

RAQUEL DE CASTRO PORTES

**IDENTIFICAÇÃO DO USO DA TERRA SOB MANEJO AGROECOLÓGICO
UTILIZANDO IMAGEM DE ALTA RESOLUÇÃO E CONHECIMENTO
LOCAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Solos e Nutrição de Plantas para obtenção do título de *Magister Scientiae*.

**VIÇOSA
MINAS GERAIS - BRASIL
2010**

RAQUEL DE CASTRO PORTES

**IDENTIFICAÇÃO DO USO DA TERRA SOB MANEJO AGROECOLÓGICO
UTILIZANDO IMAGEM DE ALTA RESOLUÇÃO E CONHECIMENTO
LOCAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Solos e Nutrição de Plantas para obtenção do título de *Magister Scientiae*.

APROVADA: 23 de fevereiro de 2010.

Prof. Elpídio Inácio Fernandes

Filho

(Co-orientador)

Prof. José Marinaldo Gleriani

(Co-orientador)

Prof. Irene Maria Cardoso

Prof. Carlos Antônio Oliveira

Vieira

Prof. Ivo Jucksch

(Orientador)

AGRADECIMENTOS

Agradeço à Universidade Federal de Viçosa e Departamento de Solos pela oportunidade de realização do curso.

À CAPES – Coordenação de Aperfeiçoamento aos Profissionais do Ensino Superior pela bolsa concedida.

A todos os agricultores e agricultoras da bacia do Rio São Joaquim, pela confiança depositada ao abrirem a porteira de suas propriedades e permitirem o caminamento para obtenção das amostras de padrões de uso e cobertura do solo da bacia.

À Marli e Geraldo que me receberam em sua casa com carinho e aconchego, ao Zaquel com seus conhecimentos que muito contribuíram para o trabalho de campo, e ao Sr. Cosme e Dona Amélia que foram essenciais por intermediar inicialmente o diálogo com os moradores.

Aos funcionários da EFA-Puris e todos os moradores que participaram da atividade desenvolvida na escola

Ao Carlos Eduardo Pacheco Lima e o professor Maurício Paulo Ferreira Fontes, por disponibilizarem a imagem IKONOS da bacia.

Ao meu orientador Ivo Jucksch, pelo carinho, ensinamentos e por ter me levado ao mundo agroecológico.

Ao professor Elpídio Inácio Fernandes Filho, pelos ensinamentos, idéias, amizade, carinho e oportunidades.

À professora Irene Maria Cardoso, por ter-me aberto portas e pelas sugestões e recomendações a pesquisa, tanto no seu andamento, como na correção da dissertação.

Ao professor José Marinaldo Gleriani, que muito ajudou com suas sugestões e auxílios na utilização do Spring.

Ao professor Carlos Antônio Oliveira Vieira, pela disposição em participar da banca de defesa da dissertação e pelas sugestões valiosas.

Aos Eduardo de Sá Mendonça, Anor Fiorini de Carvalho, pelas sugestões no desenvolvimento do trabalho.

Aos funcionários do Departamento de Solos, Luciana, Claudinha, Carla, Seu Vicente, Fábio, Bené e Claudinho, pela dedicação que desempenham suas funções e apoio durante o curso.

Aos amigos de laboratório e em especial a Alice Scudeler pela parceria e contribuição em campo e laboratório e Bruno Resck pelo auxílio no Idrisi.

Aos meus pais, Amasiles e Manoel por tudo que fizeram por mim ao longo desta vida, apoio, carinho, dedicação e amor. Aos meus irmãos Wilson, Rafael e a cunhada Ana e sobrinha Gabi pelo carinho.

Ao meu marido Diogo, por ser meu companheiro de todos os momentos, paciência, ajuda, carinho e amor. A Nadije e Hamilton e família, por ter me acolhido como parte da família. À Quica, pelas alegrias que trouxe ao meu lar e pela companhia.

Aos meus amigos do coração, Flávio, Brunão, Samuca, Gracinha, Diana, Guilherme, Gustavo e Natália, por tornarem a vida em Viçosa melhor de viver e a todos que direta ou indiretamente ajudaram na realização deste trabalho.

Obrigada!!!

SUMÁRIO

LISTA DE FIGURAS	vi
LISTA DE TABELAS	viii
RESUMO	ix
ABSTRACT	x
1. INTRODUÇÃO	1
2. OBJETIVOS	3
3. REVISÃO DE LITERATURA	4
3.1. Geoprocessamento e Sistemas de Informações Geográficas	4
3.2. Satélite IKONOS	5
3.3. Sensoriamento Remoto	6
3.4. Classificação de imagens de satélites	6
3.4.1. Classificação supervisionada	7
3.4.2. Classificação não supervisionada	11
3.4.3. Avaliação das classificações	13
3.4.4. Classificação automática da imagem IKONOS	15
3.4.5. Mapeamento Participativo	17
4. METODOLOGIA	18
4.1. Caracterização geral do município Araponga	18
4.2. A área de estudo – Bacia do Rio São Joaquim	18
4.3. Base de dados e equipamentos	19
4.4. Procedimentos metodológicos	20
4.4.1. Coleta de Pontos de Controle Terrestre	21
4.4.2. Georreferenciamento	21

4.4.3. Delimitação da bacia hidrográfica	24
4.4.4. Coleta das amostras de treinamento e validação.....	24
4.4.5. Classificação não supervisionada – Isoseg	24
4.4.6. Vetorização das amostras de treinamento e validação.....	26
4.4.7. Classificação supervisionada da imagem IKONOS II.....	30
4.4.8. Pós classificação	34
4.4.9. Identificação do uso e cobertura do solo pela comunidade	35
5. RESULTADOS E DISCUSSÃO	39
5.1. Georreferenciamento.....	39
5.2. Agrupamento das classes pelo Isoseg	39
5.3. Classificações supervisionadas	40
5.4. Classificação <i>pixel a pixel</i> por Máxima Verossimilhança	43
5.5. Classificação <i>pixel a pixel</i> por Redes Neurais Artificiais - <i>Error Backpropagation</i>	45
5.6. Classificação por regiões – Bhattacharya	53
5.7. Classificação do uso do solo pela comunidade	53
6. CONSIDERAÇÕES FINAIS.....	61
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	62
ANEXO I	66
ANEXO II	68

LISTA DE FIGURAS

Figura 1 - Rede Neural Artificial multicamadas (Fonte: NUNES & PINHEIRO, 2007).	10
Figura 2 – Mapa de localização da bacia do Rio São Joaquim, município Araponga – MG.	19
Figura 3 - Fluxograma dos procedimentos metodológicos.....	21
Figura 4 - Pontos de Controle Terrestre.....	Erro! Indicador não definido.
Tabela 4 (Cont.) - Chave de interpretação de uso e cobertura do solo coletados na bacia.	26
Figura 5 – Mapa das amostras de treinamento.....	Erro! Indicador não definido.
Figura 6 – Mapa das amostras amostras de validação	Erro! Indicador não definido.
Figura 7 – Módulo MAXLIKE do IDRISI Andes.	30
Figura 8 – Módulo MLP do IDRISI Andes.	31
Figura 9 – Coleta das amostras de treinamento na imagem segmentada.....	34
Figura 10 – Apresentação da imagem IKONOS II.....	36
Figura 11 – Identificação das informações para serem mapeadas e criação da legenda.	36
Figura 12– Divisão da bacia por regiões.....	37
Figura 13 – Interpretação visual da imagem e delineamento do uso e cobertura do solo	38
Figura 14 – Interpretação visual da imagem e delineamento do uso e cobertura do solo	38
Figura 15 – Acurácia do produtor para classificação automática utilizando 17 classes.	41
Figura 16 - Acurácia do usuário para classificação automática utilizando 17 classes....	41
Figura 17 – Acurácia do produtor para classificação automática utilizando 14 classes.	42
Figura 18 – Acurácia do usuário para classificação automática utilizando 14 classes. ...	42

Figura 19 – Classificação do uso e cobertura do solo pelo MaxVer – 17 classes.....	Erro!
Indicador não definido.	
Figura 20 – Treinamento de arquiteturas para combinação 1, com 17 classes de amostras de treinamento e 20.000 interações.	46
Figura 21 – Classificação do uso e cobertura do solo pelo MaxVer – 14 classes.....	Erro!
Indicador não definido.	
Figura 22 – Treinamento de arquiteturas para combinação 2, com 17 classes de amostras de treinamento e 20.000 interações.	48
Figura 23 – Treinamento de arquiteturas para combinação 1, com 14 classes de amostras de treinamento e 20.000 interações.	48
Figura 24 – Treinamento de arquiteturas para combinação 2, com 14 classes de amostras de treinamento e 20.000 interações.	49
Figura 25 - Classificação do uso e cobertura do solo pelas RNA's – 17 classes.....	Erro!
Indicador não definido.	
Figura 26 – Classificação do uso e cobertura do solo pelas RNA's – 14 classes.	Erro!
Indicador não definido.	
Figura 27– Classificação do uso e cobertura do solo por regiões – 17 classes.....	Erro!
Indicador não definido.	
Figura 28 – Classificação do uso e cobertura do solo por regiões – 14 classes.....	Erro!
Indicador não definido.	
Figura 29 – Classificação do uso e cobertura do solo classificado pela comunidade.	Erro! Indicador não definido.
Figura 30 - Acurácia do produtor para classificação da comunidade.	58
Figura 31 – Acurácia do usuário para classificação da comunidade.	58
Figura 32 – Proporção das propriedades rurais e seus respectivos manejos.....	59
Figura 33 - Imagens classificadas de cada região pelos agricultores.....	60

LISTA DE TABELAS

Tabela 1 - Características da imagem IKONOS II.....	5
Tabela 2 - Matriz de erros genérica.....	13
Tabela 3 - Intervalos de aceitação dos resultados do Índice Kappa.....	15
Tabela 4 - Chave de interpretação de uso e cobertura do solo coletados na bacia.	25
Tabela 5 - Quantidade de amostras de treinamento e amostras de validação.	27
Tabela 6 - Pontos de Controle Terrestre e Erro Médio Quadrático.	39
Tabela A1 - Arquiteturas geradas para a combinação de bandas 1, para 17 classes.....	66
Tabela A2 - Arquiteturas geradas para a combinação de bandas 1, para 14 classes.....	66
Tabela A3 - Arquiteturas geradas para a combinação de bandas 2, para 17 classes.....	66
Tabela A4 - Arquiteturas geradas para a combinação de bandas 2, para 14 classes.....	67
Tabela A5 - Matriz de erros da classificação por MaxVer utilizando 17 classes – Kappa 0,51.....	69
Tabela A6 - Matriz de erros da classificação por MaxVer utilizando 14 classes – Kappa 0,58.....	70
Tabela A7 - Matriz de erros da classificação por RNA's utilizando 17 classes – Kappa 0,48.....	71
Tabela A8 - Matriz de erros da classificação por RNA's utilizando 14 classes – Kappa 0,58.....	72
Tabela A9 - Matriz de erros da classificação por regiões utilizando 17 classes – Kappa 0,76.....	73
Tabela A10 - Matriz de erros da classificação por regiões utilizando 14 classes – Kappa 0,68.....	74
Tabela A11 - Matriz de erros da classificação da comunidade 8 classes – Kappa 0,55 .	75

RESUMO

PORTES, Raquel de Castro. M. Sc., Universidade Federal de Viçosa, fevereiro de 2010. **Identificação do uso da terra sob manejo agroecológico utilizando imagem de alta resolução e conhecimento local.** Orientador: Ivo Jucksch. Co-orientadores: Elpídio Inácio Fernandes Filho e José Marinaldo Gleriani.

Este trabalho objetivou avaliar o potencial de classificadores automáticos e da metodologia empregada na classificação da comunidade residente na bacia para mapeamento do uso e cobertura do solo sob manejo agroecológico. A área de estudo é a Bacia do Rio São Joaquim, no município de Araponga, Zona da Mata mineira. Na metodologia, no primeiro momento, foi realizada a ida a campo onde foram coletados os Pontos de Controle Terrestre para georreferenciar imagem IKONOS II e as amostras de treinamento e validação das classes de uso e cobertura do solo através de GPS. Em laboratório, foram realizadas classificações supervisionadas automáticas pelos algoritmos da Máxima Verossimilhança, Redes Neurais Artificiais e Bhattacharya. Para cada algoritmo, foram feitas duas classificações, 17 e 14 classes. Uma classificação do uso e cobertura do solo foi realizada pelos moradores da bacia onde foram identificadas as classes de uso e cobertura do solo. As imagens classificadas foram levadas ao laboratório e transformadas em formato digital. Os resultados demonstram que dentre os classificadores automáticos, o Bhattacharya apresentou melhor resultado, Kappa 0,76, resultado muito bom para classificação da área em questão. Já o Kappa da imagem classificada pela comunidade foi de 0,55, resultado considerado bom de acordo com a literatura. Estes resultados demonstram que o algoritmo Bhattacharya é o mais eficiente para o mapeamento e que é possível que a comunidade local interprete o meio em que vive e possa realizar com autonomia mapeamentos para traçar estratégias futuras. Sendo assim, os resultados encontrados nesta pesquisa além de serem úteis para futuros planejamentos de pesquisa-ação na bacia hidrográfica em estudo, servirão como conhecimento universal para classificação do uso do solo em outras áreas com manejo agroecológico.

ABSTRACT

PORTES, Raquel de Castro. M. Sc., Universidade Federal de Viçosa, february of 2010. **Identification of land use in agro-ecological management using high-resolution image and local knowledge.** Adviser: Ivo Jucksch. Co-advisers: Elpídio Inácio Fernandes Filho e José Marinaldo Gleriani.

This study evaluated the potential of automatic classifiers, and methodology of the classification of the resident community in the basin to use mapping and land cover under agroecological management. The study area is the São Joaquim River Basin in the municipality of Araçuaia, Zona da Mata mineira. In the method, at first, was held to a field trip where they were collected ground control points to georeference image IKONOS II and the training samples and validation of the use classes and soil covered by GPS. In the laboratory, supervised classifications were performed by automatic algorithms Maximum Likelihood, Neural Networks and Bhattacharya. For each algorithm, two ratings were made 17 and 14 classes. A use classification and land cover was done by the residents of the basin where the classes were identified for use and land cover. The classified images were taken to the laboratory and turned into digital format. The results show that among the automatic classifiers, the Bhattacharya shows better result, Kappa 0.76, very good result for classification of the area. Already Kappa image classified by the community was 0.55, considered good result according to the literature. These results demonstrate that the algorithm Batacharya is the most efficient for the mapping and it is possible that the local community to interpret the environment in which to live and perform with autonomy mappings to map future strategies. Therefore, the findings of this study in addition to being useful for future planning of action research in the basin under study, will serve as universal knowledge for classification of land use in other areas of agroecological management.

1. INTRODUÇÃO

O planejamento dos espaços agrários é uma peça chave para elaboração de estratégias para o seu desenvolvimento. Nos dias atuais, a falta de informações espaciais em grandes escalas tem causado prejuízos nos processos de tomada de decisão, tornando-os demorados e onerosos.

Os Sistemas de Informações Geográficas (SIG's) tem contribuído para subsidiar diversos estudos na tomada de decisões e conseqüente intervenção no espaço geográfico, devido sua grande capacidade de integração de dados convencionais e georreferenciados, através do seu Banco de Dados Georreferenciados (BDG). A potencialidade do BDG consiste na armazenagem, integração, consulta, visualização e realização de análises de informações provenientes de uma única base de dados.

Aliado aos SIGs, os produtos do Sensoriamento Remoto, como as imagens de satélite proporcionam uma rica fonte de dados variados da superfície terrestre que podem ser extraídos, como o uso e cobertura do solo através da classificação automática.

O uso de imagens de alta resolução espacial permite a identificação e mapeamento de pequenos objetos na superfície terrestre. Isto torna o uso dessas imagens úteis no mapeamento de uso e cobertura do solo em paisagens diversificadas, como àquelas sob manejo agroecológico. A agroecologia prevê o uso de sistemas diversos, com um dos seus princípios.

De acordo com ALTIERI (2000) Os sistemas de produção com base agroecológica vêm sendo implantados na agricultura familiar, geralmente em pequenas propriedades e apresentam alta diversificação genética decorrentes da consorciação de espécies, tornando a paisagem agrícola mais diversa e com padrões heterogêneos de uso e cobertura do solo.

Contudo, a evolução tecnológica das imagens de satélite não foi acompanhada pelas técnicas de classificação e o aumento da variação interna das classes de uso do solo dos sistemas agroecológicos gera sobreposições das classes no espaço, que acabam dificultando a classificação.

Neste sentido, são necessárias pesquisas que direcionem o foco na avaliação de diferentes métodos de classificação de imagens de alta resolução em sistemas agroecológicos.

No estudo aqui apresentado será empregada a avaliação do potencial de classificadores automáticos e da metodologia realizada pela comunidade local para mapeamento do uso e cobertura do solo no planejamento agroecológico da bacia hidrográfica do Rio São Joaquim, no município de Araponga – MG.

Nesta bacia, desde 1987 o Centro de Tecnologias Alternativas da Zona da Mata (CTA - ZM), assessora os agricultores e suas organizações (sindicato, associações, cooperativas etc.) no desenvolvimento de sistemas agroecológicos. Este trabalho é realizado em parceria com a Universidade Federal de Viçosa, em especial o Departamento de Solos, que realiza trabalhos de extensão e pesquisa nas propriedades destes agricultores, procurando contribuir para a construção do conhecimento agroecológico no município (Cardoso e Ferrari, 2006).

Muitos destes estudos na bacia são realizados pontualmente nas propriedades rurais, sendo necessários estudos que ampliem a escala de trabalho, para o entendimento espacial da dinâmica sócio-ambiental em toda a bacia hidrográfica.

Os mapas de uso e cobertura do solo de uma bacia hidrográfica são importantes ferramentas para sua gestão, uma vez que permite aos agricultores a compreensão da paisagem de onde moram. Além disto, a produção de mapas, utilizando Sensoriamento Remoto e participação comunitária possibilita estreitar o diálogo do saber científico e o popular, resgatando e valorizando o conhecimento local.

