

GILBERTO FIALHO MOREIRA

**CLASSIFICAÇÃO AUTOMATIZADA DO USO E
COBERTURA DO SOLO UTILIZANDO IMAGENS
LANDSAT NO MUNICÍPIO DE ARAPONGA, MG**

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

VIÇOSA
MINAS GERAIS - BRASIL
2009

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

T

M838c
2009

Moreira, Gilberto Fialho, 1980-

Classificação automatizada do uso e cobertura do solo
utilizando imagens Landsat no município de Araponga, MG
/ Gilberto Fialho Moreira – Viçosa, MG, 2009.
xiv, 85f.: il. (algumas col.) ; 29cm.

Orientador: Raphael Bragança Alves Fernandes.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 80-85

1. Solo – Uso – Araponga (MG). 2. Plantas e solo.
3. Sensoriamento remoto. 4. Sistemas de informação
geográfica. 5. Redes neurais (Computação).
6. Processamento de imagens. 7. Teste de interpretação
de imagens. 8. Landsat (satélites). 9. SPRING (Programa
de computador). 10. JAVA (Linguagem de programação de
computador). 11. Máxima verossimilhança restrita.
12. Parque Estadual da Serra do Brigadeiro
I. Universidade Federal de Viçosa. II. Título.

CDD 22.ed. 631.4098151

GILBERTO FIALHO MOREIRA

**CLASSIFICAÇÃO AUTOMATIZADA DO USO E
COBERTURA DO SOLO UTILIZANDO IMAGENS
LANDSAT NO MUNICÍPIO DE ARAPONGA, MG**

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

APROVADA: 27 de novembro de 2008

Prof. Carlos Antônio Oliveira Vieira
(Co-orientador)

Prof. João Luiz Lani

Prof. Guido Assunção Ribeiro

Prof. Hélio Garcia Leite

Prof. Carlos Ernesto R. G. Schaefer
(Presidente da banca)

DEUS;

primeiramente por ter enviado um ser iluminado que sempre fica ao meu lado, fazendo com que tudo dê certo;

segundo por ter me dado amigos tão legais que agüentam as minhas constantes reclamações e sempre estão a postos para me ajudar no que precisar e;

por último, não menos importante, todas as pessoas que convivo, que de um jeito ou de outro, fizeram com que eu crescesse, me dando forças pra lutar e modificar a minha realidade;

Dedico

ERA BYTE

Evolução
Era byte
Tecnologia avançada
Informações têm que ser
processadas
Digital
Será real?
Na certa confusão
Na rede
Na cabeça da gente
No mundo
Em tudo
Analfabytes
Segredos
Mensagens
Senhas
Sacanagens
Letras
Imagens
É coisa demais
Não sei como suportar
Ufa!
Não agüento mais
Clica
Clica
Digita
Envia
Recebe
Tem gente na linha
Analógico
Que nada
Já não é mais a lógica
Agora é fibra óptica
Oh!
Ligeiro
Rapidinho
Ao vivo
Instantâneo
Eu aqui e você lá
Já não demora chegar
Só não faz a saudade passar
Será?

[Gilberto Fialho Moreira]

“Os grandes avanços científicos não se deveram à descoberta de novos fatos, mas apareceram como uma nova maneira de pensar e de formular fatos conhecidos”

René Thom

AGRADECIMENTOS

Agradecer ao IEF e ao Centro de Estudos e Desenvolvimento Florestal, pelo apoio durante esta batalha; à Universidade Federal de Viçosa e ao o Departamento de Solos, pela paciência e tanto aprendizado que me servirá para a vida toda e; ao financiamento inicial do CNPq e da Capes. Agradecimentos são difíceis e fáceis, são bons e são maus. Agradecer é faca de dois gumes, pois não sabemos se agradecemos o bastante ou mesmo se agradecemos a todos que participaram, nem que seja como coadjuvante nas cenas que fazem parte desta história. História bela e ao mesmo tempo suada, corrida e sufocante. A pressão das mãos alheias e daquelas que afagaram no momento de cansaço e até de desespero pelo medo e por desacreditar em si mesmo. Que bom que todos puderam e estiveram presentes. Momentos, dos quais não esqueceremos jamais. Por isso agradeçamos juntos: à vida, a Deus, à saúde, à inteligência, aos pais, aos orientadores, aos professores, aos amigos, às plantas, ao céu azul e cinza, ao verde, ao toque, às escolhas, às decisões, às lágrimas, aos sorrisos, por sermos únicos, às festas baratas, às noites mal dormidas, as comidas instantâneas... Agradeçamos pela talvez melhor fase de nossas vidas, agradeçamos sempre por termos sido UNIVERSITÁRIOS.

BIOGRAFIA

GILBERTO FIALHO MOREIRA, filho de Sebastião Pinto Moreira (*in memoriam*) e Iraci Maria Moreira, nasceu na cidade de Viçosa, Minas Gerais, no dia 04 de fevereiro de 1980.

Em abril de 2001, ingressou no curso de Geografia pela Universidade Federal de Viçosa (UFV), Minas Gerais, graduando-se (licenciatura e bacharelado) em maio de 2006. No mesmo mês ingressou no Mestrado no Programa de Pós-graduação em “Solos e Nutrição de Plantas”, do Departamento de Solos, da mesma Instituição. Em outubro de 2006 tomou posse ao cargo de Analista Ambiental no Instituto Estadual de Florestas de Minas Gerais, vindo a trabalhar no Centro de Estudos e Desenvolvimento Florestal localizado no Campus da UFRV, no qual em 2008 se tornou coordenador, atuando principalmente na área de geoprocessamento e no mapeamento da cobertura florestal, bem como em *prol* do meio ambiente.

SUMÁRIO

RESUMO.....	xii
ABSTRACT.....	xiv
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA.....	4
2.1. Biomas e Formações.....	4
2.1.1. Bioma Mata Atlântica.....	6
2.1.2. Formações Florestais.....	11
2.1.2.1. Floresta Ombrófila Densa.....	11
2.1.2.2. Floresta Semidecídua.....	11
2.1.2.3. Complexos Rupestres de Altitude e Campos de Altitude.....	12
2.2. Classificação de Cobertura Vegetal.....	14
2.3. Técnicas de Geoprocessamento e Sistemas de Informações Geográficas.....	15
2.4. Sensoriamento Remoto.....	16
2.4.1. Classificação de Imagens.....	21
2.4.1.1. Método da Árvore de Decisão.....	23
2.4.1.2. Método da Máxima Verossimilhança.....	26
2.4.1.3. Método das Redes Neurais Artificiais.....	26
2.4.1.4. Validação da Classificação.....	30
2.4.2. Sensor TM Landsat.....	31
3. MATERIAIS E MÉTODOS.....	33
3.1. Localização da Área de Estudo e Caracterização Geral.....	33
3.2. Materiais e Bases de Dados.....	34
3.3. <i>Softwares</i> Utilizados.....	35
3.4. Trabalho de Campo.....	36
3.5. Trabalho de Laboratório.....	38
3.5.1. Preparação dos Dados para Utilização no Método da Máxima Verossimilhança.....	39
3.5.2. Preparação dos Dados para Entrada na Rede.....	40
4. RESULTADOS.....	44
5. DISCUSSÃO.....	52
5.1. Floresta Estacional Semidecídua.....	56
5.2. Floresta Ombrófila.....	59
5.3. Campo de Altitude.....	62
5.4. Pastagem.....	65
5.5. Eucalipto.....	68
5.6. Café.....	71
6. CONSIDERAÇÕES FINAIS.....	74
7. CONCLUSÕES.....	79
REFERÊNCIAS BIBLIOGRÁFICAS.....	80

LISTA DE FIGURAS

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA.....	4
Figura 1 – Biomas do Brasil identificados pelo IBGE.....	5
Figura 2 – Mata Atlântica brasileira original e atuais remanescentes.....	7
Figura 3 – Tipos Vegetacionais (formações) encontradas no Estado de Minas Gerais.....	10
Figura 4 – Perfil topográfico das diversas formações da Mata Atlântica.....	10
Figura 5 – Reflectância espectral de alguns alvos ao longo do comprimento de onda.....	18
Figura 6 – Faixas do espectro eletromagnético desde os raios gama até as ondas de rádio, mostrando a faixa do visível e a faixa do infravermelho.....	18
Figura 7 – Representação da classificação pela metodologia da árvore de decisão. No exemplo o uso da metodologia foi para análise de decisão na área da saúde médica.....	23
Figura 8 – Esquema representativo de uma arquitetura neural MLP (<i>Multilayer Perceptron</i>) dentro do contexto de Redes Neurais Artificiais.....	27
3. MATERIAIS E MÉTODOS.....	33
Figura 9 – Localização da área de estudo correspondente ao município de Araponga (MG) com destaque para o Parque Estadual da Serra do Brigadeiro.....	33
Figura 10 – Imagem do satélite Landsat5 TM de 16/11/2005, destacando-se o município de Araponga (MG), formada a partir da combinação das bandas 3/4/5.....	36
Figura 11 – Modelo digital de elevação (MDE) da área estudada.....	41
4. RESULTADOS.....	44
Figura 12 – Cobertura vegetal do município de Araponga (MG), segunda a classificação automatizada por Árvores de Decisão, efetuada previamente no trabalho de CARVALHO <i>et al.</i> (2005).....	45
Figura 13 – Cobertura vegetal do município de Araponga (MG), segunda a classificação automatizada por MAXVER.....	47
Figura 14 – Cobertura vegetal do município de Araponga (MG), segunda a classificação automatizada por Redes Neurais Artificiais.....	48
5. DISCUSSÃO.....	52
Figura 15 – Legenda de cores usada na comparação das classes de vegetação obtidas em imagens de diferentes sensores e na avaliação da classificação efetuada por diferentes ferramentas de geoprocessamento.....	55
Figura 16 – Tipologia vegetacional Floresta Estacional Semidecídua presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).....	56
Figura 17 – Imagens (a) ÍKONOS e (b) Landsat, destacando-se a área com Floresta Estacional Semidecídua.....	57

