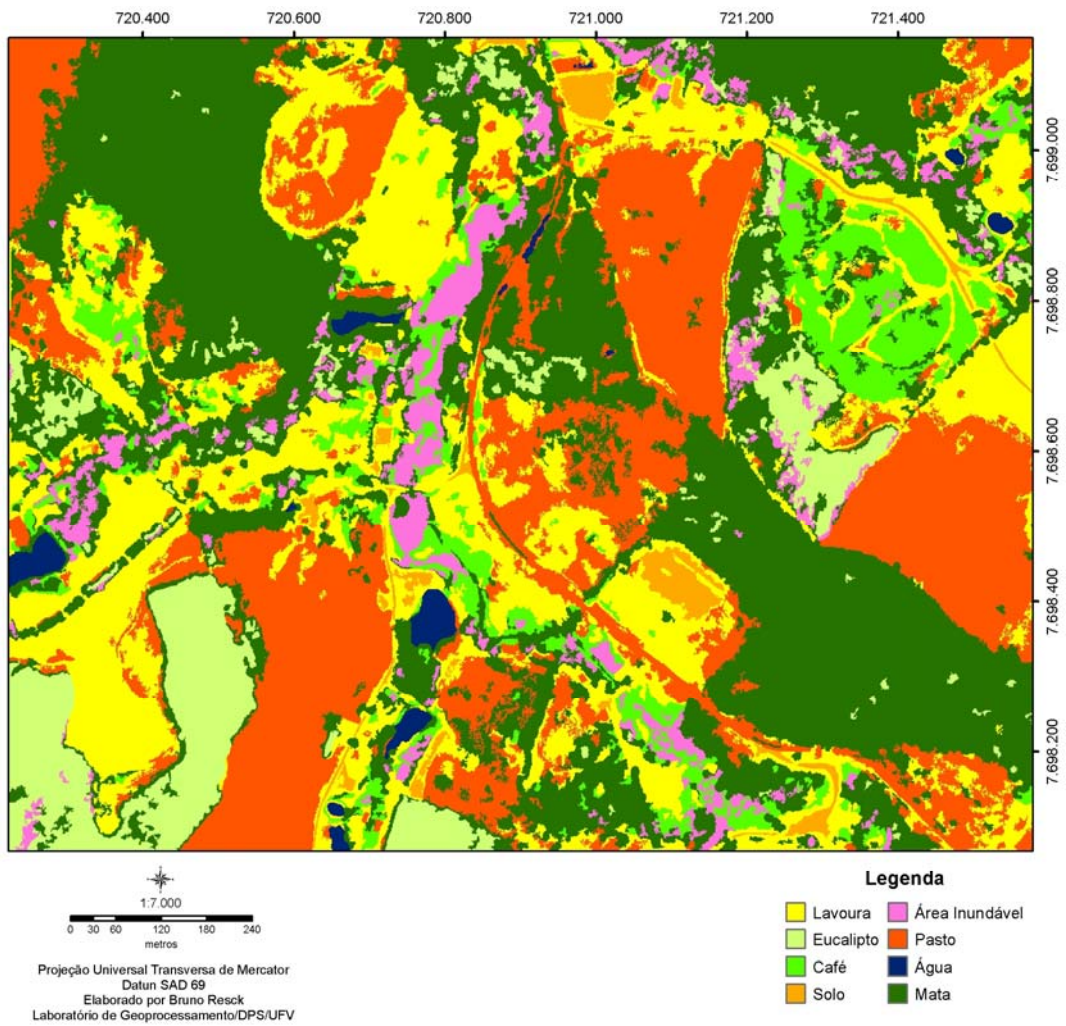


Figura 14. Mapa temático gerado pela classificação por Máxima Verossimilhança após aplicação do filtro.