2. OBJETIVOS

A pesquisa aqui apresentada tem por objetivos gerais avaliar o potencial de classificadores automáticos para o mapeamento do uso e cobertura do solo sob manejo agroecológico, em sistemas agroflorestais (SAF's) com cultivo de café, com intuito de gerar uma metodologia eficiente para distinção de padrões heterogêneos de uso do solo e avaliar a metodologia empregada na construção participativa do mapa de uso e cobertura do solo realizada pelos agricultores da bacia do Rio São Joaquim.

Como objetivos específicos, criar um banco de dados geográfico da bacia hidrográfica, que poderá ser utilizado pelos agricultores para traçar estratégias de gestão territorial e pelos pesquisadores de um modo geral, visto que a bacia é considerada uma unidade geográfica para estudos integrados e interdisciplinares com enfoque agroecológico.

3. REVISÃO DE LITERATURA

3.1. Geoprocessamento e Sistemas de Informações Geográficas

A ciência da geoinformação tem dado suporte a vários setores que tratam de questões ambientais. Os SIGs permitem na análise espacial utilizar vários elementos do meio ambiente de forma integrada, gerando resultados eficientes com rapidez e custo baixo.

Segundo CÂMARA *et al* (2010) o termo geoprocessamento denota a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica e vem influenciando de maneira crescente as áreas de cartografia, análise de recursos naturais, transportes, comunicações, energia e planejamento urbano e regional. As ferramentas computacionais para geoprocessamento, chamadas de Sistemas de Informações Geográficas (SIGs), permitem realizar análises complexas, ao integrar dados de diversas fontes e ao criar bancos de dados georeferenciados.

Na literatura, encontramos variações conceituais sobre SIGs dada a sua característica interdisciplinar, uma vez que existem múltiplos usos para a tecnologia. CÂMARA (1998) define SIGs de uma maneira geral através de suas características:

- Insere e integra, em uma única base de dados, informações espaciais provenientes de dados cartográficos, dados censitários e cadastro urbano e rural, imagens de satélite, redes e modelos numéricos de terreno;
- Oferece mecanismos para combinar as várias informações, através de algoritmos de manipulação e análise, bem como consulta, recuperação, visualização e plotagem do conteúdo da base de dados georeferenciados.

Necessariamente, na estrutura geral de todos os SIGs existem seis componentes distintos como interface, entrada e integração dos dados, consulta e análise espacial, visualização e plotagem, gerência de dados espaciais e banco de dados geográficos.

O Banco de Dados Geográficos (BDG) é o repositório de dados de um SIG, que armazena e recupera dados geográficos em suas diferentes estruturas de dados (imagens,

vetores, grades), bem como as informações descritivas que são os atributos não-espaciais. Deste modo, o BDG permite que novas informações sejam inseridas para complementar aquelas já existentes.

Portanto, os SIGs são hoje considerados uma importante ferramenta de trabalho para diversas áreas do conhecimento e principalmente para análises que integram aspectos econômicos, ambientais e sociais.

3.2. Satélite IKONOS

O satélite IKONOS II foi lançado no dia 24 de setembro de 1999, e está operacional desde o início de janeiro de 2000 (ENGESAT, 2009). O satélite possui uma câmera que registra informações com 1m de resolução na banda pancromática e de 4 metros nas faixas espectrais (vermelho, azul e verde e infravermelho próximo) (LIU, 2006). A Tabela 1 apresenta algumas características da imagem IKONOS II.

Tabela 1 - Características da imagem IKONOS II

Altitude	680 km
Inclinação	98,1°
Velocidade	7km/s
Sentido da órbita	Descendente
Duração da órbita	98 minutos
Tipo de órbita	Sol-síncrona
Ângulo de visada	Rápida alternância entre diferentes ângulos
Resolução espacial	Pancromática: 1m Multiespectral: 4m
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

Fonte: ENGESAT, 2009.

As vantagens e benefícios de aplicações de dados adquiridos pelo satélite IKONOS citadas por LIU (2006) são:

- a) Alta resolução espacial entre as imagens orbitais atualmente disponíveis no mercado;

- b) Possibilidade de fusão das imagens PAN com as imagens multiespectrais para a geração de imagens coloridas com 1 m de resolução;
- c) Grande quantidade de dados disponíveis que facilita a interpretação visual;
- d) Imagens geradas em formato de 11 *bits* (2048 níveis de cinza) aumentam o poder de contraste e discriminação dos dados.

3.3. Sensoriamento Remoto

Sensoriamento Remoto é definido por INPE (2009) como utilização de sensores para aquisição de informações sobre objetos ou fenômenos sem que haja contato direto entre eles.

O sensoriamento remoto baseia-se na medição de energia eletromagnética (EM) que pode assumir diversas formas. A mais importante fonte de EM é o sol. A EM incidente na superfície terrestre reflete ou emite EM em diferentes proporções, e estas diferenças permitem que esses componentes sejam identificados (MATHER, 2004).

De acordo com MORAES (2005) a EM refletida e emitida pelos objetos terrestres resulta das interações entre a energia eletromagnética e estes objetos. Essas interações são determinadas pelas propriedades físicoquímicas e biológicas desses objetos.

O registro das EM dos alvos imageados pelo sensor são armazenados em forma de imagens digitais, as quais são caracterizadas por INPE (2009) como sendo uma função bidimensional, da intensidade de luz refletida ou emitida por uma cena, na forma $I(x,y)$, onde os valores de I representam, a cada coordenada espacial (x,y) , a intensidade da imagem nesse ponto. Essa intensidade é representada por um valor inteiro, não negativo e finito. Cada ponto imageado pelos sensores, corresponde a uma área mínima denominada de “*pixel*” que deve estar geograficamente identificado, e para o qual são registrados os valores digitais relacionados a intensidade de energia refletida em faixas (bandas) bem definidas do espectro eletromagnético.

3.4. Classificação de imagens de satélites

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 análises associadas aos sistemas computacionais (VILELA *et al.*, 2000).

O processo de classificação de imagens é de grande importância na extração de informações de imagens de Sensoriamento Remoto. A classificação das imagens de satélites multiespectrais consiste da associação de cada *pixel* da imagem a um “rótulo” que descreve um objeto real (vegetação, solo, entre outros). Assim, 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 solo, de vegetação, entre outros). 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 suas respectivas classes (CAVASSIM JUNIOR & CENTENO, 2003).

Deste modo, independente se a classificação é supervisionada ou não supervisionada, existem para ambos, regras de decisões para que o classificador associe determinado *pixel* a determinada classe ou regiões de similaridade de níveis de cinza. Tais regiões são baseadas nas características espectrais do *pixel*, ou do *pixel* e seus vizinhos. Quando a regra de decisão toma como base as características somente do *pixel*, a classificação é dita *pixel a pixel*. Caso contrário, é dita por região (MOREIRA, 2005).

3.4.1. Classificação supervisionada

Os métodos de classificação supervisionada baseiam-se no conhecimento *a priori* da área pelo analista, sendo este que define as características espectrais das classes, identificando as amostras de treinamento que são os dados de entrada para que o algoritmo proceda através de estatísticas, a classificação (JANSSEN & GORTE, 2004; MATHER, 2004).

As etapas envolvidas na classificação supervisionada são descritas a seguir por ARAKI (2005):

- a) Definição das classes informacionais. Ex: Pastagem, solo exposto, mata, etc.
- b) Coleta das amostras de treinamento e validação representativas das classes informacionais. Nesta etapa, o conhecimento da área do analista e o trabalho de campo são fundamentais para aquisição de amostras representativas de cada classe.
- c) Extração das estatísticas das amostras de treinamento, como média, desvio padrão, variância, covariância e correlação.
- d) Manipulação das estatísticas das amostras de treinamento. Definição das bandas e classes utilizadas através das assinaturas, ajuste de parâmetros para cada classificador.
- e) Classificação da imagem.
- f) Validação e possível correção
- g) Imagem classificada

3.4.1.1. Classificador de Máxima Verossimilhança

O classificador de Máxima Verossimilhança (MaxVer) é o método de classificação supervisionada mais usado no processo de identificação e delineamento das classes (LIU, 2006).

O algoritmo utiliza a média e a covariância das amostras de treinamento. Dados estes parâmetros, pode ser computada a probabilidade estatística de um *pixel* desconhecido pertencer a uma classe 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 à classe cuja probabilidade tenha sido a mais alta, ou a nenhuma delas no caso de os valores de probabilidade estarem abaixo de um determinado valor estipulado pelo analista (LIU, 2006).

A função de densidade de probabilidade é dada pela Equação 1:

Equação 1

$$P_c = [-0,5 \log(\text{Det}(\mathbf{V}_c))] - [-0,5(\mathbf{X} - \mathbf{M}_c)\mathbf{T}(\mathbf{V}_c) - (\mathbf{X} - \mathbf{M}_c)]$$

Onde:

P_c = probabilidade do vetor \mathbf{X} ser assinalado na classe c ;

\mathbf{X} = vetor de medidas dos *pixels* desconhecidos;

\mathbf{V}_c = matriz de covariância da classe c contemplando todas as bandas (K, \dots, L);

$\text{Det}(\mathbf{V}_c)$ = determinante da matriz de covariância \mathbf{V}_c ;

\mathbf{M}_c = vetor das médias para cada classe c ; e

\mathbf{T} = matriz transposta.

3.4.1.2. Classificação por de Redes Neurais Artificiais

As redes neurais artificiais são modelos matemáticos inspirados no sistema nervoso biológico. Aprendem pela experiência, generalizam exemplos através de outros e abstraem características (DREYFUS, 2005).

De acordo com RIBEIRO *et al.*, (2005), uma Rede Neural Artificial (RNA) 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 ou calibração 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

A Figura 1 apresenta uma rede neural multicamadas, onde os dados de entrada são as bandas da imagem e a camada de saída a imagem classificada.




Figura 1 - Rede Neural Artificial multicamadas (Fonte: NUNES & PINHEIRO, 2007).

O algoritmo *Error Backpropagation* é aplicado de forma supervisionada e, segundo VIEIRA (2000) minimiza uma função de erro interagindo os dados de saída da rede com conjuntos de saídas desejadas, treinadas com base em uma seleção de dados amostrais. O processo continua até o erro convergir para um nível baixo e aceitável. A função de erro é apresentada na Equação 2:

Equação 2

$$E = \frac{1}{2} \sum (T_i - O_i)^2$$

Onde:

T_i = vetor de saídas desejadas para o conjunto de treinamento i ;

O_i = vetor de saída da rede para o conjunto de treinamento dado.

3.4.1.3. Classificação por região

A classificação por região é um método alternativo, e que diferentemente da classificação por *pixel*, provê um meio, dentro do qual a variabilidade espacial e a textura natural podem ser usadas no processo de classificação. Ao invés de considerar as características espectrais de um determinado *pixel* no processo de decisão, um agrupamento de *pixels* é selecionado e usado como unidade de classificação. Os classificadores por região utilizam como critério de decisão, a informação espectral de cada *pixel* da imagem e a informação espacial que envolve agrupamentos de *pixels*. Estes classificadores procuram simular o comportamento de um fotointérprete, ao

reconhecer áreas homogêneas nos dados orbitais, baseados nas propriedades espectrais e espaciais dessas áreas na imagem. A informação de borda é utilizada inicialmente para separar regiões e as propriedades espaciais e espectrais agrupam áreas com mesma textura (KURY & VIEIRA, 2002)

A classificação por região inicia-se a partir da segmentação da imagem. Neste processo, divide-se a imagem em regiões que devem corresponder às áreas de interesse da aplicação. Entende-se por regiões um conjunto de "*pixels*" contíguos, que se espalham bidirecionalmente e que apresentam uniformidade. A divisão em porções consiste basicamente em um processo de crescimento de regiões, de detecção de bordas ou de detecção de bacias (INPE, 2009).

O crescimento de regiões é uma técnica de agrupamento de dados, na qual somente as regiões adjacentes, espacialmente, podem ser agrupadas. Inicialmente, este processo de segmentação rotula cada "*pixel*" como uma região distinta. Calcula-se um critério de similaridade para cada par de região adjacente espacialmente. O critério de similaridade baseia-se em um teste de hipótese estatístico que testa a média entre as regiões. A seguir, divide-se a imagem em um conjunto de sub-imagens e então realiza-se a união entre elas, segundo um limiar de agregação definido.

O Bhattacharya utiliza a medida da distância de Bhattacharya para medir a separabilidade estatística entre um par de classes espectrais. Ela mede a distância média entre as distribuições de probabilidades de classes espectrais, ao contrário do Ioseg que é automático, requer uma etapa de treinamento, sendo um método de classificação supervisionada.

3.4.2. Classificação não supervisionada

De modo distinto da classificação supervisionada, a classificação não supervisionada não utiliza amostras de treinamento para classificação. Deste modo, o analista pouco e nada tem conhecimento *a priori* do local para coletar suas amostras. Os algoritmos utilizados para este tipo de classificação examinam *pixels* desconhecidos na imagem e os agregam a partir de suas características espectrais, de acordo com a estatística escolhida. No passo final, cabe ao analista identificar os agrupamentos de *pixels* e relacioná-los a cada classe (VANACÔR, 2006).

A principal vantagem deste método de classificação ao realizar agrupamento (*cluster*), permite que o analista consiga previamente definir a quantidade de classes que podem ser utilizadas em uma classificação supervisionada.

3.4.2.1. Classificador Iseseg/Isodata

Dentre os algoritmos de classificação não supervisionada, o método Iseseg ou Isodata é um dos mais utilizados. Ele procura agrupar regiões a partir de atributos estatísticos de média, matriz de covariância e área a partir de uma medida de similaridade entre elas, a partir da distância Mahalanobis entre a classe e as regiões candidatas a relação de pertinência com esta classe (KÖRTING, 2006).

A distância de Mahalanobis é representada pela Equação 3:

Equação 3

$$D = \frac{1}{2}(\mathbf{X} - \mathbf{m}_i)^T \mathbf{C}_i^{-1} (\mathbf{X} - \mathbf{m}_j)$$

Onde:

D = distância de Mahalanobis;

T = matriz transposta;

C_i = matriz de covariância;

m_i e m_j = vetor de média das classes i e j ;

X = região de análise

As etapas de agrupamentos de dados não supervisionados pelo Iseseg são descritas por MOREIRA (2003):

1- Definição do limiar: o usuário define um limiar de aceitação, dado em porcentagem. Este limiar por sua vez define uma distância de Mahalanobis, de forma que todas as regiões pertencentes a uma dada classe estejam distantes da classe por uma distância inferior a esta. Quanto maior o limiar, maior esta distância e, conseqüentemente, maior será o número de classes detectadas pelo algoritmo.

2- Detecção das classes: nesta fase, as regiões são ordenadas em ordem decrescente de área e inicia-se o procedimento para agrupá-las em classes. Serão tomados como parâmetros estatísticos de uma classe (média e matriz de covariância) os parâmetros estatísticos da região de maior área que ainda não tenha sido associada à classe alguma. Em seguida, associam-se a esta classe todas as regiões cuja distância de Mahalanobis for inferior à distância definida pelo limiar de aceitação.

3- Competição entre classes: as regiões são reclassificadas, considerando-se os novos parâmetros estatísticos das classes, definidos na etapa anterior. O parâmetro estatístico (média de cada classe) é então recalculado. O processo repete-se até que a média das classes não se altere (convergência).

Ao final deste processo, o analista com seu conhecimento define a cada classe um tema, tornando desta forma, um mapa temático.

3.4.3. Avaliação das classificações

Para avaliar a classificação, o mapa temático gerado e o mapa de referência são tabulados em forma de matriz de contingência $m \times m$ (Tabela 2), que é conhecida por matriz de erros ou de confusão, onde m é o número de classes. As linhas na matriz são as classes derivadas do mapa de referência e as colunas são as classes geradas pela classificação.

Um exemplo da matriz de erros genérica de acordo com COLGATON & GREEN (2008) é dada pela Tabela 2:

Tabela 2 - Matriz de erros genérica

Imagem de referência ($i =$ linhas)	Imagem classificada ou temática ($j =$ colunas)			
		1	2	k
1	n_{11}	n_{12}	n_{1k}	n_{1+}
2	n_{21}	n_{22}	n_{2k}	n_{2+}
k	n_{k1}	n_{k2}	n_{kk}	n_{3+}
Total coluna n_{+j}	$n + 1$	$n + 2$	$n + k$	n

A partir da matriz de erros, pode ser gerado o Índice de Exatidão Global que indica o número de *pixels* corretamente classificados dividido pelo número total de *pixels* da imagem de referência.

O exame da matriz de erros revela, para cada categoria, erros de omissão e de comissão. Erros de omissão podem ser descritos como a omissão no mapa de uma determinada feição constatada em campo, e, erros de comissão são descritos como atribuição no mapa de determinada feição a uma classe a qual a mesma não pertence, segundo levantamento de campo (CAMPBELL, 1987).

O Índice Kappa que revela-nos a exatidão da imagem classificada, sendo utilizado para sua obtenção o Índice de Exatidão Global e o valor esperado calculado usando as marginais da matriz de erros, como demonstrado na Equação 4.

Equação 4

$$\text{Índice Kappa(K)} = \frac{\text{valor observado} - \text{valor esperado}}{1 - \text{valor esperado}}$$

Onde:

Valor observado = Índice de Exatidão Global;

Valor esperado = valor calculado usando as marginais da matriz de erros.

De acordo com CONGALTON (1991) o uso do Índice Kappa (K) é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, por exemplo, que utiliza somente os elementos diagonais (concordância real).

Após este processo, os valores dos índices obtidos de cada imagem classificada serão analisados para averiguar o desempenho de cada classificador na classificação do uso do solo em ambientes com sistemas agroecológicos e convencionais.

O Índice Kappa é dividido por intervalos de valores conforme nível de aceitação, como indicado por GALPARSORO & FERNÁNDEZ (1999):

Tabela 3 - Intervalos de aceitação dos resultados do Índice Kappa

$K \leq 0,2$	Péssimo
$0,2 \leq K \leq 0,4$	Razoável
$0,4 \leq K \leq 0,6$	Bom
$0,6 \leq K \leq 0,8$	Muito bom
$0,8 \leq K \leq 1,0$	Excelente

3.4.4. Classificação automática da imagem IKONOS

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 (MOREIRA, 2005).

Os algoritmos tradicionalmente usados no processo de classificação consideram normalmente que as classes são linearmente separáveis e utilizam como unidade de medida o *pixel*. Porém, com o aumento da resolução espacial e espectral das imagens produzidas por esta nova série de sensores, existe um aumento na variação interna das classes (objetos), e conseqüentemente uma sobreposição das classes no espaço característico, inviabilizando o uso destes procedimentos padrões (KURY & VIEIRA, 2002).