Figura 18 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO <i>et al.</i> , 2005) com enfoque na Floresta Estacional Semidecídua.....	57
Figura 19 – Imagem da Figura 17 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com Floresta Estacional Semidecídua.....	58
Figura 20 – Tipologia vegetacional Floresta Ombrófila presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).....	60
Figura 21 – Imagem (a) ÍKONOS e (b) Landsat destacando a área com Floresta Ombrófila.....	60
Figura 22 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO <i>et al.</i> , 2005) com enfoque na área ocupada efetivamente pela Floresta Ombrófila.....	61
Figura 23 – Imagem da Figura 21 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com Floresta Ombrófila.....	61
Figura 24 – Fitofisionomia vegetacional Campo de Altitude presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).....	63
Figura 25 – Imagens (a) ÍKONOS e (b) Landsat destacando área com Campo de Altitude.....	63
Figura 26 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO <i>et al.</i> , 2005) com enfoque em Campo, considerado no referido trabalho como as formações Campo e Campo Rupestre.....	64
Figura 27 – Imagem da Figura 25 (b) classificada com as metodologias (a) MAXVER e (b) RNA destacando-se a área com Campo de Altitude.....	64
Figura 28 – Tipologia vegetacional pastagem presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).....	66
Figura 29 – Imagens (a) ÍKONOS e (b) Landsat destacando área com Pastagem.....	66
Figura 30 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO <i>et al.</i> , 2005) com enfoque em pastagem...	67
Figura 31 – Imagem da Figura 32 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com pastagem.....	67
Figura 32 – Tipologia vegetacional eucalipto presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).....	69
Figura 33 – Imagens (a) ÍKONOS e (b) Landsat destacando área com eucalipto.....	69
Figura 34 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO <i>et al.</i> , 2005) com enfoque na área de eucalipto.....	70
Figura 35 – Imagem da Figura 33 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com eucalipto.....	71
Figura 36 – Plantio de café presente na área de estudo, Araponga (MG).....	72
Figura 37 – Imagens (a) ÍKONOS e (b) Landsat destacando área com café..	72
Figura 38 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO <i>et al.</i> , 2005) com enfoque nas áreas de café.....	73
Figura 39 – Imagem da Figura 37 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com café.....	73

6. CONSIDERAÇÕES FINAIS.....	74
7. CONCLUSÕES.....	79
REFERÊNCIAS BIBLIOGRÁFICAS.....	80

LISTA DE QUADROS

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA.....	4
Quadro 1 – Fisionomias vegetais inseridas na Mata Atlântica e suas respectivas extensões no território brasileiro.....	8
Quadro 2 – Evolução do conceito, denominações e classificação dos Complexos Rupestres de Altitude.....	13
Quadro 3 – Características de alguns satélites artificiais e imagens comumente usadas no monitoramento ambiental.....	20
Quadro 4 – Exemplo de uma matriz de erros.....	30
Quadro 5 – Caracteres e aplicações das bandas do sensor TM do Landsat-5.....	32
3. MATERIAIS E MÉTODOS.....	33
4. RESULTADOS.....	44
Quadro 6 – Distribuição das classes de cobertura vegetal no município de Araponga (MG) obtida pela classificação pelos métodos de Árvores de Decisão, Máxima Verossimilhança (MAXVER) e Redes Neurais Artificiais (RNA) considerando imagem Landsat do ano de 2005.....	44
Quadro 7 – Matriz de erros obtida na avaliação da distribuição de classes de cobertura vegetal no município de Araponga (MG) para a classificação efetuada utilizando-se o método de Máxima Verossimilhança – MAXVER.....	49
Quadro 8 – Matriz de erros obtida na avaliação da distribuição de classes de cobertura vegetal no município de Araponga (MG) para a classificação efetuada utilizando-se o método de Redes Neurais Artificiais – RNA.....	50
5. DISCUSSÃO.....	52
6. CONSIDERAÇÕES FINAIS.....	74
7. CONCLUSÕES.....	79
REFERÊNCIAS BIBLIOGRÁFICAS.....	80

LISTA DE FÓRMULAS

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA.....	4
Equação 2.1 – Fórmula Usada na Conversão de Números Digitais para Radiância.....	25
Equação 2.2 – Fórmula Usada na Conversão da Radiância para Reflectância Aparente.....	25
Equação 2.3 – Fórmula Usada para Calcular o Erro de uma Classificação.....	28
Equação 2.4 – Fórmula Usada no Cálculo do Índice Kappa.....	31
3. MATERIAIS E MÉTODOS.....	33
4. RESULTADOS.....	44
5. DISCUSSÃO.....	52
6. CONSIDERAÇÕES FINAIS.....	74
7. CONCLUSÕES.....	79
REFERÊNCIAS BIBLIOGRÁFICAS.....	80

RESUMO

MOREIRA, Gilberto Fialho, M.Sc., Universidade Federal de Viçosa, novembro de 2008. **Classificação automatizada do uso e cobertura do solo utilizando imagem Landsat no Município de Araponga, MG.** Orientador: Raphael Bragança Alves Fernandes. Co-orientadores: Elpídio Inácio Fernandes Filho e Carlos Antônio Oliveira Vieira.

Planejar o espaço na busca de entender o presente com informações do passado, bem como projetar cenários futuros é de fundamental importância para a melhor gestão ambiental. Neste sentido, dentro de um programa mais amplo de monitoramento, a detecção da cobertura florestal - de forma ágil, rápida e eficiente - pode contribuir para uma melhoria na proteção e qualidade ambiental, principalmente, em municípios que se destacam por apresentarem biodiversidade relevante, em especial àqueles que são sede de alguma Unidade de Conservação (UC). O uso de imagens de satélite tem se intensificado nos últimos anos, e incrementa o arsenal de informações disponíveis sobre o meio natural. Entretanto, a maior parte da tecnologia disponível para a detecção automatizada, em especial os *softwares* utilizados, apresentam elevado custo financeiro de aquisição. Neste contexto, o objetivo do presente trabalho foi avaliar novas tecnologias e metodologias de detecção automatizada da cobertura vegetal em imagens orbitais. Para tanto, foram executadas as classificações pelos métodos da Máxima Verossimilhança (MAXVER), das Redes Neurais Artificiais (RNA) e das Árvores de Decisão, utilizando-se de tecnologias de caráter gratuito e, ou, já disponíveis no Instituto Estadual de Florestas (IEF-MG). Essa iniciativa também visa contribuir na avaliação de novas soluções para os problemas e desafios relacionados ao mapeamento de cobertura vegetal enfrentados pelo setor de monitoramento ambiental do IEF-MG, em especial pelo Centro de Estudos e Desenvolvimento Florestal, ligado à Gerência de Monitoramento e Geoprocessamento. Para a efetivação do presente projeto foram utilizados as bandas 1, 2, 3, 4, 5 e 7 da cena 217/74 de imagens do sensor LandSat 5 TM (*Thematic Mapper*), tomadas em 16/11/2005 (verão), correspondente ao município de Araponga (MG), onde concentra-se a maior área do Parque Estadual da Serra do Brigadeiro (PESB). Essa mesma cena foi utilizada para a produção do documento: "Mapeamento da Flora Nativa e Reflorestamento de Minas Gerais" (MFNR-MG), atualmente um referencial para a gestão ambiental do Estado de Minas Gerais. Foram consideradas nesse estudo as seguintes classes de vegetação: Floresta Estacional Semidecídua,

