

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

CLASSIFICAÇÃO DA COBERTURA E USO DO SOLO UTILIZANDO REDES
NEURAS ARTIFICIAIS COMO SUBSÍDIO AO PLANO DE MANEJO DO PARQUE
NACIONAL DA SERRA DO CIPÓ E ÁREA DE PROTEÇÃO AMBIENTAL MORRO DA
PEDREIRA / MG

ELIANA DE SOUZA

VIÇOSA
MINAS GERAIS - BRASIL
FEVEREIRO, 2007

Universidade Federal de Viçosa
Centro de Ciências Humanas, Letras e Artes
Departamento de Artes e Humanidades
Curso de Geografia

CLASSIFICAÇÃO DA COBERTURA E USO DO SOLO UTILIZANDO REDES
NEURAIS ARTIFICIAIS COMO SUBSÍDIO AO PLANO DE MANEJO DO PARQUE
NACIONAL DA SERRA DO CIPÓ E ÁREA DE PROTEÇÃO AMBIENTAL MORRO DA
PEDREIRA / MG

Monografia apresentada a Universidade
Federal de Viçosa como parte das exigências
da disciplina GEO 481 - Monografia e
Seminário do curso de Geografia, para a
obtenção do título de Bacharela em Geografia.

Autora: Eliana de Souza
Orientador: Elpídio Inácio Fernandes Filho

Viçosa
Minas Gerais - Brasil
Fevereiro, 2007

Eliana de Souza

CLASSIFICAÇÃO DA COBERTURA E USO DO SOLO UTILIZANDO REDES
NEURAS ARTIFICIAIS COMO SUBSÍDIO AO PLANO DE MANEJO DO PARQUE
NACIONAL DA SERRA DO CIPÓ E ÁREA DE PROTEÇÃO AMBIENTAL MORRO DA
PEDREIRA / MG

Aprovada: 26 de Fevereiro de 2007.

Prof. Patrício Aureliano Silva Carneiro

Prof. Carlos Antônio Oliveira Vieira

Prof. Elpídio Inácio Fernandes Filho
(Orientador)

Dedico este trabalho à minha mãe,

Geralda Maria de Souza

Minha sincera gratidão!

AGRADECIMENTOS

À Deus por ter me concedido a vida por meio dos meus pais.

Aos meus pais, Geralda M. Souza e Sebastião C. Souza (*in memória*). Sem os quais eu não teria chegado até aqui.

Ao Professor Elpídio pela orientação durante longo tempo da minha graduação e no caminhar desta pesquisa. Obrigada pela confiança em mim depositada e pelo incentivo.

Ao Professor Carlos Schaefer pela oportunidade de participar dos trabalhos do “Projeto Cipó”, o que tornou possível realizar esta pesquisa.

Ao César Chagas, pelo acompanhamento nos trabalhos de campo e laboratório, especialmente no processo de classificação.

Ao Professor Carlos Vieira pelo apoio em Redes Neurais, correções e sugestões.

Aos professores de Geografia André Luiz L. Faria pelas orientações e sugestões e Patrício Carneiro pela contribuição.

A todos que colaboraram com esta pesquisa em atividades de campo e ou laboratório. Acauã, Bruno, Roberto, Elton, Walnir e Luiz Carlos.

Aos amigos do Labgeo e estudantes do DPS que compartilharam comigo importantes idéias e momentos da minha “caminhada” na UFV. Em especial ao saudoso amigo Henrique de Oliveira (*in memória*), e família pelo incentivo, e momentos de descontrações.

Ao IBAMA pela infra-estrutura e recursos humanos disponibilizados.

A Universidade Federal de Viçosa e aos Departamentos de Artes e Humanidades e Solos por tudo que se fizeram necessário para esse trabalho que representa a conclusão de uma etapa da minha carreira profissional. Obrigada, em nome da Sociedade Brasileira.

SUMÁRIO

LISTA DE FIGURAS.....	iv
LISTA DE TABELAS.....	iv
RESUMO.....	vii
1. INTRODUÇÃO.....	1
2. CARACTERIZAÇÃO GERAL DA ÁREA DE ESTUDO.....	2
3. REVISÃO DE LITERATURA	5
3.1 A questão ambiental.....	5
3.2 Estratificação ambiental.....	7
3.2.1 Biomas.....	7
3.2.2 Bioma Mata Atlântica.....	8
3.2.3 Bioma Cerrado.....	9
3.3 <i>Hotspots</i> Mundiais: Bioma Mata Atlântica e Bioma Cerrado.....	10
3.4 Tipologias vegetais.....	11
3.4.1 Floresta de Galeria.....	11
3.4.2 Mata Seca.....	11
3.4.3 Cerradão.....	11
3.4.4 Cerrado sentido restrito.....	11
3.4.5 Formações Campestres.....	12
3.4.6 Campo Rupestre.....	12
3.4.7 Mata de Candeia.....	13
3.4.8 Floresta Estacional Semidecidual.....	13
3.4.9 Floresta Estacional Semidecidual (Capões de mata).....	13
3.5 Unidades de Conservação.....	15
3.5.1 Parque Nacional – PARNA.....	16
3.5.2 Área de Proteção Ambiental – APA.....	16
3.6 Geoprocessamento.....	16
3.6.1 Sistema de Informação Geográfica.....	17
3.6.2 Sensoriamento Remoto.....	17
3.7 Classificação de imagem.....	19
3.7.1 Máxima Verossimilhança - MAXVER.....	19
3.7.2 Redes Neurais Artificiais - RNA.....	19
4. MATERIAIS E MÉTODOS.....	24
4.1 Software.....	24

4.2	Hardwares.....	25
4.3	Dados cartográficos.....	25
4.4	Metodologias.....	25
4.4.1	Trabalho de laboratório.....	25
4.4.2	Trabalho de campo.....	26
4.4.3	Definição das classes de cobertura e uso do solo.....	27
4.4.4	Definição das Variáveis.....	27
4.4.4.1	Imagem de satélite.....	27
4.4.4.2	Índice de Vegetação por Diferença Normalizada - NDVI.....	27
4.4.4.3	Modelo Digital de Elevação – MDE.....	28
4.4.4.4	Declividade.....	28
4.4.4.5	Índice Topográfico Combinado - ITC.....	29
4.4.4.6	Geologia.....	29
4.4.5	Amostragem.....	29
4.4.6	Conjuntos de variáveis.....	30
4.4.6.1	Conjunto 1.....	30
4.4.6.2	Conjunto 2.....	30
4.4.6.3	Conjunto 3.....	31
4.4.7	Classificação.....	32
4.4.8	Validação da exatidão da classificação.....	33
4.4.9	Pós-processamento.....	34
5.	RESULTADOS E DISCUSSÃO.....	35
5.1	Classificação do conjunto 1.....	35
5.2	Classificação do conjunto 2.....	37
5.3	Classificação do conjunto 3.....	38
5.4	Classificação do conjunto 1 pelo MAXVER.....	40
5.5	Avaliação do índice de significância entre as classificações.....	41
5.6	Representação do mapa de cobertura e uso do solo.....	42
6.	CONCLUSÕES.....	45
7.	LITERATURA CITADA.....	46

LISTA DE FIGURAS

FIGURA 1 – LOCALIZAÇÃO DAS UC'S NO ESTADO DE MINAS GERAIS.....	4
FIGURA 2 – LOCALIZAÇÃO DAS UC'S EM RELAÇÃO NO MAPA DE BIOMAS. ..	5
FIGURA 3 – CAMPO RUPESTRE HERBÁCEO EM PRIMEIRO PLANO.	13
FONTE: ELPÍDIO INÁCIO FERNANDES FILHO.....	13
FIGURA 4 – CAMPO RUPESTRE HERBÁCEO / ARBUSTIVO.....	14
FIGURA 5 – COBERTURA VEGETAL: CERRADO	14
FIGURA 6 – ARQUITETURA DE REDE NEURAL, MODELO MULTICAMADAS. 20	
FIGURA 7 – VARIÁVEIS SELECIONADAS PELO APLICATIVO <i>FUNCPOW</i> PARA O CONJUNTO 2.	32
FIGURA 8 – MAPA GERADO PELA CLASSIFICAÇÃO POR REDE NEURAL COM AS VARIÁVEIS DO CONJUNTO 1.....	44

LISTA DE TABELAS

TABELA 1 – CARACTERÍSTICAS DAS BANDAS DO SENSOR ETM+	18
TABELA 2 – ÍNDICE KAPPA ENTRE GRUPO DE VARIÁVEIS	31
TABELA 3 – MATRIZ DE CONFUSÃO – CONJUNTO 1.....	36
TABELA 4 – MATRIZ DE CONFUSÃO – CONJUNTO 2.....	38
TABELA 5 – MATRIZ DE CONFUSÃO – CONJUNTO 3.....	39
TABELA 6 – MATRIZ DE CONFUSÃO DO CONJUNTO 1 PELO MAXVER.....	41
TABELA 7 – ÍNDICES DE SIGNIFICÂNCIA DAS CLASSIFICAÇÕES – TESTE Z. 42	
TABELA 8 – QUANTIFICAÇÃO DAS CLASSES MAPEADAS	43

RESUMO

As Unidades de Conservação (UC's) Parque Nacional da Serra do Cipó (PNSCi) e a Área de Proteção Ambiental Morro da Pedreira. Situam-se na Serra do Cipó, borda oeste da Cordilheira do Espinhaço, MG, são territorialmente delimitadas pela importância da biodiversidade nelas contidas, beleza cênica e relevantes monumentos históricos, geológico. Essas áreas devem ser usadas sob plano de manejo adequado para garantir a manutenção dos recursos para as gerações presentes e futuras. Este trabalho teve como objetivo avaliar a classificação supervisionada por redes neurais das classes de cobertura e uso do solo, a partir dos dados obtidos pelo sensor ETM⁺ e de dados do meio físico, com vistas a subsidiar o plano de manejo. O simulador de Redes Neurais utilizado foi o JavaNNS, (2001). Os trabalhos de campo foram realizados entre Agosto a Dezembro de 2006 para a coleta de dados de referência. 300 pontos de amostras foram coletados. As classes de cobertura e uso do solo identificadas foram: Cerrado (Formações campestre); Campo Rupestre herbáceo; Campo Rupestre herbáceo/arbustivo; Floresta de Candeia; Cerradão (Cerradão + Cerrado Senso restrito); Floresta de Galeria, Mata Seca; Pastagem; Floresta Semidecidual; Capões de mata e Água. As variáveis discriminantes bandas 1, 2, 3, 4, 5 e 7 do Landsat; geologia, altitude (MDE), declividade, e índices (CTI e NDVI) derivados do MDE e bandas da imagem, compuseram três conjuntos de variáveis para classificações. O Conjunto 1 agregou todas as variáveis; o Conjunto 2 agregou as bandas 4 e 1 do Landsat, a geologia e o MDE; o Conjunto 3 foi composto com as bandas espectrais. O resultado da classificação mostrou maior exatidão de mapeamento quando utilizou as variáveis discriminantes do Conjunto1, sendo a classificação deste conjunto estatisticamente melhor que a classificação realizada para os demais conjuntos. O índice *kappa*, que representa a concordância entre o mapa temático gerado e os dados de referência de campo, para o Conjunto 1 foi de 0,95, considerado um resultado de classificação excelente. A classificação do Conjunto 3 apresentou *kappa* de 0,61. O conjunto 1 foi classificado pelo MAXER para uma comparação entre classificadores, obtendo um *kappa* de 0,74. Concluiu-se que a classificação por redes neurais mostrou-se mais adequada para classificar a cobertura e uso do solo das UC's do que o algoritmo MAXVER; os dados do meio físico mostraram se relevantes no processo de classificação e por fim concluiu que o mapa de cobertura e uso do solo gerado com a classificação pela RN com as variáveis do Conjunto 1 é um documento cartográfico com dados de base para subsidiar a elaboração do plano de manejo das UC's deste estudo.

1. INTRODUÇÃO

As Unidades de conservação (UC's) constituem uma porção do espaço geográfico delimitadas territorialmente pela ocorrência de importante biodiversidade e beleza cênica. A Criação UC têm-se mostrado como uma das melhores estratégias de conservação da biodiversidade, principalmente quando monitoradas a partir de informações de um plano de manejo bem elaborado (COSTA, 2000).

A elaboração do plano de manejo envolve estudos do espaço geográfico de todo o domínio do territorial da unidade a ser planejada. O conhecimento do espaço é o primeiro passo para que se possa fazer o planejamento de ações e atividades a serem desenvolvidas, principalmente em unidades de conservação, que são áreas criteriosamente delimitadas para a conservação de relevante biodiversidade.

No final da década de 80, os objetivos do geoprocessamento, passaram a ser mais abrangente, incluindo técnicas empregadas para o tratamento de imagens digitais, a manipulação de dados geográfico e o cruzamento de dados (MOREIRA, 2005). Essas novas técnicas criadas implicaram no desenvolvimento conjunto de processamento de dados digitais e Sistemas de Informações Geográficas além da criação de técnicas de classificação de imagens e geração de fontes de dados a partir de dados de satélites (MOREIRA, 2005).

Os avanços na área de Geoprocessamento, e a disponibilidade de dados de sensoriamento remoto tais como as imagens de satélites para mapeamento dos recursos naturais cuja aquisição tem sido feita deste início da década de 70 tem possibilitado realizar o processo de mapeamento das características da cobertura da terra de forma menos subjetivo e com maior potencial de repetição em situações subseqüentes (NOVO, 1989).

O mapeamento da cobertura terrestre, especialmente as classes de e uso do solo tem sido feito nos últimos anos utilizando técnicas computacionais por meio de algoritmos de classificação. Mais recentemente tem se utilizado Redes Neurais Artificiais para trabalhos de classificação, empregando dados de sensores remotos e dados de mapas temáticos.

A classificação da cobertura e uso do solo permite a elaboração de um mapa que é um dos documentos considerado de grande relevância para estudos e tomada de decisão quando se elabora um plano de manejo de uma UC. Com o mapa faz-se o reconhecimento das principais formações vegetais e suas extensões.

O mapa funciona como fonte de informação primária para embasar o zoneamento e a elaboração de cenários para o período presente e futuro por meio da delimitação de zonas de

agrupamento de tipologias homogêneas e determinação de zonas e o tipo de uso com graus de uso mais ou menos restritivo.

O mapa de cobertura e uso do solo contribui para a proteção de enclaves florestais disjuntos em meio a biomas diferentes daqueles de origem, sobretudo no Brasil onde algumas leis de proteção dos recursos naturais são específicas para cada bioma.

Considerando a importância do mapeamento da cobertura vegetal para a conservação ambiental, o objetivo geral deste trabalho foi avaliar a classificação supervisionada por redes neurais das classes de cobertura e uso do solo das Unidades de Conservação Parque Nacional da Serra do Cipó e Área de Proteção Ambiental Morro da Pedreira – MG, a partir dos dados obtidos pelo sensor ETM⁺ do satélite Landsat 7 e de dados do meio físico, com vistas a subsidiar o plano de manejo.

2. CARACTERIZAÇÃO GERAL DA ÁREA DE ESTUDO

A área de estudo compreende as Unidades de Conservação (UC's) Parque Nacional da Serra do Cipó (PNSCi) e a Área de Proteção Ambiental Morro da Pedreira. Essas UC's situam-se na Serra do Cipó, borda oeste da Cordilheira do Espinhaço, Estado de Minas Gerais. Juntas possuem 131.739,4 ha, sendo 31.632,4 ha referente ao território do PNSCi. A área abrange os municípios de Santana do Riacho, Jaboticatubas, Morro do Pilar, Itambé do Mato Dentro, Itabira, Nova União e Taquaraçu de Minas (Figura 1). São UC's cujo ordenamento territorial é de responsabilidade do Governo Federal por meio do Instituto Brasileiro de Meio Ambiente e Recursos Naturais Renováveis (IBAMA).

Através do decreto Nº 90.223, de 25 de setembro de 1984, foi criado o Parque Nacional da Serra do Cipó. A APA Morro da Pedreira foi criada por meio do Decreto Nº 98.891, de 26 de janeiro de 1990 com os objetivos de garantir a proteção do PNSCi, o conjunto paisagístico de parte do maciço do Espinhaço, proteger e preservar o Morro da Pedreira, sítios arqueológicos e cobertura vegetal que abriga grande diversidade de espécies da fauna silvestre, objetivou também proteger os mananciais da região (IBAMA, 2006a). A área contém um rico acervo arqueológico, com destaque para o Sítio Arqueológico de Santana do Riacho, além de inúmeros registros de pinturas rupestres em abrigos e cavernas.

O relevo é composto por dois geossistemas, um montanhoso formado pelo conjunto de alinhamentos de cristais e superfícies aplainadas entre as altitudes 1.100 e 1.600 metros (Espinhaço) e outro semi-montanhoso da Bacia Inter-planáltica do Médio Rio Cipó que corresponde aos vales (IBAMA, 2006c).

A geologia do Espinhaço vem sendo estudada desde um século e meio atrás, principalmente pela importância dos depósitos de diamantes (RENGER, 1979). Na Serra do Cipó a geologia é composta pelo Super-Grupo Espinhaço, Grupos Macaúbas e Bambuí e Depósitos do Quaternário formando um mosaico de rochas com predomínio de rochas metamórficas com graus variados de metamorfismo e xistosidade. Dentre as unidades litológicas destacam-se: rochas quartzíticas e metapelíticas com recobrimento de mais de 50% das UC's, ocorrem também rochas cristalinas granítico-gnaissicas, rochas calcárias e, em menor extensão, as rochas metabásicas e sedimentos do quaternário (COMIG, 1997).