Muitas pesquisas vêm avaliando diferentes algoritmos de classificação para uso do solo em imagem IKONOS, através de classificação *pixel a pixel*, Redes Neurais Artificiais e por região, demonstrando resultados satisfatórios para superação da dificuldade de classificação de imagens de alta resolução.

A pesquisa desenvolvida por DANIEL *et al* (2008) apresenta dados de uma classificação da imagem IKONOS, bandas 1, 2 e 3, para elaboração de um mapa de uso e ocupação do solo de um assentamento no Mato Grosso do Sul. Neste trabalho, foram realizados dois tipos de classificação da imagem, uma classificação *pixel a pixel* pelo algoritmo da Máxima Verossimilhança (MaxVer), com área mínima mapeável de 0,5 ha e interpretação visual através de vetorização dos polígonos das classes de uso do solo. Como resultado, método *pixel a pixel* gerou uma grande confusão e sobreposição das classes analisadas devido ao grande nível de detalhamento da imagem, enquanto a classificação visual obteve os melhores resultados.

O trabalho realizado por MOREIRA *et al* (2009) avaliou diferentes classificadores automáticos, como MaxVer, RNA, Bhattacharya e Iseseg para classificação do uso e cobertura do solo em uma bacia hidrográfica. As principais classes encontradas na área de estudo foram a cobertura florestal, agricultura, pastagem, área urbana e hidrografia. Os resultados encontrados demonstraram que o algoritmo que obteve melhores resultados foi o Bhattacharya com índice Kappa de (0,76), seguido do RNA (0,63), MaxVer (0,534) e Iseseg (0,509).

O trabalho de RIBEIRO *et al* (2005) avaliou diferentes métodos de classificação automática da imagem IKONOS, bandas azul, verde, vermelho e infravermelho próximo para mapeamento do uso do solo, realizados *pixel a pixel* e por regiões. A área em estudo apresenta muita diversificação de uso, com 15 classes informacionais: mata ciliar, milho, cerrado, braquiária, restos culturais, campo pedregoso, pasto, solo exposto, campo limpo/sujo, rio, café maduro, café jovem, reforma de café, rodovia e ferrovia. Foram utilizados os algoritmos da mínima distância, através do *software* Funcpow, o da MaxVer por meio do MAXLIKE e RNA (*Error Backpropagation*) para classificação. Para cada algoritmo, foi utilizada a classificação *pixel a pixel* e por regiões, que geram um total de seis análises. Os melhores resultados alcançados foram pelos algoritmos da MaxVer (0,824) e *Error Backpropagation* (0,824), ambos por regiões. Como os dois métodos não apresentaram estatisticamente diferenças, os autores recomendam o uso do MaxVer por apresentar menor esforço computacional, maior rapidez no processo e estar presente em muitos softwares de sensoriamento remoto.

MENDONÇA (2006) avaliou seis algoritmos para classificar uma imagem IKONOS, sendo três por *pixel a pixel* e três por regiões, MaxVer, Distância Mínima Euclidiana, RNA, Bhattacharya, Iseseg e Histograma, respectivamente. Ao analisar os resultados, o mesmo autor concluiu que os algoritmos por *pixels* apresentaram valores de Índice Kappa razoáveis e os algoritmos por regiões resultados excelentes, sendo o Iseseg o que apresentou os melhores resultados (0,87) seguido do Histograma (0,83) e Bhattacharya (0,82).

A pesquisa desenvolvida por CAVASSIM & CENTENO (2003) demonstra como nos outros trabalhos citados anteriormente, melhores resultados na classificação de uma imagem IKONOS através de classificação baseada em regiões, quando comparado ao método *pixel a pixel* utilizando MaxVer. A imagem classificada *pixel a*

pixel apresentou menor Índice Kappa além de apresentar ruídos na imagem classificada. Já a imagem classificada por região, as classes ficaram mais homogêneas.

Estes trabalhos ilustram bem o quadro da busca por novos processos de classificação de imagens de alta resolução, e mesmo não sendo utilizados em áreas sob manejo agroecológico, indicam que o melhor caminho para classificação em geral sejam pelo método por regiões.

3.4.5. Mapeamento Participativo

O debate atual da participação comunitária e Sistemas de Informações Geográficas vêm alcançando expressivas contribuições teóricas e metodológicas sobre a temática. Diversos trabalhos demonstram o potencial que a ferramenta da geoinformação possui para contribuir com a ruptura do seu uso antidemocrático e excludente (CARTON, 2002; SLETTTO, 2002; TRUNG *et al*, 2004).

De acordo com WEINER *et al* (2002), os Sistemas de Informação Geográfica estão sendo integrados nas comunidades para servir muitos propósitos e com vários graus de eficácia, ajudando a desenvolver suas próprias estratégias espaciais e políticas.

O Estabelecimento da relação entre o saber científico e o conhecimento tradicional é um desafio fundamental, pois é condição *sine qua non*, para que se possam obter bons resultados em um planejamento que venha a envolver povos tradicionais (ATAIDE & MARTINS, 2009).

Na literatura nacional encontramos muitos trabalhos desenvolvimento metodologias através da etnocartografia, como o caso dos trabalhos de ATAIDE & MARTINS (2009); CARVALHO (2006) e ALMEIDA (2006) agregando conhecimento científico e popular dos povos indígenas da Amazônia brasileira.

4. METODOLOGIA

4.1. Caracterização geral do município Araponga

O município de Araponga localiza-se na mesorregião da Zona da Mata Mineira, no Domínio pedobioclimático dos Mares de Morros Florestados (AB'SABER, 1970). A vegetação primária predominantemente é de floresta subperenifólia. A região é embasada tipicamente de rochas gnáissico-graníticas e o relevo é bastante acidentado (RESENDE, 1996).

A classe de solos predominante é o Latossolo Vermelho Amarelo, caracterizado como solos muito intemperizados, distróficos, profundos e de boa drenagem. Possuem grande homogeneidade de características ao longo do perfil, mineralogia da fração argila predominantemente caulinítica ou caulinítica-oxídica, que se reflete em valores de relação Ki baixos inferiores a 2.2, e praticamente ausência de minerais primários de fácil intemperização. A relação Ki indica a relação molecular de $\text{SiO}_2/\text{Al}_2\text{O}_3$ da fração argila do solo. (IBGE, 2007; CURI *et al*, 2003).

A temperatura média da região é de 18°C, precipitação anual variando de 1.200 a 1.800 mm, com período seco de 2 a 4 meses entre junho e setembro. Em função da pluviosidade e também do profundo manto de alteração (maior armazenamento de água), o relevo que foi intensamente dissecado favorece a predominância de pequenos cursos de água.

De acordo com IBGE no ano de 2007, o município possuía 8.029 habitantes distribuídos em 309 km².

Na área rural do município, a situação fundiária é bem característica da Zona da Mata mineira, prevalecendo pequenas propriedades que se desenvolvem em sua maioria, na produção familiar de subsistência e produção de café.

4.2. A área de estudo – Bacia do Rio São Joaquim

A área de estudo deste trabalho é a bacia do Rio São Joaquim, um recorte espacial de Araponga, com aproximadamente 1.089 hectares, possuindo características fisiográficas comuns ao município, mencionadas anteriormente.

A bacia do Rio São Joaquim é composta, na sua grande maioria, por pequenas propriedades rurais, condição esta propícia para a agricultura familiar. Nelas, o principal cultivo é o café. Nas propriedades com manejo agroecológico, os SAF's garantem além do café, outros produtos que são vendidos no comércio local ou para subsistência, decorrentes da consorciação de espécies.

Algumas propriedades há cerca de 20 anos vem adotando princípios agroecológicos no cultivo de café. Existem SAFs de diferentes idades com variadas espécies, sendo a principal uma espécie não lenhosa, a bananeira (*Musa spp.*).

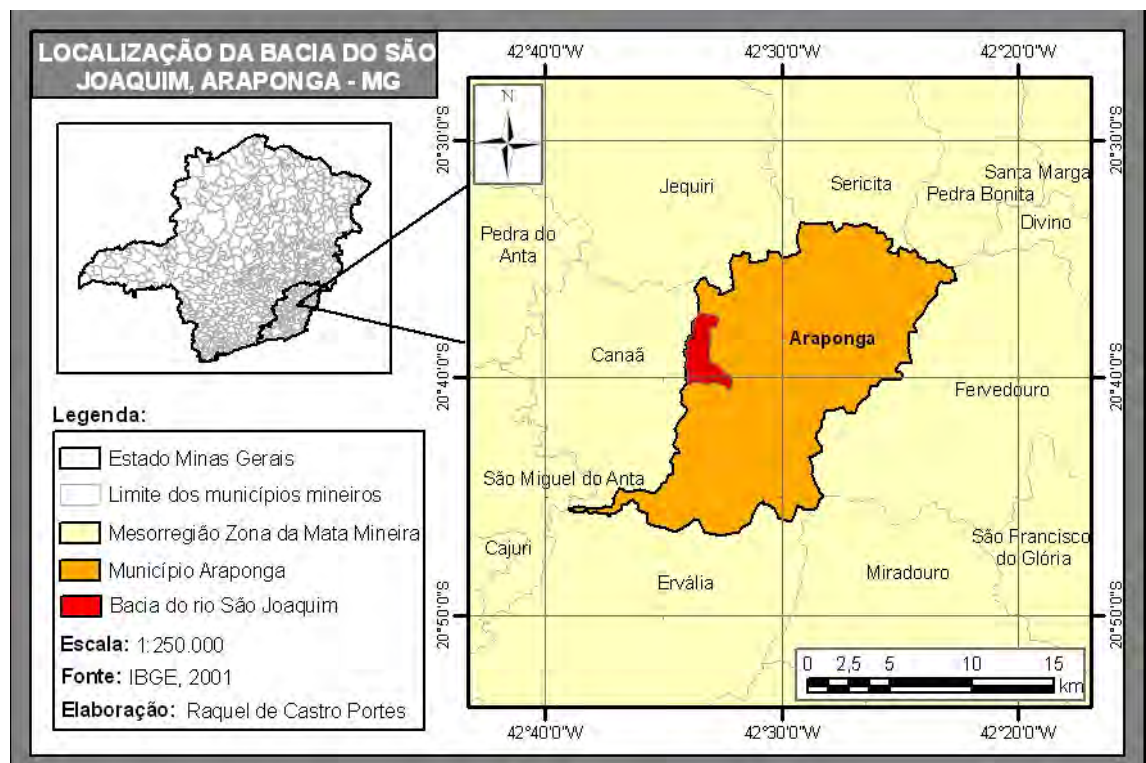


Figura 2 – Mapa de localização da bacia do Rio São Joaquim, município Araponga – MG.

4.3. Base de dados e equipamentos

- Imagem IKONOS de 04 de agosto de 2009, bandas azul, verde, vermelha e infravermelho próximo, com 4 metros de resolução espacial;
- Carta planialtimétrica, escala 1:50.000, folha São Miguel do Anta (SF-23-X-B-V-2), IBGE, 1999:
 - Curvas de nível com equidistância de 20m;

Para o processamento das informações e classificação da imagem foram utilizados o *software* ArcGis 9.3 Arc Info (ESRI, 2007), IDRISI Andes e Spring 5.1.

- Sistema de Posicionamento Global - GPS Garmim Etrex Vista HCX.
- Mesa digitalizadora.

4.4. Procedimentos metodológicos

A primeira etapa do trabalho consistiu em corrigir a imagem IKONOS II, que continha um deslocamento espacial de aproximadamente 200 metros. Assim, foi necessário realizar coleta a campo de Pontos de Controle Terrestre (PCTs) via GPS para posterior Georreferenciamento no software ArcGis 9.3.

Os padrões das classes de uso e cobertura do solo foram coletadas via GPS, que serviram de dados de entrada para vetorização no SIG das amostras de treinamento e validação.

Devido a grande quantidade de amostras para treinamento nas classificações, foi necessário realizar classificação não supervisionada, através do Iseseg para diminuir o número de amostras e facilitar o processo.

A próxima etapa procederam-se as classificações supervisionadas através dos algoritmos MaxVer, RNAs e Bhattacharya, com amostras de 14 e 17 classes de uso e cobertura do solo e posterior validação para cada classificação, com as amostras de validação.

O último passo foi a identificação do uso e cobertura do solo pela comunidade da bacia, onde foram identificadas as classes e o manejo de cada propriedade, sendo agroecológicas, em fase de transição ou convencionais.

A Figura 3 ilustra os passos dos procedimentos metodológicos adotados nesta pesquisa.

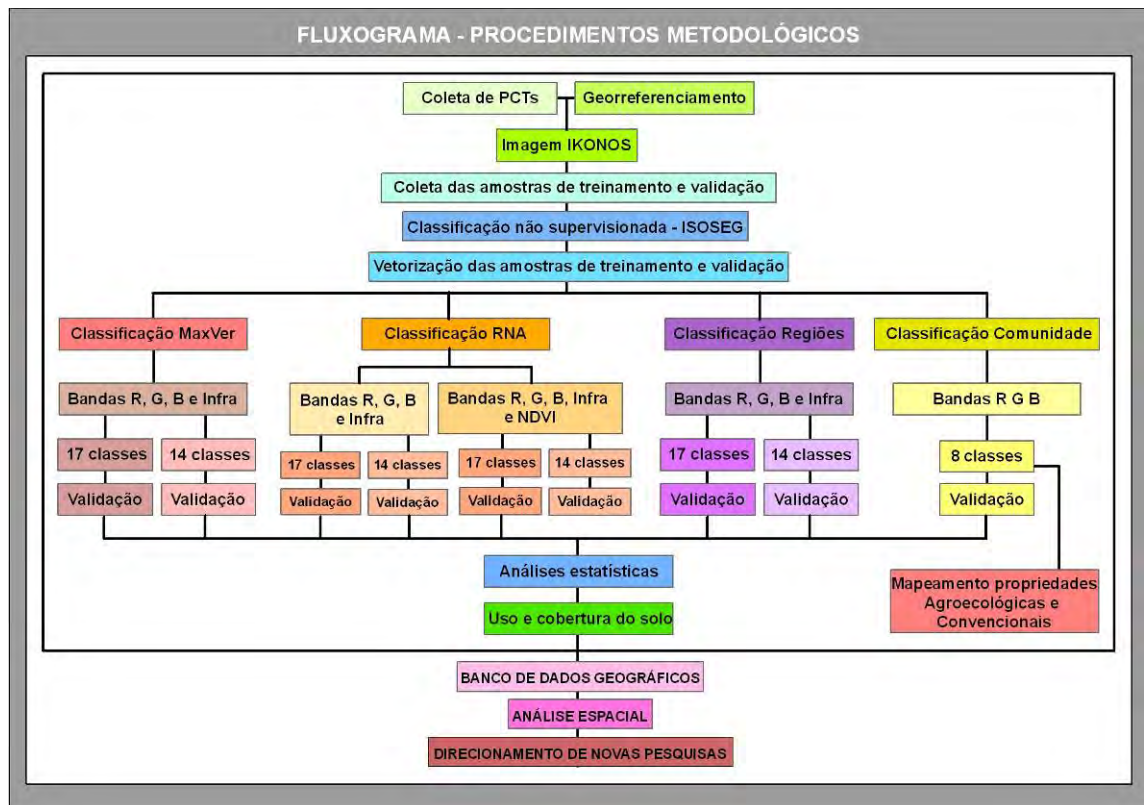


Figura 3 - Fluxograma dos procedimentos metodológicos.

4.4.1. Coleta de Pontos de Controle Terrestre

A imagem IKONOS II continha um deslocamento espacial de aproximadamente 200 metros, e deste modo foi necessário realizar sua correção geométrica. Para isto, Pontos de Controle Terrestre (PCTs) com coordenadas X e Y foram coletados ao longo da bacia via GPS, em lugares estratégicos que possibilitassem sua visualização na imagem para proceder o georreferenciamento. O modelo de GPS possibilitou a coleta dos PCTs com deslocamento variando de 3 a 4 metros. Foram coletados 76 PTCs, como demonstra a Figura 4.

4.4.2. Georreferenciamento

Foram inseridos no *software* ArcGis 9.3 os PCTs onde foi realizada a correção. O georreferenciamento consistiu em interpolar espacialmente os PCTs com a imagem e inter relacioná-los através de regressão dos mínimos quadrados que determinaram os coeficientes para a equação de transformação. A equação utilizada no processo foi a polinomial de 1º grau (linear).

O erro médio quadrático (RMS) (Equação 5) permitiu a visualização da exatidão de cada PCT, (de acordo com a equação polinomial) apresentando o RMS de cada um e a soma de todos os erros (RMS total).