Floresta Ombrófila, Campo de Altitude, Pastagem, Café e Eucalipto. Para a classificação automatizada das imagens, inicialmente os dados foram preparados com os Sistemas de Informações Geográficas (SIG): Sistema de Processamento de Informações Georreferenciadas (SPRING) e ArcGis 9.0. Posteriormente, foi realizada a classificação das imagens pelos métodos de MAXVER e o das RNA's. O SIG SPRING foi usado na classificação por MAXVER e, para as RNA's, foi utilizado o software *Stuttgart Neural Network Simulator* (SNNS). Ao final dos trabalhos de classificação, adicionalmente foi realizada uma comparação com os resultados alcançados no MFNR-MG, no qual outro método de classificação, o de Árvores de Decisão, foi empregado em seu procedimento de análise. Os resultados obtidos indicaram que a metodologia por MAXVER, por mais que tenha gerado confusão entre algumas classes por considerar somente o valor da reflectância, o que dificultou ou mesmo impediu a diferenciação entre algumas tipologias vegetacionais, em especial, entre campo de altitude e afloramentos rochosos; e entre eucalipto e floresta semidecídua, apresentou um bom resultado, atingindo um desempenho geral de aproximadamente 80%. A classificação efetuada por RNA's também não distinguiu efetivamente todas as classes pretendidas, mesmo considerando o plano de informação altitude, segundo fornecido pelo modelo de elevação do terreno. A comparação, dos classificadores testados no presente trabalho com a metodologia adotada no MFNR-MG indicou diferenças expressivas na quantificação das coberturas vegetacionais da área estudada, em especial quanto à formação Florestal Ombrófila, a qual se apresentou bem mais evidente nas classificações aqui executadas (MAXVER e RNA). Embora a metodologia de RNA's seja amplamente aceita como a mais adequada para a classificação de imagens de satélites, a complexidade e o tempo demandado na preparação dos materiais, bem como os vários procedimentos de tentativa e erro requeridos para sua execução dificultam ou mesmo restringem sua utilização, principalmente na demanda comercial. Por sua vez, dada a simplicidade e os resultados alcançados, a classificação por MAXVER desponta como uma opção mais viável em muitas situações, tais como às classes que não são distinguidas por algum outro fator que não seja a reflectância da imagem utilizada. No entanto, as duas metodologias aqui testadas (RNA e MAXVER), bem como a utilizada no MFNR-MG, não apresentaram bons resultados para as duas classes de cobertura vegetal exótica pretendida neste trabalho (eucalipto e café).

ABSTRACT

MOREIRA, Gilberto Fialho, M.Sc., Universidade Federal de Viçosa, November 2008. **Automated Classification of soil use and coverage, with the use of Landsat Image in the city of Araponga, MG.** Advisor: Raphael Bragança Alves Fernandes. Co-advisors: Elpídio Inácio Fernandes Filho and Carlos Antônio Oliveira Vieira.

The projection of future scenarios and the space planning, in the search to understand the present, with information from the past, are extremely important for a better environmental management. In this sense, inside a broader monitoring program, the detection of the forest coverage in an agile, fast and efficient way, may contribute to improve the environmental protection and quality, especially in cities that present relevant biodiversity or comprise any Conservation Unit (CU). The use of satellite images has been intensified over the last years, thus providing more information about the natural environment. However, most part of the technology available for automated detection is very expensive, mainly the *software* systems used. Therefore, the objective of the present work was to evaluate new technologies and methodologies for the automated detection of plant coverage in orbital images. For such, classifications were performed by the methods of Maximum Likelihood (MLE), Artificial Neural Networks (ANN) and Decision Tree Method (DTM), using free technologies and/or technologies already available at the Instituto Estadual de Florestas (Forest State Institute) (IEF-MG). This initiative also intends to contribute for the evaluation of new solutions for the problems and challenges related to the mapping of the plant coverage faced by the environmental monitoring sector of the IEF-MG, mainly by the Centro de Estudos e Desenvolvimento Florestal (Forest Study and Development Center), linked to the Monitoring Management and Geoprocessing. For the execution of the present project, the bands 1, 2, 3, 4, 5 and 7 of the scene 217/74 of images of the LandSat 5 TM (*Thematic Mapper*) sensor, taken on 11/16/2005 (summer) were used, corresponding to the city of Araponga (MG), where most part of the area of Parque Estadual da Serra do Brigadeiro (Serra do Brigadeiro State Park) (PESB) is concentrated. This same scene was used for the production of a document entitled: "Mapeamento da Flora Nativa e Reflorestamento de Minas Gerais" (Mapping of the Native Flora and Reforestation of Minas Gerais) (MFNR-MG), which is nowadays a reference for the environmental management in the state of Minas Gerais. The following vegetation classes were considered in this study: Semidecidual Stational Forest,

Ombrophile Forest, Altitude Field, Pasture, Coffee and Eucalyptus. For the automated classification of the images, the data were initially prepared with the Geographic Information Systems (GIS): Georeferenced Information Processing System (GIPS) and ArcGis 9.0. Later, it was performed the classification of the images by the MLE and ANN methods. The GIS GIPS method was used in the classification by MLE while, for the ANN, it was used the *Stuttgart Neural Network Simulator* (SNNS) software system. In the end of the classification works, it was carried out an additional comparison with the results achieved in the MFNR-MG, with the use of the Decision Tree Method for the analysis. The results achieved indicated that the MLE methodology presented a good result, with a general performance of 80%, although it generated some disorder between some classes for considering only the reflectance value, thus hindering or even preventing the differentiation between some plant typologies, especially between altitude field and rock outcrops; and between eucalyptus and semidecidual forest. The classification carried out by ANN did not effectively distinguish all the desired classes either, even considering the altitude information plan, as provided by the model of the terrain elevation. The comparison between the classifiers tested in the present work and the methodology adopted in the MFNR-MG indicated great differences in the quantification of the plant coverages of the area studied, especially as to the Ombrophile Forest formation, which was much more evident in the classifications carried out here (MLE and ANN). Although the ANN methodology is widely accepted as the most adequate for the classification of satellite images, its complexity and the time demanded in material preparation, as well as several procedures of trial and error required for its execution, hinder or even prevent its use, mainly in commercial demand. On the other hand, due to its simplicity and the results achieved, the MLE classification turns out to be the most viable option in many situations, such as when classes cannot be distinguished by another factor but the reflectance of the image used. However, both methodologies tested (ANN and MLE), as well as the one used in MFNR-MG, did not present good results for both classes of exotic plant coverage intended in this work (eucalyptus and coffee).

1. INTRODUÇÃO

Planejar o espaço na busca de entender o presente com informações do passado, bem como projetar cenários futuros é de fundamental importância para a melhor gestão ambiental. Neste sentido, dentro de um programa mais amplo de monitoramento, a detecção da cobertura florestal - de forma ágil, rápida e eficiente - pode contribuir para uma melhoria na proteção e qualidade ambiental, principalmente, em municípios que se destacam por apresentarem biodiversidade relevante, em especial àqueles que são sede de alguma Unidade de Conservação (UC). Este é o caso, por exemplo, do município de Araponga, na Zona da Mata mineira, que abriga a maior área do Parque Estadual da Serra do Brigadeiro. Este trata-se de uma UC que apresenta um histórico de gerenciamento deficiente de seu patrimônio natural, notadamente de seus recursos naturais, haja vista a intensa exploração de madeira no passado para manter, principalmente, os fornos de siderúrgicas mineiras. Essa área, objeto do presente estudo, pertence ao Bioma Mata Atlântica, um ecossistema com altíssimo grau de biodiversidade e endemismo. As informações aqui geradas e disponibilizadas poderão auxiliar no melhor conhecimento da dimensão desse bioma no município selecionado, bem como de sua situação florestal e as pressões a que está submetido, tendo em vista as tendências de uso da terra na região.

O uso de imagens de satélite tem se intensificado nos últimos anos, incrementando-se o arsenal de informações disponíveis sobre o meio natural. Entretanto, a maior parte da tecnologia disponível para a detecção automatizada, em especial os *softwares* utilizados, apresentam elevado custo de aquisição. A intenção do presente estudo foi avaliar uma ferramenta que alia imagens de custo mais acessível, Redes Neurais Artificiais (RNA), e Sistema de Informações Geográficas (SIG) para um estudo de caso que possa servir de piloto ou modelo para aplicação na detecção da cobertura florestal e do uso e ocupação do solo de outras áreas ou mesmo biomas presentes no estado de Minas Gerais e em outros estados.

O Instituto Estadual de Florestas (IEF-MG), um dos órgãos ambientais de Minas Gerais, é o responsável, dentre outras atribuições, pela preservação e conservação da vegetação, pela pesquisa em biomassas e biodiversidade, pelo inventário florestal e o mapeamento da cobertura vegetal do Estado. Uma das iniciativas desse órgão com vista à gestão do espaço ambiental mineiro é a efetivação do levantamento da cobertura vegetal do Estado, o que vem sendo realizado desde 2003. No entanto, com o aparecimento de novas tecnologias (*softwares*, imagens, sensores, dentre outros) a cada dia, torna-se relevante o aperfeiçoamento e teste de

novas ferramentas de trabalho, de forma a atender melhor e mais adequadamente aos objetivos do referido órgão de fiscalização.

A busca de novas tecnologias e metodologias que auxiliem o monitoramento ambiental pode ainda contribuir com novas soluções para os problemas e desafios enfrentados pelo IEF-MG. Este órgão tem sob sua responsabilidade o inventário natural do Estado de Minas Gerais. Dada a importância deste tipo de monitoramento, este órgão criou o Centro de Estudos e Desenvolvimento Florestal (CEDEF), ligado à Gerência de Monitoramento e Geoprocessamento. A função do CEDEF é justamente a avaliação de novas metodologias na detecção automatizada da cobertura vegetal em imagens orbitais.