Os eventos tectônicos que modelaram o relevo do Espinhaço produziram dobramentos com um padrão geomorfológico de expressivo contraste com as áreas adjacentes. Na porção da Serra do Cipó o relevo é movimentado com altitude variando entre 591 à 1.704 metros; mais de 50% da área de está acima da cota de 1.100 metros.

Em relação à cobertura vegetal destacam-se os campos rupestres, que recobrem as regiões de altitude acima de 1000 m, com uma variedade de espécies, como *paepalanthus*, *vellozia* e *chamaecrista*. Em regiões de umidade um pouco mais elevada encontram-se as matas mesófilas (capões de mata), geralmente com forte controle litológico, determinado pela presença de rochas metabásicas. Nas áreas mais baixas encontram-se amostras de cerrado e cerradão. Ao longo dos cursos d'água estão presentes as matas de galeria e nos afloramentos de calcário que margeiam a serra encontram-se as matas secas sobre calcário (IBAMA, 2006c; COMIG, 1997).

O acesso à Serra do Cipó é feito por rodovia asfaltada, como também por vias de acesso não pavimentadas. A MG 010 liga a capital, Belo Horizonte, à cidade de Conceição do Mato Dentro, passando pela sede do PNSCi. A facilidade de acesso, a proximidade da região metropolitana de Belo Horizonte e a grande atração turística confere à Serra do Cipó um a condição de área de média/alta pressão antrópica (MMA, 2004).

No que se refere aos recursos hídricos a Serra do Cipó é um ambiente de alta importância para a conservação de nascentes. Nela concentram-se nascentes que produzem água para duas bacias hidrográficas, Bacia do Rio das Velhas e Bacia do Rio Doce. Com a primeira contribuem os rios Cipó, Rio Parauninha, Rio Preto e Rio Mascote. O Rio Preto de Cima contribui com a Bacia do Rio Doce (IBGE, 1977). O rio Cipó, que deu nome a Serra, pela extensão de meandros em forma de cipó, foi o símbolo para a criação do PNSCi, que objetivou a conservação de suas nascentes e, conseqüentemente, garantir a produção de água para o abastecimento da área metropolitana de Belo Horizonte.

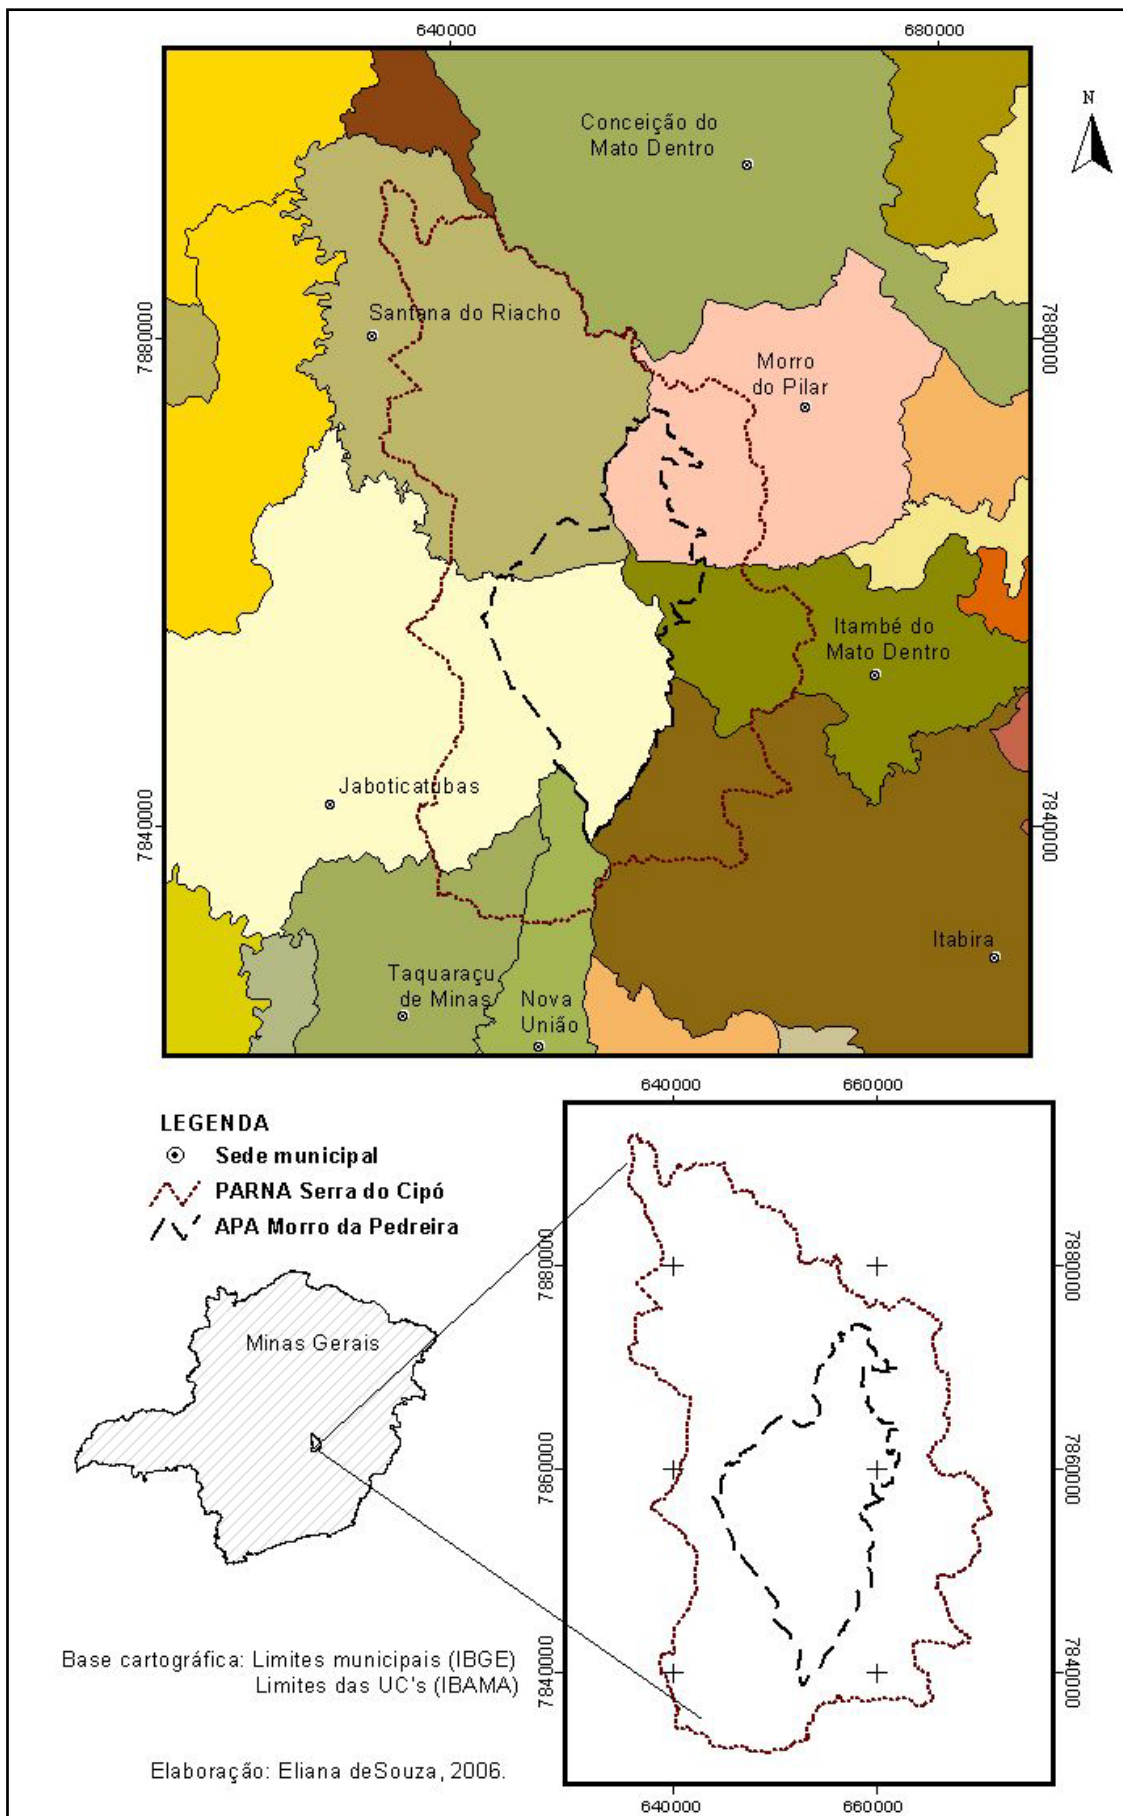


Figura 1 – Localização das UC's no Estado de Minas Gerais.

No que diz respeito ao turismo na Serra do Cipó o recurso hídrico é um dos principais focos de atração, principalmente pelas quedas d'água. Destacam-se a Cachoeira Vêu da Noiva, Cachoeira Grande, Cachoeira Serra Morena, na APA. No PANCi tem-se a Cachoeira Farofa e Taioba, além do Cânion das Bandeirinhas, “cartão postal do Parque” de grande procura pelos visitantes.

De acordo com o mapa de Biomas do Brasil (IBAMA, 2006 b), o PNSCi e a APA Morro da Pedreira inserem-se em sua totalidade no Bioma Cerrado (Figura 2). Entretanto, observa-se a presença de extensas formações vegetais do Bioma Mata Atlântica na forma de enclaves de Matas Semidecíduas nessas UC's, o que denota a necessidade de rever os princípios que regem a conservação de áreas florestais no Bioma Cerrado.



**Figura 2 – Localização das UC's em relação no mapa de biomas.
Fonte: IBAMA (2006b) – Escala 1:6.000.000.**

3. REVISÃO DE LITERATURA

3.1 A questão ambiental

O discurso conservacionista se intensificou no final do século XX, momento em que a questão ambiental assumiu importância central nos debates sobre o futuro da humanidade (GASTAL, 2002). A partir deste momento vários foram os documentos publicados que

discorreram sobre as questões ambientais. Em 1972 o Clube de Roma publicou “Os limites do crescimento” ou Relatório *Meadows*, documento que movimentou os ambientalistas preocupados com a sustentabilidade do planeta.

Em Estocolmo, a conferência da ONU sobre o ambiente humano, também em 1972, reuniu 113 países, 250 organizações não governamentais e organismos da ONU para discutirem problemas ambientais, sobretudo, a poluição. A pobreza e o subdesenvolvimento foram reconhecidos como causas da degradação ambiental.

Em 1987 a publicação do Relatório *Brundtland* (Nosso Futuro Comum) trouxe uma nova forma de tratar a questão ambiental, vinculada aos aspectos econômicos e sociais, desenhando o mapa político da humanidade (GASTAL, 2002). O conceito de desenvolvimento sustentável de acordo com esse relatório refere-se a “...crescimento convincente e, ao mesmo tempo, duradouro do ponto de vista social e ambiental”. Em 1992 nasceu um instrumento internacional voltado para a biodiversidade, a Conferência das Nações Unidas sobre o Desenvolvimento e Meio Ambiente, realizada no Rio de Janeiro com a elaboração e assinatura de cinco documentos, a saber: a Declaração do Rio sobre o Meio Ambiente e Desenvolvimento, a Agenda 21, os Princípios para a Administração Sustentável das Florestas, a Convenção sobre mudanças do Clima e a Convenção sobre Diversidade Biológica. (GASTAL, 2002).

No Brasil, as ações governamentais desenvolvidas visando à conservação da biodiversidade, estão concretizadas em um capítulo sobre o Meio Ambiente na Constituição Federal de 1988, com a Política Nacional de Meio Ambiente, com o Conselho Nacional de Meio Ambiente – Conama e com o Sistema Nacional de Meio Ambiente – Sisnama. O Sistema Nacional de Unidades de Conservação (SNUC), criado em 2000, representa o esforço do Estado Brasileiro em estabelecer a coesão, o ordenamento e o aprimoramento das iniciativas governamentais em relação as unidades de conservação.

No Capítulo da Constituição Federal que aborda do Meio Ambiente define-se que todos tem direito ao meio ambiente ecologicamente equilibrado, sendo este um bem de uso comum do povo e essencial à qualidade de vida sadia. Este documento impõe ao poder público e à coletividade o dever de defender e preservar o meio ambiente para as presentes e futuras gerações. Incumbe ao poder público a função de preservar e restaurar os processos ecológicos essenciais e o provimento do manejo ecológico das espécies e ecossistemas, bem como a definição, em todas as unidades da federação, de espaços territoriais e seus componentes a serem especialmente protegidos (BRASIL, 2005).

3.2 Estratificação ambiental

A estratificação de ambientes no Brasil, em escala continental, foi realizada por Ab'Saber, consolidando uma tradição que se iniciou a primeira divisão fitogeográfica do Brasil feita por Karl Martius em 1823 (Ab'SABER, 1996; RIZINNI, 1997). Nessa estratificação Ab'SABER utilizou o conceito de Domínios Morfoclimáticos, que em suas palavras corresponde a um certo espaço relevante em áreas continentais, onde a ação dos climas, sobretudo os mais recentes, resultou em determinado modelado regional.

As características da vegetação, portanto, se apresentam de forma distinta respondendo principalmente aos fatores climáticos. De acordo com Ab'saber (1996), para o entendimento da cobertura vegetal dos diferentes domínios da natureza, deve-se ter por base os conceitos de Domínios Morfoclimáticos e fitogeográficos (bioma). Ainda de acordo com Ab'Saber (1996), em grande parte a linguagem de domínios morfoclimáticos e biomas se superpõem, não existindo impedimento no uso de um ou de outro, uma vez que não se misture os conceitos. Outras divisões fitogeográficas do território Brasileiro foram feitas, vale ressaltar a divisão de Rizinni em 1963, que definiu três províncias florístico-vegetacionais (RIZINNI, 1997).

Neste trabalho foi adotado a divisão fitogeográfica de biomas, assim como proposta por Ab'Saber (1996). A estratificação ambiental a partir do conceito de bioma é importante, uma vez que as legislações de gerenciamento dos recursos naturais no Brasil, sobretudo de unidades de conservação, usa a delimitação do país em biomas para tratar as questões de uso e manejo dos recursos naturais.

3.2.1 Biomas

Um bioma é entendido como uma unidade biótica de maior extensão geográfica, compreendendo várias comunidades em diferentes estágios de evolução denominado de acordo com o tipo de vegetação. Os biomas foram delimitados considerando fatores climáticos tais como a temperatura, a pluviosidade e a umidade relativa, e em menor escala considerou o tipo de substrato (RIBEIRO & WALTER, 1998).

No Brasil, considera-se a ocorrência de seis grandes biomas: Bioma Amazônia, Bioma Mata Atlântica, Bioma Caatinga, Bioma Cerrado, Bioma Pantanal e Bioma Pampa. O Mapa de Vegetação do Brasil foi tomado como referência para embasar a delimitação dos biomas a partir da tipologia original da vegetação (RIBEIRO & WALTER, 1998; IBGE, 2004b).

Algumas formações florestais sob a forma de capões com fortes similaridades com a floresta atlântica, aparecem no PNSCi e APA Morro da Pedreira, área de estudo deste

trabalho, corroborando com AB'Saber (1996) que diz que pequenos “enclaves” também denominados refúgios podem ocorrer no interior de bioma que se apresenta como pano de fundo, ou seja, como predominante. A explicação dessas ocorrências, segundo AB'Saber (1996), relaciona-se com a diversidade dos solos e sobretudo a um distanciamento do padrão do domínio pedológico regional. Portanto, neste trabalho embora as UC's estudadas estejam, de acordo IBAMA (2006b), inseridas no Bioma Cerrado, estas serão entendidas como um ecótono, zona de transição entre dois Biomas.

3.2.2 Bioma Mata Atlântica

O Bioma Mata Atlântica ocorre desde o norte até o sul do Brasil, ocupando principalmente o sistema costeiro do país. Esse bioma compreende um complexo ambiental que incorpora cadeias de montanhas, platôs, vales e planícies de toda a faixa continental atlântica leste brasileira. Abrange litologias do embasamento Pré-Cambriano, sedimentos da Bacia do Paraná e sedimentos Cenozóicos (IBGE, 2004b).

A fitofisionomia do bioma Mata Atlântica, constitui o grande conjunto florestal extra-amazônico, formado por florestas ombrófilas (densa, aberta e mista) e estacionais (semidecíduais e decíduais).

A Floresta Ombrófila densa constitui o núcleo do bioma, com forte influência marítima condicionando a riqueza estrutural e florística da vegetação. As formações primárias remanescentes das Florestas Estacionais ocupam situações geográficas mais interioranas em relação às Florestas Ombrófilas, afastadas ou mais abrigadas da influência estabilizadora marítima, apresentando inserções disjuntas da Estepe e da Savana (IBGE, 2004b).

A perda da biodiversidade é um dos grandes problemas a que este bioma enfrenta, pois, ele tem sido palco dos principais episódios da colonização e ciclos de desenvolvimento do país. O Bioma Mata Atlântica abriga a maior densidade de população e as mais importantes atividades econômicas do país (IBGE, 2004b). Esse ambiente foi intensamente devastado, sendo mais preservado em parques nacionais e na Serra do Mar, onde o relevo montanhoso dificulta a exploração florestal e a ocupação humana (FLORENZANO, 2002).