A obtenção RMS pela seguinte equação:

Equação 5

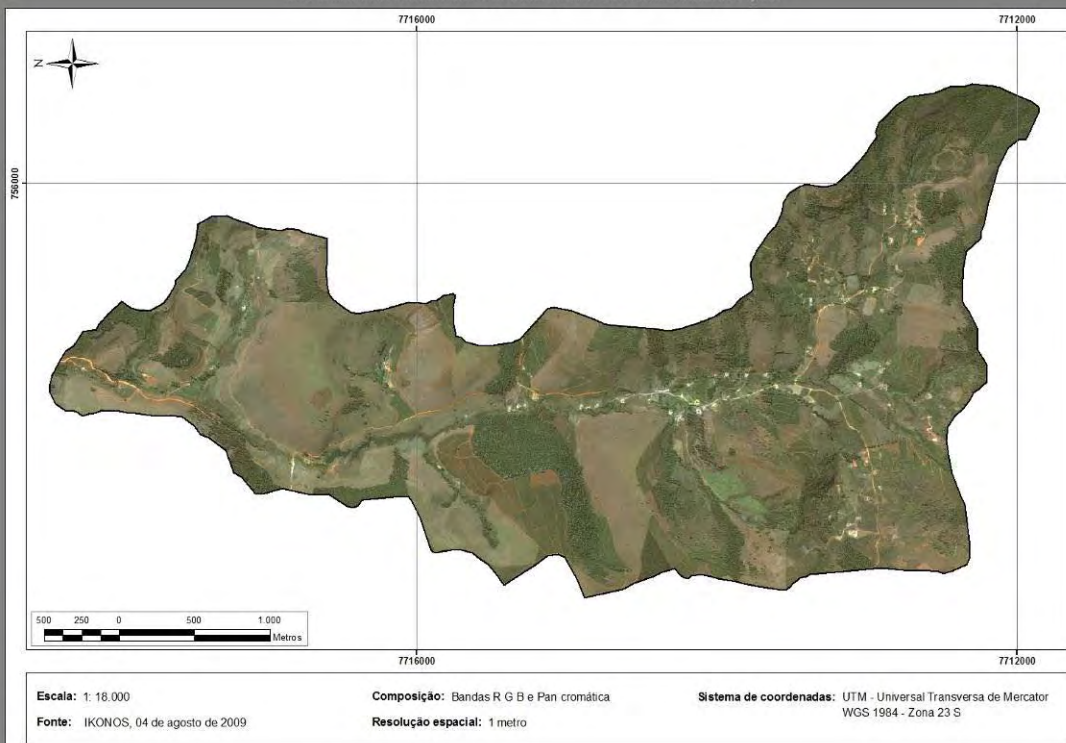
$$\text{RMS} = \sqrt{\frac{(\mathbf{X}_F - \mathbf{X}_{i\text{GPS}})^2 + (\mathbf{Y}_F - \mathbf{Y}_{i\text{GPS}})^2}{\mathbf{n}}}$$

Onde:

\mathbf{X}_F e \mathbf{Y}_F = Coordenadas da imagem original

$\mathbf{X}_{i\text{GPS}}$ e $\mathbf{Y}_{i\text{GPS}}$ = Coordenadas dos PCTs

IMAGEM IKONOS DA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG



Escala: 1: 18.000

Fonte: IKONOS, 04 de agosto de 2009

Composição: Bandas R G B e Pan cromática

Resolução espacial: 1 metro

Sistema de coordenadas: UTM - Universal Transversa de Mercator
WGS 1984 - Zona 23 S

4.4.3. Delimitação da bacia hidrográfica

Para obtenção do limite da bacia foi necessário, em primeiro momento, extrair as curvas de nível com equidistância de 20 metros da carta planialtimétrica da folha São Miguel do Anta (SF-23-X-B-V-2) do IBGE do ano de 1999, em formato digital. As curvas de nível não possuíam informação de sua altitude. Deste modo, elas passaram pelo processo de cotação, na qual cada curva de nível obteve seu valor Z. O próximo passo realizado foi geração do modelo digital de elevação (MDE), com células de 4 metros, através da extensão *Spatial Analyst* com a ferramenta *Topo to raster*, do ArcGis 9.3. O arquivo do MDE serviu como fonte para o delineamento do limite da bacia, sendo utilizada a ferramenta *Hidrology* da mesma extensão que gerou o MDE.

4.4.4. Coleta das amostras de treinamento e validação

A coleta das amostras de treinamento e validação foi realizada em campo, com apoio do GPS, onde foi percorrida toda extensão da bacia para detecção dos diferentes usos e cobertura do solo. Foram detectadas 40 classes de uso e cobertura do solo, como demonstra a Tabela 4.

4.4.5. Classificação não supervisionada – Isoseg

O número de classes de uso e cobertura do solo detectadas em campo foi muito elevado e a utilização de todas no processo de classificação automática implicaria no maior esforço dos classificadores e conseqüentemente geraria maior confusão. Deste modo, as bandas 1 2 3 e infravermelho próximo da imagem foram importadas para o *software* IDRISI Andes e passou por uma classificação não supervisionada Isoseg. O objetivo desta etapa foi realizar o agrupamento das classes que possuem características espectrais semelhantes para diminuir o número total de classes de uso e cobertura do solo.

Tabela 4 - Chave de interpretação de uso e cobertura do solo coletados na bacia.






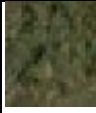
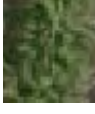
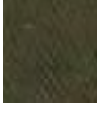
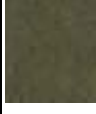
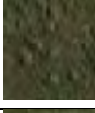
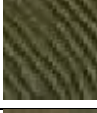
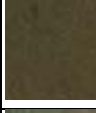


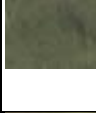
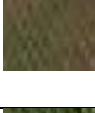

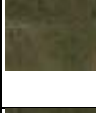
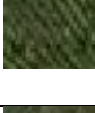
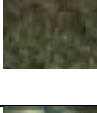


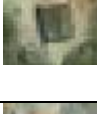
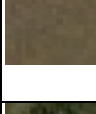

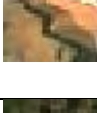
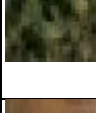
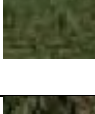
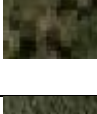
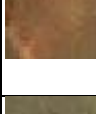
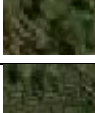



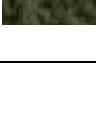
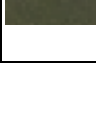


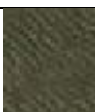

Nº Classe	Descrição	Nº Classe	Descrição	Nº Classe	Descrição
1	 Afloramento de rocha	15	 Café jovem com milho	29	 Pastagem com braquiária
2	 Água – barraginha	16	 Café pequeno	30	 Pastagem com capim gordura seco e capoeira
3	 Bambuzal	17	 Café pequeno com milho	31	 Pastagem com capim gordura e sapê
4	 Café abandonado que virou capoeira	18	 Café podado – linha sim e linha não	32	 Pastagem com capim gordura seco
	 Café adulto	19	 Café recepado	33	 Pastagem com capim gordura, rabo de burro e sapê
6	 Café adulto bem desfolhado	20	 Cana	34	 Pastagem com rabo de burro
7	 Café adulto com banana, cana e mamão	21	 Cana queimada	35	 Pastagem com rabo de burro no brejo
8	 Café com banana	22	 Casa e terreiro	36	 Pastagem com sapê
9	 Café com banana e mamão	23	 Construção	37	 Pomar
10	 Café com mamona	24	 Eucalipto adulto	38	 Solo exposto
11	 Café adulto com banana, eretrina, ingá e acabate	25	 Eucalipto adulto modelo + novo	39	 Solo exposto arado
12	 Café com ingá e mamão	26	 Mata	40	 Taboa

Tabela 4 (Cont.) - Chave de interpretação de uso e cobertura do solo coletados na bacia.

Nº	Classe	Descrição	Nº	Classe	Descrição	Nº	Classe	Descrição
13		Café esqueletado	27		Milharal seco			
14		Café jovem	28		Pastagem arada com mentrasto e picão			

4.4.6. Vetorização das amostras de treinamento e validação

Realizado o processo de agrupamento, foram definidas 17 classes. No *software* ArcGis 9.3 foram criadas dois arquivos, um para as amostras de treinamento e outro para as amostras de validação, ambos com 17 classes. O montante das amostras foi separado em duas partes, e iniciou-se a vetorização das amostras de treinamento e posteriormente de validação. As amostras não se sobreporam no espaço, sendo vetorizadas em áreas distintas (Figuras Figura 5 e Figura 6, respectivamente). O número de amostras vetorizadas em polígonos seguiu o critério de ocorrência na bacia e distribuição espacial. No geral coletou-se 6 amostras de treinamento e validação para cada padrão. Entretanto, algumas classes como pouca representatividade em área, o número de amostras foi menor. No caso da pastagem, foram coletadas mais amostras (15) devido à grande variedade que ela apresentava.

A Tabela 5 demonstra a quantidade de amostras de treinamento e validação para cada classe de uso e cobertura do solo.

Tabela 5 - Quantidade de amostras de treinamento e amostras de validação.

ID	Classe	N° amostras de treinamento	N° amostras de validação
1	Mata	6	6
2	Café solteiro adulto	6	6
3	Café solteiro jovem	6	6
4	Café pequeno	6	6
5	Eucalipto adulto	4	4
6	Eucalipto jovem	3	3
7	Solo exposto	6	6
8	Capoeira	4	4
9	Milharal	6	6
10	Cana	6	6
11	Cana queimada	2	2
12	Água	6	6
13	Taboa	6	6
14	Sombra	6	6
15	Afloramento de rocha	3	3
16	Pastagem	15	15
17	Café com árvore - SAF	6	6
Total		97	97

IMAGEM IKONOS DA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG COM AS AMOSTRAS DE TREINAMENTO

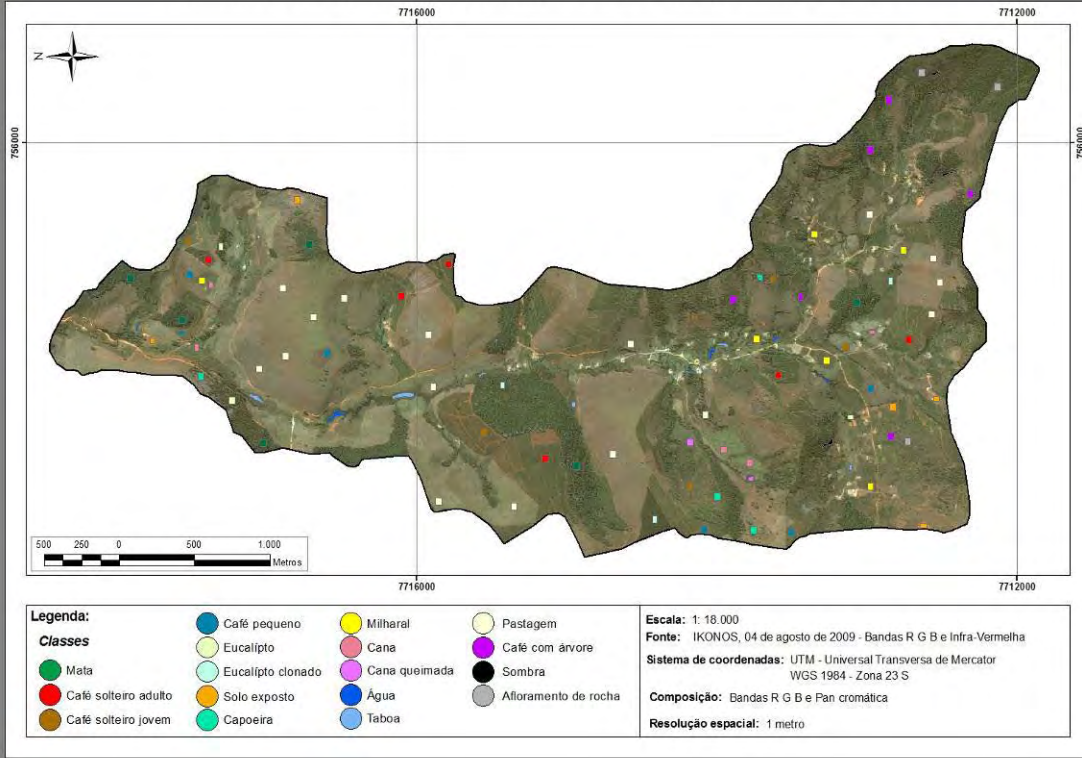
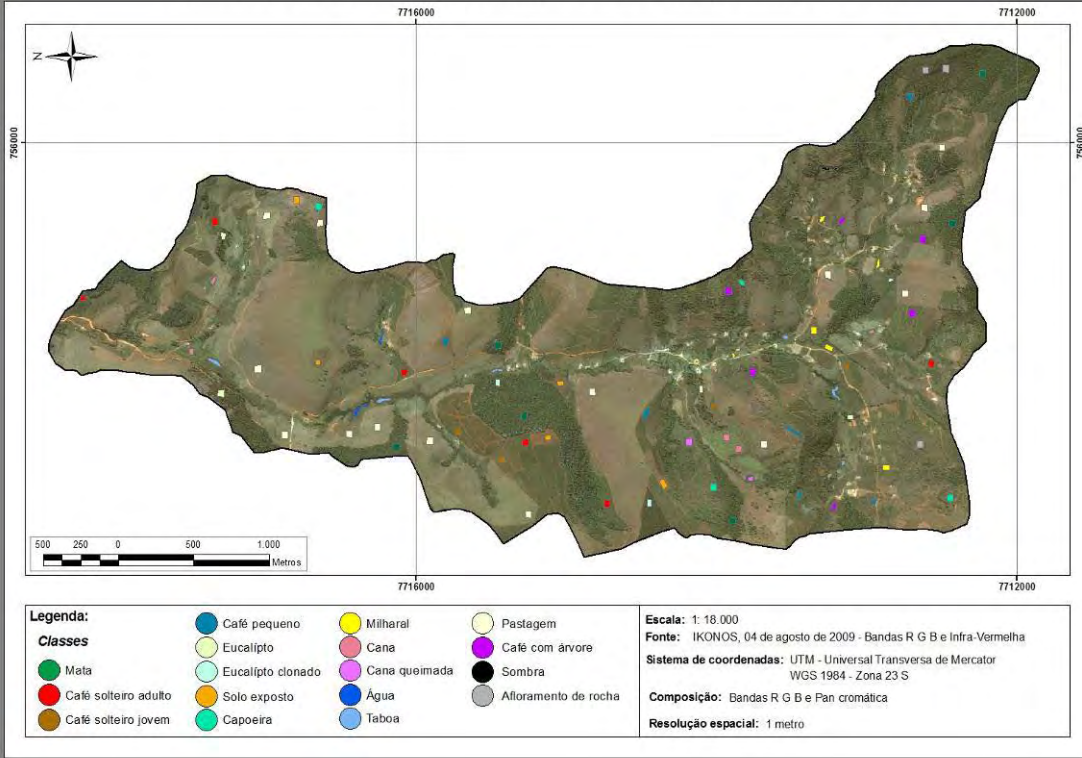


IMAGEM IKONOS DA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG COM AS AMOSTRAS DE AVALIAÇÃO



4.4.7. Classificação supervisionada da imagem IKONOS II

4.4.7.1. Classificação *pixel a pixel* por Máxima Verossimilhança

As amostras de treinamento e as bandas 1 2 3 e Infravermelho próximo foram importadas para o *software* IDRISI Andes para geração do arquivo de assinaturas para cada classe de uso e cobertura do solo, no módulo MAKESIG. Neste processo, foi calculada a média e a covariância dos *pixels* de cada polígono das amostras de treinamento. O passo seguinte foi feito no módulo MAXLIKE, utilizando as assinaturas para a classificação MaxVer. Dados estes parâmetros de entrada, foi computado a probabilidade de cada *pixel* pertencer a uma classe ou outra. Foi adotada a equiprobabilidade para cada assinatura (Figura 7).

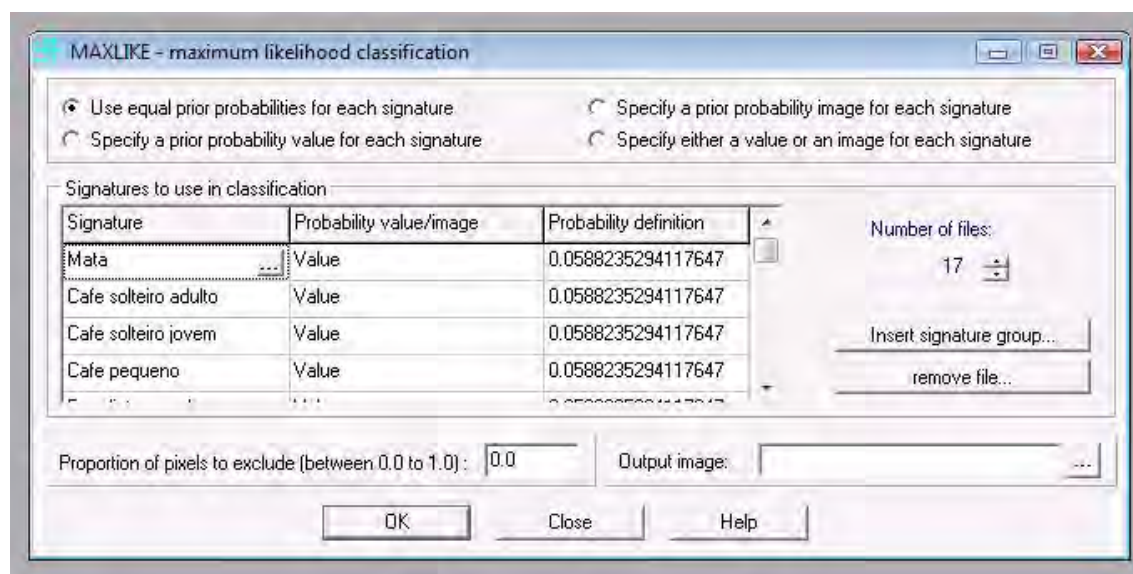


Figura 4 – Módulo MAXLIKE do IDRISI Andes.

Após realização da classificação, utilizou-se o arquivo com as amostras de validação para avaliação da imagem classificada. A matriz de erros gerada foi analisada através dos erros de omissão e comissão de cada classe estudada, sendo realizado um novo agrupamento de classes a fim de diminuir as confusões dos classificadores e obter

melhor resultado. Portanto, foi criado um arquivo com 14 classes de amostras de treinamento e outro arquivo com 14 classes de amostras de validação.

O novo arquivo com as 14 classes de amostras de treinamento juntamente com as bandas 1 2 3 e infravermelho próximo serviram com os dados de entrada para geração de um arquivo de assinaturas para a classificação MaxVer. Nesta nova classificação, usou-se mais uma vez a equiprobabilidade para cada assinatura.

4.4.7.2. Classificação *pixel a pixel* por Redes Neurais Artificiais - *Error Backpropagation*

A classificação por RNA ocorreu no *software* IDRISI Andes, com o módulo *Multi-Layer-Peceptor* (MLP) que utiliza o algoritmo *Error Backpropagation* para treinamento e posterior classificação (Figura 8).