A classificação automatizada da cobertura vegetal pode trazer benefícios à conservação ambiental do estado de Minas Gerais. Se realizada a partir de técnicas validadas, ou seja, aquelas que melhor representem a realidade, e com o uso de imagens de fácil acesso (disponível gratuitamente para todos e quaisquer cidadãos, principalmente via *internet*), pode proporcionar: a melhoria e agilidade nos procedimentos de classificação de diversos ambientes, a abertura de novas possibilidades dentro do formato tradicional atualmente utilizado em órgãos ambientais, como o IEF-MG, e a redução dos custos associados aos programas de monitoramento ambiental. Com relação aos custos envolvidos, é importante destacar a necessidade da busca de novas tecnologias e de materiais e ferramentas de baixo custo e, ou mesmo, gratuitas, já que os órgãos públicos nem sempre conseguem adquirir o que há de mais moderno disponível no mercado, devido aos recursos limitados.

Neste contexto, o presente trabalho teve por objetivo avaliar metodologias para a detecção da cobertura vegetal, utilizando a classificação de imagens de satélite por meio de Redes Neurais Artificiais (RNA) e do método da Máxima Verossimilhança (MAXVER). Como objetivos específicos foram considerados: i) avaliar a adequabilidade da utilização de imagens de baixo custo ou gratuitas para o propósito de identificação de coberturas florestais; ii) promover a comparação de três classificadores, o já utilizado pelo IEF-MG em estudos anteriores (Árvores de Decisão) e os métodos RNA e MAXVER, verificando, assim, as possibilidades de se utilizar imagens de satélite do sensor Landsat para a detecção da cobertura vegetal por meio das metodologias apontadas. A efetivação desta classificação automatizada poderá apontar classificadores mais adequados ao mapeamento da superfície vegetada. Isso, devido ao fato de a área ter características muito complexas como relevo muito acidentado, tipos de solos diferentes, e constantes formações de nuvens que afetam diretamente as informações da imagem e, conseqüentemente, os resultados de sua

classificação. Várias são as informações que podem ser utilizadas para uma melhor delimitação das feições desejadas, sabendo-se que as mesmas podem possuir características que correspondem similarmente na resposta espectral na imagem orbital.

Na busca de um melhor embasamento para orientar no entendimento dos resultados alcançados com este estudo é que se deu a organização dos assuntos abordados. Sendo assim, em primeira instância será feita uma revisão de literatura que mostrará as diferenças entre alguns conceitos, como bioma e formações, os quais, muitas das vezes são utilizados de forma inadequada ou até mesmo confusa. Para que não haja dúvida de qual conceito utilizado na análise deste trabalho, evidenciou-se o bioma e, neste, as formações que lhes são natas na área estudada neste trabalho, o município de Araponga/MG. Serão descritas também as características fitofisiológicas do referido local e as informações que lhes permitem sobressair nas áreas em que se encontram atualmente.

Como o trabalho de classificação e todo o arcabouço de conhecimentos que envolvem esta atividade estão inseridos nas chamadas geotecnologias (tecnologias disponíveis para se trabalhar com dados geográficos ou espaciais), serão apresentados alguns comentários acerca de estudo com os Sistemas de Informações Geográficas. O Sensoriamento Remoto, bem como suas atribuições, como a classificação de imagens – objetivo deste estudo, também serão discutidas.

A seguir, estão descritos os materiais e métodos utilizados, com a localização da área de estudos e a sua caracterização geral; os materiais e as bases de dados utilizados para a execução deste trabalho e os *softwares* utilizados para tal; a descrição do trabalho de campo e de laboratório, mostrando-se posteriormente, os procedimentos seguidos para cada metodologia aqui utilizada (MAXVER e RNA). Na seqüência, são apresentados os resultados, bem como a discussão dos mesmos.

Finalmente as considerações finais e a conclusão geral deste estudo são elencadas, de forma a expor os pontos de relevância obtidos, bem como mostrar e apontar soluções e sugestões para resolver alguns dos problemas enfrentados quando se trabalha com a classificação automatizada de imagens de sensores remotos na detecção da cobertura vegetal.

2. REVISÃO DE LITERATURA

2.1. Biomas e Formações

Um Bioma é entendido como uma unidade biótica de maior extensão geográfica e compreende várias comunidades em diferentes estágios de evolução denominadas de acordo com o tipo de vegetação. Os Biomas têm sido delimitados considerando fatores climáticos tais como temperatura, pluviosidade e umidade relativa e, em menor escala, considerando o tipo de substrato (RIBEIRO e WALTER, 1998). Várias modificações conceituais foram apresentadas por diversos autores ao longo do tempo, acrescentando outros fatores ambientais ao conceito original, como solo, por exemplo. O termo Bioma (do grego, *bio* = vida + *oma* = grupo ou massa) refere-se a uma área do espaço geográfico representada por um tipo uniforme de ambiente, identificado e classificado de acordo com o macroclima, a fitofisionomia (formação), o solo e a altitude. Considerado como ambiente por Walter (1986), este conceito de Bioma é fundamentalmente ecológico, pois leva em consideração não apenas o clima, mas também fatores como a altitude e as características do solo, considerando desta forma, todo o ecossistema. Além disso, este conceito permite classificar e identificar a área designada, uma vez que o próprio nome do Bioma em questão já indica o tipo de ambiente, inclusive quais suas principais características determinantes.

No Brasil é admitida a ocorrência de seis grandes Biomas: Amazônia (ou Amazônico), Mata Atlântica, Caatinga, Cerrado, Pantanal e Pampa (Campo Sulino) (Figura 1). O mapa de vegetação do Brasil foi o principal documento tomado como referência para embasar a delimitação desses Biomas, definidos em especial pela tipologia original vegetacional (RIBEIRO e WALTER, 1998 e IBGE, 2004). Coutinho (2005) afirmou que o termo Bioma, proposto em substituição aos termos fitofisionomia e formação, apenas adicionou a fauna à uniformidade fitofisionômica e climática, características desta unidade biológica. Enquanto Formação refere-se basicamente à vegetação, Bioma refere-se ao conjunto vegetação e fauna associada, considerando assim, a fisionomia e o habitat.

Para COLINVAUX (1993), Formação é a vegetação de uma grande região climática, ou seja, corresponde a um tipo de vegetação que ocupa extensa área geográfica, com composição definida de espécies dominantes, clima particular e reconhecida pela sua fisionomia.

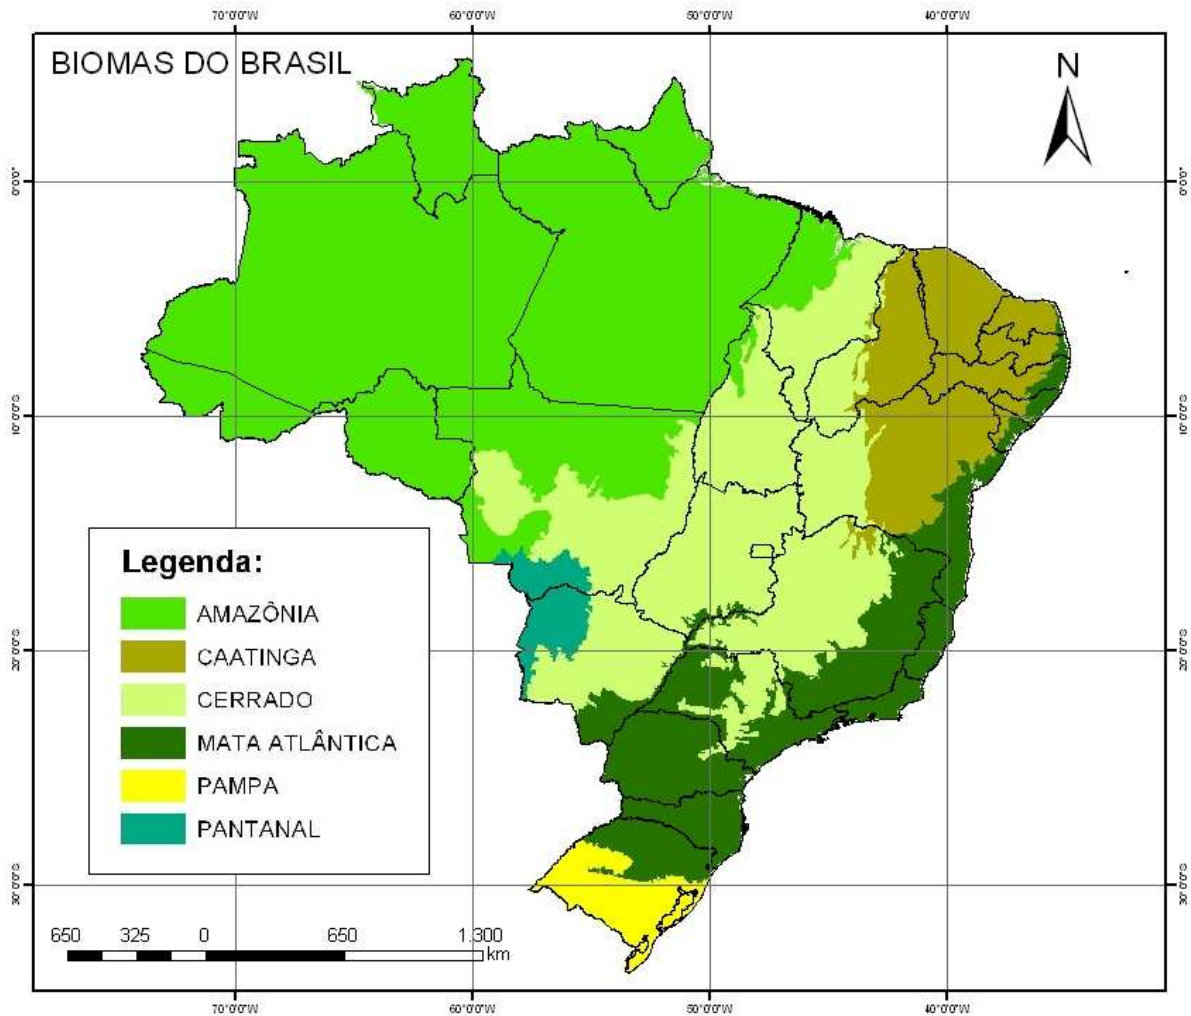


Figura 1 – Biomas do Brasil identificados pelo IBGE (Adaptado de IBGE, 2004).