Considerado um dos mais importantes ecossistemas do Planeta O Bioma Mata Atlântica é um dos mais ameaçados. De acordo com o MMA (2002), ele foi reduzido a 8% de sua extensão original abriga vasta maioria dos animais e plantas ameaçados de extinção no Brasil. No Bioma Mata Atlântica constitui patrimônio nacional sendo a utilização dos seus recursos naturais deste feito na forma da lei dentro de condições que assegurem a preservação do meio ambiente (BRASIL, 1988).

O Corte, a exploração e a supressão de vegetação primária ou em estágios avançados e médio de regeneração no Bioma Mata Atlântica é proibido conforme o decreto 750 de 1993 (Brasil, 1993). Excepcionalmente essas atividades poderão ser feitas mediante autorização do IBAMA. Tais atividades são autorizadas somente quando necessárias à execução de obras, planos, atividades ou projetos de utilidade pública ou interesse social e após estudo e relatório de impacto ambiental.

3.2.3 Bioma Cerrado

O Bioma cerrado é o segundo maior do Brasil em área, superado apenas pela Floresta Amazônica, possui cerca de 2 milhões de km². Se estende desde o Pantanal Matogrossense até a faixa litorânea maranhense (IBGE, 2004 b). Este caracteriza-se pela presença de invernos secos e verões chuvosos, o clima é classificado como tropical chuvoso pela classificação de Köppen Aw. As chuvas concentram-se nos meses de outubro a março, variando entre 600 e 2200 mm anuais (RIBEIRO & WALTER, 1998; IBGE, 2004 b).

A vegetação do Bioma Cerrado apresenta fisionomias que englobam formações florestais, savânicas e campestres. Em sentido Fisionômico, floresta representa áreas com predominância de espécies arbóreas, onde há formação de dossel contínuo ou descontínuo. O termo savana refere-se a áreas com árvores e arbustos espalhados sobre um estrato gramíneo, sem a formação de um dossel contínuo. Por sua vez o termo campo designa áreas com domínio de espécies herbáceas e algumas arbustivas, faltando árvores na paisagem (RIBEIRO & WALTER, 1998).

Ribeiro e Walter (1998) definiram onze classes os tipos fitofisionômicos gerais do Bioma Cerrado. São eles: formações florestais (Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão); formações savânicas (Cerrado sentido restrito, Parque de Cerrado, Palmeira e Vereda) e formações campestres (Campo Sujo, Campo Rupestre e Campo Limpo).

Estimativas apontam que uma em cada três espécies de planta nativa do Cerrado é usada pelo homem, de alguma forma. Desde longos anos Índios e colonizadores obtiveram do Cerrado espécies para alimento, remédio, forragem, artesanato, obtenção de fibra, óleo e tanino, dentre outros usos (IBGE, 2004b).

O Bioma Cerrado abriga o principal pólo de expansão da produção agropecuária do país. Atividade esta que já resultou em impactos ambientais tais como: a eliminação de uma expressiva porção da cobertura vegetal nativa, fragmentação da maioria dos habitats naturais, acarretando em elevada perda de biodiversidade, aumento da erosão dos solos e assoreamento de nascentes (IBGE, 2004b).

A geologia do Bioma Cerrado é uma das mais diversificadas e complexas do País, compreendendo rochas que remontam do Pré-Cambriano ao Cenozóico, com a predominância das primeiras. O relevo exibe formas morfológicas tais como planaltos, depressões e planícies, predominando os planaltos com topos planos constituindo extensas chapadas com escassa rede de drenagem. Os fatores apontados como determinantes para a predominância das formações com fitofisionomias savânicas que caracterizam o Bioma Cerrado são entre outros o clima, os solos e o fogo (IBGE, 2004b; RIZZINI, 1997).

O termo cerrado tem sido usado segundo três concepções gerais. A primeira, mais abrangente refere-se ao Bioma. A segunda acepção, cerrado sentido amplo (*lato sensu*), refere-se as formações savânicas e campestres do bioma, incluindo desde o cerradão até o campo limpo. A terceira concepção, por sua vez, faz referencia ao cerrado sentido restrito (*stricto sensu*), designa um dos tipos fitofisionômicos que ocorrem na formação savânica, definido pela composição florística e pela fisionomia. Esta é a principal fitofisionomia do cerrado, caracterizando bem o bioma (RIBEIRO & WALTER, 1998).

3.3 Hotspots Mundiais: Bioma Mata Atlântica e Bioma Cerrado

Em estudos para a delimitação de Áreas Prioritárias para a conservação em todo o mundo foram definidas 25 áreas denominadas *hotspots*, áreas que perderam pelo menos 70% de sua cobertura vegetal original, mas que, juntas, abrigam mais de 60% de todas as espécies terrestres do planeta (GALINDO-LEAL & CÂMARA, 2005). Os Biomas Mata Atlântica e Cerrado estão entre as 25 apontadas no mundo como *hotspots*, devido à riqueza biológica e à alta pressão antrópica a que vem sendo submetidos. A Mata Atlântica esta em quarto lugar em prioridade para conservação pela diversidade de anfíbios e de plantas vasculares. As formações vegetais remanescentes desse bioma abrigam uma biodiversidade impar. Em conjunto os mamíferos, as aves, os répteis e os anfíbios que ocorrem na Mata Atlântica somam 1.807 espécies sendo 398 endêmicas, conferido pela posição geográfica que confere alta diversidade biológica (MMA, 2002). No Bioma Cerrado estimativas apontam mais de 6.000 espécies de árvores e 800 espécies de aves, além da grande variedade de peixes e outras formas de vida (MMA, 2002).

3.4 Tipologias vegetais

As classes de vegetação foram identificadas em campo de acordo com as fisionomias e por possíveis mudanças estacionais, além de fatores do ambiente (geologia, solo, relevo e hidrologia). Baseou-se nas definições do mapa de vegetação do IBGE (2004a), Oliveira Filho & Fluminham Filho (1999), Rizzini (1997), Ribeiro & Walter (1998) e Veloso et al. (1991).

3.4.1 Floresta de Galeria

A floresta de Galeria compõe a fisionomia da Savana, ela ocorre ao longo dos cursos d'água, em terrenos relativamente férteis e sem déficit hídrico. É uma Floresta geralmente perenifólia, sendo o tipo de floresta mais freqüente no Bioma Cerrado (IBGE, 2004b). Conforme Ribeiro & Walter (1998), quase sempre a floresta de Galeria é circundada por faixas de vegetação não florestal em ambas as margens, e em geral ocorre uma transição brusca com formações savânicas e campestres.

3.4.2 Mata Seca

Mata Seca são formações caracterizadas por diversos níveis de quedas de folhas durante a estação seca. As espécies são dependentes das condições químicas, físicas e principalmente da profundidade do solo. ocorre sobre solos de origem calcária, as vezes com afloramentos rochosos típicos, sendo neste caso denominada Mata Seca em solo calcário ou Mata calcário (RIBEIRO & WALTER, 1998).

3.4.3 Cerradão

O Cerradão caracteriza-se pela presença de espécies que ocorrem no Cerrado sentido restrito e também por espécies de mata. Do ponto de vista fisionômico é uma floresta, mas floristicamente é mais similar a um Cerrado (RIBEIRO & WALTER, 1998). Segundo Rizzini, (1997) o Cerradão apresenta aspectos xeromórficos, tendo sido conhecido pelo nome “Floresta Xeromorfa”, ocorrendo na maior parte das vezes sobre solos profundos e bem drenados.

3.4.4 Cerrado sentido restrito

Caracteriza-se pela presença dos estratos arbóreo e arbustivo-herbáceo definidos, com árvores distribuídas aleatoriamente sobre o terreno em diferentes densidades. As árvores

apresentam-se baixas, inclinadas, tortuosas, com ramificações irregulares e retorcidas, e geralmente com evidências de queimadas.

De acordo com a densidade arbóreo-arbustiva, ou do ambiente em que se encontram o cerrado sentido restrito apresenta quatro subtipos: Cerrado Denso, Cerrado Típico, Cerrado Ralo e Cerrado Rupestre. As três primeiras refletem variações na forma dos agrupamentos e espaçamento entre os indivíduos lenhosos, seguindo um gradiente de densidade decrescente do Cerrado Denso ao Cerrado Ralo. O Cerrado Rupestre diferencia-se dos três primeiros subtipos pelo substrato, ocorrendo tipicamente em solos rasos com a presença de afloramentos de rocha (RIBEIRO & WALTER, 1998). A Figura 5 ilustra o Cerrado típico.

3.4.5 Formações Campestres

As formações campestres do Cerrado englobam três tipos fitofisionômicos principais: o Campo Sujo, o Campo Rupestre e o Campo Limpo. O Campo Sujo caracteriza-se pela presença marcante de arbustos e substratos entremeados no estrato herbáceo. O Campo Rupestre possui estrutura similar ao Campo Sujo, diferenciando-se tanto pelo substrato, composto por afloramentos de rocha, quanto pela composição florística, que inclui espécies endêmicas. No Campo Limpo a presença de arbustos e subarbustos é insignificante (RIBEIRO & WALTER, 1998).

3.4.6 Campo Rupestre

Campo Rupestre é um tipo fitofisionômico predominantemente herbáceo-arbustivo, com a presença eventual de arvoretas pouco desenvolvidas de até dois metros de altura. Abrange um complexo de vegetação que agrupa paisagens em microrelevos com espécies típicas, ocupando trechos de afloramentos rochosos (RIBEIRO & WALTER, 1998). Geralmente ocorre em altitudes superiores a 900 metros. A ocorrência dos Campos Rupestre esta associada a solos rasos e arenosos, derivados normalmente de rochas como quartzito e arenitos, essa característica do solo torna restrita a disponibilidade de água e por consequência uma flora típica dependente das condições edáficas restritivas e do clima peculiar (RIBEIRO & WALTER, 1998). A Figura 3 ilustra a vegetação de Campo Rupestre herbáceo, enquanto que a Figura 4 apresenta o Campo Rupestre arbustivo/herbáceo.

3.4.7 Mata de Candeia

O Candea é uma formação florestal com árvores de baixa estatura entre 6 a 12 metros de altura, que ocorre normalmente nas áreas de transição entre a floresta e as formações mais abertas. A candeia é uma espécie típica de regiões de maiores altitudes do sudeste do Brasil, ocorrendo geralmente onde os solos são mais rasos com limitações para o desenvolvimento de floresta (OLIVEIRA FILHO & FLUMINHAM FILHO, 1999).

3.4.8 Floresta Estacional Semidecidual

A Floresta Estacional Semidecidual, caracteriza-se por apresentar um percentual de caducifolia em torno de 20 a 50% e esta relacionada com um clima tropical de altitude com duas estações anuais bem definidas uma chuvosa no verão e outra seca no inverno (VELOSO et al., 1991). Essa formação florestal refere-se a ecossistemas vegetais estruturados, onde a estacionalidade climática, assegura uma semidecidualidade de alguns indivíduos arbóreos, como uma forma adaptativa a condições adversas ocorrendo em altitudes acima de 500 metros.

3.4.9 Floresta Estacional Semidecidual (Capões de mata)

Esta formação florestal de acordo com Rizinni (1997), aparece na paisagem sob a forma de manchas (capões) e galerias florestais. Sua ocorrência esta associada com áreas de altitudes elevadas, com forte controle litológico e ou climático.



**Figura 3 – Campo Rupestre herbáceo em primeiro plano.
Fonte: Elpídio Inácio Fernandes Filho**



**Figura 4 – Campo Rupestre herbáceo / arbustivo.
Fonte: Elpídio Inácio Fernandes Filho.**



**Figura 5 – Cobertura vegetal: Cerrado
Fonte: Elpídio Inácio Fernandes Filho.**

3.5 Unidades de Conservação

Unidades de conservação (UC's) são espaços territoriais delimitados legalmente pelo poder público para a proteção da biodiversidade e conservação de áreas de rara beleza cênica e paisagística. São terras que pelo valor de seus recursos existentes, devem ser mantidas na forma silvestre ou sob um regime de manejo diferenciado. UC é definida no SNUC (2000) conforme apresentado a seguir:

“É um espaço territorial e seus recursos ambientais, incluindo as águas jurisdicionais, com características naturais relevantes, legalmente instituído pelo Poder Público, com objetivos de conservação e limites definidos, sob regime especial de administração, ao qual se aplicam garantias adequadas de proteção” (p.1).

A Lei N° 9.985, instituiu o Sistema Nacional de Unidades de Conservação da Natureza (SNUC, 2000), estabelecendo critérios e normas para a criação, implantação e gestão das unidades de conservação. No SNUC as UC's foram divididas em duas categorias de uso: Unidades de Proteção Integral com uso indireto dos recursos e Unidades de Uso Sustentável com uso direto. Na primeira categoria estão inclusos unidades tal como os Parques Nacionais, e na segunda pode-se citar as Áreas de Proteção Ambiental (APA).

O uso indireto, categoria a qual está submetido os Parques Nacionais (PARNA) é definido como sendo aquele que não envolve a coleta e uso, comercial ou não dos recursos naturais. Já o uso sustentável, previsto para as Áreas de Proteção Ambiental (APA), é definido como a exploração do ambiente de maneira a garantir a perenidade dos recursos ambientais renováveis e dos processos ecológicos, mantendo a biodiversidade e os demais atributos ecológicos, de forma socialmente justa e economicamente viável (Brasil, 2000).

O plano de manejo é o principal documento das UC's, ele tem como objetivo orientar o desenvolvimento de uma unidade de conservação assegurando a manutenção dos recursos naturais em seu estado original para o correto usufruto das gerações atuais e futuras, sendo periodicamente reformulado para atender as eventuais mudanças (IBAMA, 2002). No SNUC o plano de manejo é o documento que deve ser elaborado logo após a criação de cada UC de maneira a orientar as atividades a serem desenvolvidas em cada uma.

As UC's são espaços definidos via de regra por meio de projetos de lei que definem unidades de conservação em diferentes categorias de uso (BRASIL, 2005). No ano de 2006, o estado de Minas Gerais contava com seis dos sessenta e seis parques nacionais existente no Brasil e quinze áreas de proteção ambiental (IEF/MG, 2006; IBAMA, 2006).

3.5.1 Parque Nacional – PARNA

Parque Nacional é um espaço territorial de posse e domínio público. O PARNA tem como objetivo básico a preservação de ecossistemas naturais de grande relevância ecológica e beleza cênica, possibilitando a realização de pesquisas científicas e o desenvolvimento de atividades de educação e interpretação ambiental, de recreação em contato a natureza e de turismo ecológico (BRASIL, 2000).

3.5.2 Área de Proteção Ambiental – APA

As Áreas de Proteção Ambiental foram definidas no SNUC como sendo áreas extensas, com certo grau de ocupação humana, dotadas de atributos abióticos, bióticos, estéticos ou culturais, especialmente importantes para a qualidade de vida e o bem-estar das populações humanas. Tem como objetivos básicos proteger a diversidade biológica, disciplinar o processo de ocupação e assegurar a sustentabilidade do uso dos recursos naturais, sendo constituídas por terras públicas ou privadas (BRASIL, 2000; IBAMA, 2004). Tanto as terras públicas quanto as privadas são utilizadas sob um plano de manejo que poderá estabelecer normas e restrições para utilização de uma propriedade privada localizada na APA, respeitando os limites constitucionais (SNUC, 2000).

As Áreas de Proteção Ambiental devem dispor de um Conselho presidido pelo órgão responsável por sua administração e constituído por representantes dos órgãos públicos, de organizações da sociedade civil e da população residente, conforme está disposto no SNUC.

3.6 Geoprocessamento

O termo geoprocessamento de acordo com Câmara e Davis (2000) denota a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica. O estabelecimento do Geoprocessamento como disciplina científica independente ocorreu em 1989, quando nos EUA foi criado o *National Center for Geographical Information and Analysis*.

O geoprocessamento tem sido empregado em diversas áreas da ciência. As ferramentas computacionais utilizadas para realizar geoprocessamento de acordo com Câmara e Davis (2000) compõem um conjunto denominado Sistemas de Informações Geográficas.

3.6.1 Sistema de Informação Geográfica

Um Sistema de Informação Geográfica (SIG) pode ser definido como aquele que efetua tratamento computacional de dados geográficos, armazena a geometria e os atributos de dados georreferenciados e oferece mecanismos para combinar as várias informações através de algoritmos de manipulação e análise, bem como para consultar, recuperar, visualizar e plotar conteúdos de base de dados georreferenciados (Câmara e Medeiros, 1998).

O SIG permite realizar análises complexas, ao integrar dados de diversas fontes e ao criar bancos de dados geográficos, tornado ainda possível automatizar a produção de documentos cartográficos, realizar trabalhos mais rápidos e menos oneroso. As análises podem ser feitas em SIG por meio de correlação entre diversos dados coletados por sensores remotos demanda um tempo menor de aferições de campo (CÂMARA & DAVIS, 2000).

O uso de SIG tem se mostrado essencial para trabalhos práticos, sobretudo, relacionados a estudos ambientais, como nos trabalhos de Paese (1997) e Costa (2000).

Paese (1997), com o uso de SIG obteve informações de maneira rápida, eficiente e de baixo custo que possibilitou a proposição conceitual do zoneamento ambiental da Estação Ecológica de São Carlos. Com o uso do SIG realizou a caracterização estrutural da paisagem e a elaboração de mapas temáticos.