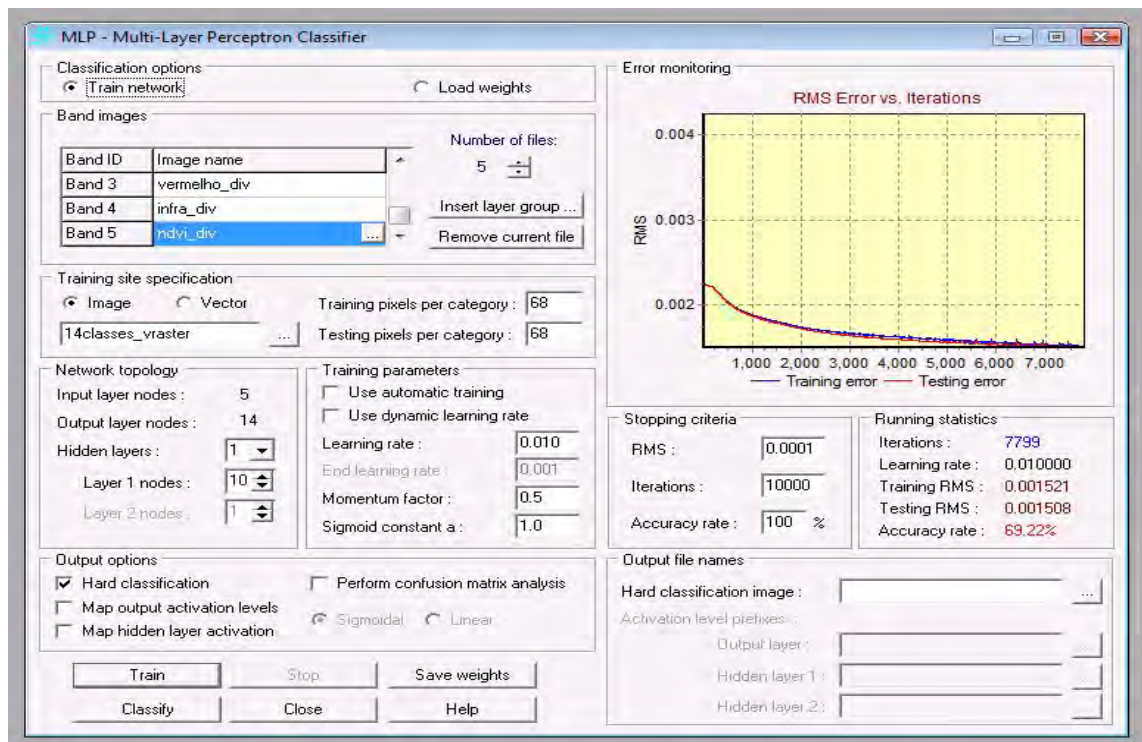


Figura 8 – Módulo MLP do IDRISI Andes.

Para o treinamento das RNAs, foram feitas duas combinações de bandas. A combinação 1 com as bandas 1 2 3 e infravermelho próximo e a combinação 2 com as bandas 1 2 3 e infravermelho próximo e o Índice de Vegetação da Diferença Normalizada (NDVI). O NDVI foi utilizado para verificar se ele influenciaria na melhoria da discriminação dos alvos vegetais da cena. A Equação 6 para obtenção do NDVI é descrita a seguir:

Equação 6

$$\text{NDVI} = \frac{\text{Infravermelho próximo} - \text{vermelha}}{\text{Infravermelho próximo} + \text{vermelha}}$$

Onde:

Infravermelho próximo = banda 1

Vermelha = banda 3

Com estas duas combinações, foram montadas diferentes arquiteturas para as RNAs, que variaram de 10; 15; 20; 25; 30 e 35 o número de neurônios, taxa de aprendizagem de 0,005; 0,007 e 0,001. Foram testados diferentes números de interações: 10.000, 15.000 e 20.000.

A metodologia utilizada neste trabalho foi proposta por VIEIRA (2000), que utiliza baixos valores de taxa de aprendizagem e números de neurônios e aumenta estes valores até que a taxa de aprendizagem seja satisfatória.

Para a combinação 1 e 2 de bandas foi feito o treinamento com as 17 e 14 classes de amostras de treinamento e posterior validação, com as amostras de verdade de campo.

As arquiteturas que apresentaram os melhores resultados entre as combinações 1 e 2 para as 17 e 14 classes de amostras de treinamento serviram posteriormente para a classificação. Assim, foram gerados 2 mapas temáticos, que posteriormente foram confrontados com os arquivos das amostras de validação para avaliação de cada classificação.

4.4.7.3. Classificação por regiões – Bhattacharya

Foram geradas duas classificações por região no *software* Spring 5.1, uma com 17 classes de amostras de treinamento e outra com 14 classes de amostras de treinamento.

Na primeira etapa, foram testadas várias combinações de similaridade e número de *pixels* para segmentação da imagem, que separou em regiões a imagem de acordo com os níveis de cinza. O melhor resultado alcançado foi com um grau de similaridade de 10 e 10 *pixels* de área, devido à heterogeneidade espectral da imagem. O passo seguinte foi a criação de um arquivo de contexto onde foram inseridas as bandas 1 2 3 e infravermelho próximo. Este arquivo teve por objetivo armazenar as bandas utilizadas no processo de classificação, bem as amostras e a escolha do método a ser utilizado, se é *pixel a pixel* ou por região.

Para as duas classificações geradas, foram seguidos os mesmos passos. A diferença entre elas foi a coleta das amostras de treinamento, que para primeira classificação foi de 17 classes e para segunda de 14 classes. Como não foi possível usar o arquivo com as amostras de treinamento das classificações com os outros algoritmos, a coleta das amostras treinamento ocorreu no próprio *software* (Figura 9), que obedeceu a localização exata que continha nos outros arquivos. Feito isto, procedeu-se a classificação das duas imagens e posteriormente a coleta das amostras de validação para cada classificação, gerando uma matriz de erros no próprio *software*, através da opção de tabulação cruzada.




Figura 6 – Coleta das amostras de treinamento na imagem segmentada.

4.4.8. Pós classificação

Os mapas temáticos gerados pelos diferentes algoritmos apresentaram ruídos que dificultam interpretação visual dos mapas. Isto ocorreu nos mapas classificados devido a alta resolução espacial da imagem e pela alta heterogeneidade espectral dos alvos. Deste modo, com o propósito de melhorar a qualidade visual dos mapas classificados, foi realizado um processo de filtragem em cada imagem para eliminar regiões de tamanhos menores que a possibilidade de representação na escala de trabalho. Foi adotado o procedimento de eliminação da área mínima mapeável no *software* ArcGis 9.3, de acordo com a seguinte rotina com a ferramenta *Raster Calculator*:

Equação 7

regiongroup(**ingrid1**, #, EIGHT, WITHIN)

Equação 8

Select([Calculation], 'count > XX')

Equação 9

Nibble(**ingrid1**, [Calculation2])

“Ingrid1” corresponde a imagem classificada, na Equação 7. Na Equação 8 o arquivo de entrada (*calculation*) é o arquivo de saída da Equação 7, em “*count:>XX*” coloca-se o número de *pixels* mínimo que se pretende considerar, neste caso: 50 *pixels* na imagem. Na Equação 9 o arquivo de entrada (*calculation2*) é o arquivo de saída Equação 8. As regiões eliminadas foram substituídas pelo vizinho com maior área de contato.

4.4.9. Identificação do uso e cobertura do solo pela comunidade

A identificação do uso e cobertura do solo elaborado pela comunidade ocorreu no dia 06 de dezembro de 2009, na Escola Família Agrícola Puris, localizada na porção sudoeste da bacia do Córrego São Joaquim, no município de Araponga – MG.

Um convite formal foi distribuído para os membros da comunidade. Comparecem para a atividade 26 adultos e 15 crianças, todos produtores de café residentes da bacia.

A atividade iniciou-se as 9:00 e seu término foi as 16:00. As 9:00 foi realizada uma dinâmica de grupo com os participantes para uma apresentação inicial. Isto foi importante para que todos se expressassem e ocorresse uma integração entre todos.

Após a dinâmica, em sala de aula foi apresentado os objetivos da atividade e em seguida o mapa da imagem IKONOS II da bacia, composição RGB e pancromática, 1 metro de resolução espacial, na escala de 1:25.000 em formato analógico A0. (Figura 10).

O próximo passo foi a construção conjunta da legenda que ocorreu em consonância com os padrões de uso e cobertura do solo. Deste modo, foram identificados 8 classes, a saber: Mata, Café, Café com árvore - SAF, Eucalipto, Milho, Cana, Taboa e Pastagem (Figura 11). Além de classes de uso e cobertura do solo, foram

identificados outras informações na imagem, como cursos d'água, nascentes e propriedades agroecológicas para criação da legenda.



Figura 7 – Apresentação da imagem IKONOS II.



Figura 8 – Identificação das informações para serem mapeadas e criação da legenda.

Após a definição da legenda, foram identificadas 3 regiões na bacia: Novo Horizonte, São Joaquim de Cima e São Joaquim (Figura 12). Para cada região existia

um mapa com a imagem IKONOS II. Assim, em cada mapa foi traçado o limite de cada região e em seguida os participantes foram divididos em três grupos, de acordo com a região em que reside.



Figura 9– Divisão da bacia por regiões.

Assim sendo, cada participante realizou a interpretação visual da região em que reside na bacia, identificando as classes de uso e cobertura do solo e os cursos d'água, nascentes e propriedades agroecológicas que foram previamente identificadas (Figura 13 e Figura 14).

As imagens classificadas foram levadas ao laboratório e transformadas em formato digital via mesa digitalizadora, utilizando o *software* ArcInfo. A edição do banco de dados ocorreu no *software* ArcGis 9.3.

Para a validação da imagem classificada pela comunidade, o arquivo que continha as 17 classes de uso e cobertura do solo foi editado e as classes que não coincidiam com as classes identificadas pela comunidade foram suprimidas do arquivo, restando apenas 8 classes no arquivo de amostras de validação. Este arquivo foi confrontado com o mapa temático gerado pela comunidade através de tabulação cruzada para verificar a acurácia da classificação.



Figura 13 – Interpretação visual da imagem e delineamento do uso e cobertura do solo .



Figura 14 – Interpretação visual da imagem e delineamento do uso e cobertura do solo .

Ao término do mapeamento, realizou-se um mosaico com as três imagens classificadas referentes a cada região e em seguida uma discussão com todos os grupos sobre o uso e cobertura do solo da bacia.

5. RESULTADOS E DISCUSSÃO

5.1. Georreferenciamento

Os Pontos de Controle Terrestre coletados via GPS que apresentaram menor exatidão e maior valor de RMS foram retirados, restando apenas 5 PCTs com os melhores resultados. O RMS total dos cinco PCTs foi de 1,33. Como demonstra a Tabela 6.

Tabela 6 - Pontos de Controle Terrestre e Erro Médio Quadrático.

PCT	X Imagem	Y Imagem	X PCT	Y PCT	RMS
1	754191.1163	7713166.4726	754176.5955	7712987.5468	1,62747
2	754587.6313	7713374.6888	754575.2049	7713197.4309	0,91916
3	754574.2763	7712771.8159	754566.9157	7712602.0823	2,30976
4	756973.8351	7717528.1184	756961.3280	7717322.6256	0,10418
5	753511.7027	7717744.0433	753480.8212	7717494.9005	0,34012
Total					1,33829

O valor de RMS superior a 1 é decorrente da baixa precisão dos PCTs obtidos pelo GPS que apresentava erro de 3 a 4 metros no momento da coleta. O ideal para correção da imagem seria realizar a ortorretificação, considerando a altitude (z) como valor adicional às coordenadas (x,y), o que garantiria melhores resultados. Apesar disto, a correção atende as exigências cartográficas para a finalidade dos produtos gerados a partir da imagem, sendo que seus usos não requerem tanta precisão.

5.2. Agrupamento das classes pelo Iseseg

Os resultados obtidos no processo de agrupamento foram analisados e permitiram um ajustamento no número de classes de uso e cobertura do solo, passando de 40 para 17, tornando viável a quantidade de classes para o processo de classificação supervisionada.

Assim, o Iseseg agrupou classes que apresentavam características espectrais semelhantes, como foi o caso das classes de pastagens com diferentes coberturas vegetais que possuíam características próximas. Deste modo, os diversos padrões da pastagem foram generalizados para uma classe apenas. O mesmo ocorreu com outras classes com valores de *pixels* próximos.

5.3. Classificações supervisionadas

Os resultados encontrados para as classificações geradas foram analisados a partir da metodologia proposta por COLGATON & GREEN (2008) utilizando a acurácia do produtor e acurácia do usuário, matriz de erro e índice Kappa.

De acordo com COLGATON & GREEN (2008) a acurácia do produtor e do usuário são maneiras de representar a precisão de cada classe de forma individual, ao invés de considerar a exatidão global da classificação.

As Equações Equação 10 Equação 11 demonstram como obter da matriz de erros a acurácia do produtor e do usuário respectivamente.


Equação 10

$$\text{Acurácia do produtor} = 1 - \text{Erro de Comissão}$$

Equação 11

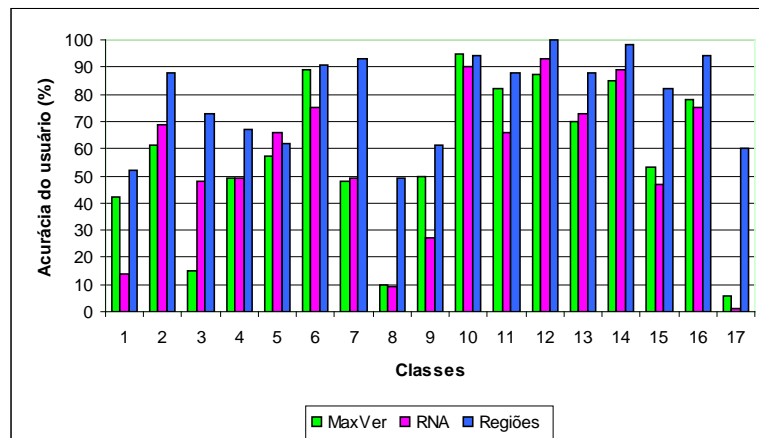
$$\text{Acurácia do usuário} = 1 - \text{Erro de Omissão}$$

As Figuras a seguir (Figura 15 a Figura 18), demonstram através de gráficos, os resultados de taxa de acurácia do produtor e usuário de cada classificador (MaxVer, RNA e Regiões) para amostras com 14 e 17 classes.




1- Mata 2- Café solteiro adulto 3- Café solteiro jovem 4- Café pequeno 5- Eucalipto adulto 6- Eucalipto jovem 7- Solo exposto 8- Capoeira 9- Milharal 10- Cana 11- Cana queimada 12- Água 13- Taboa 14- Sombra 15- Afloramento de rocha 16- Pastagem 17- Café com árvore - SAF.

Figura 15 – Acurácia do produtor para classificação automática utilizando 17 classes.




1- Mata 2- Café solteiro adulto 3- Café solteiro jovem 4- Café pequeno 5- Eucalipto adulto 6- Eucalipto jovem 7- Solo exposto 8- Capoeira 9- Milharal 10- Cana 11- Cana queimada 12- Água 13- Taboa 14- Sombra 15- Afloramento de rocha 16- Pastagem 17- Café com árvore - SAF.

Figura 16 - Acurácia do usuário para classificação automática utilizando 17 classes.



1- Mata 2- Café solteiro 3- Eucalipto adulto 4- Eucalipto novo 5- Solo exposto 6- Milharal 7- Cana 8- Cana queimada 9- Água 10- Taboa 11- Sombra 12- Afloramento de rocha 13- Pastagem 14- Café com árvore - SAF.

Figura 17 – Acurácia do produtor para classificação automática utilizando 14 classes.



1- Mata 2- Café solteiro 3- Eucalipto adulto 4- Eucalipto novo 5- Solo exposto 6- Milharal 7- Cana 8- Cana queimada 9- Água 10- Taboa 11- Sombra 12- Afloramento de rocha 13- Pastagem 14- Café com árvore - SAF.

Figura 18 – Acurácia do usuário para classificação automática utilizando 14 classes.

5.4. Classificação *pixel a pixel* por Máxima Verossimilhança

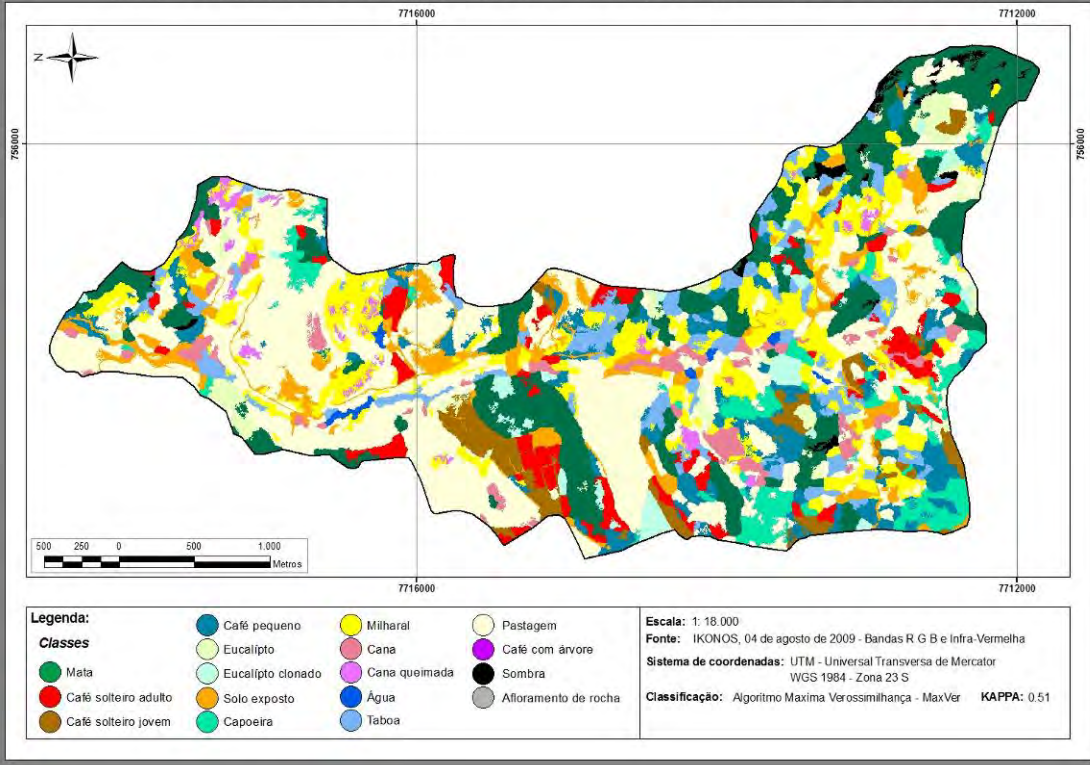
A classificação MaxVer com as 17 classes de amostras de treinamento e validação apresentou índice Kappa de 0,51, (Figura 19) considerado “Bom” de acordo com GALPARSORO & FERNÁNDEZ (1999).