Os diversos tipos de clima e relevo existentes no Brasil mantêm importantes relações, sejam elas de espaço, vegetação, solo, dentre outras características, o que permite mais um tipo de classificação ecológica de nosso espaço natural. Neste sentido aparecem os domínios morfoclimáticos, que são definidos a partir de características climáticas, botânicas, pedológicas, hidrológicas e fitogeográficas. Para entendê-los, torna-se necessário distinguir uns dos outros. AB'SABER (1977) propôs uma classificação desses ambientes, considerando que, em cada um desses sistemas, são encontrados aspectos, histórias, culturas e economias divergentes, o que proporciona singulares condições ambientais.

2.1.1. Bioma Mata Atlântica

Floresta Atlântica ou Mata Atlântica, em seu sentido mais restrito, refere-se à vegetação florestal tropical exclusivamente brasileira que ocorre na faixa litorânea junto ao Oceano Atlântico. Estima-se que essa porção do território já foi uma das maiores florestas tropicais do mundo, ocupando "originalmente" (século XI) uma área de 1.306.421 km², equivalente a, aproximadamente, 15% da extensão superficial brasileira (Figura 2). A Mata Atlântica é considerada patrimônio nacional pela Constituição Federal (Ministério do Meio Ambiente, MMA, 2004). Atualmente os remanescentes primários e em estágio médio/avançado de regeneração estão reduzidos a apenas 7,84% da cobertura florestal original, o que compreende aproximadamente 100.000 km², ou seja, aproximadamente 1,20% da extensão superficial brasileira. Isso faz com que o Bioma Mata Atlântica seja considerado o segundo mais ameaçado de extinção do mundo. Segundo dados do MMA (2004), apesar da devastação, a Mata Atlântica é um dos biomas com uma das mais altas taxas de biodiversidade do mundo: cerca de 20.000 espécies de plantas angiospermas (6,7% de todas as espécies do mundo), sendo 8.000 endêmicas, e grande riqueza de vertebrados (264 espécies de mamíferos, 849 espécies de aves, 197 espécies de répteis e 340 espécies de anfíbios). Devido ao seu altíssimo grau de biodiversidade e endemismo, a Mata Atlântica brasileira está entre os cinco principais "*Hot Spots*" de biodiversidade do mundo.

O Bioma Mata Atlântica estava distribuído por 17 estados (PI, CE, RN, PB, PE, AL, SE, BA, ES, RJ, MG, GO, MS, SP, PR, SC, RS). Ocorre de forma contínua do Rio Grande do Norte ao Rio Grande do Sul, ao longo da latitude 23° S, por cerca de 5.000 km da costa brasileira, e adentrando para o interior nas regiões Sudeste, Sul, e Centro-Oeste (AYRES *et al.*, 2005).

Segundo o Decreto Lei 750/1993 (MMA, 1993), a Mata Atlântica brasileira é definida como "o espaço que contém aspectos fitogeográficos e botânicos que tenham influência das condições climatológicas peculiares do mar, incluindo as áreas associadas delimitadas segundo o Mapa de Vegetação do Brasil (IBGE, 1993), tais como: Floresta Ombrófila Densa, Floresta Ombrófila Mista, Floresta Ombrófila Aberta, Floresta Estacional Semidecídua e Floresta Estacional Decídua, manguezais, restingas e campos de altitude associados, brejos interioranos e encraves florestais da Região Nordeste". Pela Lei Nº 11.428/2006 (SILVA *et al.*, 2006), são consideradas integrantes desse Bioma as seguintes formações florestais nativas e ecossistemas associados com as respectivas delimitações estabelecidas em mapa do Instituto Brasileiro de Geografia e Estatística (IBGE), conforme regulamento: Floresta Ombrófila Densa; Floresta Ombrófila Mista, também denominada de Mata de Araucárias;

Floresta Ombrófila Aberta; Floresta Estacional Semidecídua; e Floresta Estacional Decídua, bem como os manguezais, as vegetações de restingas, campos de altitude, brejos interioranos e encraves florestais do Nordeste.



Figura 2 – Mata Atlântica brasileira original e atuais remanescentes (adaptado de Conselho Nacional Reserva da Biosfera da Mata Atlântica, 2008).

Embora menos citada, existe também a Floresta Ombrófila Densa de Tabuleiros, denominação dada pelo fato da topografia apresentar-se plana em grandes extensões, não atingindo altitudes superiores a 200 m (RIZZINI, 1979). As matas sobre os tabuleiros distinguem-se das outras formações de mata atlântica por ocuparem uma extensa área de planície ou tabuleiro costeiro, de origem terciária, com suas espécies distribuídas ao longo de um gradiente climático (sentido litoral-interior). Outro aspecto que as tornam diferentes da Mata Atlântica de encosta (Floresta Ombrófila Densa), é o fato de o interior da mata sobre os tabuleiros terciários, em geral, apresentar pouca vegetação rasteira e ocorrência de espécies epífitas (RUSCHI, 1950). Em determinados locais dos Tabuleiros Costeiros é encontrada a Floresta de Muçununga apresentando uma fisionomia diferente da Floresta de Tabuleiros. Ela acompanha os cordões de solos arenosos, sendo formada por árvores esparsas de menor porte (PEIXOTO e GENTRY, 1990).

A expressão Floresta Atlântica, segundo RIZZINI (1979), é semelhante a “floresta amazônica”, que designa um complexo vegetacional que, embora dominado pela floresta pluvial montana, engloba vários tipos díspares. Em toda sua extensão, a Floresta Atlântica apresenta uma variedade de formações, e engloba um diversificado conjunto de ecossistemas florestais com estruturas e composições florísticas bastantes diferenciadas, acompanhando as características climáticas e geográficas.

Segundo dados do Ministério do Meio Ambiente (MMA, 2004), a Floresta Estacional Semidecídua é a fisionomia vegetal de maior extensão na Mata Atlântica, seguida pela Floresta Ombrófila Densa (Quadro 1).

Quadro 1 – Fisionomias vegetais inseridas na Mata Atlântica e suas respectivas extensões no território brasileiro

Fitofisionomias	km²	%
Floresta Ombrófila Densa	218.790	16,75
Floresta Ombrófila Aberta	18.740	1,43
Floresta Ombrófila Mista	168.916	12,93
Floresta Estacional Semidecídua	486.500	37,24
Floresta Estacional Decídua	149.052	11,41
Encraves, Formações Pioneiras, Refúgio Ecológico	264.423	20,24
Todas as fitofisionomias	1.306.421	100,00

Fonte: MMA (2004).

Esta elevada biodiversidade da Mata Atlântica é associada à extensão em latitude e variedade topográfica (matas estendem-se do nível do mar até a uma altitude de 1.800 metros), geomorfológica, edáfica e climática. Todos esses fatores juntos refletem uma rica variedade de formações vegetacionais que abrigam extraordinária riqueza de espécies (SOS MATA ATÂNTICA, 1993). A alta pluviosidade desta área deve-se à barreira que as serras litorâneas exercem para os ventos que sopram do mar carregados de vapor de água. O ar ao subir, esfria e se condensa, provocando as elevadas precipitações, sob a forma de chuva ou nevoeiro.

A distribuição da vegetação é fortemente influenciada pela distância do oceano, seguida do regime de distribuição de chuvas, da altitude e da duração da estação seca (OLIVEIRA-FILHO e FONTES, 2000). Em função disto e dada a grande extensão, a Mata Atlântica e suas áreas associadas (sistemas costeiros, mangues, restingas, campos de altitudes e rupestres) apresentam grandes variações nas formações vegetacionais em função da latitude, relevo, clima e solos (BARBOSA e THOMAS, 2002). Esses mesmos autores afirmam ainda que em toda sua extensão, a Mata Atlântica apresenta uma variedade de formações e engloba um diversificado conjunto de ecossistemas florestais com estruturas e composições florísticas bastantes diferenciadas, acompanhando as características climáticas e geográficas. As áreas de abrangência das diferentes fitofisionomias desse domínio em Minas Gerais são apresentadas na Figura 3. Nas serras, a floresta alcança até cerca de 1.600 m de altitude na sua forma típica e, a partir daí, é substituída por formas empobrecidas situadas em planaltos serranos, como é o caso da vegetação arbustiva e campestre.