Costa (2000) elaborou uma base de dados geográficos que possibilitou a compreensão e o diagnóstico do sistema sócio-ambiental da Reserva Extrativista Chico Mendes que por sua vez permitiu realizar o zoneamento ambiental, dando subsídio ao manejo adequado dos recursos naturais.

3.6.2 Sensoriamento Remoto

O Sensoriamento Remoto é definido por Novo (1989), como sendo a tecnologia que permite a aquisição de informações sobre objetos, sem o contato direto com eles. A aquisição de informações é feita por meio de sensores, que captam a energia proveniente dos objetos. A energia é convertida em sinal que é registrado e apresentado em forma adequada para extração de informações (NOVO, 1989).

O objetivo do Sensoriamento Remoto de acordo com Novo (1989) é estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do Planeta Terra em suas mais diversas manifestações. As imagens de satélites são os principais produtos do sensoriamento remoto largamente utilizado em estudos dos recursos naturais.

O primeiro satélite para fins de mapeamento de recursos terrestres foi lançado em 1972, denominado ERTS-1 (*Earth Resources Technology Satellite-1*). Posteriormente, em janeiro de 1975 ele passou a ser chamado LANDSAT. Posteriormente foram lançados outros satélites da mesma plataforma, a saber: Landsat – 1, 2, 3, 4, 6 e 7. O Landsat 7, entrou em órbita em abril de 1999. O satélite possui três sensores (MSS, TM e ETM⁺). O sensor ETM⁺ (*Enhanced Thematic Mapper Plus*) acoplado no Landsat 7 adquire dados em sete bandas espectrais, cujas características de cada uma são apresentadas na Tabela 1 (MASEK et al., 2001 & MARKHAM et al., 2004).

Tabela 1 – Características das bandas do sensor ETM+

Nº da banda	Resolução espacial	Faixa espectral	Região do espectro
	(m x m)	(μm)	
1	30 x 30	0,450 – 0,515	Azul
2	30 x 30	0,525 – 0,605	Verde
3	30 x 30	0,630 – 0,690	vermelho
4	30 x 30	0,750 – 0,900	Infravermelho próximo
5	30 x 30	1,550 – 1,750	Infravermelho Médio
6L (<i>Low gain</i>)	60 x 60	10,40 – 12,50	termal
6H (<i>High gain</i>)	60 x 60	10,40 – 12,50	termal
7	30 x 30	2,090 – 2,350	Infravermelho Médio
8	15 x 15	0,520 – 0,900	Pancromática

Fonte: GLCF, 2006.

O Landsat 7 cessou a aquisição de em maio de 2003. Pode-se citar dentre outros satélites para mapeamento de recursos naturais o IKONOS, SPOT4, e CBERS operado em parceria pelo Brasil e China (MOREIRA, 2003). Entretanto, o acervo de dados adquiridos pelo Landsat 7, tem sido uma importante fonte de informação para estudos ambientais envolvendo análise temporal e mapeamento de áreas que não tiveram alteração expressiva no uso cobertura do solo.

Além do mapeamento de recursos naturais, Florenzano (2002) destaca a utilização de imagens na identificação dos diferentes usos do espaço terrestre transformado pelo homem por meio de atividades tais como derrubada de matas, implantação de pastagens e cultivos.

3.7 Classificação de imagem

A classificação é o processo de rotular cada pixel da imagem para uma classe informacional. Quando realizada de forma automática é um processamento realizado por algoritmos de classificação, ou classificadores (MOREIRA, 2003).

A classificação pode ser feita segundo duas abordagens, supervisionada ou não supervisionada. Nas duas abordagens o analista decide parâmetros para a associação dos pixels a uma das classes informacionais (MOREIRA, 2003). A principal diferença entre as duas abordagens é que o método não supervisionado não requer a seleção de amostras de treinamento para caracterizar as classes alvos (VIEIRA, 2000).

A classificação supervisionada utiliza algoritmo cujo reconhecimento dos padrões da imagem se faz com base numa amostra de treinamento da área que é fornecido pelo analista. O analista tem conhecimento *a priori* da área de estudo.

As etapas principais da classificação são: pré-processamento dos dados; treinamento do classificador; rotulação dos pixels; pós-processamento e avaliação da exatidão do mapeamento (GONG & HOWARTH, 1990, *apud* IPPOLITI-RAMILO, 1999).

3.7.1 Máxima Verossimilhança - MAXVER

O MAXVER é um dos algoritmos de classificação supervisionada largamente utilizados. Para este algoritmo a distribuição dos dados das classes deve seguir uma distribuição normal. O que permite descrever os dados de cada classe por uma função de probabilidade, a partir de seu vetor de médias e sua matriz de covariância.

Para a classificação de um pixel desconhecido o MAXVER faz o cálculo de probabilidade de determinado pixel pertencer a uma determinada classe, o cálculo é feito para todas as classes e cada pixel é atribuído àquela classe que maximize a função de probabilidade (MOREIRA, 2003 e IPPOLITI-RAMILO, 1999).

O algoritmo Embora largamente utilizado o MAXVER têm suas limitações relatadas particularmente quanto à exigência da normalidade dos dados (KAVZOGLU & MATHER, 2003).

3.7.2 Redes Neurais Artificiais - RNA

Uma abordagem de classificação supervisionada que procurou superar o problema da normalidade dos dados é fornecida pelas Redes Neurais Artificiais (RNA). Segundo Kavzoglu & Mather (2003), a classificação por Redes Neurais é um método mais robusto, que tem

apresentando maior exatidão no mapeamento em detrimento aos métodos estatísticos clássicos como o de Máxima Verossimilhança.

As Redes Neurais Artificiais são modelos que utilizam técnicas matemáticas inspiradas no funcionamento de aprendizagem do cérebro humano. De acordo com Vieira (2000), rede neural, de forma genérica, consiste em camadas de elementos de processamento, ou neurônios, que são ligados via pesos e conectores. O modelo de rede conhecido como multicamadas é o modelo mais comum, sendo largamente usado, com o algoritmo de aprendizagem de retropropagação (VIEIRA, 2000; KAVZOGLU & MATHER, 2003).

A arquitetura da rede é construída seguindo uma estrutura conceitual onde a camada de entrada é conectada a camada de saída por uma ou duas camadas internas (Figura 3). O número de neurônios da camada de entrada corresponde ao número de variáveis discriminantes, enquanto que na camada de saída, o número de neurônios é igual ao número de classes a serem identificadas, por sua vez o número de camadas internas e o número de neurônios em cada uma são determinados de acordo com cada problema a ser resolvido (KAVZOGLU & MATHER, 2003).




Figura 6 – Arquitetura de rede neural, modelo multicamadas.
Fonte: Modificado de Kavzoglu & Mather, 2003.

Para determinar a arquitetura interna da rede (numero de camadas e neurônios) dois métodos são propostos. O método construtivo (*growing*) e método de poda (*prunig*), descritos por Kavzoglu & Mather (1999) e Vieira (2000). No primeiro, a camada interna é iniciada com um pequeno numero de neurônios que vai sendo adicionado um a um até a rede convergir até

um erro pequeno e aceitável. No segundo método, a camada interna inicia-se com um número de neurônio maior do que aquele esperado ser suficiente, e a partir dos resultados vai se removendo os neurônios considerados redundantes.

Kavzoglu & Mather (2003), argumentam que embora de forma heurística alguns autores tenham proposto número de camada interna e de neurônios, nenhum deles são universalmente aceitado para estimar a arquitetura ótima em problemas particulares.

Três vantagens de usar RNA para classificação de cobertura terrestre são assinaladas por Vieira (2000), elas correspondem a: processamento estrutural, tolerância à falha em dados e a flexibilidade estatística. A primeira vantagem diz respeito à rapidez de processamento da classificação após a definição da arquitetura interna da rede. A tolerância a dados faltosos concerne ao caráter robusto da RN que agrega dados de diversas fontes com diferentes níveis de ruídos. Quanto à flexibilidade estatística, a vantagem é que a RNA, não é afetada pela característica estatística dos dados, pois, é assumido *a priori* pelo classificador o não conhecimento da frequência da distribuição estatística dos dados e eles não precisam ser tratados por diferentes métodos estatísticos.

A distribuição não paramétrica dos dados é a característica apontada por Benediktsson & Sveinsson (1997), como a principal razão de se usar a RNA como método em classificação de dados geográficos e de sensores remotos. Entretanto a capacidade de generalizar padrões é o maior diferencial da Rede Neural em relação aos outros classificadores (VIEIRA, 2000).

O algoritmo de aprendizagem de retropropagação (*backpropagation*), o mais popular empregado em redes neurais de acordo com Kavzoglu & Mather (2003). Este algoritmo realiza o processo de aprendizagem em dois estágios. No primeiro estágio uma vez que houve a inicialização aleatória dos pesos na rede os dados de entrada são propagados seguindo um fluxo de informação unidirecional para estimar o valor de saída para cada amostra de treinamento. No segundo estágio o erro entre o valor conhecido e o estimado e retropropagado através da rede e os pesos associados com os nós são transformados de maneira que a diferença entre o valor conhecido e o desejado é minimizada. Esse processo é repetido com os pesos sendo recalculados para cada interação até o erro ser mínimo.

Para o processo de aprendizagem do classificador os parâmetros determinado são número de ciclos de treinamento e a taxa aprendizagem. Esses valores interferem significativamente na exatidão da classificação, alguns parâmetros de referência baseados em trabalhos experimentais são encontrados em Vieira (2000).

Outro fator que afeta significativamente o desempenho da rede diz respeito à capacidade dos dados de entrada em discriminar as classes informacionais. De acordo com

Benediktsson & Sveinsson (1997), a seleção de variáveis para a classificação e o procedimento considerado “chave” no processo de classificação. Este procedimento busca selecionar dados de entrada mais representativos para a classificação. A redução da dimensionalidade dos dados de entrada contribui com a diminuição do tempo de processamento e a melhor generalização pelo classificador.

Em estudo feito por Benediktsson & Mather (2003), foram utilizados dados de sensores remotos e dados do meio físico (elevação e declividade) na camada de entrada da rede neural para a classificação de área de florestas com topografia acidentada. Os dados do terreno foram utilizados para melhorar a exatidão na classificação, uma vez que as informações espectrais utilizadas por eles apresentaram forte similaridade entre si.

Chagas (2006), em trabalho de mapeamento digital de solos utilizando redes neurais utilizou atributos do terreno (elevação, declividade, aspecto, curvatura e índice topográfico combinado), informação geológica e índices derivados de imagem do Sensor ETM+ do satélite Landsat. Os resultados deste trabalho mostraram um aumento significativo no desempenho da classificação, quando os atributos do terreno foram associados aos índices da imagem para discriminação das classes de solos.

Silva, (2006), avaliando a degradação de pastagem fez a classificação automática de imagem IKONOS por meio de três algoritmos MAXVER, ISODATA e Redes Neurais. Foram discriminadas quatro categorias de pastagem com diferentes níveis de degradação, das classes solo exposto, mata e área inundável. Os resultados mostraram uma maior índice de exatidão da classificação pela rede neural.

Cetin et al. (2004), realizaram uma comparação entre o desempenho da classificação do algoritmo de Máxima Verossimilhança e da Rede Neural na discriminação das classes de uso e cobertura do solo de uma área em Istambul – Turquia. Foram utilizadas as bandas de 1 a 5 e a banda 7 do sensor ETM+ do Landsat 7 e as bandas do visível e do infravermelho próximo do satélite Terra, sensor ASTER. As classes classificadas foram: oceano, rodovia, solo exposto, pastagem, lagos, área urbana, floresta decídua e floresta de coníferas. As amostras para treinamento e validação utilizadas na classificação foram as mesmas para os dois classificadores. Os resultados de índice *kappa*, mostraram melhor exatidão de mapeamento pela rede neural, em todas as combinações de dados de entrada. Foram testadas classificações com as bandas de cada sensor individual, e destas com seus respectivos componentes principais além da classificação com todas as bandas dos dois sensores junto com as imagens geradas pela combinação dos componentes principais de cada conjunto de

três bandas dos dois sensores. O melhor resultado foi obtido pela última combinação de dados que agregou todas as informações.

Braga et al. (2006), em trabalho feito na Serra do Salitre, Minas Gerais: utilizaram uma imagem do satélite IKONOS, bandas 1, 2, 3 e 4 para classificar as seguintes classes de cobertura e uso do solo: Café, Mata Ciliar, Solo, Campo Limpo, Campo Sujo, Braquiária e Pasto. O classificador de Máxima Verossimilhança obteve-se um índice kappa de 0,78, estatisticamente melhor do que a exatidão obtida pela classificação híbrida, não supervisionada, que apresentou índice kappa de 0,75.

Nangendo et al. (2007), realizaram uma comparação do desempenho de quatro métodos de classificação na discriminação das classes de cobertura e uso do solo da reserva florestal de Budongo na Uganda – África. Os classificadores utilizados foram o de Máxima Verossimilhança (ML), ML combinado com um sistema especialista (MLEsp), Anglo Espectral de Mapeamento (AEM), e AEM combinado com sistema especialista (AEMEsp). Os dados para classificação foram obtidos de uma imagem do sensor ETM+ do Landsat, dados do terreno (atitude, declividade, aspecto e posição do terreno) e um índice de percentual do dossel das espécies vegetal gerado com informações obtidas em trabalho de campo. As classificações realizadas com o sistema especialistas fizeram uso de todos os dados enquanto que as demais foram feitas apenas com os dados da imagem de satélite. As classes discriminadas pelos classificadores foram: floresta típica, áreas queimadas, savana e três classes de floresta que se diferem quanto à densidade do estrato arbóreo, e predomínio de espécie. A exatidão de classificação teve o pior índice kappa quando usou o classificador ML (0,75). O classificador MLEsp apresentou índice kappa de 0,82. A melhor exatidão de classificação foi alcançada pelo classificador AEM. Quando combinado com o Sistema Especialista, (AEMEsp) o índice kappa foi de 0,93.

Jianwen & Bagan (2005), fizeram uma comparação entre o classificador de Máxima Verossimilhança (MAXVER) e Redes Neurais para classificar uma imagem do Sensor ASTER. As classes discriminadas foram: água, floresta, pastagem, agricultura, área urbana, estrada e outras. A exatidão global do MAXVER foi de 86.64% enquanto que a exatidão da Rede Neural foi de 95.68%.

Ribeiro & Caetano (2001), realizaram comparação entre o desempenho do classificador de Máxima Verossimilhança (MAXVER) e Redes Neurais na discriminação de classes de cobertura e uso do solo de uma área no entorno do lago de Itaipu no Paraná. Os dados utilizados foram extraídos das bandas 3, 4 e 5 de uma imagem do sensor TM do Landsat. As classes classificadas foram: cultura, água, reflorestamento, pastagem, solo

exposto, área urbana e nuvem. Foram realizadas três classificações com número distintos de classes classificadas. No conjunto um conteve todas as classes, no conjunto dois, foram suprimidas as classes nuvem e área urbana e no terceiro conjunto apenas a classe nuvem foi suprimida. Para todos os conjuntos a classificação por Rede Neural apresentou melhor desempenho de classificação.

Ribeiro, et al. (2005), Compararam o desempenho da classificação pelo algoritmo de Mínima Distância, Máxima Verossimilhança (MAXVER) e Rede Neural, na classificação de uma imagem IKONOS para discriminar 15 classes de cobertura e uso do solo, a saber: mata ciliar, cerrado, braquiária, pasto, campo limpo, campo sujo, café maduro, café jovem, reforma de café, milho, restos de culturais, campo pedregoso, solo exposto, rio, rodovia e ferrovia. As amostras foram coletadas por pixel e por região. Os resultados da classificação, obtidos pela matriz de confusão foram comparados estatisticamente pelo teste Z. O maior desempenho foi obtido pela classificação das amostras coletadas por região, classificadas pela rede neural e pelo algoritmo de Máxima Verossimilhança tiveram índice kappa de 0.82%, portanto não apresentando diferença de significativas ao nível de 95% de probabilidade. O menor desempenho foi obtido pelo algoritmo de Mínima Distância. Neste trabalho os autores recomendaram o uso do MAXVER, para a classificação, uma vez que ele a rede neural não apresentou diferenças significativas e por ele estar implementado na maioria dos softwares e exigir menor custo computacional.

4. MATERIAIS E MÉTODOS

4.1 Software

Para a aquisição, processamento de dados, e classificação do mapa de cobertura e uso do solo fez-se uso dos os softwares que seguem listados acompanhados das respectivas funções desempenhadas.

ERDAS IMAGINE 8.5 (2001): usado para o processamento da imagem, redução da dimensionalidade, reamostragem e composição de bandas, elaboração do índice de vegetação, composição da camada com todas as variáveis e coleta das amostras.

Java Neural Network Simulator (JavaNNS, 2001): simulador de redes neurais utilizado para treinamento e classificação das amostras.

Executáveis FuncPow, Transforme e Gerapat (Cedidos pelo prof. Carlos VIEIRA, DEC/UFV): processamento dos arquivos para classificação na rede neural, seleção de variáveis pela análise da matriz *kappa* e teste de significância entre as redes.

ArcGIS 9.0, ESRI (2004). Utilizado para definição dos parâmetros dos dados vetoriais, conversão dos sistemas de projeção, Datum e unidades; álgebra de mapas, derivação dos mapas do meio físico (Declividade, Índice Topográfico Combinado), elaboração do mapa classificado e quantificação de áreas.