Analisando as Figuras Figura 15 e Figura 16 através da acurácia do produtor e acurácia do usuário de cada classe estudada, observou que as classes Mata, Café solteiro adulto, Café solteiro jovem, Café pequeno, Capoeira e Café com árvore apresentaram maior confusão na classificação. Portanto, o classificador não conseguiu discriminar os vários estágios de crescimento do cultivo de café presente na bacia (Café solteiro adulto, Café solteiro jovem e Café pequeno).

A classe Capoeira também não foi bem classificada, sendo confundida com outros tipos de uso, como a Mata. Deste modo, ela foi suprimida da análise, visto que ela representa uma área pequena em relação ao total da bacia.

Para a classe Café com árvore - SAF, o classificador não teve bom desempenho ao classificá-la, visto que apenas acertou 20%. Já as classes que apresentam menor heterogeneidade espectral intra-classe como Cana, Água e Pastagem, o classificador foi excelente, apresentando resultados acima de 80% para acurácia do produtor e do usuário.

USO E COBERTURA DO SOLO NA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG PELO CLASSIFICADOR MAXVER (17 CLASSES)



A partir destes resultados, um novo agrupamento de classes foi realizado afim de diminuir as confusões dos classificadores e obter melhor resultado no total da classificação. Deste modo, as classes que se confundiam entre elas, como Café solteiro adulto, Café solteiro jovem e Café pequeno, foram agrupadas em uma única classe, Café solteiro. As classes de Mata e Café com árvore - SAF, mesmo apresentando resultados baixos, continuaram preservadas para as próximas classificações, devido sua importância na discriminação dos classificadores.

Após o procedimento de agrupamento das classes com menor acuraria, diminuindo o número de classes para 14, o MaxVer obteve um índice Kappa 0,58 (Figura 21). A nova classe de Café solteiro que é composta pelas classes de Café solteiro adulto, Café solteiro jovem e Café pequeno foi responsável pelo aumento total do índice Kappa, visto que as outras classes pouco variaram analisando a acuraria do produtor e usuário.

5.5. Classificação *pixel a pixel* por Redes Neurais Artificiais - *Error Backpropagation*

Utilizando 17 classes de amostras de treinamento para combinação 1 de bandas, o melhor resultado da taxa de acurácia foi de 64,91% para 25 neurônios, taxa de aprendizagem de 0.005 e 20.000 interações (Figura 20). Já para combinação 2 de bandas, que foi adicionada a banda NDVI, a taxa de acurácia de maior valor foi de 65,04% para 20 neurônios, taxa de aprendizagem de 0.007 e 20.000 interações (Figura 22).


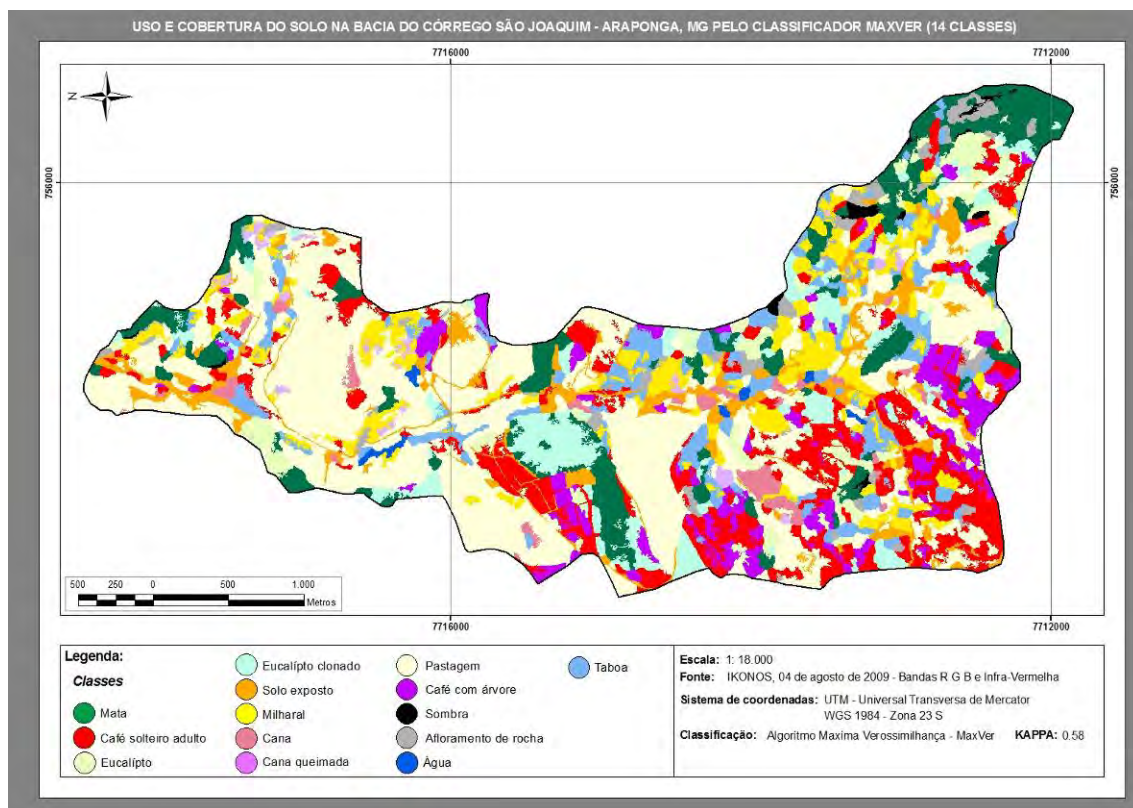


Figura 16 – Treinamento de arquiteturas para combinação 1, com 17 classes de amostras de treinamento e 20.000 interações.






Figura 22 – Treinamento de arquiteturas para combinação 2, com 17 classes de amostras de treinamento e 20.000 interações.

A Figura 23 revela que para 14 classes de amostras de treinamento para combinação 1 de bandas, a melhor taxa de acurácia foi de 68,43% para 20 neurônios, taxa de aprendizagem de 0,01 e 20.000 interações. Para a combinação 2 de bandas, (Figura 24), com adição da banda NDVI, a taxa de acurácia que obteve o melhor resultado foi de 70,45% para 25 neurônios, taxa de aprendizagem de 0,005 e 20.000 interações.




Figura 23– Treinamento de arquiteturas para combinação 1, com 14 classes de amostras de treinamento e 20.000 interações.




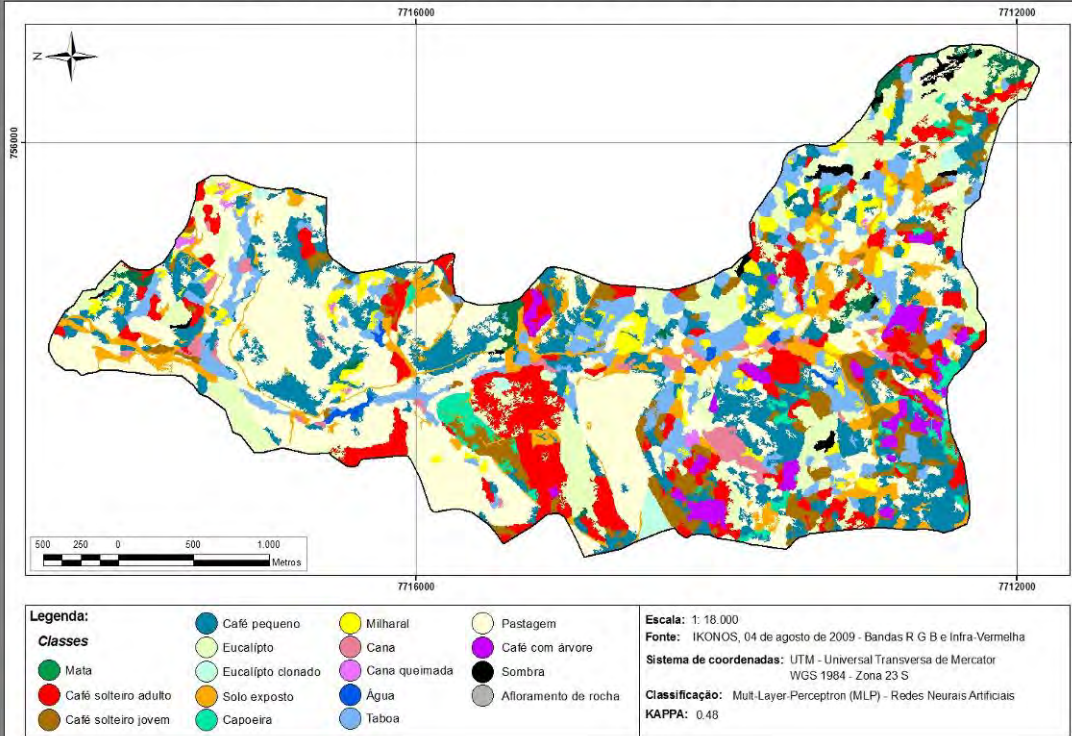
Figura 24 – Treinamento de arquiteturas para combinação 2, com 14 classes de amostras de treinamento e 20.000 interações.

Os resultados revelaram que com o aumento do número de interações houve aumento pouco significativo da taxa de acurácia das arquiteturas geradas. O valor ótimo de números de neurônios variou de 20 a 25 neurônios na camada intermediária. Para as taxas de aprendizagem não houve uma taxa específica que apresentasse os melhores resultados. Estes dados da pesquisa demonstram que é sempre necessário realizar o treinamento das arquiteturas das RNAs de acordo com a metodologia proposta por VIEIRA (2000) por não existir uma regra de números de neurônios, taxas de aprendizagem e número de interações. Com a adição da banda NDVI para as duas combinações de bandas, para 17 e 14 classes demonstrou que não aumentou significativamente os valores da taxa de acurácia, somente para as 14 classes, como poderá ser observado mais adiante.

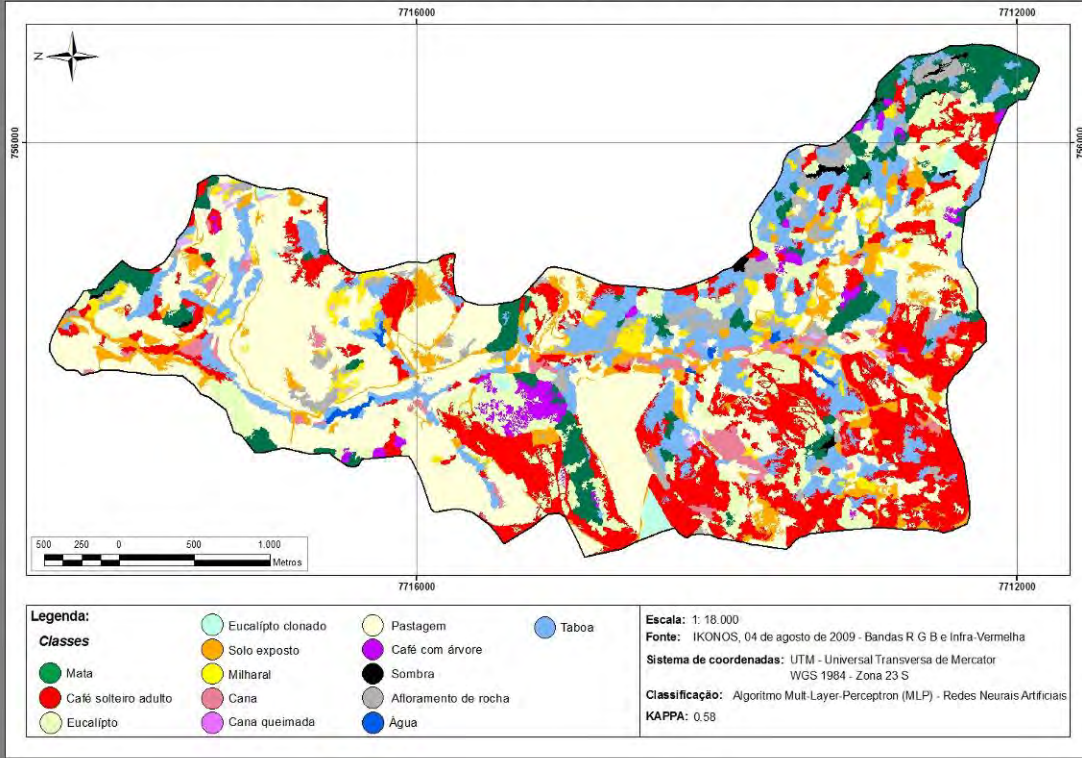
O classificador RNA's para 17 classes, usando a combinação 2, com taxa de acurácia de 65,04% apresentou índice Kappa de 0,48 (Figura 25). Quando comparado ao MaxVer, as RNA's tiveram uma exatidão maior na classificação do eucalipto jovem. Porém, a classe Café com árvore - SAF obteve resultados inferiores e considerados ruins, sendo a classe que mais se confundiu com as outras.

Para 14 classes mapeadas, que utilizou o arquivo com a arquitetura com taxa de acurácia 70,45%, da combinação 2, as RNA's apresentaram Kappa de 0,68, (Figura 26) apresentaram resultados próximos ao MaxVer em relação a classe Café solteiro, devido ao que foi mencionado anteriormente. Já para a classe Café com árvore - SAF, não houve aumento significativo.

USO E COBERTURA DO SOLO NA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG CLASSIFICADO POR REDES NEURAIS ARTIFICIAIS (17 CLASSES)



USO E COBERTURA DO SOLO NA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG CLASSIFICADO POR REDES NEURAS ARTIFICIAIS (14 CLASSES)



5.6. Classificação por regiões – Bhattacharya

Dentre os classificadores analisados nesta pesquisa, o classificador por regiões Bhattacharya apresentou os melhores resultados da classificação, com índice Kappa de 0,76 para mapeamento de 17 classes (Figura 27). Comparando com os outros classificadores utilizados nesta pesquisa, o Bhattacharya teve desempenho superior ao classificar todas as 17 classes e obteve acurácia de produtor de 0,80 e usuário de 0,60 para a classe Café com árvore - SAF. Esta classe foi a que mais confusão gerou nos outros classificadores.

Porém, quando foram utilizadas 14 classes para mapeamento do uso e cobertura do solo, o desempenho do classificador caiu, Kappa de 0,68 (Mapa 10). A exatidão da classe Café com árvore - SAF também caiu. Isto ocorreu porque ela se confundiu com a classe de Café solteiro.

Portanto, com a utilização de uma classe genérica pra café, contendo os vários estágios da cultura em uma única classe, foi responsável para que o classificador por regiões se confundisse.

Como pôde ser visto pelos dados gerados na pesquisa, o algoritmo por regiões apresentou melhores resultados de acurácia de produtor e usuário para classificação de uso e cobertura do solo numa bacia hidrográfica que possui muitos padrões distintos na imagem e classes que possui alta variabilidade espectral entre os *pixels*, demonstrando que o processo de segmentação da imagem, anterior ao processo de classificação foi essencial para alcançar tais resultados.

5.7. Classificação do uso do solo pela comunidade

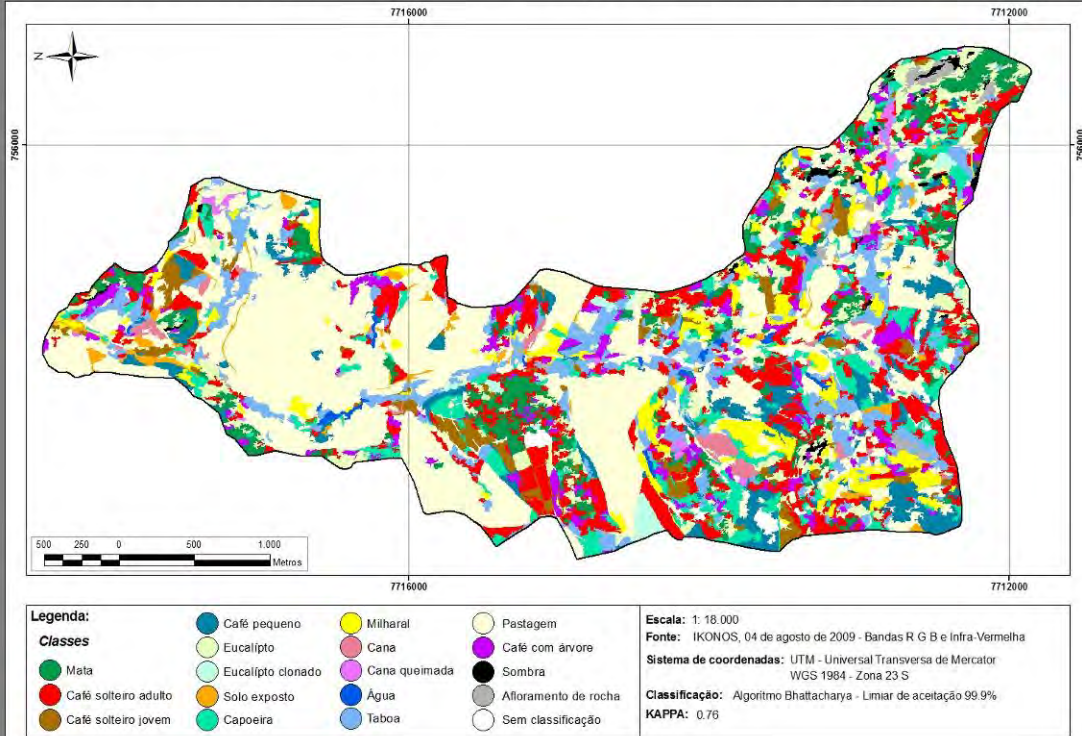
A classificação de uso e cobertura do solo pela comunidade alcançou índice Kappa de 0,55 (Mapa 11), considerado “Bom” de acordo com GALPARSORO & FERNÁNDEZ (1999). A classe que apresentou o menor resultado, abaixando conseqüentemente o índice Kappa foi a Taboa. Apenas um grupo identificou a classe na imagem e a classificou. Outra classe que obteve resultados baixos foi Milharal.