TONHASCA JR. (2005) admite que a formação dos ambientes físicos dos principais habitats que compõem a Mata Atlântica, deve-se, a criação das encostas pelo soerguimento cristalino, juntamente com a planície litorânea resultante de acúmulo de detritos da erosão e sedimentos marinhos (Figura 4), sendo elas: manguezais e restinga próximos à costa, as matas de planície nos aluviões, a mata úmida de encosta, a mata de altitude e a mata semidecídua a oeste das serras.

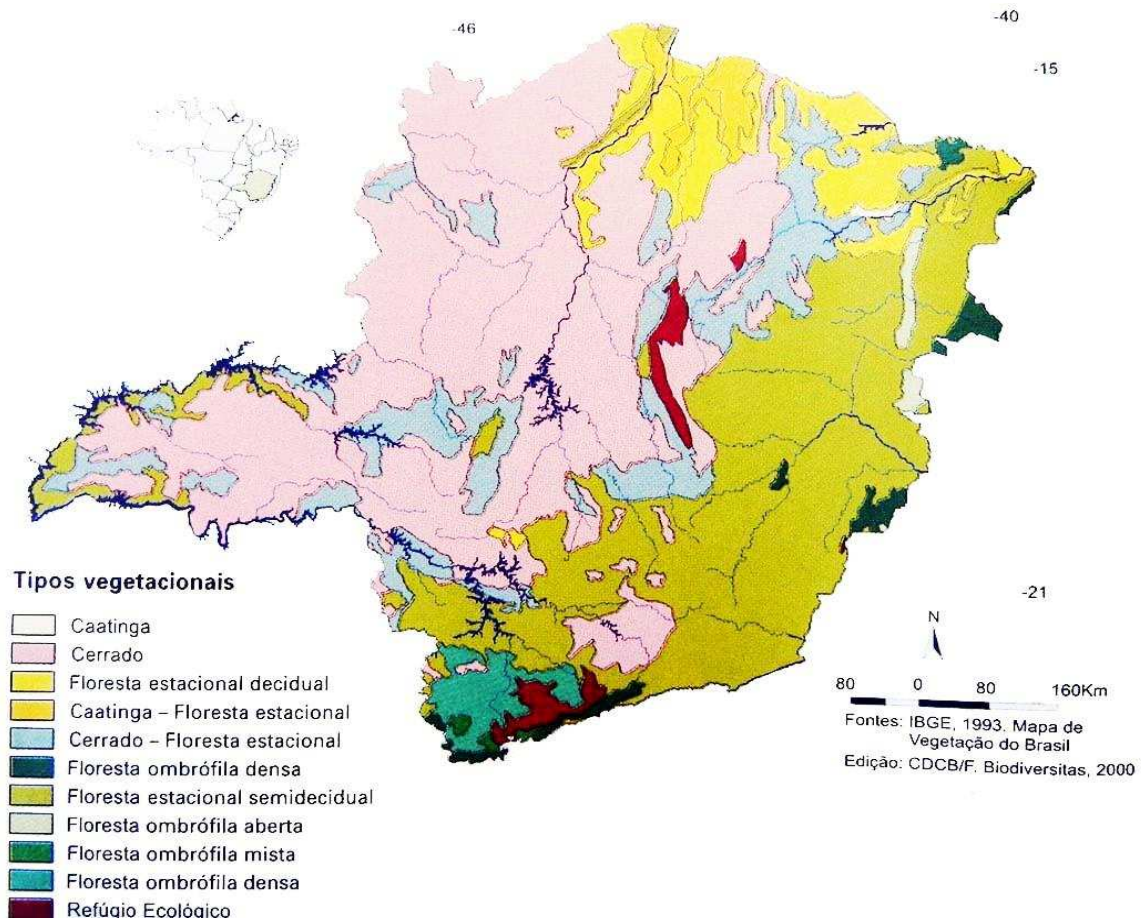


Figura 3 – Tipos Vegetacionais (formações) encontradas no Estado de Minas Gerais (FUNDAÇÃO BIODIVERSITAS, 2000).




Figura 4 – Perfil topográfico das diversas formações da Mata Atlântica (TONHASCA JR., 2005).

2.1.2. Formações Florestais

Neste tópico são apresentadas as Formações Florestais contidas na área de estudo, ou seja, no município de Araponga (MG).

2.1.2.1. Floresta Ombrófila Densa

Conhecida também como Floresta Pluvial Tropical, esta formação florestal, para muitos autores, representa a Mata Atlântica propriamente dita, semelhante em diversos aspectos à Floresta de Terra Firme da Amazônia (BROWN, 1987). O termo ombrófila é de origem grega e significa “Amigo das Chuvas”, muito semelhante ao termo pluvial, que é de origem latina.

Esse tipo de vegetação encontra-se inserida ao norte do Trópico de Capricórnio, em áreas acima de 700 m de altitude, e que possuam estação seca igual ou superior a 30 dias, bem como em áreas ao sul do mesmo Trópico, em altitudes inferiores a 700 m e que possuam pluviosidade anual de 2.000 a 3.600 mm por ano (VELOSO *et al.*, 1991). Esta formação encontra-se inserida no domínio dos Mares de Morros, distribuída ao longo de toda a costa atlântica sobre um sistema de serras litorâneas.

Para CAMPOS FILHO (2004), o interior desta formação abriga um elevado número de epífitas, lianas e pteridófitas. Dentre as epífitas se destacam os representantes das famílias das Bromeliáceas e Orquidáceas nas quais apresentam uma alta densidade nas encostas. Nas vegetações baixas as espécies de pacovás (*Heliconia*) e as samambaias arborescentes, dentre elas o popular xaxim (*Cyathea*) são as que mais se destacam. É caracterizada por fanerófitos com subformas de macro e mesofanerófitos, além de lianas lenhosas e epífitas em abundância, característica que a diferencia de outras formações. Sua principal característica ecológica reside no fato de se apresentar sempre verde (perenifólia), o que permite a ocorrência de altíssima riqueza e diversidade. Chega a apresentar um dossel ("teto da floresta") formado por árvores de 20 a 30 metros de altura.

2.1.2.2. Floresta Semidecídua

Fitofisionomia intrínseca ao Bioma Mata Atlântica, constituído de uma formação transicional entre florestas de encosta litorâneas (Ombrófila) e formações não florestais do interior. É formada por fanerófitos com gemas foliares protegidas da seca por escamas, tendo folhas adultas esclerófilas ou membranáceas decíduais. A porcentagem das árvores caducifólias no conjunto florestal situa-se entre 20 e 50 % (VELOSO *et al.*, 1991). O fenômeno de abscisão foliar tem sido atribuído a fatores como disponibilidade de água, baixa temperatura e disponibilidade de nutrientes. Ela

ocorre predominantemente associada ao clima mais estacional das regiões interioranas, onde prevalecem condições mais homogêneas de solo e relevo (IBGE, 1992).

De acordo com MANTOVANI (2003), esta formação tem seu maior domínio no sudeste brasileiro, ocorrendo principalmente nos planaltos e serras interioranas de São Paulo, Paraná e Minas Gerais. Porém, atualmente essa distribuição está completamente descaracterizada pelo avanço acentuado de áreas com vegetação secundária, decorrentes de diferentes atividades antrópicas, mais especificamente a agricultura intensiva e a pecuária.

2.1.2.3. Complexos Rupestres de Altitude e Campos de Altitude

BENITES *et al.* (2003) e CAIAFA (2002) apresentam uma síntese da evolução das denominações e sucessivas categorias em que se enquadraram o que atualmente se conhece por Complexos Rupestres (Quadro 2). Assim, inicialmente, as áreas de vegetação rupestre de altitude não eram consideradas como uma formação à parte, sendo incorporados a outros ecossistemas de forma genérica.

A altitude é um fator importante, pois influencia os elementos do clima, que por sua vez determinam a formação do solo e a ocupação por espécies de plantas adaptadas a tais condições edáficas. Além da água, a profundidade do solo, quando não se trata de afloramentos rochosos, é considerada um dos fatores chave para o estabelecimento das comunidades de vegetação dos Campos de Altitude. Uma característica importante dessas formações é o alto grau de endemismo de suas espécies vegetais, sendo muitas delas restritas a uma serra ou mesmo a um único morro (WWF-BRASIL, 2008).