ARC/INFO, ESRI (1994): utilizado para processamento de dados vetoriais: edição, mosaicação, orientação da drenagem; reescalonamento dos valores dos mapas atributos rasterizados e geração do Modelo Digital de Elevação.

4.2 Hardwares

Aparelho receptor de Sistema de Posicionamento Global - GPS GARMIM: usado em campo para a captura de pontos de padrões das classes de cobertura e uso do solo, checagem dos padrões da imagem e dos limites das unidades geológica.

Microcomputador com HD de 200 GB, memória RAM 1GB e processador Pentium.

4.3 Dados cartográficos

Foram utilizados os seguintes dados cartográficos: mapa geológico Carta Baldim e Carta Conceição do Mato Dentro (COMIG, 1997), escala 1: 100.000; Mapa Geológico CPRM, 2004. escala 1:1.000.000; Imagem de satélite da plataforma Landsat 7, órbita/ponto 218-73, adquirida em 23 de abril de 2000, da qual extraiu as bandas 1, 2, 3, 4, 5, e 7 imageadas pelo sensor ETM⁺; Carta topográfica: carta Jaboticatubas, escala 1:50.000 e cartas Baldim, Conceição do Mato Dentro e Itabira, escala 1:100.000. (IBGE 1997), com curvas de nível cotadas pelo “Projeto Geominas”, e Limites territoriais da área de estudo: PARNA da Serra do Cipó e APA Morro da Pedreira foram fornecidos pelo IBAMA.

4.4 Metodologias

As metodologias utilizadas neste trabalho constaram das seguintes técnicas: trabalhos de laboratório com implementação de banco de dados em Sistema de Informação Geográfica, processamento de dados e classificação supervisionada; trabalho de campo para reconhecimento de padrões e coleta de amostras das classes de cobertura e uso do solo. Os procedimentos estão detalhados a seguir.

4.4.1 Trabalho de laboratório

Os trabalhos de processamento dos dados e classificação foram realizados no Laboratório de Geoprocessamento do Departamento de Solos da UFV.

Os trabalhos de laboratório iniciaram antes do trabalho de campo. A primeira etapa do trabalho consistiu na implementação de um banco de dados geográfico em SIG. Para tanto foram compilados os dados cartográficos, que passaram por análise e processamentos que se fizeram necessários. Os processamentos dos dados ocorreram em função da necessidade de definir critérios para a montagem de um projeto, quais sejam: definição de sistema de projeção cartográfico, Datum, unidade de representação e modelo de representação; também fez-se necessário a edição dos dados no sentido de corrigir falhas, reduzir a dimensionalidade e transformações para o formato dos softwares utilizados.

O formato matricial de representação dos dados exigiu a definição de um tamanho de célula usado para a reamostragem da imagem e representação dos atributos do meio físico. Esta definição deu-se em função da escala dos dados utilizados. Esta é uma importante decisão quando se define um projeto no qual são usados dados de várias fontes. O uso de um tamanho único pixel facilita operações entre mapas e permite a rotina de trabalho de determinados softwares. Neste trabalho foi utilizado tamanho de célula de 30 x 30 metros.

A área do projeto foi delimitada com 1 km a mais para além do limite da área de interesse. Com a geração de um *buffer* criou-se essa área de borda como estratégia de garantir eventuais problemas de imprecisão de limites das UC's. Para atender a mecanismos de processamento dos softwares e modelo de dados utilizado, utilizou-se como limite um retângulo de 1.330 x 2.159 pixels (aproximadamente 270.000 ha), recobrindo as duas unidades de conservação, mais a borda de 1 km. Este limite foi utilizado para definir a dimensão de todos os mapas utilizados, otimizando o tempo de processamentos, com a redução do tamanho dos arquivos.

Para uso no campo elaboraram-se mapas temáticos; um mapa denominado mapa de unidades ambientais elaborado com informações da geologia, da declividade e da elevação; e outro mapa denominado carta imagem elaborada a partir da composição colorida das bandas (RGB 345) do Landsat. Em ambos os mapas foi plotado uma base cartográfica com hidrografia, rede viária e topônimos adquiridos nas cartas do IBGE. Esse material foi usado para a escolha dos transectos percorridos e serviu à orientação em campo.

4.4.2 Trabalho de campo

Os trabalhos de campo ocorreram durante o levantamento de solo da área por uma equipe do Departamento de Solos da Universidade Federal de Viçosa, coordenado pelo

professor Carlos Schaefer, com o apoio do IBAMA que garantiu o acesso as UC's. As incursões à campo ocorreram entre os meses de agosto a dezembro de 2006, realizadas em quatro etapas totalizando aproximadamente vinte (20) dias.

Os transectos pré-definidos foram percorridos procurando acessar as diferentes tipologias da cobertura vegetal e uso do solo. Foram visitados os diferentes compartimentos da paisagem, com diferentes formas de relevo e unidades geológicas. Durante o percurso adquiriu pontos georreferenciados por meio de GPS das distintas tipologias de cobertura e uso do solo, sendo coletados trezentos pontos.

4.4.3 Definição das classes de cobertura e uso do solo

Após um reconhecimento geral da área, em função da escala e da resolução dos dados disponíveis para o processo de classificação foram identificadas onze classes de cobertura e uso do solo: Cerrado (Formações campestre), Campo Rupestre herbáceo, Campo Rupestre herbáceo/arbustivo, Floresta de Candeia, Cerradão (Cerradão + Cerrado Senso restrito), Floresta de Galeria, Mata Seca, Pastagem, Floresta Semidecidual, Capões de mata e Água. Duas outras classes, nuvem e sobra de nuvem, compuseram o arquivo de classificação, por estarem presente na cena da imagem utilizada, totalizando 13 classes informacionais.

4.4.4 Definição das Variáveis

A seleção de variáveis para uso neste trabalho deveu-se: ao tipo de dado necessário para solucionar o problema investigado, aos disponíveis, bem como suas características e o conhecimento teórico dos trabalhos de Benediktsson & Mather (2003), Carvalho Júnior (2005), Silva (2006) e Chagas (2006).

4.4.4.1 Imagem de satélite

Foi usada uma imagem da plataforma Landsat-7, da qual extraiu-se as bandas 1, 2, 3, 4, 5, e 7 do sensor ETM⁺. Essa imagem foi adquirida pelo Sensor ETM⁺ em 23 de abril de 2000 (ESDI, 2006). Após o *download* da imagem, disponível gratuitamente na *internet*, realizou-se o pré-processamento da mesma.

4.4.4.2 Índice de Vegetação por Diferença Normalizada - NDVI

Os índices de vegetação foram concebidos para ressaltar o comportamento espectral da vegetação; eles estão baseados nas diferenças quantitativas entre a radiação refletida e

transmitida por esses dois alvos (IPOLLITTI-RAMILO, 1999). O NDVI é um indicador do índice de área foliar e conseqüentemente da fenologia. Para Moreira (2003), o NDVI é o índice de vegetação mais empregado na avaliação do vigor da cobertura vegetal, sendo para ele uma das vantagens do uso desse índice a redução do número de bandas utilizadas na análise.

A composição NDVI é feita por meio de uma operação matemática entre as bandas da região espectral do vermelho e a banda da região espectral do infravermelho próximo. Na análise da vegetação quanto maior for o vigor da vegetação, maior é o contraste entre essas bandas. O índice NDVI é obtido segundo a Equação 1.

$$\text{NDVI} = \frac{(\text{IVP} - \text{VER})}{(\text{IVP} + \text{VER})} \quad (1)$$

Em que: IVP – Banda espectral do Infravermelho próximo e VER – Banda espectral do vermelho.

4.4.4.3 Modelo Digital de Elevação – MDE

O Modelo Digital de Elevação - corresponde ao mapa que representa o atributo da elevação do terreno. Ele foi obtido a partir da interpolação dos dados de altitude extraídos das cartas topográficas (IBGE, 1997). O processo de interpolação resultou numa matriz onde as células foram associadas a um valor que representa a elevação do terreno.

Foi realizado o mosaico das cartas e a edição das curvas para eliminar falhas nas conectividades entre as cartas. A integração da carta Jaboticatubas de escala 1:50.000 com as demais de escala 1:100.000 foi feita a partir da interpolação das curvas da carta de menor escala (1:50.000) para a mesma equidistância das demais. As curvas derivadas de um MDE foram unificadas com as demais.

O tratamento dos dados primário para gerar o MDE foi realizado de maneira a buscar a geração de um modelo com a melhor qualidade de representação do espaço real e que garantisse a representatividade dos atributos dele derivado. A rede hidrográfica foi orientada de acordo com a direção de fluxo da drenagem. A rede hidrográfica, as curvas de nível, os pontos cotados e o limite da área foram usados para gerar MDE.

4.4.4.4 Declividade

A declividade identifica a taxa máxima de mudança no valor de uma célula central em relação às suas vizinhas. Cada célula do mapa de declividade tem seu valor calculado a partir

de uma função feita sobre o MDE com 3x3 células vizinhas (CARVALHO JÚNIOR, 2005). O mapa de declividade foi obtido utilizando a função *slope* da extensão *spacial analyst* do módulo ArcGIS Desktop, ESRI (2004).

4.4.4.5 Índice Topográfico Combinado - ITC

O índice topográfico combinado foi gerado a partir das informações do Modelo Digital de Elevação, sendo definido como uma função da declividade e da área de contribuição por unidade de largura ortogonal à direção do fluxo (CHAGAS, 2006). A obtenção do ITC pode ser feito pela equação 2.

$$\text{ITC} = \ln \frac{(As)}{(\text{Tan}\beta)} \quad (2)$$

Em que: *As* representa área de contribuição (fluxo acumulado + 1) * tamanho da célula do grid em m²) e β é a declividade expressa em radianos.

4.4.4.6 Geologia

O mapa geológico representa a litologia da área, ou seja, o material de origem que derivou o tipo de solo e que pode ter influencia sobre a tipologia vegetal. O mapeamento geológico realizado pela COMIG – Companhia Mineradora de Minas Gerais (1997) em Escala 1:100.000 cobre 82% da área estudada com as Cartas Baldim e Conceição do Mato Dentro. Para o recobrimento do restante da área em mesma escala realizou o remapeamento das unidades geológica do mapa da CPRM – Companhia de Pesquisa de Recursos Minaerais (2004), em escala 1:1.000.000. Durante os trabalhos de campo realizou-se amostragem que integrado a interpretação de imagens de satélite possibilitou editar os limites das feições litológica obtendo assim um mapa com recobrimento total da área de estudo em escala 1:100.000.

4.4.5 Amostragem

As amostras foram coletadas de forma aleatória sobre uma imagem comporta por todas as variáveis da camada de entrada da rede. O reconhecimento dos padrões foi feito a partir de pontos obtidos em campo sobre a imagem composta com todas as variáveis definidas. Para cada conjunto de variáveis adquiriu o mesmo número de amostras para

treinamento e para a validação da classificação. O número de amostras foi calculado de acordo com o proposto por Mather (1999, *apud* CHAGAS, 2006), que recomenda usar um tamanho de amostra com no mínimo trinta (30) vezes o número de variáveis discriminantes. Para tanto coletou aleatoriamente 5.200 amostras para treinamento (400 para cada classe) e 2.600 para a validação da exatidão da classificação (200 amostras por classe). A aquisição das amostras de padrões das classes foi realizada utilizando o programa ERDAS IMAGINE.

4.4.6 Conjuntos de variáveis

Com objetivo de avaliar a significância das variáveis no processo de classificação das classes de cobertura e uso do solo, estas foram organizadas em três conjuntos. Esse procedimento ocorreu para verificar o desempenho do classificador em relação ao tipo e quantidade de informação da camada de entrada da rede.

4.4.6.1 Conjunto 1

O conjunto 1 foi formado por todas as onze (11) variáveis como dados da camada de entrada, quais sejam: informações das bandas espectrais da imagem Landsat, geologia, MDE, declividade, ITC e NDVI.

4.4.6.2 Conjunto 2

O segundo conjunto foi composto por variáveis selecionadas utilizando o aplicativo *funcpow*. Esse aplicativo fez a seleção das variáveis utilizando como base a estatística do MAXVER. No processo de seleção foram utilizadas as amostras de treinamento e validação.

O agrupamento de variáveis discriminantes do Conjunto 2 ocorreu com o propósito de avaliar se a rede classificaria melhor as classes informacionais com todas as variáveis ou se a seleção de variáveis mais significativas implicaria em melhor desempenho da Rede produzindo um resultado com melhor exatidão de classificação.

As variáveis foram identificadas numericamente, da seguinte forma: variáveis de numeradas de 1 à 6 corresponderam respectivamente as bandas 1, 2, 3, 4, 5 e 7 da imagem do sensor ETM⁺ do Landsat; variáveis de 7 a 11 corresponderam respectivamente à: geologia, altitude (MDE), declividade, ITC e NDVI (Tabela 2).

A Tabela 2 apresenta os resultados de índice *kappa* das combinações feitas entre as variáveis mais significativas para discriminar as classes de cobertura e uso do solo. Inicialmente selecionou-se a variável 4 para ser analisada em conjunto com as demais, duas a

duas. O resultado de *kappa* entre a variável 4 e as demais é apresentado na primeira linha de valores da Tabela 2. Ao final da análise da variável 4 com as demais foi escolhido a variável 1, que apresentou maior índice *kappa* para compor um conjunto e ser analisado com as demais variáveis.

Após ser apresentados dos valores de *kappa* entre as combinações, a variável com maior índice foi escolhida. O procedimento foi repetido, agregando-se variáveis ao conjunto até que o acréscimo de variável não resultou em aumento estatisticamente significativo. A análise de significância foi computada usando o Teste Z.

Tabela 2 – Índice kappa entre grupo de variáveis

Variáveis combinadas	Variáveis									
	1	2	3	5	6	7	8	9	10	11
Variável 4	0,57*	0,57	0,56	0,56	0,55	0,51	0,57	0,43	0,46	0,56
Variáveis 4, 1		0,6	0,61	0,61	0,6	0,66	0,71*	0,63	0,6	0,6
Variáveis 4, 1, 8		0,73	0,73	0,73	0,73	0,81*		0,73	0,7	0,7
Variáveis 4, 1, 8, 7		0,7	0,68	0,69	0,68			0,69	0,71	0,69

* Variável selecionada para compor o Conjunto 2, por apresentar maior índice *kappa*.

A combinação de variáveis produziu resultado diferente dependendo da primeira variável escolhida para iniciar a comparação. Desse modo foram testadas diferentes combinações de conjunto, iniciando com variáveis esperadas serem capazes de distinguir melhor as classes amostradas. Iniciou-se com as seguintes variáveis: banda 4 (infravermelho), Geologia, NDVI e (MDE).

O conjunto de dados que apresentou melhor resultado agregou as variáveis: banda 4 e 1 do Landsat, geologia e altitude (MDE), selecionadas nesta ordem (Tabela 2). O resultado estatístico deste conjunto apresentou índice *kappa* de 0.81. A Figura 4 ilustra da seleção das variáveis do Conjunto 2 entre todas as variáveis selecionadas para

4.4.6.3 Conjunto 3

O terceiro conjunto de variáveis foi composto apenas pelos dados da imagem Landsat, ou seja, informações espectrais das bandas de um (1) a cinco (5) e da banda sete (7) do sensor ETM⁺. Estes dados são os mais comumente usados em processo de classificação de uso e cobertura do solo.

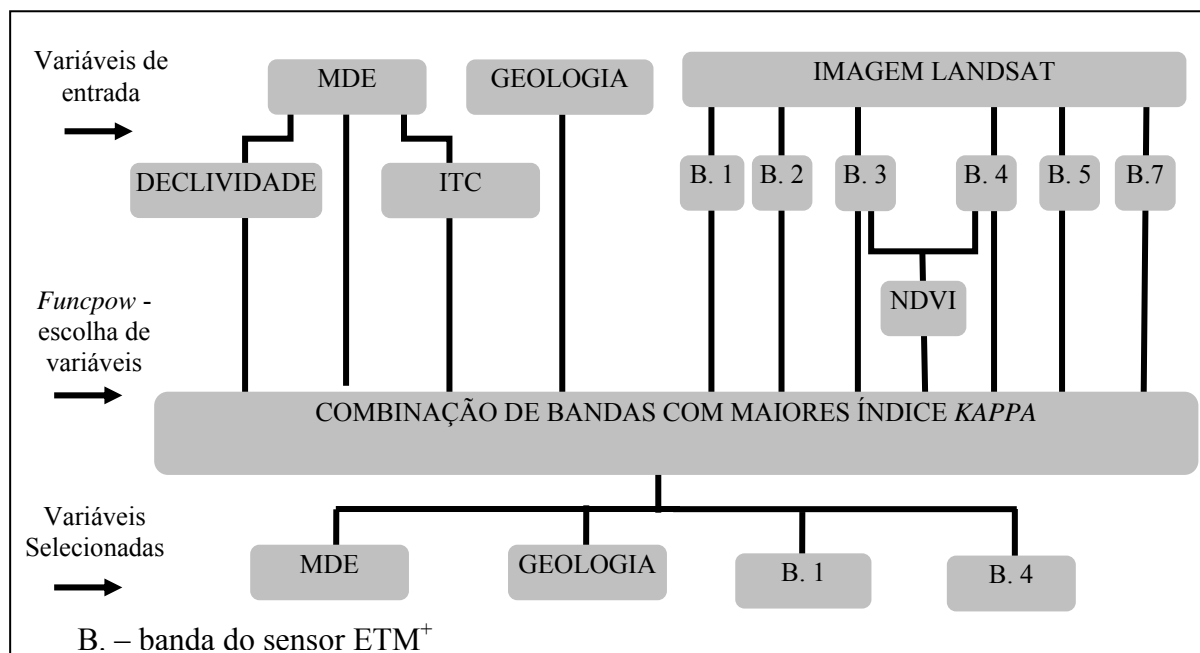


Figura 7 – Variáveis selecionadas pelo aplicativo *funcpow* para o Conjunto 2.