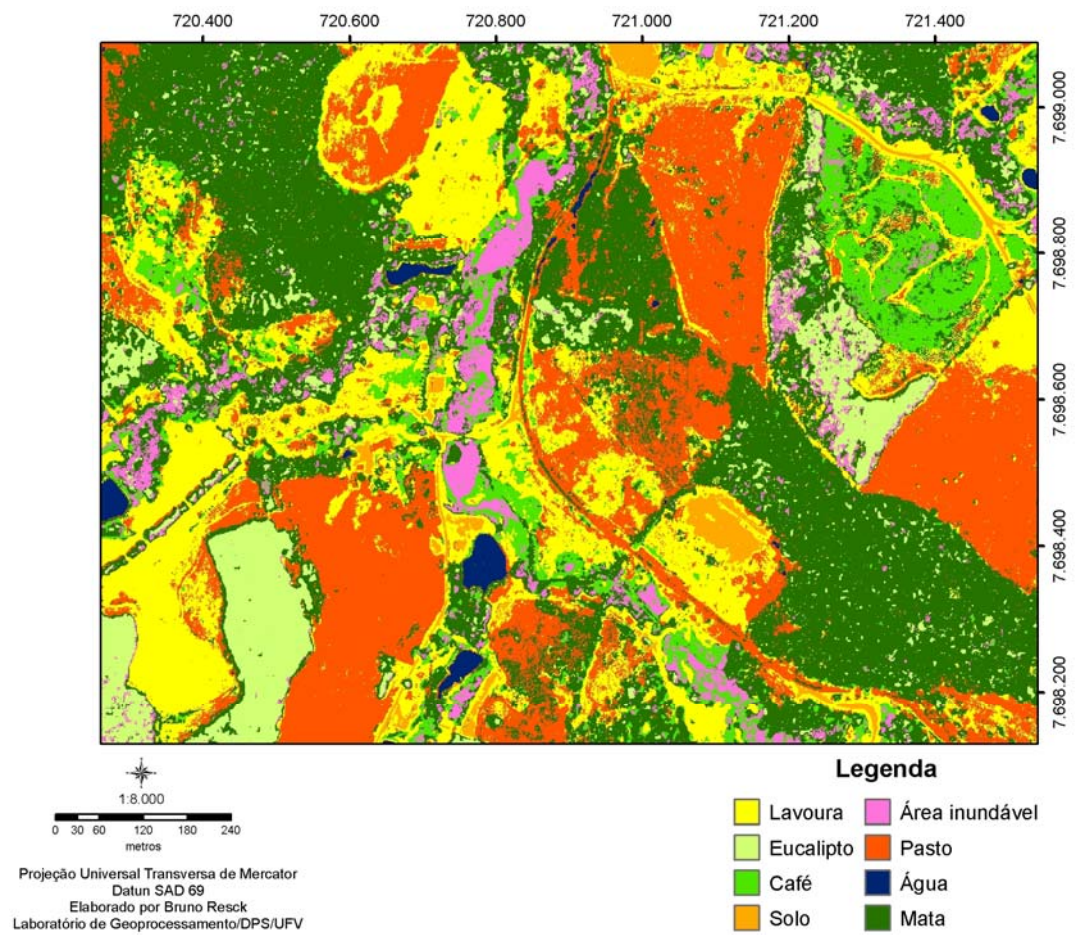


Figura 15. Mapa temático gerado pela classificação por Rede Neural sem aplicação do filtro.