Na realização da atividade, os agricultores utilizaram além da imagem IKONOS, o conhecimento que tinham da área, e como já faziam 4 meses que a imagem havia sido

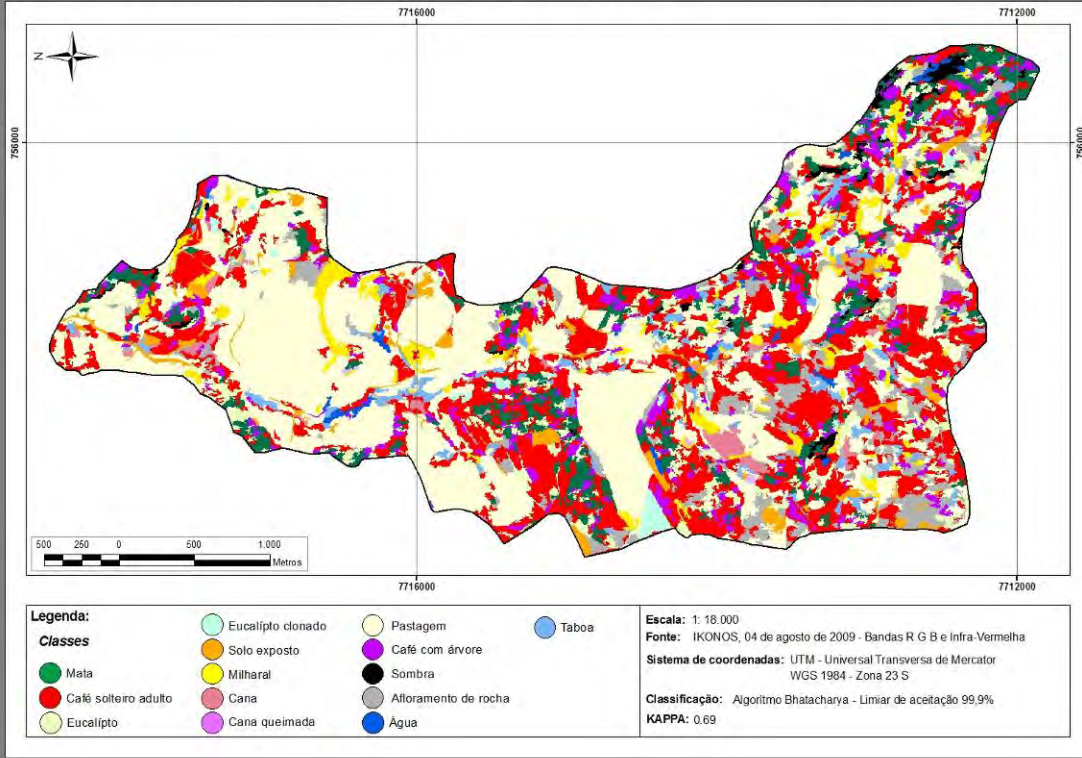
adquirida, muitas mudanças já haviam ocorrido no uso do solo da bacia, como foi o caso do milho, que já tinha sido cortado. Isto influenciou no mapeamento, visto que os agricultores não se lembravam mais que aquele cultivo estava lá quando a imagem foi capturada. Isto demonstra a capacidade de abstração das pessoas envolvidas no mapeamento e também na valorização do conhecimento que eles possuem da área.

Deve-se considerar também que qualidade visual da impressão da imagem não era boa, que foi o primeiro contato que a comunidade teve com a bacia vista de cima. Assim, comunidade apresentou-se muito bem na classificação do uso e cobertura do solo, demonstrando o potencial que ela possui para realizar análises espaciais através de suas percepções espaciais e conhecimentos locais.

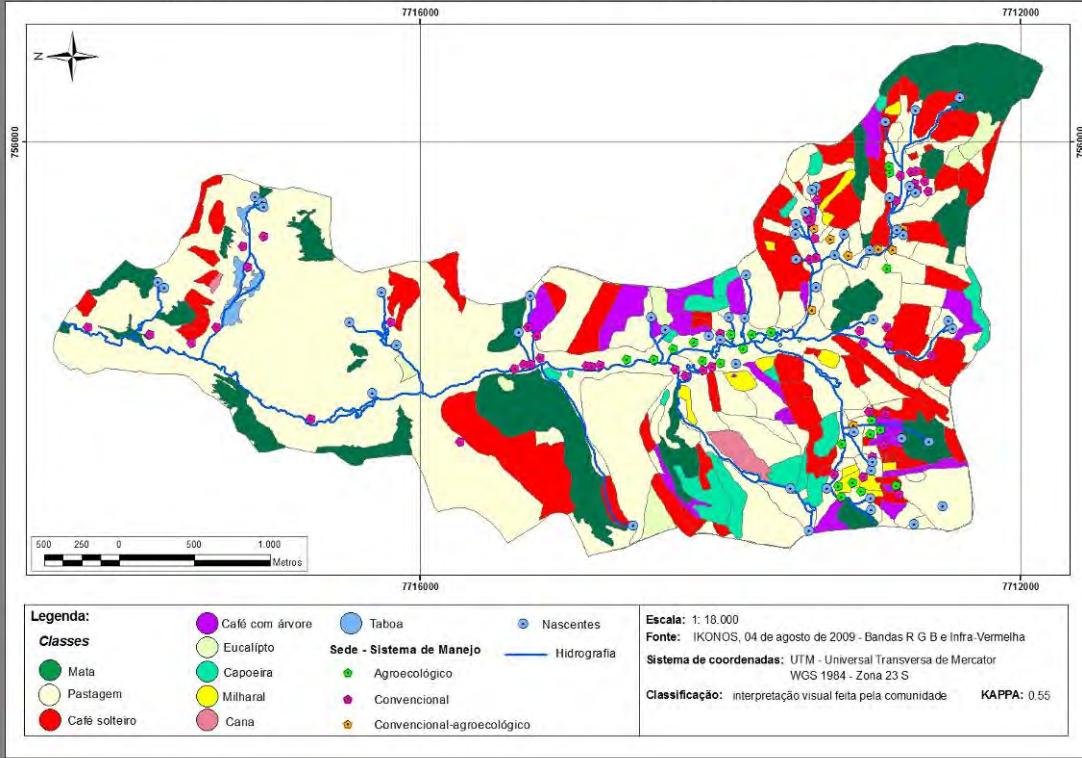
USO E COBERTURA DO SOLO NA BACIA DO CÓRREGO SÃO JOAQUIM - ARAPONGA, MG PELO CLASSIFICADOR BHATTACHARYA - REGIÕES (17 CLASSES)




USO E COBERTURA DO SOLO NA BACIA DO CÔRREGO SÃO JOAQUIM - ARAPONGA, MG PELO CLASSIFICADOR BHATTACHARYA - REGIÕES (14 CLASSES)




CLASSIFICAÇÃO DO USO DO SOLO NA BACIA DO CÔRREGO SÃO JOAQUIM - ARAPONGA, MG POR INTERPRETAÇÃO VISUAL - COMUNIDADE





1- Mata 2- Café solteiro 3- Café com árvore - SAF 4- Eucalipto 5- Milho 6- Cana 7- Taboa 8- Pastagem

Figura 30 - Acurácia do produtor para classificação da comunidade.



1- Mata 2- Café solteiro 3- Café com árvore - SAF 4- Eucalipto 5- Milho 6- Cana 7- Taboa 8- Pastagem

Figura 31 – Acurácia do usuário para classificação da comunidade.

A Figura 32 é um resultado alcançado junto à comunidade que definiu do total de propriedades da bacia, quais eram agroecológicas, as que estavam em processo de transição e convencionais. Note que 26% das propriedades da bacia são agroecológicas, 10% transicionais e 64% convencionais, do total de 81 propriedades. Como as propriedades agroecológicas na bacia são pequenas propriedades, não existe equivalência em área.




Figura 2 – Proporção das propriedades rurais e seus respectivos manejos.

Pelas figuras 29 e 32, podemos observar que a distribuição espacial das propriedades agroecológicas e em transição agroecológica se concentra nas porções sul e na porção central, onde prevalecem as pequenas propriedades. Na porção norte a ocorrência maior de propriedades de sistema de manejo convencional, em grandes propriedades.

A figura 33 é resultado do mapa de classificação Bhattacharya com 17 classes, que apresentou melhor desempenho entre os classificadores avaliados. Ela demonstra que a classe que prevalece na bacia é a pastagem, o que evidencia o padrão característico de uso e cobertura do solo na Zona da Mata mineira, sendo a pastagem o pano de fundo do mapa.

As classes de café solteiro ocupam cerca de 8% da área da bacia, sendo a segunda classe de maior uso. Os SAFs representam 5% da área da bacia. Capoeira e mata, no somatório caracterizam 15% da cobertura da bacia, um valor significativo que pode ser analisado juntamente com a distância que estas classes possuem umas das outras, com a classe de café com árvore (SAFs), para formação de um corredor ecológico.




Figura 33 – Distribuição de área das classes de uso e cobertura do solo

6. CONSIDERAÇÕES FINAIS

- Dentre os classificadores avaliados nesta pesquisa, a classificação por região pelo algoritmo Bhattacharya foi a que obteve o melhor resultado, com Índice Kappa de 0,76, considerado muito bom. Isto demonstra o grande potencial para classificação de áreas com muitas classes de uso e cobertura do solo e padrões heterogêneos intra-classe;
- Para classificar o uso do solo com sistemas agroflorestais com café, o Bhattacharya foi o melhor algoritmo. Os outros dois classificadores não obtiveram resultados tão bons;
- A adição da banda NDVI na classificação pelas RNA's não apresentou resultados significativos que justifiquem sua utilização para esta pesquisa;
- A utilização de imagens de alta resolução espacial não permite diferenciar o manejo em agroecológico e convencional, sendo necessário levantamento de campo para averiguação, visto que áreas de produção de café consorciadas com banana, ora eram agroecológicas ora convencional;
- A implementação do SIG participativo para classificação do uso e cobertura do solo pela comunidade, demonstrou que a percepção espacial e conhecimento local são duas potencialidades que juntas favorecem o melhor entendimento do espaço vivido, podendo ser utilizadas para diversos fins.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- AB'SABER, A. N. **Províncias geológicas e domínios morfoclimáticos no Brasil. Geomorfologia**, [s.n]. São Paulo, 1970.
- ATAIDE, M. S. & MARTINS, A. L. U. **A Etnocartografia como ferramenta de gestão**. ACT – Brasil. 2009.
Disponível em: <http://www.equipe.org.br/publicacoes_dentro.php?tipoid=6>
Acesso em: 14 out. 2009.
- CÂMARA, G; DAVIS, C; MONTEIRO, A. M; PAIVA, J. A; D'AGE, J. C. L. **Geoprocessamento: Teoria e Aplicações**. São José dos Campos: INPE.
Disponível em: <www.dpi.inpe.br/gilberto/livro/>. Acesso em: 22 abril de 2010.
- CÂMARA, G. **Sistemas de informação Geográfica para aplicações ambientais e cadastrais: Uma visão geral**. In: SILVA, M. S. (Org). Cartografia, Sensoriamento e Geoprocessamento. 1. ed. Lavras: Universidade Federal de Lavras – UFLA, 1998.
- CAMPBELL, J. B. **Introduction to remote sensing**. Nova Iorque: The Guilford Press, 1987.
- CARTON, L. **Strengths and Weaknesses of Spatial Language: Mapping activities as debating instrument in a spatial planning process**. XXII Congresso Internacional de Washington, USA, 2002.
- CAVASSIM JUNIOR, I. & CENTENO, J. **Classificação de uma imagem IKONOS utilizando as técnicas “pixel a pixel” e a análise orientada a região**. In: III Colóquio Brasileiro de Ciências Geodésicas, Curitiba, Paraná, 2003.
- COLGATON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 49, n. 12,[s.n], 1991.
- COLGATON, R. G. & GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 2. ed. Nova Iorque: CRC Press, 2008.
- CORRÊA, G. F. **Modelo de Evolução mineralógica da fração argila de solos do planalto de Viçosa, MG**. 1984. Dissertação (Mestrado em Solos e Nutrição de Plantas) Universidade Federal de Viçosa, Viçosa, 1984.

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

DANIEL, O; VITORINO, A. C. T; VERONESI, C. O; QUEIROZ, L.S. Avaliação do uso da terra por meio de imagens IKONOS: o caso do assentamento Fazenda Nova da Lagoa Grande, MS. **Revista Brasileira de Agroecologia.** vol. 3 – Suplemento especial, 2008.

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

ENGESAT – IKONOS. Disponível em:
http://www.engesat.com.br/index.php?action=read&news_id=494&system=news.
Acesso em: 21 de agosto de 2009.

GALPARSORO, L. U.& FERNANDÈZ, P. S. Medidas de concordância: el índice Kappa. **CAD Aten Primaria,** A Coruña, n. 6, p. 169-171, 1999. Disponível em:
<http://gaptalavera.sescam.jccm.es/web1/gaptalavera/prof_InvDocForm/Explicacion_kappaFisterra.pdf>. Acesso em: 29 set. 2009.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE) - **Manual Técnico de Pedologia,** 2º Edição - Série Manuais Técnicos em Geociências, nº 4, Rio de Janeiro, 2007.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE) Disponível em: <http://www.ibge.gov.br/cidadesat/topwindow.htm?1> Acesso em: 21 de agosto de 2009.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAS (INPE). **Tutorial do Spring.** Disponível em:
<http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_sen.html>
Acesso: 17 out. 2009.

JANSSEN, L. L. F. & GORTE, B. G. H. **Digital image classification.** In: Principles of Remote Sensing: An introductory textbook. NORMAN, K.; JANSSEN, L. L. F.; HUURNEMAN, G. C. 3. ed. [s.n] [s.l.], 2004.

JORDAN, G. **Public participation and GIS: Report back.**1999. Disponível em:
http://www.iapad.org/publications/ppgis/public_participation_and_gis_report_back.PDF

- KURY, E. B.; VIEIRA, C. A. O. **Classificação automática de imagens de alta resolução** In: UFVGEO 2002 - I Workshop sobre Geoprocessamento da UFV, 2002.
- LIU, W. T. H. **Aplicações de sensoriamento remoto**. Campo Grande: UNIDERP, 2006.
- MATHER, P. M. **Computer Processing of Remotely-Sensed Images: An Introduction**. 3. Ed. Editora John Wiley & Sons Ltd. Inglaterra, 2004.
- MENDONÇA, L. E. R. **Utilização de algoritmos de classificação em uma imagem IKONOS para mapeamento de feições terrestres: um estudo de caso**. 2006. Dissertação (mestrado em Ciência Florestal), Universidade Federal de Viçosa, Viçosa, 2006.
- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2 ed. Viçosa: UFV, 2005.
- MOREIRA, A. A.; SOARES, V. P.; GLERIANI, J. M.; RIBEIRO, C. A. A. S. **Utilização de algoritmos de classificação para o mapeamento do uso e cobertura da terra na bacia hidrográfica no Ribeirão São Bartolomeu, Viçosa – MG, a partir de uma imagem do sensor IKONOS II**. In: XIII Simpósio Brasileiro de Geografia Física Aplicada, Viçosa, MG. Anais v.1 p.1-13, 2009.
- NUNES, G. B & PINHEIRO, R. B. **Trabalho final de computação gráfica**. Disponível em:
<<http://www.tecgraf.puc-rio.br/~mgattass/RedeNeural/redeneural.html>>.
Acesso em: 12 set. 2009.
- RESENDE, M.; CURI, N.; RESENDE, S. B.; CORRÊA, G. F. **Pedologia: base para distinção de ambientes**. Viçosa: NEPUT, 1996.
- RESOLUÇÃO CONAMA Nº 303, DE 20 DE MARÇO DE 2002**. Disponível em:
<http://www.mma.gov.br/port/conama/res/res02/res30302.html>. Acesso em 21 de agosto 2009.
- RIBEIRO, R. M. P; SOARES, V. P; VIEIRA, C. A. O. **Avaliação de métodos de classificação de imagens IKONOS para mapeamento da cobertura terrestre**. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 2005.

- ROSSI, A. S; MANGABEIRA, J. A. C; ROMEIRO, A. R; CORRALES, F. M. Rede regional de agroecologia – um plano piloto: um sistema de informações integradas na gestão rural sustentável. **Revista Brasileira de Agroecologia**. v. 2 n.1, 2007.
- SANTOS, F. J; KLAMT, E. Gestão agroecológica de microbacias hidrográficas através de técnicas de geoprocessamento e sensoriamento remoto – Caso Fazenda Patanoso. **Revista Ciência Rural**. v. 34, n.6, Santa Maria, 2004.
- SILVA, A. M; SCHULZ, H. E; CAMARGO, P. B. **Erosão e hidrossedimentologia em bacias hidrográficas**. São Carlos: RiMa, 2003.
- SLETTTO, B. **Producing space (s), representing landscapes: maps and resource conflicts in Trinidad**. [s.l.] Cultural Geographies, 2002.
- TAGG, J.; HOLME, D.; KOOIMAN, A. **Communities and Government Jointly Managing Wildlife in Namibia: Geographic Information Systems as a Monitoring and communication tool**. 1996.
- TRUNG, N. H.; TRI, L.Q.; VAN MENSVOORTS, M. E.F.; BREGT, A. Gis for Participatory Land Use Planning in the Mekong Delta, Vietnam. Congress on it in agriculture, 2004.
- VANÂCOR, R. N. **Sensoriamento Remoto e Geoprocessamento aplicados ao mapeamento das áreas susceptíveis a movimento de massa na região nordeste do estado do Rio Grande do Sul**. 2006. Dissertação (Pós-graduação em Sensoriamento Remoto) Universidade Federal do Rio Grande do Sul, 2006.
- VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. Tese (Ph. D.) - University of Nottingham, 2000.
- 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, 2000.
- WEINER, D.; HARRIS, M. T.; CRAIG, J. W. **Community Participation and Geographic Information Systems**. London: Taylor and Francis Group, 2002.

ANEXO I

Tabela A1 - Arquiteturas geradas para a combinação de bandas 1, para 17 classes.

Número de neurônios	10.000 interações			15.000 interações			20.000 interações		
	Taxa de aprendizagem								
	0,005	0,007	0,01	0,005	0,007	0,01	0,005	0,007	0,01
10	60,9	62,43	60,7	62,9	61,97	64,3	63,9	64,1	64,91
15	60,29	62,03	36,23	61,3	63,44	45,79	62,83	61,3	63,03
20	59,63	47,59	9,96	62,1	61,5	5,88	63,77	61,7	5,88
25	45,66	21,99	17,71	52,57	46,06	6,25	64,91	34,49	5,88
30	20,32	5,01	5,21	25,4	10,29	5,88	21,26	14,91	5,88
35	14,5	6,28	6,25	8,29	15,11	5,88	5,88	5,88	5,88

Tabela A2 - Arquiteturas geradas para a combinação de bandas 1, para 14 classes.