Quadro 2 – Evolução do conceito, denominações e classificação dos Complexos Rupestres de Altitude

Ano	Denominação	Descrição	Autor
1843	“Óréades”	Região fitogeográfica ocupada por todo e qualquer campo.	Martius
1949	“Campos alpinos”	Toda e qualquer área altimontana, relacionado aos Alpes europeus.	Barreto
1963	“Campos”	Formação vegetal que incluíam os, por ele denominados, campos altimontanos.	Rizzini
1970	“Campos rupestres”	Referindo-se exclusivamente às formações sobre quartzito.	Joly
1979	“Campos limpos” subdivididos em: “campos quartzíticos” e “campos altimontanos”.	“Campos quartzíticos” para áreas sobre quartzito (por exemplo, o Espinhaço); “Campos altimontanos” sobre rochas cristalinas diversas (por exemplo, serras do Mar e Mantiqueira) em cotas acima de 1.800 m.	Rizzini
1980	“Campos limpos” subdivididos em: “campos rupestres” e “campos de altitude”	“Campo rupestre” com altitudes acima de 1.000m, com solos pouco profundos e muito pedregosos com baixa retenção de água, sob quartzito ou arenito; “Campo de altitude” estariam acima de 2.100 m, relevo suave ou em platôs.	Ferri
1983	“Campo rupestre” e “campo montano”	“Campo rupestre” ocorrendo acima de 1.000 m de altitude e associados a rochas quartzíticas; “Campo montano” ocorreria nos platôs do Itatiaia, Serra da Mantiqueira, Pico da Bandeira, Serra dos Órgãos, da Bocaina, e Caparaó, entre outros associados a rochas ígneas.	Eiten
1991	“Refúgios vegetacionais” ou “Relíquias vegetação”	Toda e qualquer vegetação floristicamente diferente do contexto geral da flora dominante. Para os campos de altitude, seriam as comunidades localizadas acima de 1.800m de altitude.	Veloso
1994	“Complexos rupestres de quartzitos” e “Complexos rupestres de granito”	“Complexos rupestres de quartzito” para a vegetação do Espinhaço. “Complexo rupestre de granito” para a vegetação da Mantiqueira.	Semir

Fonte: BENITES *et al.* (2003) e CAIAFA (2002).

Os Complexos Rupestres de Altitude formam um tipo de vegetação altamente especializado que ocorre no alto das montanhas das regiões Sudeste, Centro-Oeste, Nordeste e em outras áreas isoladas do país. A rigor aparecem acima dos 1.000 metros de altitude e sobre solos rasos ou afloramentos rochosos. Este tipo de vegetação também ocorre em extensões menores e, pontualmente, em áreas onde as condições edafoclimáticas são favoráveis, principalmente, na ausência ou incipiência de solo associado a altitudes entre 1.000 e 2.000 metros (OLIVEIRA-FILHO e FLUMINHAN-FILHO, 1999). Trata-se de um mosaico de comunidades controlado pela topografia e geomorfologia, microclima, bem como a natureza geológica e pedológica do substrato.

A vegetação das áreas de Campo de Altitude é composta geralmente por plantas de baixo porte, com folhas coreáceas e providas de recursos morfológicos para compensarem a baixíssima capacidade de retenção de água pelo solo. Sua flora é formada principalmente por gramíneas, bromélias, orquídeas, velosiáceas, sempre-vivas, dentre outras (OLIVEIRA-FILHO e FLUMINHAN-FILHO, 1999).

2.2. Classificação de Cobertura Vegetal

BATISTA *et al.* (2007), buscando avaliar se as florestas nativas eram espectralmente separáveis de florestas de eucalipto, utilizaram o sensor HSS – *Hyperspectral Scanner System*, com dados de todas as 50 bandas espectrais de uma área do Vale do Paraíba (SP). Os resultados indicaram que a faixa espectral do infravermelho próximo foi a que melhor separou o eucalipto da vegetação natural, sendo que as amostras da floresta plantada possuíam maiores valores de radiância, provavelmente devido à sua homogeneidade provocada pelo dossel que não permite influência de sombras. Já na faixa espectral do infravermelho médio, a floresta nativa apresentou maior radiância do que a cobertura de eucalipto. Com esse estudo foi possível identificar que as coberturas florestais de eucalipto e de florestas nativas são espectralmente separáveis na faixa espectral do infravermelho próximo, sendo que na faixa do infravermelho médio, essa separação é de mais fácil identificação.

O potencial de utilização das imagens Landsat na avaliação da cobertura já é há muito conhecido. LEE *et al.* (1974) já haviam observado que tais imagens podem ser facilmente utilizadas para a distinção de áreas florestadas de outras não florestadas, muito embora tenham encontrado dificuldades em separar espécies de coníferas, tendo sido reconhecidas apenas diferenças de idade entre elas. Entretanto, KALENSKY e SCHERK (1975) relatam adequada classificação de floresta de coníferas, floresta decídua e área florestada. Tais autores obtiveram acuidade de classificação variando entre 67 % e 81 % para dados Landsat de apenas uma

passagem do sensor, enquanto para dados multitemporais, os valores obtidos foram consistentemente superiores a 80 % de acerto.

A vegetação tem uma assinatura espectral semelhante quando comparada com a grande maioria dos alvos terrestres. Assim vários estudos relacionados à identificação e mapeamento da vegetação têm-se baseado na premissa do contraste espectral entre a reflectância da vegetação e os elementos de fundo da cena (GURGEL, 2003). A combinação entre a reflectância da vegetação nas faixas espectrais do vermelho e do infravermelho próximo tem sido denominada índice de vegetação.

A importância da acurácia no mapeamento da cobertura florestal refere-se à necessidade de obtenção de melhorias na elaboração de planos de manejo dos recursos naturais e também na determinação de áreas prioritárias para conservação, assim como na análise da paisagem. Neste contexto, diferentes estudos foram conduzidos buscando, a partir de dados remotos, conseguirem a classificação da cobertura vegetal da superfície terrestre.

2.3. Técnicas de Geoprocessamento e Sistemas de Informações Geográficas

Tendo em vista a inserção num mundo cada vez mais informatizado e adaptado às linguagens computacionais, a análise espacial acaba sendo envolvida por novas tecnologias que muito influenciam suas diretrizes de trabalho, tipicamente denominadas geotecnologias. ROSA (2005) as define como um conjunto de ferramentas para coleta, processamento, análise e disponibilização de informação com referência geográfica. Tal estrutura é formada por soluções em *hardware*, *software* e *peopleware*, os quais juntos constituem poderosos instrumentos para o processo de tomada de decisão.

O geoprocessamento engloba diversas técnicas de tratamento e manipulação de dados geográficos, por meio de programas computacionais, do sensoriamento remoto, digitalização de dados, automação de tarefas cartográficas e pelos Sistemas de Informações Geográficas ou SIG's (CARVALHO *et al.*, 2000).

Os SIG's são definidos como um modelo matemático dinâmico, construído com um banco de dados geográficos gerenciados, para facilitar a atualização e a aplicação de dados georreferenciados de camadas de informações espaciais no planejamento e na otimização de uma determinada tarefa (LIU, 2006; CARVALHO *et al.*, 2000). Dados gerados num SIG podem ser úteis no planejamento e gerenciamento dos recursos ambientais. YANG (1999), por exemplo, produziu o mapa geomorfológico de parte do rio Amarelo na China, utilizando imagens Landsat TM (*Thematic Mapper*) e um Modelo

Digital de Elevação (MDE) gerado em SIG, e concluiu que o modelo poderia ser usado para o monitoramento da evolução dinâmica do ambiente do delta desse rio.

Modelos digitais de elevação têm sido aplicados na atualização de mapas, tanto planimétricos como altimétricos, e isto ocorre já há muito tempo, como no trabalho de MASRY e McLAREN (1979). MILLER *et al.* (1978) também acompanharam as alterações ocorridas com o tempo em florestas por meio da análise de modelos digitais. Da década de 70 do século passado até 2008 muito se evoluiu, sendo grande parte dessa evolução nos modelos digitais de elevação, em especial em suas aplicações, devida à evolução do sensoriamento remoto, uma vez que tanto os modelos como as imagens orbitais constituem dados digitais. Com a idéia de combinar, via superposição, essas duas fontes de dados, FLEMING e HOFFER (1979) procuraram resolver dificuldades na interpretação de imagens orbitais causadas pelo relevo no mapeamento de tipos de cobertura florestal. Eles combinaram imagens MSS Landsat com dados topográficos referentes à elevação, inclinação e orientação direcional (aspecto). Nessa mesma época, TESCHE e BERGSTROM (1978), ao lidarem com modelos digitais, recomendaram a combinação desses com dados relacionados com a cobertura do solo, para facilitar estudos semelhantes de avaliação de cobertura do solo.

2.4. Sensoriamento Remoto

É definido como uma técnica de aquisição e de aplicações das informações sobre um objeto sem nenhum contato físico como o mesmo (LIU, 2006). É definida ainda como uma tecnologia que permite a obtenção de imagens, entre outros dados, da superfície terrestre, por meio da captação e registro de energia refletida e/ou emitida. Ou ainda, como a arte e a ciência de se obter informações à distância, ou seja, dados sobre objetos ou fenômenos sem haver o contato físico com os mesmos (ARONOFF, 1989).

Por sua vez, RODRÍGUEZ (2000), citado por FRANÇA (2008), conceitua sensoriamento remoto como um conjunto de *hardwares* e *softwares* utilizados na coleta e tratamento das informações espectrais obtidas à distância, acerca dos alvos dispostos na superfície terrestre. Os sensores do satélite captam as energias eletromagnéticas da superfície do planeta, captando dados a partir da interação da radiação eletromagnética com objetos e fenômenos existentes na superfície.