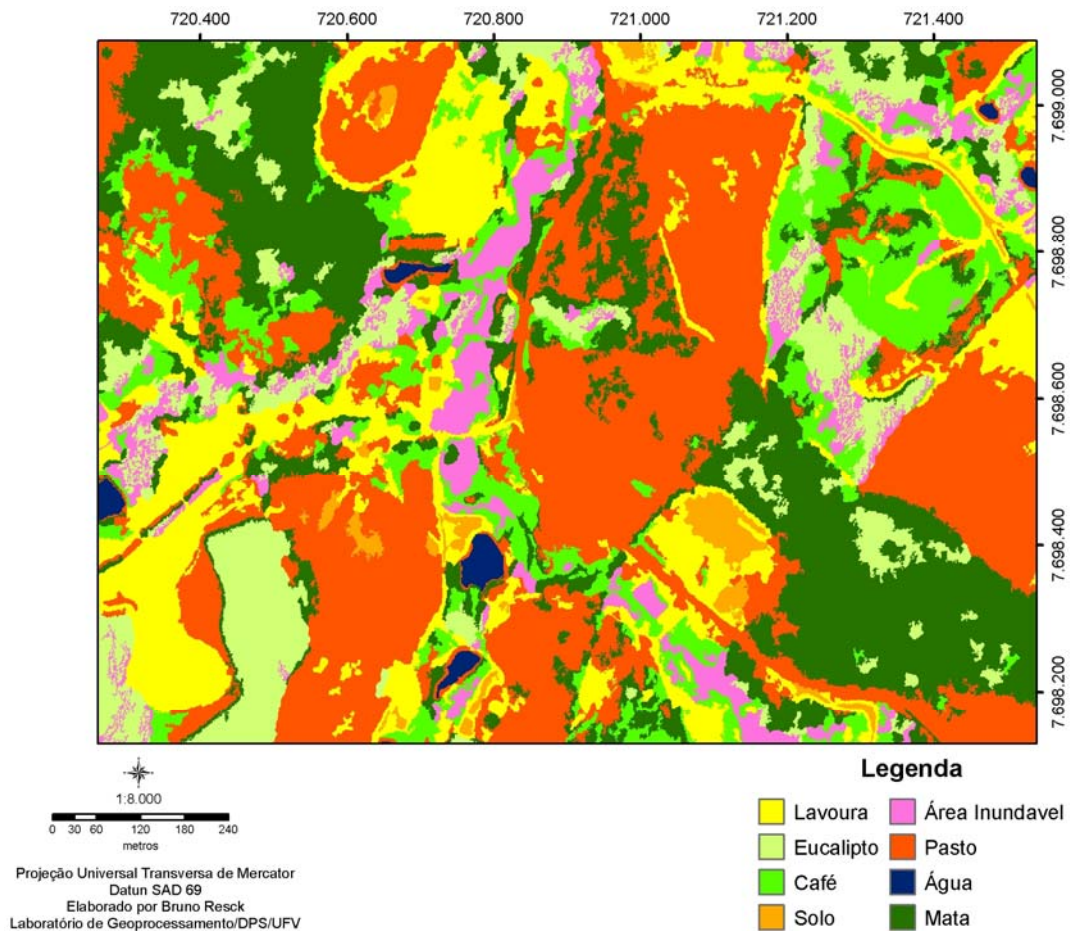


Figura 16. Mapa temático gerado pela classificação pela Rede Neural após aplicação do filtro.

De forma geral os classificadores apresentaram bom desempenho nas imagens temáticas geradas. As confusões entre classes foram evidenciadas visualmente, e corroboram com os resultados das matrizes de confusão e índices Kappa.

É importante ressaltar que devido à alta resolução espacial das imagens IKONOS, existe uma grande variação dos níveis de cinza entre os vizinhos, comparando com os sensores de média e baixa resolução, tornando o processo de classificação mais complexo.

Ribeiro (2003) em trabalho utilizando diferentes classificadores para classificar o uso e cobertura de uma imagem IKONOS obteve bons resultados para a Rede Neural 82,4% e para Máxima Verossimilhança 82,4%. Ambos os métodos em seu trabalho não obtiveram diferença estatística ao nível de significância de 95% de probabilidade, recomendando a autora a utilização, neste caso, do algoritmo de Máxima Verossimilhança devido ao baixo esforço

computacional e por apresentar disponível na maioria dos programas de classificação de imagens.

Mendonça (2006) utilizou diferentes métodos para classificação de uma imagem IKONOS e diferentes estratégias de amostragem para treinamento e validação. Para treinamento dos classificadores utilizou os métodos por pixel e por regiões, onde concluiu que houve diferença significativa entre os índices Kappa calculados para estes métodos. Por outro lado, quando utilizado diferentes tamanhos de amostras, o autor conclui que não existe diferença significativa entre os classificadores utilizando 250, 500, 750 e 1000 pixels para treinamento.

No trabalho onde se buscou testar diferentes métodos de classificação de imagens de alta resolução espacial, para o mapeamento de pastagens de diferentes categorias de degradação, Silva (2006) encontrou índices Kappa para os classificadores por Máxima Verossimilhança e por Rede Neural, de 0.987 e 0.907, concluindo que estes classificadores apresentam alto potencial para classificação de imagens IKONOS.