4.4.7 Classificação

Foram realizados testes para a escolha da arquitetura interna da rede e parâmetros de treinamento do algoritmo de classificação. Realizou-se treinamentos e validação das amostras dos conjuntos de variáveis 1, 2 e 3, observando o desempenho por meio da matriz de confusão. Testou diferentes arquiteturas interna para a rede e diferentes taxas de aprendizagem, na busca do melhor desempenho do classificador.

O processo de classificação constou do treinamento e classificação das amostras dos três conjuntos de variáveis pela rede neural. A arquitetura interna da rede para classificar os três conjuntos de variáveis foi escolhida de forma experimental, tanto o número de camadas quanto o número de neurônios. Várias arquiteturas foram testadas, observando o desempenho através da matriz de confusão. Para cada conjunto, o número de neurônios na camada de entrada correspondeu ao número de variáveis discriminantes de cada conjunto e o número de neurônios na camada de saída, correspondeu às treze classes a serem classificadas. Foram testados diferentes parâmetros para o treinamento.

4.4.8 Validação da exatidão da classificação

A avaliação da exatidão de uma classificação é o último passo do processo de classificação. A exatidão de uma classificação representa a concordância entre a informação do mapa temático gerado e a informação real do espaço geográfico mapeado.

Congalton & Green (1999), esclarecem que a exatidão da classificação depende de muitos fatores, incluindo a quantidade de esforço, o nível de detalhes (projeto de classificação) e a variabilidade de categorias a serem mapeadas. Portanto o índice de exatidão de classificação considerado excelente para um determinado caso pode não ser para outro.

A análise da matriz de confusão é considerada o método mais indicado para avaliar a exatidão de classificação de dados de sensores remotos e dados geográficos (CONGALTON & GREEN, 1999). Na matriz de confusão os dados de referência estão apresentados nas colunas e os dados classificados apresentados nas linhas. Os valores da diagonal principal representam o nível de concordância entre os dois conjuntos de dados.

A matriz de confusão apresenta indicadores da exatidão da classificação. Nela derivamos o erro de comissão e de omissão, encontramos o coeficiente *kappa* e a exatidão global. A exatidão global (P_o), representa a concordância de classificação para todo o mapa de um modo geral. O cálculo da P_o é feito dividindo o total de unidades amostrais classificados corretamente pelo total de unidades amostrais registrado na amostra, conforme a Equação 3.

$$P_o = \frac{\sum_{i=1}^m n_{ii}}{N} \quad (3)$$

Nesta equação, N representa o número total de unidades amostrais contempladas pela matriz; n_{ii} representa os elementos da diagonal principal e m o número de classes da matriz.

A exatidão global (P_o) fornece um índice de classificação que representa a concordância para todo o mapa sem apresentar a exatidão das classes de forma individual. Portanto para a análise da estatística de exatidão de cada classe, procede –se dividindo o número de unidades amostrais classificadas corretamente numa classe pelo número total de amostras de referência dessa classe. O resultado indica a probabilidade de uma unidade de referência esta corretamente classificada, este é, portanto, uma medida do erro de omissão. Por outro lado o erro de comissão é encontrado dividindo-se o total de pixel classificado corretamente numa classe pelo número total de pixel que foram classificados nesta classe (IPPOLITE-RAMILO, 1999).

A estatística kappa, que também aparece na matriz de erro, diferentemente da exatidão global, utiliza todos os dados da matriz para o cálculo da concordância do mapeamento. Esta estatística é indicada por Congalton e Green (1999), como o indicador mais adequado para avaliação da exatidão de classificação.

A análise do *kappa* é uma técnica multivariada discreta usada para determinar estatisticamente se uma matriz de confusão é significativamente melhor que outra (BISHOP 1975 *apud* CONGALTON e GREEN, 1989). O índice *kappa* varia de 0 a 1. Valores próximo de 0 indica baixa concordância entre o mapa gerado e as informações de campo, enquanto que valores próximo de 1 indica maior concordância da classificação.

O cálculo do kappa é calculado segundo a Equação 4. Onde **P_o** é a exatidão global; **P_e** é calculado segundo a Equação 5. Na Equação 5, (p_{i+}) e (p_{+i}) representam as proporções marginais da linha i e coluna i, respectivamente.

$$K = \frac{P_o - P_e}{1 - P_e} \quad (4)$$

$$P_e = \frac{\sum_{i=1}^M P_{i+} * P_{+i}}{N^2} \quad (5)$$

Landis e Koch (1977, *apud* MOREIRA, 2005) estratificaram os valores do índice *kappa* em intervalos para comparar qualitativamente uma classificação, de maneira que. Nesta abordagem valores acima de 0,8 são considerados excelentes e valores entre 0,6 e 0,8 são considerados como uma classificação muito boa. Considerando os resultados da matriz de erro foram avaliadas as classificações feitas para os diferentes conjuntos de variáveis e classificadores.

4.4.9 Pós-processamento

Como etapa final do processo de classificação, utilizou-se um filtro para eliminar grupo de células com área de até 5 ha presente na imagem classificada. As células eliminadas foram substituídas por dados das classes vizinhas. Esse processamento foi realizado no programa ArcGIS 9.0, utilizando o comando *RegionGroup*. A filtragem visa melhorar a

qualidade visual da imagem classificada, eliminando pequenas células, consideradas ruídos. Após essa etapa a imagem classificada foi apresentada em um mapa e as classes temáticas tiveram suas respectivas áreas quantificadas.

5. RESULTADOS E DISCUSSÃO

O melhor desempenho de classificação para os três conjuntos de variáveis foi obtido utilizando uma camada interna com trinta (30) neurônios e parâmetros de retropropagação do erro sugeridos por Vieira (2000), quais sejam: 3.000 ciclos (número de vezes que o erro é retropropagado) e taxa de aprendizagem (η) de 0.25. e de 0,1 para diferença máxima (d_{\max}) entre os valores de saída e aprendizagem.

Subseqüente ao treinamento foi realizado a classificação dos pixels e geração da matriz de confusão. A avaliação das classificações foi feita por meio de comparação entre as estatísticas das matrizes de confusão. O conjunto de variáveis que obteve maior exatidão na classificação teve as mesmas amostras classificadas pelo algoritmo MAXVER para uma comparação entre classificadores.

5.1 Classificação do conjunto 1

A tabela 3 apresenta a matriz de confusão obtida para a classificação das variáveis do Conjunto 1 pela rede neural. O índice de exatidão global de foi 95%, e índice *kappa* de 0.95.

Observa-se na matriz de confusão (Tabela 3) que todas as classes mapeadas apresentaram índice de exatidão acima de 80%. Do total de treze classes onze apresentaram índice superior a 90% e as demais índice entre 80 e 90%. Os piores desempenhos foram obtidos pelas classes Campo Rupestre herbáceo/arbustivo e classe Floresta de Galeria com exatidão de 87,5 e 89,0%, respectivamente. Por outro lado, o melhor desempenho, foi obtido pela classe água com índice de exatidão de 99,5%.

O maior confundimento entre classes ocorreu com as classes de Campo Rupestre. A classe Campo Rupestre herbáceo (4) apresentou uma maior confusão com a classe Campo Rupestre herbáceo/arbustivo (3), sendo que 11,5% dos pixels que deveriam ser assinalados à classe 4 foram classificados erroneamente na classe 3. Também 6% dos pixels da classe 3 foram classificados como pertencentes a classe 4. A semelhança entre as classes de campo rupestre favoreceu o confundimento, pois ambas ocorrem em situação similar de posição altimétrica e unidade litológica.

As classes que apresentaram melhor desempenho de classificação foram as classes água, com 99,5%; Floresta Semidecídua com 98,5% e Cerrado com 98%. Estas classes são bem distintas no que se referem à resposta espectral (água e vegetação) e no tipo de fisionomia (cerrado e floresta).

A classe Floresta de Galeria, com o segundo pior índice de exatidão, obteve 89% de acerto na classificação. O confundimento dessa classe ocorreu com as classes de vegetação florestal de Cerradão e Floresta Semidecídua, devido à semelhança na resposta espectral desses tipos de vegetação, já que as fitofisionomia dessas espécies (densidade, área foliar e tipo de vegetação) são semelhantes.

A presença de sombra de nuvem na imagem provocou um confundimento entre essa classe e outras, com um total de 4% dos pixels da classe sombra, assinalados erroneamente como pertencente a outras classe, especialmente com a classe cerrado que obteve (3%) dos pixels da classe sombra.

Tabela 3 – Matriz de confusão – conjunto 1

classes	1	2	3	4	5	6	7	8	9	10	11	12	13	total	Exatidão do analista
1	199	4	0	2	0	0	0	0	0	0	3	0	0	208	95.7
2	1	196	3	0	0	1	0	0	0	1	0	0	6	208	94.2
3	0	0	183	23	3	0	0	0	0	0	2	0	0	214	85.5
4	0	0	12	175	1	0	0	0	0	1	0	0	0	189	92.6
5	0	0	0	0	184	4	1	0	0	0	0	0	0	189	97.4
6	0	0	2	0	0	192	3	2	0	1	6	0	0	206	93.2
7	0	0	0	0	0	0	178	0	0	0	0	0	0	178	100.0
8	0	0	0	0	0	0	0	198	3	0	0	0	0	201	98.5
9	0	0	0	0	7	0	0	0	197	1	0	0	0	205	96.1
10	0	0	0	0	0	0	1	0	0	196	6	0	0	203	96.6
11	0	0	0	0	5	3	1	0	0	0	183	3	1	196	93.4
12	0	0	0	0	0	0	9	0	0	0	0	197	1	207	95.2
13	0	0	0	0	0	0	4	0	0	0	0	0	192	196	98.0
Total	200	200	200	200	200	200	200	200	200	200	200	200	200	2600	
Exatidão produtor	99.5	98.0	91.5	87.5	92.0	96.0	89.0	99.0	98.5	98.0	91.5	98.5	96.0		

Exatidão global = 95.0; Kappa = 0.946; Variância = 0,000021; Z calculado = 204,278; Z tabelado = 1,96
 Identificação das classes: 1-Água; 2-Cerrado – Formações campestre; 3-Campo Rupestre herbáceo; 4-Campo Rupestre herbáceo / arbustivo; 5-Floresta de Candeia; 6-Cerradão - Cerradão + Cerrado sentido restrito; 7-Floresta de Galeria; 8-Floresta Estacional Semidecidual (capão); 9-Floresta Seca; 10-Nuvem; 11-Pastagem; 12-Floresta Estacional Semidecidual; 13-Sombra.

5.2 Classificação do conjunto 2

As variáveis selecionadas pelo aplicativo *funcpow*, para discriminar as classes de cobertura e uso do solo apresentou índice *kappa* de 0,91 ficando inferior em apenas 3.3% em relação ao índice obtido pelo conjunto 1.

A Tabela 4 apresenta a estatística da matriz de confusão da classificação do Conjunto2. Com exceção da classe Campo Rupestre herbáceo arbustivo que obteve 59% de exatidão no mapeamento, as demais classes obtiveram exatidão acima de 80%.

A informação geológica foi uma variável que esteve presente em todos os conjuntos selecionados pelo aplicativo para combinações de variáveis selecionadas como maior índice *kappa*. Esse resultado corrobora com a afirmação de Alvim (citado por RIZZINI, 1997) de que a qualidade do solo condicionada principalmente pela origem geológica é o fator que determina o tipo de uma vegetação. Ressalta-se o controle litológico, na área de estudo das seguintes tipologias vegetal: Mata Seca, predominante sobre o substrato calcário; Campos Rupestres que ocorrem sobre rochas quartzíticas e dos Capões de Florestas semidecíduas que na sua maioria estão sobre rochas metabásicas.

Outra variável escolhida pelo aplicativo foi a altitude, esta, fortemente associada à ocorrência de tipologias vegetais como os Campos Rupestres, Capões era esperada ser representativa no processo de classificação, uma vez que o padrão do relevo da área apresenta acentuada variação topográfica condicionante de tipologias vegetais variadas. Destaca as formações vegetais de campo rupestre e formações florestais semidecíduas (capões) associadas a altitudes elevadas.

As bandas espectrais selecionadas pelo *funcpow* para compor o Conjunto 2 têm suas representatividades na discriminação das classes de cobertura e uso do solo em função das características de respostas de alvos presente na área de estudo. A banda 4 que capta a refletância dos alvos na região do infravermelho é entre todas as bandas do Sensor ETM+ aquela que mais contribui para distinção de padrões de vegetação, principalmente, considerando os dois extremos de resposta espectral apresentada na nas UC's deste estudo, onde áreas campestres são altamente contrastantes com as áreas florestais.

Tabela 4 – Matriz de confusão – Conjunto 2

classes	1	2	3	4	5	6	7	8	9	10	11	12	13	total	Exatidão do analista
1	198	2	0	0	0	0	0	0	0	0	0	0	0	200	99
2	1	195	3	0	1	0	0	0	0	0	5	0	0	205	95,1
3	0	0	180	81	1	0	0	0	0	0	0	0	1	263	68,4
4	0	0	15	119	1	0	0	0	0	0	0	0	0	135	88,1
5	0	0	1	0	191	11	1	2	1	0	6	0	0	213	89,1
6	0	0	1	0	1	181	28	1	2	0	10	0	0	224	80,8
7	0	0	0	0	0	4	162	0	0	0	1	0	0	167	97
8	0	0	0	0	3	0	0	197	1	0	0	0	0	198	99,5
9	0	0	0	0	0	0	1	0	196	1	0	0	0	200	98
10	0	0	0	0	2	4	5	0	0	199	4	0	0	204	97,5
11	0	3	0	0	0	0	3	0	0	0	174	5	1	194	89,7
12	0	0	0	0	0	0	0	0	0	0	0	195	1	199	98
13	1	0	0	0	0	0	0	0	0	0	0	0	197	198	99,5
Total	200	200	200	200	200	200	200	200	200	200	200	200	200	2600	
Exatidão do produtor	99	97,5	90	59,5	95,5	90,5	81	98,5	98	99,5	87	97,5	98,5		

Exatidão global = 91,7; Kappa = 0,910; Variância = 0,000034; Z calculado = 155,319 ; Z tabelado = 1,96
 Identificação das classes: 1-Água; 2-Cerrado – Formações campestre; 3-Campo Rupestre herbáceo; 4-Campo Rupestre herbáceo / arbustivo; 5-Floresta de Candeia; 6-Cerradão - Cerradão + Cerrado sentido restrito; 7-Floresta de Galeria; 8-Floresta Estacional Semidecidual (capão); 9-Floresta Seca; 10-Nuvem; 11-Pastagem; 12-Floresta Estacional Semidecidual; 13-Sombra.

5.3 Classificação do conjunto 3

A classificação do conjunto 3 utilizou como informações na camada de entrada apenas os valores espectrais das bandas do sensor ETM⁺ do Landsat. O resultado da exatidão da classificação está apresentado na matriz de confusão (Tabela 5), com índice *kappa* de 0,61.

Este conjunto de variáveis apresentou o pior índice de classificação quando comparado com os conjuntos 1 e 2, classificados pela rede. Este conjunto apresentou também os maiores conflitos entre classes, especialmente entre as classes de Campo Rupestre herbáceo e Campo Rupestre herbáceo/arbustivo.

Analisando a exatidão de classificação por classe vê-se que das treze classes apenas três apresentaram *kappa* maior que 0,90. Cinco das 13 classes ficaram com um índice de entre 0,60 e 0,71 e as demais cinco classes ficaram com o *kappa* menor que 0,6. As classes com

maior exatidão de classificação foram as classes água, nuvem e sombra com exatidão de 0,99; 0,95 e 0,96 respectivamente. Estas classes possuem uma ocorrência espacial pouco ligada às variáveis do meio físico, sendo, portanto a discriminação das mesmas dependente da informação espectral da imagem, mais que dos dados do meio físico.

As classes que tiveram um índice de exatidão médio foram classes de vegetação florestal (Candeia, Cerradão, Mata Seca e Capões), que obtiveram índice *kappa* entre 0,60 e 0,71. O conflito nessas classes ocorreu em maior proporção entre elas mesmas, devido a semelhança entre o porte da vegetação e resposta espectral das espécies. Na classe Floresta de Candeia 18% dos pixels que deveriam ser classificados nesta classe foram classificados como Cerradão. Na classe Mata Seca, 20,5 % dos seus pixels que foram amostrados para essa classe foram classificados como Floresta Ombrofila Montana.