Número de neurônios	10.000 interações			15.000 interações			20.000 interações		
	Taxa de aprendizagem								
	0,005	0,007	0,01	0,005	0,007	0,01	0,005	0,007	0,01
10	63,07	66,31	65,18	65,18	66,72	65,18	66,72	66,31	67,05
15	66,72	63,96	65,34	67,78	66,56	67,61	67,05	67,45	67,37
20	67,45	64,85	43,34	67,53	66,96	49,84	66,07	66,72	68,43
25	67,29	50,57	15,02	65,99	62,66	35,15	66,88	67,37	7,14
30	64,45	48,86	15,42	67,86	24,84	7,14	67,69	23,13	5,03
35	34,42	6,66	7,14	60,39	21,75	8,12	62,5	18,99	7,14

Tabela A3 - Arquiteturas geradas para a combinação de bandas 2, para 17 classes.

Número de neurônios	10.000 interações			15.000 interações			20.000 interações		
	Taxa de aprendizagem								
	0,005	0,007	0,01	0,005	0,007	0,01	0,005	0,007	0,01
10	59,02	56,02	60,03	60,36	59,76	59,83	61,36	60,96	58,76
15	57,69	57,75	55,48	37,97	63,03	62,58	63,5	61,97	61,3
20	59,63	59,83	6,42	60,9	35,09	19,45	63,84	65,04	44,05
25	61,5	15,37	6,42	60,9	30,21	5,88	63,44	50,8	5,88
30	59,02	10,23	6,62	32,29	13,03	6,42	35,36	58,89	5,88
35	37,57	12,1	7,49	27,07	5,21	6,62	21,79	5,88	5,88

Tabela A4 - Arquiteturas geradas para a combinação de bandas 2, para 14 classes.

Número de neurônios	10.000 interações			15.000 interações			20.000 interações		
	Taxa de aprendizagem								
	0,005	0,007	0,01	0,005	0,007	0,01	0,005	0,007	0,01
10	65,5	64,45	65,26	65,99	67,61	66,23	67,69	66,23	67,29
15	65,18	65,42	61,53	65,5	68,1	68,26	67,78	69,4	68,51
20	65,42	64,94	61,2	67,05	66,8	21,92	67,21	68,51	68,26
25	65,34	61,44	52,11	67,61	64,77	15,83	70,45	67,29	17,37
30	65,99	62,91	7,14	67,69	17,69	7,87	69,72	57,87	7,14
35	56,09	14,85	7,14	61,77	35,06	7,14	68,04	8,04	7,14

ANEXO II

Tabela A5 - Matriz de erros da classificação por MaxVer utilizando 17 classes – Kappa 0,51

Amostras de validação	Imagem classificada - Temática																	Total	E,C, (%)
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17		
1	305	23	1	0	32	11	0	22	0	1	0	0	1	14	1	0	48	459	0,3355
2	114	396	85	14	42	2	0	54	1	0	0	1	28	0	0	0	271	1008	0,6071
3	3	12	71	47	10	0	0	73	29	9	2	0	15	1	6	29	29	336	0,7887
4	0	1	170	288	3	0	202	73	46	1	0	0	1	0	12	218	8	1023	0,7185
5	93	22	24	25	207	6	0	32	1	0	0	0	1	2	8	2	72	493	0,5801
6	148	111	1	0	23	177	0	9	0	3	0	14	2	0	0	2	57	545	0,6752
7	0	0	3	48	0	0	232	17	0	0	0	0	0	0	0	137	0	437	0,4691
8	4	20	73	16	13	0	0	48	5	0	0	0	4	0	3	4	57	247	0,8057
9	1	0	0	23	0	0	3	12	258	0	14	0	65	0	56	0	5	437	0,4096
10	2	3	0	0	0	2	0	3	0	413	0	13	3	0	0	13	11	463	0,1080
11	0	0	0	0	0	0	1	5	42	0	138	1	1	0	23	1	0	212	0,3491
12	0	0	0	0	0	0	0	0	0	0	0	222	0	1	0	0	0	223	0,0045
13	20	26	0	79	14	1	0	27	24	0	0	0	352	0	11	0	34	590	0,4034
14	8	0	0	0	7	0	0	5	0	0	0	0	0	116	44	0	1	181	0,3591
15	3	0	0	40	3	0	29	26	88	0	8	3	22	2	194	0	3	421	0,5392
16	0	0	0	9	0	0	14	39	17	4	7	1	0	0	2	1407	0	1500	0,0620
17	23	38	57	3	7	0	0	22	0	3	0	0	5	0	0	0	39	197	0,8020
Total	724	652	487	592	361	199	481	467	511	434	169	255	500	136	360	1809	635	8772	
E,C, (%)	0,5787	0,3926	0,8542	0,5135	0,4266	0,1106	0,5177	0,8972	0,4951	0,0484	0,1834	0,1294	0,2960	0,1471	0,4611	0,2222	0,8396		0,4456

1- Mata 2- Café solteiro adulto 3- Café solteiro jovem 4- Café pequeno 5- Eucalipto grande 6- Eucalipto jovem 7- Solo exposto 8- Capoeira 9- Milharal 10- Cana 11- Cana queimada 12- Água 13- Taboa 14- Sombra 15- Afloramento de rocha 16- Pastagem 17- Café com árvore

Tabela A6 - Matriz de erros da classificação por MaxVer utilizando 14 classes – Kappa 0,58

Amostras de validação	Imagem classificada - Temática															
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	Total	E. C. (%)
1	315	57	32	10	0	0	1	0	0	1	14	1	0	62	493	0,3611
2	11	610	15	0	97	29	8	1	1	7	0	8	23	48	858	0,2829
3	107	89	229	6	0	1	0	0	0	0	2	8	0	126	568	0,5968
4	216	206	41	179	0	0	3	0	14	1	0	0	0	113	773	0,7684
5	0	52	0	0	254	0	0	0	0	0	0	0	139	0	445	0,4292
6	3	23	0	0	21	300	0	7	0	67	0	65	7	3	502	0,4024
7	1	3	0	2	0	0	414	0	12	3	0	0	13	10	458	0,0961
8	0	0	0	0	1	42	0	145	1	1	0	23	1	0	214	0,3224
9	0	0	0	0	0	0	0	0	222	0	1	0	0	0	223	0,0045
10	20	140	11	2	0	24	0	0	0	376	1	10	0	43	627	0,4003
11	8	0	7	0	0	0	0	0	0	0	116	44	0	1	176	0,3409
12	3	71	5	0	59	93	0	9	3	22	2	197	6	5	475	0,5853
13	0	21	0	0	46	21	4	7	1	0	0	4	1618	0	1722	0,0604
14	40	459	21	0	0	1	4	0	1	22	0	0	2	221	771	0,7134
Total	724	1731	361	199	481	511	434	169	255	500	136	360	1809	635	8305	
E. C. (%)	0,5649	0,6476	0,3656	0,1005	0,4719	0,4129	0,0461	0,1420	0,1294	0,2480	0,1471	0,4528	0,1056	0,6520		0,3744

1- Mata 2- Café solteiro 3- Eucalipto grande 4- Eucalipto novo 5- Solo exposto 6- Milharal 7- Cana 8- Cana queimada 9- Água 10- Taboa 11- Sombra 12- Afloramento de rocha 13- Pastagem 14- Café com árvore.

Tabela A7 - Matriz de erros da classificação por RNA's utilizando 17 classes – Kappa 0,48

Amostras de validação	Imagem cassificada – Temática																	E, O, (%)	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17		Total
1	98	3	1	0	6	12	0	8	0	0	0	0	1	10	0	0	7	146	0,3288
2	211	452	47	0	34	11	0	44	0	25	0	0	9	0	0	0	294	1127	0,5989
3	15	81	234	92	21	2	0	98	7	4	0	0	50	0	5	0	96	705	0,6681
4	0	3	67	289	2	0	228	102	125	10	5	0	1	0	30	256	4	1122	0,7424
5	287	63	20	14	240	9	0	21	1	0	0	0	0	4	0	0	66	725	0,6690
6	7	0	0	0	5	150	0	0	0	0	0	0	0	0	0	0	0	162	0,0741
7	0	0	0	16	0	0	238	5	0	0	0	10	0	0	0	193	0	462	0,4848
8	6	21	111	0	23	0	0	40	0	0	0	0	0	0	0	2	108	311	0,8714
9	0	0	0	43	0	0	0	10	139	0	20	0	69	0	35	0	4	320	0,5616
10	6	6	4	0	0	7	0	5	0	392	0	0	2	0	0	3	8	433	0,0947
11	0	0	0	0	0	0	1	6	40	0	112	2	0	0	9	0	0	170	0,3412
12	0	0	0	0	0	0	0	1	0	0	1	239	0	0	0	0	0	241	0,0083
13	31	19	3	101	14	8	0	43	78	2	1	0	364	1	27	0	42	734	0,5041
14	11	0	0	0	7	0	0	9	0	0	0	1	1	121	79	0	1	230	0,4739
15	0	0	0	23	7	0	12	22	87	0	24	3	3	0	170	0	1	353	0,5184
16	0	0	0	13	0	0	2	52	34	1	6	0	0	0	5	1355	0	1468	0,0770
17	52	4	0	0	2	0	0	1	0	0	0	0	0	0	0	0	4	63	0,9365
Total	724	652	487	592	361	199	481	467	511	434	169	255	500	136	360	1809	635		
E, C, (%)	0,8646	0,3067	0,5195	0,5118	0,3352	0,2462	0,5052	0,9143	0,7280	0,0968	0,3373	0,0627	0,2720	0,1103	0,5278	0,2510	0,9937		0,4714

1- Mata 2- Café solteiro adulto 3- Café solteiro jovem 4- Café pequeno 5- Eucalipto grande 6- Eucalipto jovem 7- Solo exposto 8- Capoeira 9- Milharal 10- Cana 11- Cana queimada 12- Água 13- Taboa 14- Sombra 15- Afloramento de rocha 16- Pastagem 17- Café com árvore

Tabela A8 - Matriz de erros da classificação por RNA's utilizando 14 classes – Kappa 0,58

Amostras de validação	Imagem classificada - Temática														Total	E, O, (%)
	1	2	3	4	5	6	7	8	9	10	11	12	13	14		
1	251	10	24	12	0	0	0	0	0	1	13	0	0	14	325	0,2277
2	48	1036	30	3	1	34	15	0	0	26	0	8	22	179	1402	0,2611
3	184	165	252	9	0	0	0	0	0	0	3	0	0	252	865	0,0787
4	7	0	5	150	0	0	0	0	0	0	0	0	0	0	162	0,0741
5	0	30	0	0	268	2	0	0	13	0	0	0	186	0	499	0,4629
6	0	38	0	0	5	117	0	16	0	19	0	24	0	4	223	0,4753
7	15	12	2	9	0	0	416	0	0	2	0	0	6	56	518	0,1969
8	0	0	0	0	1	65	0	126	5	5	0	17	0	0	219	0,4247
9	0	0	0	0	0	0	0	1	230	0	0	0	0	0	231	0,0043
10	49	205	17	16	0	117	2	2	0	428	1	35	0	76	948	0,5485
11	4	0	7	0	0	0	0	0	3	0	115	42	0	1	172	0,3314
12	3	125	7	0	194	133	0	15	4	19	4	223	2	2	731	0,6949
13	0	22	0	0	12	43	1	9	0	0	0	11	1593	0	1691	0,0580
14	163	88	17	0	0	0	0	0	0	0	0	0	0	51	319	0,8401
Total	724	1731	361	199	481	511	434	169	255	500	136	360	1809	635	8305	
Erro C,	0,6533	0,4015	0,3019	0,2462	0,4428	0,7710	0,0415	0,2544	0,0980	0,1440	0,1544	0,3806	0,1194	0,9197		0,3671

1- Mata 2- Café solteiro 3- Eucalipto grande 4- Eucalipto novo 5- Solo exposto 6- Milharal 7- Cana 8- Cana queimada 9- Água 10- Taboa 11- Sombra 12- Afloramento de rocha 13- Pastagem 14- Café com árvore.

Tabela A9 - Matriz de erros da classificação por regiões utilizando 17 classes – Kappa 0,76

Amostras de validação	Imagem classificada - Temática																	E.O. (%)	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17		Total
1	6176	0	0	0	672	0	0	64	48	0	0	0	0	0	0	0	112	7072	0,1266
2	512	10304	0	0	560	192	0	896	0	16	0	0	208	0	0	0	1872	14560	0,2923
3	16	1088	6912	2480	0	0	0	112	0	0	0	0	176	0	0	0	0	10784	0,359
4	0	0	0	7264	0	0	288	368	1664	0	0	0	48	0	0	1648	0	11280	0,356
5	4752	0	112	0	4048	0	0	1360	0	0	0	0	0	32	0	0	176	10480	0,6137
6	0	0	0	0	0	3552	0	0	0	0	0	0	0	0	0	0	0	3552	0
7	0	0	0	0	0	0	7168	0	0	0	0	0	0	0	0	0	0	7168	0
8	320	0	112	48	1232	0	0	3664	16	0	0	0	208	0	0	0	656	6256	0,4143
9	0	0	64	0	0	0	32	96	7104	0	0	0	0	0	528	64	112	8000	0,112
10	0	0	0	0	0	0	0	0	0	7072	0	0	0	0	0	0	0	7072	0
11	0	0	0	0	0	0	0	0	0	0	2464	0	0	0	0	0	0	2464	0
12	0	0	0	0	0	0	0	0	0	0	0	6336	0	0	0	0	0	6336	0
13	0	304	1232	0	0	176	16	16	1920	16	112	16	6912	0	272	0	1216	12208	0,4338
14	32	0	0	0	0	0	0	0	0	0	0	0	0	3600	32	0	0	3664	0,0174
15	0	0	0	0	0	0	0	0	240	0	0	0	0	16	4896	0	0	5152	0,0496
16	0	0	1040	1072	0	0	176	96	592	464	240	0	304	0	0	27424	0	31408	0,1268
17	128	48	0	0	0	0	0	736	0	0	0	0	0	16	240	0	6224	7392	0,1876
Total	11936	11744	9472	10864	6512	3920	7680	7408	11584	7568	2816	6352	7856	3664	5968	29136	10368		
E.C.	0,4825	0,1226	0,2702	0,3313	0,3783	0,093	0,066	0,5053	0,3867	0,065	0,125	0	0,1201	0,017	0,1796	0,0587	0,3996		

1- Mata 2- Café solteiro adulto 3- Café solteiro jovem 4- Café pequeno 5- Eucalipto grande 6- Eucalipto jovem 7- Solo exposto 8- Capoeira 9- Milharal 10- Cana 11- Cana queimada 12- Água 13- Taboa 14- Sombra 15- Afloramento de rocha 16- Pastagem 17- Café com árvore

Tabela A10 - Matriz de erros da classificação por regiões utilizando 14 classes – Kappa 0,68

Amostras de validação	Imagem classificada - Temática														Total	E. C.
	1	2	3	4	5	6	7	8	9	10	11	12	13	14		
1	3424	544	32	0	0	0	0	0	0	0	32	0	0	0	4032	0,1507
2	4976	14784	832	16	1120	656	32	96	0	1792	0	112	528	7712	32656	0,5472
3	496	816	4576	16	0	0	0	0	0	160	16	0	0	896	6976	0,344
4	0	1856	0	3248	0	0	0	0	0	0	0	0	0	0	5104	0,3636
5	0	1920	0	0	4480	0	0	0	0	0	0	0	2768	0	9168	0,5113
6	0	96	0	0	0	1520	0	240	0	0	0	0	0	0	1856	0,181
7	0	0	0	0	0	0	6592	0	0	80	0	0	0	0	6672	0,0119
8	0	0	0	0	0	0	0	2224	0	0	0	0	0	0	2224	0
9	0	16	0	0	0	0	0	0	3600	0	320	832	0	0	4768	0,2449
10	32	0	0	0	0	1072	0	0	0	3824	0	0	0	256	5184	0,2623
11	0	0	304	0	0	0	0	0	0	0	1808	2112	0	0	4224	0,5719
12	0	4176	0	0	0	1056	32	0	0	1072	0	624	160	416	7536	0,9171
13	0	2144	0	0	896	3824	32	224	176	800	0	1616	25520	208	35440	0,2799
14	2448	2256	144	0	0	0	0	0	0	0	0	192	0	384	5424	0,9292
Total	11376	28608	5888	3280	6496	8128	6688	2784	3776	7728	2176	5488	28976	9872		
E.C. (%)	0,699	0,4832	0,2228	0	0,3103	0,8129	0,0143	0,2011	0,0466	0,5051	0,1691	0,8862	0,1192	0,9611		

1- Mata 2- Café solteiro 3- Eucalipto grande 4- Eucalipto novo 5- Solo exposto 6- Milharal 7- Cana 8- Cana queimada 9- Água 10- Taboa 11- Sombra 12- Afloramento de rocha 13- Pastagem 14- Café com árvore.

Tabela A11 - Matriz de erros da classificação da comunidade 8 classes – Kappa 0,55

Amostras de validação	Imagem classificada - Temática									
	1	2	3	4	5	6	7	8	Total	E. O. (%)
1	9504	0	0	2656	0	0	0	0	12160	0,2184
2	0	16608	5056	0	0	0	0	0	21664	0,2333
3	0	736	3712	0	0	0	0	0	4448	0,1654
4	0	1504	32	2224	0	0	0	0	3760	0,4085
5	0	32	16	0	1728	0	0	0	1776	0,0270
6	0	16	0	0	0	4304	0	0	4320	0
7	0	16	0	0	0	0	0	0	16	1
8	2112	6176	0	2144	5136	2048	7584	29440	54640	0,4612
Total	11616	25088	8816	7024	6864	6352	7584	29440	67520	
E. C. (%)	0,1818	0,3380	0,5789	0,6833	0,7482	0,3224	1	0		

1- Mata 2- Café solteiro 3- Café com árvore 4- Eucalipto 5- Milho 6- Cana 7- Taboa 8- Pastagem