5. CONCLUSÕES E RECOMENDAÇÕES

Nas condições em que o trabalho foi realizado, podemos concluir que:

- Os métodos de classificação por Máxima Verossimilhança e Rede Neural, mostraram-se eficientes para a classificação de imagens IKONOS para uso e cobertura, apresentando valores de Kappa 0.75% e 0.74%;
- As classes mais homogêneas espectralmente foram melhores classificadas, apresentando menos sobreposição às outras classes;
- A alta resolução espectral da imagem IKONOS dificultou a distinção entre as classes, influenciando na precisão final;
- Os resultados obtidos pelos algoritmos de Máxima Verossimilhança e Rede Neural não diferenciam estatisticamente ao nível de significância de 95%;
- Recomenda-se para este estudo a utilização do classificador por Máxima Verossimilhança, devido ao fato deste algoritmo exigir menor esforço computacional e pessoal, e por ser implementado na maioria dos softwares de classificação de imagens;
- Recomenda-se a utilização de diferentes metodologias de amostragem para treinamento, assim como a utilização de variáveis como textura e forma para o aperfeiçoamento e possível melhora nos índices Kappa;
- As imagens temáticas geradas pelos classificadores após utilização do filtro apresentaram boa qualidade visual.

REFERÊNCIA BIBLIOGRÁFICA

BRITES, R. S. **Verificação de exatidão em classificadores de imagens digitais orbitais: efeitos de diferentes estratégias de amostragem e avaliação de índices de exatidão**. 1996. 101 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-MG, 1996.

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

CONGALTON, R.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999.

COELHO, D.; SOUZA, A. L. De; OLIVEIRA, C. M. L. de. Levantamento da cobertura florestal natural da microrregião de Viçosa, MG, utilizando-se imagens de Landsat 5. **Revista Árvore**. 2005, vol.29, n.1, pp. 17-24. ISSN 0100-6762.

DREIFUS, G. Neural Networks: an overview. In: _____. **Neural Networks: Methodology and applications**. Paris: ESPCI, Laboratoire d'Électronique. 2005. pp.1-84.

EASTMAN, J. R. **Guide to GIS and image processing**. Worcester, MA: Clark University, 2006.

FERNANDES, M. M. **Caracterização de solos e uso atual empregando aerofotos não convencionais nas sub-bacias Morengo, Palmital e Silibar – Rio Turvo Suojo, MG**. 1996. 107 f. Dissertação (Mestrado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa, Viçosa-MG, 1996.

FERNANDES, R. C. et al. **Mapeamento geoambiental com o uso de imagens de alta resolução espacial do sistema lagunar-estuarino Nísia Floresta-Papeba-Guarairas no litoral oriental do estado do Rio Grande do Norte**. Anais do XIII Simpósio de Sensoriamento Remoto. Florianópolis: INPE, 2007. p.p. (523-530).

FONTES, L. E. F.; FERNANDES, R. B. A.; RODRIGUES, J. S.; FILHO, E. I. F. Recursos hídricos e uso do solo no município de Viçosa, MG. In: FONTES, L. E. F.; FERNANDES, R. B. A.; RODRIGUES, J. S.; **Recursos hídricos e percepção ambiental no município de Viçosa, MG**. Viçosa, MG: Ambiente Brasil centro de estudo. 2006. p. 1-20.

GRUIJER, J. de. Spatial sampling schemes for remote sensing. In: STEIN, A. MEER, F. GORTE, B. (Ed) **Spatial statistics for remote sensing**. Netherlands: Kluwer Academic Publishers, 2005.

IBGE, **Introdução ao processamento digital de imagens**. Manuais técnicos em geociências – n. 9. Rio de Janeiro: IBGE, 2001.

JANSSEN, L. L. F.; GORTE, B.G.H. Digital image classification. In: KERLE, N. JANSSEN, L.L.F.; HUURNEMAN, G. C. (Ed). **Principles of remote sensing**. Enschede, the Netherlands: International Institute for Geoinformation Science and Earth Observation. Third edition, 2004.

JENSEN, J. R. **Introductory digital image processing**. New Jersey: Prentice Hall, 1986.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and Image Interpretation**. 2ª ed. New York: John Wiley. 1994.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**. 3ª Ed. Ed. Chichester: John Wiley & Sons.

MATTOS, Ana Dantas Mendez de et al. Valoração ambiental de áreas de preservação permanente da microbacia do ribeirão São Bartolomeu no Município de Viçosa, MG. **Revista Árvore**. 2007, vol.31, n.2, pp. 347-353. ISSN 0100-6762.