Tabela 5 – Matriz de confusão – Conjunto 3

classes	1	2	3	4	5	6	7	8	9	10	11	12	13	total	Exatidão do analista
1	198	3	0	0	0	0	0	0	0	0	0	0	0	201	98,5
2	0	108	40	24	1	2	5	0	0	0	42	3	0	225	48
3	0	26	88	74	2	0	0	0	0	0	4	0	0	194	45,4
4	0	14	35	71	0	0	44	0	0	0	7	0	0	127	55,9
5	0	0	1	0	129	27	17	15	4	0	10	11	0	241	53,9
6	0	0	0	2	36	142	52	3	0	0	1	0	1	199	71,4
7	0	0	3	2	16	17	28	11	8	0	5	0	1	115	45,2
8	0	4	0	0	11	1	41	130	15	0	3	36	0	231	56,3
9	0	0	0	0	5	0	0	33	132	0	0	45	0	256	51,6
10	0	1	0	0	0	0	6	0	0	191	4	0	0	196	97,4
11	0	43	33	27	0	11	7	8	0	6	124	1	0	251	49,4
12	0	0	0	0	0	0	0	0	41	3	0	104	5	168	61,9
13	2	1	0	0	0	0	0	0	0	0	0	0	193	196	98,5
Total	200	200	200	200	200	200	200	200	200	200	200	200	200	2600	
Exatidão produtor	99	54	44	35,5	64,5	71	26	65	66	95,5	62	52	96,5		

Exatidão global = 63,9; Kappa = 0,609; Variância = 0,000104; Z calculado = 59,863 ; Z tabelado = 1,96
 Identificação das classes: 1-Água; 2-Cerrado – Formações campestre; 3-Campo Rupestre herbáceo; 4-Campo Rupestre herbáceo / arbustivo; 5-Floresta de Candeia; 6-Cerradão - Cerradão + Cerrado sentido restrito; 7-Floresta de Galeria; 8-Floresta Estacional Semidecidual (capão); 9-Floresta Seca; 10-Nuvem; 11-Pastagem; 12-Floresta Estacional Semidecidual; 13-Sombra.

Na classe pastagem 21% dos pixels que deveriam ser classificados como pertencente a essa classe foram classificados como Cerrado. Às áreas de Cerrado são comumente utilizadas para pastagem por apresentar vegetação herbácea, à semelhança da classe de pastagem, portanto a semelhança entre essas classes em parte se explica pelo porte da cobertura vegetal.

A supressão das informações do meio físico, neste conjunto acarretou na diminuição da heterogeneidade de dados. Como consequência houve a diminuição da exatidão de classificação da maioria das classes de cobertura vegetal que ocorrem condicionadas á fatores do meio físico.

5.4 Classificação do conjunto 1 pelo MAXVER

A partir dos resultados da classificação para os três conjuntos pela rede neural, escolheu-se o Conjunto 1 para comparar a classificação das mesmas variáveis com as mesmas amostras de treinamento e validação pelo classificador da rede neural e pelo MAXVER. Este conjunto de amostras foi escolhido por ter apresentado maior exatidão de classificação dentre os três conjuntos de variáveis classificados.

A Tabela 6 apresenta a matriz de confusão obtida pela classificação do conjunto 1 pelo algoritmo MAXVER. Na comparação entre os resultados das classificações feitas para o Conjunto 1 pela rede ($kappa$ de 0,75) e a classificação feita pelo MAXVER com as mesmas variáveis ($kappa$ de 0,95), percebe-se que a primeira classificação teve maior desempenho com diferença de aproximadamente 20% na exatidão.

A análise de exatidão de classificação por classes mostra dois extremos nos resultados da classificação de quatro das treze classes mapeadas. As classes água e Mata Seca não tiveram nenhum pixel classificado corretamente, e de modo oposto, as classes nuvem e sombra tiveram todos os pixels classificados corretamente. No confundimento entre as classes água e sombra, todos os pixels que deveriam ser classificados como pertencente à classe água foram erroneamente classificados como pertencente à classe sombra. Na classe Mata Seca 75% dos pixels foram classificados como pertencente à classe Floresta Ombrófila Montana e os demais 25% foram classificados como Floresta de Galeria.

Tabela 6 – Matriz de confusão do Conjunto 1 pelo MAXVER

classes	1	2	3	4	5	6	7	8	9	10	11	12	13	total	Exatidão do analista
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	194	0	0	0	0	0	0	0	0	0	0	0	194	100
3	0	0	183	74	0	0	0	0	0	0	0	0	0	257	71,2
4	0	0	13	124	0	0	0	0	0	0	0	0	0	137	90,5
5	0	0	0	0	177	0	0	0	0	0	0	0	0	177	100
6	0	0	0	0	0	157	7	0	0	0	0	0	0	164	95,7
7	0	0	0	0	15	20	180	15	50	0	4	1	0	285	63,2
8	0	0	0	0	0	0	0	183	0	0	0	0	0	183	100
9	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	8	23	12	0	0	200	0	0	0	201	99,5
11	0	6	4	0	0	0	1	2	0	0	196	0	0	249	78,7
12	0	0	0	0	0	0	0	0	150	0	0	199	0	352	56,5
13	200	0	0	1	0	0	0	0	0	0	0	0	200	401	49,9
Total	200	200	200	200	200	200	200	200	200	200	200	200	200	2600	
Exatidão produtor	0	97	91,5	62	88,5	78,5	90	91,5	0	100	98	99,5	100		

Exatidão global = 76,7; Kappa = 0,747; Variância = 0,000078; Z calculado = 84,596 ; Z tabelado = 1,96
 Identificação das classes: 1-Água; 2-Cerrado – Formações campestre; 3-Campo Rupestre herbáceo; 4-Campo Rupestre herbáceo / arbustivo; 5-Floresta de Candeia; 6-Cerradão - Cerradão + Cerrado sentido restrito; 7-Floresta de Galeria; 8-Floresta Estacional Semidecidual (capão); 9-Floresta Seca; 10-Nuvem; 11-Pastagem; 12-Floresta Estacional Semidecidual; 13-Sombra.

5.5 Avaliação do índice de significância entre as classificações

Foi realizado um teste de significância (Teste Z) para comparar as classificações feitas para todos os conjuntos de variáveis classificados pela Rede Neural e a classificação feita pelo MAXVER para o conjunto 1.

O teste Z determina se dois ou mais valores independentes de *kappa* e consequentemente duas ou mais matriz de confusão são significativamente diferentes. Com esse teste é possível comparar estatisticamente dois ou mais algoritmo, assim como dois ou mais conjuntos de dados, tornando possível ver qual produz maior exatidão de classificação (CONGALTON e GREEN, 1989).

Utilizou os dados da matriz de confusão, índice *kappa* e variância, de cada uma das classificações para observar a significância entre os classificadores através do teste Z

Os resultados de significância (Tabela 7) mostraram que as classificações feitas pela rede para os três conjuntos são estatisticamente diferentes, sendo a classificação com as onze variáveis (Conjunto 1) melhor do que a classificação com as quatro variáveis (Conjunto 2) que por sua vez mostrou-se melhor que a classificação feita com as seis variáveis (Conjunto 3)

corresponde às imagens do sensor ETM⁺ conforme (Tabela 4). Comparando a classificação pela rede com as classificações feita pelo MAXVER, observa-se que todas diferem estatisticamente, sendo a classificação pelo MAXVER melhor apenas que a classificação feita para o conjunto 3.

Tabela 7 – Índices de significância das classificações – Teste Z

Conjuntos	Conjunto 1	Conjunto 2	Conjunto3	MAXVER
Exatidão global	95,0	91,7	63,9	76,7
KAPPA	0,946	0,91	0,609	0,747
VAR.	0,000021	0,000034	0,000104	0.000078
Conjunto 1	206,43			
Conjunto 2	<u>4,85*</u>	156,06		
Conjunto 3	<u>30,14*</u>	<u>25,62*</u>	59,72	
MAXVER	<u>20*</u>	<u>15,40*</u>	<u>10,23*</u>	84,58

* Existe diferença significativa ao nível de 95% de probabilidade.

Na tabela 7 os valores da diagonal, em negrito, indicam que todos os classificadores são estatisticamente melhores que uma classificação aleatória com 95% de significância. Por outro lado os resultados grifados, fora da diagonal, que compara a classificação entre conjuntos indicam que houve diferenças significativas entre os classificadores. A diferença entre classificadores e dada sempre que esses valores são maiores que 1,96 (valor padronizado, referente à estatística do teste Z).

Analisando os índices *kappa* fornecidos pelas matrizes de confusão pode-se dizer que de acordo com o proposto por Landis e Koch (1977, *apud* MOREIRA, 2005) o resultados da classificação dos Conjuntos 1 e 2 com *kappa* maior que 0,80 são consideradas excelentes. Enquanto que a classificação do conjunto 3 e a classificação do conjunto 1 pelo MAXVER, com *kappa* maior que 0,60 são consideradas muito boas.

5.6 Representação do mapa de cobertura e uso do solo

Através dos resultados da matriz de confusão e do teste de significância das classificações observou-se que o conjunto 1, classificado com todas as variáveis, pela rede neural apresentou com exatidão global de mapeamento e menor confusão entre classes, mostrou-se mais satisfatório para a representação do mapa de cobertura e uso do solo das unidades de conservação PNSCi e APA Morro da Pedreira.

Foram concluídas todas as etapas do processo de classificação para o conjunto 1 com a classificação pela rede neural. Após a classificação realizou-se a filtragem da imagem e em

seguida fez a quantificação das áreas de ocorrência de cada classe (Tabela 8) e representação das classes no mapa (Figura 5).

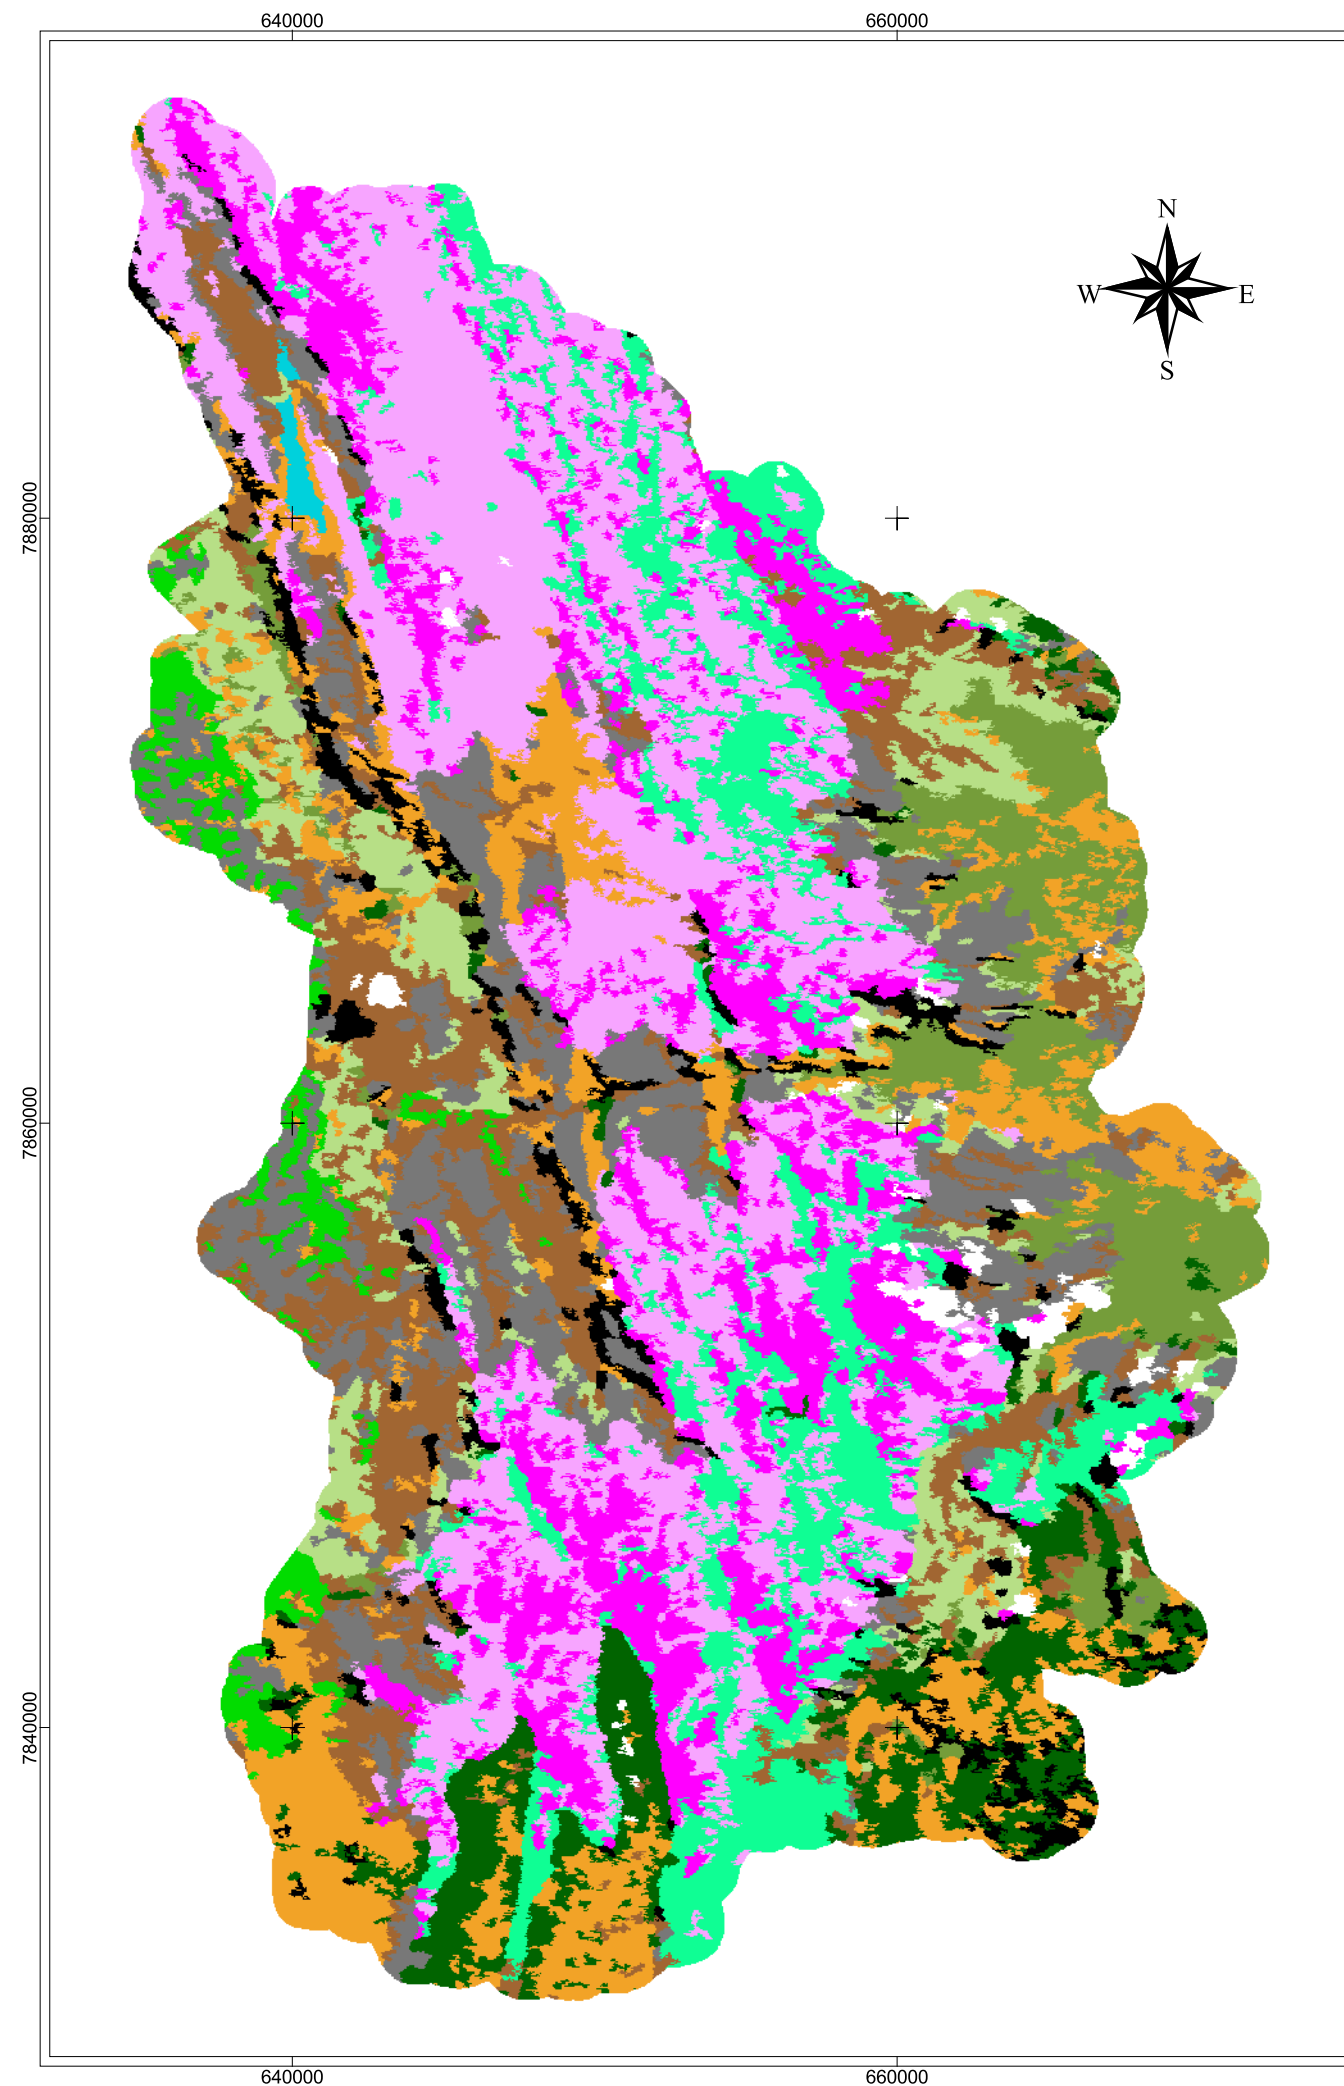
Na análise visual da Figura 5, que apresenta o mapa de uso e cobertura produzido pela classificação do conjunto 1 pela rede neural, percebe-se que embora apenas 4% dos pixels da classe sombra tenha sido classificado em outras classes (Tabela 3), o conflito é visualmente perceptível. A classe sombra está ligada espacialmente com a classe nuvem e onde aparece mapeado a classe sombra e não aparece a classe nuvem na proximidade significa que houve conflito de classificação entre a classe sombra e outras. A confusão ocorreu predominantemente em área escarpada, provocada pelas áreas sobreadas.