MENDONÇA, L. E. R. de. **Utilização de algoritmos de classificação em uma imagem IKONOS para o mapeamento de feições terrestres: um estudo de caso**. 2006. 65 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2006.

MENDONZA ROJAS, E. H. **Síntese genética de redes neurais artificiais ART2 na classificação de imagens ASTER para mapeamento do uso e cobertura da terra na região norte do estado do Mato Grosso**. 2004. 124 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 2004.

MOREIRA, M. A . **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2. Ed. Viçosa: UFV, 2003.

NASCIMENTO, M. C. do; SOARES, V. P.; RIBEIRO, C. A. A. S.; SILVA, E. Mapeamento dos fragmentos de vegetação florestal nativa da bacia hidrográfica do rio Alegre, Espírito Santo, a partir de imagens do satélite IKONOS II. **Revista Árvore**. 2006, vol.30, n.3, pp. 389-398.

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

ORLANDINI, D. **Avaliação do uso dos recursos naturais de uma sub-bacia do Ribeirão São Bartolomeu com vista ao aumento da produção de água com qualidade**. Dissertação (Mestrado em Ciências Florestais) Universidade Federal de Viçosa, Viçosa, 2002.

REZENDE, S. B.; RESENDE, M. Solos dos mares de morro: ocupação e uso. In: ALVAREZ, V. H.; FONTES, M. P. F.; FONTES, L. E. F. (ed) **O solo nos grandes domínio morfoclimáticos do Brasil e o desenvolvimento sustentado**. Viçosa, MG: UFV, SBCS, DPS. 1996. p. 261-288.

RIBEIRO, M. P. R. **Avaliação de métodos de classificação de imagens IKONOS II para o mapeamento da cobertura terrestre**. 2003. 53 f. Tese (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-MG, 2003.

RODRÍGUES, A . C. M. **Sensoriamento remoto e geoprocessamento aplicados na análise da legislação ambiental no município de São Sebastião (SP)**. 2006. 201 f. Dissertação (Mestrado em Geografia) – Faculdade de Filosofia, Letras e Ciências Humanas da Universidade Federal de Viçosa, São Paulo, SP, 2005.

RODRIGUES, Izabella Martins da Costa GARCIA, Flávia Cristina Pinto. *Papilionoideae (Leguminosae)* arbóreas e lianas na estação de pesquisa, treinamento e educação ambiental (EPTEA), Mata do Paraíso, Viçosa, Zona da Mata Mineira. **Revista Árvore**. 2007, vol.31, n.3, pp. 521-532. ISSN 0100-6762.

ROSA, R. **Intrdução ao sensoriamento remoto**. Uberlândia: Ed. UFU. 1992.

SKIDMORE, A . K. Accuracy assesment of spatial information. In: STEIN, A . MEER, F. GORTE, B. (Ed) **Spatial statistics for remote sensing**. Netherlands: Kluwer Academic Publishers, 2005.

VALENTE, E. L. **Caracterização da intensidade de degradação do solo e cobertura vegetal de uma área do médio Rio Doce, utilizando imagem IKONOS II**. 2005. 89 f. Tese (Mestrado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa, Viçosa, 2005.

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.

WOLDAL, T. Eletromagnetic energy and remote sensing. In: KERLE, N. JANSSEN, L.L.F.; HUURNEMAN, G. C. (Ed). **Princípios of remote sensing**. . Enschede, the Netherlands: International Institue for Geoinformation Science and Earth Obervation. Third edition, 2004.

ANEXO I

Quadro 13. Arquiteturas testadas para o conjunto 1.

Nº Neurônios	Tx. Aprendizado	Tx. Acurácia (%)	Interações	Acurácia (%)	Interações	Acurácia (%)
06	0.003	100	10.000	7,81	20.000	27,34
08	0.003	100	10.000	7,97	20.000	27,50
10	0.003	100	10.000	9,22	20.000	30,00
12	0.003	100	10.000	8,28	20.000	31,41
14	0.003	100	10.000	15,31	20.000	35,22
15	0.003	100	10.000	16,25	20.000	36,09
25	0.003	100	10.000	24,69	20.000	36,88
35	0.003	100	10.000	24,22	20.000	37,50
45	0.003	100	10.000	23,28	20.000	38,13
<hr/>						
06	0.005	100	10.000	15,78	20.000	28,44
08	0.005	100	10.000	21,09	20.000	37,03
10	0.005	100	10.000	18,59	20.000	37,28
12	0.005	100	10.000	23,91	20.000	37,50
14	0.005	100	10.000	23,44	20.000	38,59
15	0.005	100	10.000	25,63	20.000	39,04
25	0.005	100	10.000	24,38	20.000	40,31
35	0.005	100	10.000	25,16	20.000	42,33
45	0.005	100	10.000	25,94	20.000	44,38
<hr/>						
06	0.007	100	10.000	15,63	20.000	38,13
08	0.007	100	10.000	24,22	20.000	38,44
10	0.007	100	10.000	24,53	20.000	40,94
12	0.007	100	10.000	25,94	20.000	42,19
14	0.007	100	10.000	26,72	20.000	41,88
15	0.007	100	10.000	28,44	20.000	42,50
25	0.007	100	10.000	28,59	20.000	43,75
35	0.007	100	10.000	27,34	20.000	45,31
45	0.007	100	10.000	27,97	20.000	47,03
<hr/>						
06	0.01	100	10.000	26,56	20.000	38,75
08	0.01	100	10.000	31,88	20.000	37,50
10	0.01	100	10.000	29,69	20.000	43,28
12	0.01	100	10.000	30,12	20.000	44,00
14	0.01	100	10.000	31,00	20.000	44,70
15	0.01	100	10.000	31,72	20.000	42,19
25	0.01	100	10.000	33,13	20.000	47,19
35	0.01	100	10.000	30,63	20.000	43,50
45	0.01	100	10.000	10,31	20.000	40,00

Quadro 14. Arquiteturas testadas para o conjunto 2.

Nº Neuronios	Tx. Aprendizado	Tx. Acurácia (%)	Interações	Acurácia (%)	Interações	Acurácia
06	0.003	100	10.000	56,25	20.000	65,30
08	0.003	100	10.000	60,94	20.000	66,62
10	0.003	100	10.000	62,81	20.000	63,59
12	0.003	100	10.000	65,31	20.000	65,94
14	0.003	100	10.000	60,16	20.000	67,19
15	0.003	100	10.000	66,09	20.000	68,28
25	0.003	100	10.000	67,34	20.000	68,40
35	0.003	100	10.000	65,47	20.000	68,44
45	0.003	100	10.000	66,88	20.000	69,53
06	0.005	100	10.000	63,13	20.000	67,50
08	0.005	100	10.000	64,53	20.000	68,25
10	0.005	100	10.000	67,81	20.000	72,50
12	0.005	100	10.000	65,47	20.000	73,40
14	0.005	100	10.000	66,25	20.000	71,04
15	0.005	100	10.000	70,00	20.000	71,85
25	0.005	100	10.000	69,06	20.000	72,50
35	0.005	100	10.000	70,47	20.000	71,55
45	0.005	100	10.000	69,69	20.000	73,50
06	0.007	100	10.000	61,56	20.000	70,31
08	0.007	100	10.000	70,00	20.000	75,83
10	0.007	100	10.000	71,25	20.000	66,41
12	0.007	100	10.000	67,34	20.000	65,88
14	0.007	100	10.000	67,81	20.000	69,38
15	0.007	100	10.000	70,94	20.000	77,29
25	0.007	100	10.000	72,50	20.000	78,04
35	0.007	100	10.000	73,44	20.000	69,38
45	0.007	100	10.000	74,06	20.000	72,81
06	0.01	100	10.000	68,44	20.000	71,25
08	0.01	100	10.000	65,22	20.000	76,09
10	0.01	100	10.000	66,72	20.000	77,19
12	0.01	100	10.000	76,07	20.000	77,34
14	0.01	100	10.000	71,25	20.000	76,25
15	0.01	100	10.000	73,74	20.000	80,54
25	0.01	100	10.000	72,50	20.000	79,08
35	0.01	100	10.000	74,22	20.000	77,97
45	0.01	100	10.000	73,91	20.000	78,75