Em termos de ocorrência das classes há como se observa na Tabela 8, o predomínio dos Campos Rupestres com aproximadamente 30% da área. As classes de Cerrado ocupam 20% e as áreas de pastagem e Capões ocupam em torno de 10% cada classe. As áreas cobertas por nuvem e sombra ocupam aproximadamente 4,5% da área. A quantificação das áreas de ocorrência de cada classe classificada é de grande importância para o manejo da área, uma vez que os estudos temporais baseiam-se na análise qualitativa, e quantitativa.

Na análise qualitativa pode-se avaliar, por exemplo, mudanças espaciais ocorridas com determinada classe bem como as mudanças na fisionomia das espécies vegetal. Enquanto que na análise quantitativa a informação é numericamente representada através dos resultados das mudanças qualitativas. Essa última análise permite adquirir dados que podem ou não ser observados visualmente, pela análise qualitativa.

Tabela 8 – Quantificação das classes mapeadas

Classe	Área (ha)	(%)
1 - Água	329,76	0,22
2 – Cerrado – Formações Campestre	17.542,53	11,48
3 - Campo Rupestre herbáceo	34.666,83	22,68
4 - Campo Rupestre herbáceo/arbustivo	17.254,17	11,29
5 - Floresta de Candeia	8.953,83	5,86
6 – Cerradão + Cerrado sentido restrito	16.217,19	10,61
7 - Floresta de Galeria	3.027,15	1,98
8 - Floresta Estacional Semidecídua (Capão)	15.511,59	10,15
9 - Floresta Seca	9.130,86	5,97
10 - Nuvem	1.397,52	0,91
11 - Pastagem	15.355,44	10,05
12 - Floresta Semidecídua Montana	8.144,55	5,33
13 - Sombra	5.294,70	3,46
Total	152.826,12	100.00



Mapa da cobertura e uso do solo: Parque Nacional da Serra do Cipó e Área de Proteção Ambiental Morro da Pedreira - MG


Legenda

- Água
- Cerrado sentido restrito
- Campo de Altitude
- Campo Rupestre
- Floresta de Candeia
- Cerrado senso lato
- Floresta de Galeria
- Floresta Estacional semidecídua (capão)
- Mata Seca
- Nuvem
- Pastagem
- Floresta Estacional semidecídua
- Sombra

Escala 1:100.000



Projeção Universal Transversa de Mercator
Zona UTM - 23 / Datum SAD 69



Mapa elaborado no LabGeo - DPS / Universidade Federal de Viçosa.
Elaboração: Eliana de Souza 2006.

Figura 8 - Mapa gerado pela classificação por Rede Neural com as variáveis do Conjunto 1.

6. CONCLUSÕES

Com base nos resultados apresentados conclui-se que a classificação por redes neurais mostrou-se uma técnica adequada para classificar a cobertura e uso do solo das UC's PNSCi e APA Morro da Pedreira, com índice de exatidão geral de 95% para o conjunto que agregou todas as variáveis discriminantes.

O maior índice *kappa*, foi obtido quando usou todas as variáveis, o que ressalta o caráter robusto da rede neural e sua capacidade de generalizar das classes informacionais.

As variáveis utilizadas mostraram-se representativas para no processo de classificação, empregando distinção entre as classes.

Os resultados mostraram que os dados do meio físico são fontes de relevantes informações que auxiliam aos dados espectrais de imagem no processo de classificação. Observou-se a relevância de tais dados na comparação entre a classificação com apenas as bandas espectrais da imagem Landsat com *kappa* de 0,61 e a classificação usando informações das bandas espectrais mais, dados do meio físico, com índice e 0.95.

A classificação pela rede neural mostrou-se mais adequada para a classificação dos padrões de cobertura e uso do solo da área objeto de estudo deste trabalho, do que o algoritmo MAXVER, como observados nos resultados das matrizes de confusão de um mesmo conjunto de variável classificado pela rede com exatidão geral de 95% e pelo MAXVER com exatidão geral de 77%. Estes dados reafirmam o melhor desempenho da rede neural em relação ao algoritmo MAXVER, na classificação de padrões.

O mapa de cobertura e uso do solo gerado pela classificação por rede neural apresenta-se como um documento cartográfico com informações consistentes para subsidiar o plano de manejo da APA Morro da Pedreira e Parque Nacional da Serra do Cipó.

A classificação automática da cobertura e uso do solo apresenta-se como uma técnica viável para uso em produção de mapas pela disponibilidade de obtenção de dados de sensoriamento remoto e dados do meio físico.

7. LITERATURA CITADA

- AB'SABER, A.. Domínios Morfoclimáticos e Solos do Brasil. In: **O Solos nos domínios morfoclimáticos do Brasil e o desenvolvimento sustentado**. ALVAREZ, V. Hugo V. et al.. Viçosa, MG: SBCS, UFV, DPS, 1996. P.1-18.
- ANDRADE, M. C.. A questão do Território. In: **A questão do Território no Brasil**. São Paulo: Hucitec. 1995.
- BENEDIKTSSON, A. J.; SVEINSSON, J.R.. Feature extraction for multisource data classification with artificial neural network. **International Journal of Remote Sensing**. V. 18, p.727-740, 1997.
- BRAGA, A. L. et al.. Comparação entre as classificações híbrida e supervisionada no mapeamento do uso do solo usando imagens de alta resolução. In: Anais do Congresso Brasileiro de Cadastro Técnico Multifinalitário. **CD-ROM**. Florianópolis: UFSC. 2006.
- BRASIL. **Constituição da República Federativa do Brasil**. Título 8. Capítulo VI. Do Meio Ambiente. Texto consolidado até a Emenda Constitucional nº 48 de 10 de agosto de 2005. Brasília: Secretaria Especial de Editoração e Publicações. 2005.
- BRASIL. **DECRETO Nº 750**. Dispões sobre o uso dos recursos da Mata Atlântica. Brasília. 1993.
- CÂMARA, G.; DAVIS, C.. Por que Geoprocessamento? In: CÂMARA, G., et al.. **Introdução à Ciência da Geoinformação**. INPE: São José dos Campos, 2000. Disponível em <<http://www.dpi.inpe.br/gilberto/livro.html>>. Acesso em: 21 de Ago de 2004.
- CÂMARA, G.; FELGUEIRAS, C. A.. Sistema de Informações Geográficas do INPE. In: ASSAD, E. D.; SANO, E. E.. **Sistemas de Informações Geográficas Aplicações na Agricultura**. Planaltina: EMBRAPA. Brasília, DF, 1993.
- CARVALHO JUNIOR W. de. Classificação supervisionada de paisagens de áreas montanhosas utilizando redes neurais artificiais através de atributos geomorfométricos. 2005. **Tese (Doutorado em Solos e Nutrição de Plantas)**. Departamento de Solos. Universidade Federal de Viçosa. Viçosa: Minas Gerais. 2005.
- CARVALHO, M. S. et al. **Conceitos básicos de sistemas de informação geográfica e cartografia aplicados à saúde**. Organização Panamericana da Saúde: Brasília, 2000. 122p.
- CETIN, M. et al. Classification of multi-spectral and multi-sensor images using principal components analysis and artificial neural networks: Beykoz case. In: **XX Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS)**. Istanbul: Turkey. 2004, 7 p.
- CHAGAS, C. da S. Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de mar de morros. 2006. 223 p. **Tese (Doutorado em Solos e Nutrição de Plantas)**. Departamento de Solos. Universidade Federal de Viçosa. Viçosa: Minas Gerais. 2006.

COMIG - Companhia Mineradora de Minas Gerais. Projeto Espinhaço: Geologia da Folha Baldim e Folha Conceição do Mato Dentro. In: GROSSI-SAD, J. H. et al.. (Org). **CD-ROM**. Belo Horizonte: COMIG. 1997.

CONGALTON, R. G. & GREEN, K. Basic Analysis Techniques. In: CONGALTON, R. G. & GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999.

COSTA, S. de S. M. da. **Caracterização ambiental da Reserva Extrativista Chico Mendes (Acre, Brasil): subsídios ao plano de manejo**. (Tese de doutorado). Universidade Federal de São Carlos. São Carlos: UFSCAr. 2000. 151p.

CPRM - Companhia de Pesquisa de Recursos Minerais. Carta Geológica do Brasil ao Milionésimo. Folha SE.23 - Belo Horizonte. Serviço Geológico do Brasil. Ministério de Minas e Energia. Secretária de Minas e Metalurgia. Escala 1:1000.000. 2004. **CD-ROM**.

ESDI. Earth Science Data Interface. Disponível em:<
<http://glcfapp.umiacs.umd.edu:8080/esdi/index.jsp>> Acesso em 10 de Setembro de 2006.

ESDI. Earth Science Data Interface. Imagem LANDSAT 7. Disponível em:<
<http://glcfapp.umiacs.umd.edu:8080/esdi/index.jsp>> Acesso em 20 de Jun. de 2006.

ESRI. **Environmental System Research Institute**. ARC/INFO. New York, 1994.

ESRI. **Environmental System Research Institute**. ArcGIS 9.0. New York, 2004.

FIGUEIRAS, C.A.; CÂMARA, G. Sistemas de Informações geográficas do INEP. In: ASSAD, E.D.; SANO, E.E. ED. **Sistemas de informações geográficas: aplicações na agricultura**. Brasília, DF: EMBRAPA/ CPAC, 1993. p. 39-57.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de textos. 2002.

GALINDO-LEAL, C.; CÂMARA, I. de G. **Mata Atlântica: biodiversidade, ameaças e perspectivas**. Belo Horizonte: Conservação Internacional. 2005. p. 3-65.

GASTAL, M. L. Os limites para a conservação da biodiversidade. In: Bensusan, Nurit. (Org.) **Seria melhor mandar ladrilhar? Biodiversidade como, para que, por quê?** Brasília: Insituo Socioambiental, 2002. 252 p.

GLCF - *Global Land Cover Facility*. Disponível em: <
<http://glcf.umiacs.umd.edu/library/faq.shtml#datashare> >. Acesso em 22 de out de 2006.

IBAMA. . Instituto Nacional do Meio Ambiente e dos Recursos Naturais Renováveis. **Decreto N° 98.891**. Dispõe sobre e criação da Área de Proteção Ambiental Morro da Pedreira. Brasília. 1990.

IBAMA. . Instituto Nacional do Meio Ambiente e dos Recursos Naturais Renováveis. **Roteiro Metodológico de Planejamento: parque nacional, reserva biológica, estação ecológica**. IBAMA. 2002. 136p.

IBAMA. Instituto Nacional do Meio Ambiente e dos Recursos Naturais Renováveis. Disponível em<<http://www.ibama.gov.br/siucweb/mostraUc.php?seqUc=3>> Acesso em: 20 setembro de 2006c.

IBAMA. Instituto Nacional do Meio Ambiente e dos Recursos Naturais Renováveis. Disponível.< <http://www.ibama.gov.br/siucweb/listaUcCategoria.php?abrev=APA>> Acesso em:25 de agosto de 2006a.

IBAMA. Instituto Nacional do Meio Ambiente e dos Recursos Naturais Renováveis. Mapa das Unidades de conservação Federal do Brasil. Escala 1:6.000.000, 2006b.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Mapa de Biomas do Brasil**. Escala 1: 5.000.000. 2004b.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Mapa de Vegetação do Brasil**. Escala 1: 5.000.000. 3ª ed. 2004a.

IBGE - Instituto Brasileiro de Geografia e Estatística. Projeção Universal Transversa de Mercator. **Carta SE-23-Z-C-VI-2 / MI 2535-2 - Jaboticatubas**. Escala 1:50.000.1977.

IBGE - Instituto Brasileiro de Geografia e Estatística. Projeção Universal Transversa de Mercator. **Carta SE-23-Z-C-III/MI 2497 - Baldim**. Escala 1:100.000.1977.

IBGE - Instituto Brasileiro de Geografia e Estatística. Projeção Universal Transversa de Mercator. **Carta SE-23_Z-D-I /MI 2498 - Conceição do Mato Dentro**. Escala 1:100.000. 1977.

IBGE - Instituto Brasileiro de Geografia e Estatística. Projeção Universal Transversa de Mercator. **Carta SE-23-Z-D-IV /MI 2536 - Itabira**. Escala 1:100.000. 1977.

IEF/MG - Instituto Estadual de Florestas de Minas Gerais. Disponível em: <<http://www.ief.mg.gov.br/parques/areasprot.asp>>, Acesso em 16 de Setembro de 2006>.

IPPOLITI-RAMILO, G. A. **Imagens TM/LandSat-5 da época de pré-plantio para a previsão da área de culturas de verão**. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais. São José dos Campos: INPE. 1999.

JavaNNS. Java Neural Network Simulator. Version 1.1. University of Tübingen. **2001.**http://www-ra.informatik.uni-ebingen.de/software/JavaNNS/welcome_e.html

JIANWEN, M.; BAGAN, H.. Land-use classification using ASTER data and self-organized neural networks. **International Journal of Applied Earth Observation and Geoinformation**. 2005. p. 183-188.

KAVZOGLU, T.; MATHER P. M. Pruning artificial neural networks: an example using land cover classification of multi-sensor images. **International Journal of Remote Sensing**. 1999. v. 20, p. 2787-2830.

KAVZOGLU, T.; MATHER, P.M.. The use of backpropagating artificial neural network in land cover classification. **International Journal of Remote Sensing**. 2003. v.24, p.4907 – 4938.

- MARKHAM, B. L. et al. Landsat Sensor Performance:History and Current Status. **IEEE Transactions on Geoscience and Remote Sensing**. v. 42, n. 12, 2004. p.2691 – 2694.
- MASEK, J. G. et al. Landsat-7 ETM+ as an observatory for land cover initial radiometric and geometric comparisons with landsat-5 thematic mapper. **Remote Sensing of Environment**. v.78, 2001. p. 118– 130.
- MMA - Ministério do Meio Ambiente. **Avaliação e identificação de áreas e ações prioritárias para conservação, utilização sustentável e repartição dos benefícios da biodiversidade nos biomas brasileiros**. Brasília: DF MMA, Secretaria de Biodiversidade e Florestas, 2002. 404 p.
- MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto: metodologias de Aplicação**. 3ª ed. Viçosa: UFV, 2005. 320p.
- NANGENDO, Grace et al.. Mapping east african tropical forests and woodlands: a comparison of classifier. **Journal of Photogrammetry and Remote Sensing**. v. 61. 2007. p. 393-404.
- NOVO, E. M. L. de M. **Sensoriamento Remoto: princípios e aplicações**. São José dos Campos: Edgard Blucher, 1989. 308p.
- OLIVEIRA FILHO A. T., FLUMINHAM FILHO, M. Ecologia da Vegetação do Parque Florestal Quedas do Rio Bonito. **CERNE**. Lavras: UFLA. v. 5, n.2, p51-64, 1999
- PAESE, A. **Caracterização e análise ambiental do Campus da Universidade Federal de São Carlos (UFSCar), São Carlos, SP**. Dissertação (mestrado). Universidade Federal de São Carlos. 1997. 87p.
- RENGER, F.E. Evolução dos conceitos Geológicos da Serra do Espinhaço. In: **Atas do Primeiro Simpósio de Geologia de Minas Gerais: Geologia do Espinhaço**. Sociedade Brasileira de Geologia. Boletim n1. 1979.
- RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do Bioma Cerrado. In: SANO, Sueli Matiko; ALMEIDA, Semiramir Pedrosa de(org.). **Cerrado: ambiente e flora**. Planaltina: Embrapa-CPAC. 1998, p.89-166.
- RIBEIRO, R. M. P. et al.. Avaliação de métodos de classificação de imagens IKONOS para o mapeamento da cobertura terrestre. In: **Simpósio Brasileiro de Sensoriamento Remoto**. Goiânia: INPE. 2005. p. 4277-4283.
- RIZZINI, C. T. **Tratado de Fitogeografia do Brasil: aspectos ecológicos, sociológicos e florístico**. Rio de Janeiro: Âmbito cultural Edições Ltada. 2ªed. 1997. 537 p.
- SILVA, E. P. da. **Geoprocessamento na discriminação de pastagens degradadas utilizando rede neural artificial em imagem IKONOS II**. 2006. Tese (Doutorado) Departamento de Solos e Nutrição de Plantas. Universidade Federal de Viçosa. Viçosa. 2006.
- SNUC. Sistema Nacional de Unidades de Conservação. Lei N° 9.985. Brasília: Distrito Federal. 2000. 20p.

VELOSO, H. P. et al. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, Departamento de Recursos Naturais e Estudos Ambientais. 1991.124p.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. (Tese de doutorado). University of Nottingham, 2000. 323 p.