O sensoriamento remoto é uma forma de transformação de energia que acelera uma carga elétrica, provocando perturbações no campo elétrico e magnético e propagando no vácuo, chegando até os sensores remotos, onde são captadas estas perturbações e, por conseguinte, transformado em uma imagem que representa, por

meio de valores e/ou cores em uma escala, os comportamentos da interação dessa energia para com os objetos que a mesma interagiu. Quando esta radiação interage com a matéria, o resultado dependerá das propriedades elétrico-magnéticas dos materiais dispostos na superfície terrestre, como propriedades físicas e composições químicas. Esses materiais podem transmitir, refletir ou absorver a radiação eletromagnética em diferentes formas. Assim, os sistemas sensores poderão registrar o comportamento dos diferentes corpos, quando da interação com o fenômeno físico ao longo do espectro eletromagnético, e estabelecer a relação existente entre eles, que vem a ser entendido e interpretado por meio das técnicas de processamento de imagens.

As propriedades dos alvos vão definir suas respostas espectrais, que servirão como referências para o desenvolvimento de estudos em sensoriamento remoto (FLORENZANO, 2002). As assinaturas dos alvos são representadas através das curvas de reflectância espectral, onde pode ser observado o comportamento espectral dos alvos (Figura 5).

Os conceitos de comprimento de ondas na faixa do visível e do infravermelho são mais relevantes do que nas outras faixas para o sensoriamento remoto na detecção da cobertura. A percepção do olho humano decorre da captação de energia eletromagnética contida no intervalo compreendido entre os comprimentos de onda 0,38 e 0,75 μm , definindo a denominada faixa do visível. É neste intervalo que se podem distinguir os comprimentos de onda aproximados do azul (0,4 a 0,5 μm), verde (0,5 a 0,6 μm) e vermelho (0,6 a 0,7 μm) (STEFFEN, 2008).

A radiação eletromagnética nos sensores remotos abrange também partes do espectro eletromagnético, que o olho humano não consegue perceber. Todo o espectro é subdividido em regiões denominadas: do ultravioleta, do visível, do infravermelho e microondas (ou ondas eletromagnéticas) (Figura 6). Os valores de comprimento de onda superiores a 0,75 μm não são perceptíveis à visão humana, constituindo a faixa do infravermelho (IV). A faixa do IV é subdividida em três componentes: infravermelho próximo (0,75 a 1,3 μm), infravermelho médio (1,3 a 3,0 μm) e infravermelho distante (7,0 a 15,0 μm). Esta última faixa é também conhecida como infravermelho termal ou emissivo (STEFFEN, 2008).




Figura 5 – Reflectância espectral de alguns alvos ao longo do comprimento de onda (adaptado de FLORENZANO, 2002).




Figura 6 – Faixas do espectro eletromagnético desde os raios gama até as ondas de rádio, mostrando a faixa do visível e a faixa do infravermelho (adaptado de FLORENZANO, 2002).

As imagens obtidas por meio do Sensoriamento Remoto são usadas em importantes áreas do conhecimento. Como exemplo disto, dentre outras aplicações, tem-se o controle do desmatamento e queimadas na Amazônia Legal, como realizados pelos projetos PRODES e DETER, do Instituto Nacional de Pesquisa Espacial (INPE), conforme descrição feita por LEITE (2008); o monitoramento dos recursos hídricos e florestais; o monitoramento de áreas agrícolas, do crescimento urbano e da ocupação do solo; bem como em diversas atividades da educação formal e informal em que o componente espacial é necessário. Uma das possibilidades que mais foi aperfeiçoada com o advento e modernização tecnológica do sensoriamento remoto orbital foi o monitoramento da evolução espacial e temporal das mudanças na cobertura da superfície terrestre. Valendo-se de sensores multiespectrais, fenômenos como queimadas, desmatamentos, expansão urbana e mudanças na cobertura vegetal, passaram a ser estudados de forma objetiva e mais precisa.

Para atingir seus objetivos, o sensoriamento remoto utiliza modernos sensores, aeronaves, espaçonaves, com o objetivo de estudar o ambiente terrestre por meio do registro e das análises da interação da radiação eletromagnética e alvos existentes na superfície terrestre em suas mais diversas manifestações.

Atualmente, assumindo uma série de funções anteriormente atendidas pela aerofotogrametria, o Sensoriamento Remoto multiespectral apresenta uma série de vantagens, como por exemplo: o baixo custo por área específica; alta frequência de repetitividade da tomada de imagens; aspecto multiespectral das imagens; caráter digital dos dados adquiridos e facilidade de integração com bases de dados geocodificados, cartográficos ou numéricos (SOUZA *et al.*, 2007).

Os dados de Sensoriamento Remoto podem ser adquiridos no formato de imagens bidimensionais quando são necessárias informações com alta resolução espacial como é o caso das imagens TM/Landsat. Atualmente, as imagens digitais são as mais usadas. Para tanto, deve-se observar o tipo de sensor, a localização da cena de cobertura da área, sua qualidade quanto à porcentagem de nuvens presentes, datas disponíveis, época do ano ou aquisição por programação. As imagens podem ser originárias de diferentes satélites, com características e peculiaridades diferentes, o que pode diferenciar bastante os valores por quilômetro imageado (Quadro 3).

Quadro 3 – Características de alguns satélites artificiais e imagens comumente usadas no monitoramento ambiental

Satélites	Características			Resolução espacial		Resolução			Valor aproximado por km ² imageado (R\$)
	Altitude (km)	Faixa imageada (km)	Pancromática (m)	Multi-espectral (m)	Espectral	Temporal (dias)	Radiométrica		
CBERS	778	113	20	20	4 multi e 1 pan	26	8 bits	0,00	
Landsat	705	185	15	30	8 multi e 1 pan	16	8 bits	0,00	
SPOT 5	822	60	2.50 – 5	10	4 multi e 1 pan	26	8 bits	4,80	
ASTER	730	60	-	15.30 – 90	14 multi e 1 pan	-	8.8 e 14 bits	3,20	
ÍKONOS 2	680	13	1	4	4 multi e 1 pan	3	11 bits	40,00	
QUICKBIRD	450	16	0,61-0,72	2.44 – 2.88	4 multi e 1 pan	1 – 3.5	11 bits	61,00	
ALOS	651	70	2,5	10	4	fase teste	8 bits	0,40	

Adaptado de ENGESAT (2006) In: SOUZA *et al.* (2007).

OBS: estimativa efetuada em setembro de 2008. Valor do dólar: R\$ 2,40.

Os sinais eletromagnéticos da radiação coletados pelos sensores remotos a bordo de satélites no espectro solar são modificados, dispersos e absorvidos por gases e aerossóis através de sua passagem pela atmosfera no caminho entre a superfície da terra e o sensor em questão. Neste sentido, ZULLO JUNIOR (1994) afirma que os principais efeitos observados nas imagens de satélite, devido à presença real da atmosfera entre o satélite e a superfície terrestre, são a diminuição da faixa de valores digitais possíveis registrados pelo sensor, diminuição do contraste entre superfícies adjacentes e alteração do brilho de cada ponto da imagem. Os gases (vapor d'água, oxigênio e dióxido de carbono) e os aerossóis refletem, refratam, absorvem e espalham a radiação desde quando ela atinge a atmosfera até quando a deixa, depois de refletida pelo solo. Buscando remover os efeitos atmosféricos de imagem de Sensoriamento Remoto, existem alguns sistemas de correção, como por exemplo, o Sistema de Correção Radiométrica de Imagens de Satélite. Atualmente existe um grande número de satélites de Sensoriamento Remoto em operação e outros planejados para entrar em operação.

2.4.1. Classificação de Imagens

A necessidade de se criar métodos digitais de classificação de imagens, reduzindo a subjetividade do intérprete humano e, ao mesmo tempo, considerando algumas características do meio, e não exclusivamente o valor espectral do *pixel*, tem levado ao desenvolvimento de novos aplicativos. A tendência de integração dos dados de imagens digitais, adquiridos via satélite, e dos dados da base cartográfica gerenciados por SIG, é considerada inevitável para avançar mais nas análises e interpretações das imagens. Neste sentido, as técnicas que se utilizam das diferentes fontes de dados digitais das imagens adquiridas pelo Sensoriamento Remoto via satélite e avião, com as informações cartográficas gerenciadas pelo SIG, são opções importantes para a geração de mapas temáticos (LANDGREBE, 2005; RICHARDS, 2004).

A classificação de imagens de Sensoriamento Remoto é uma das técnicas mais utilizadas para a extração de informações com diferentes objetivos, permitindo ainda a incorporação destas informações em um SIG. A classificação pode ser entendida como uma partição do espaço de atributos segundo alguns critérios. Os métodos de classificação (ou classificadores) podem ser divididos em classificadores por *pixel* ou por regiões e podem levar em conta uma ou mais bandas da imagem (no caso de imagens multiespectrais). Os classificadores por *pixel* utilizam a informação espectral de cada pixel isolado para rotular individualmente cada um de acordo com as variáveis

discriminantes (bandas espectrais), às classes informacionais. Classificadores por regiões baseiam-se na informação de um conjunto de *pixels* vizinhos (região), técnica esta conhecida também por classificação por objeto (RENNÓ, 1998).

Os classificadores podem também ser divididos em supervisionados, nos quais as classes são definidas *a priori*, com base em informações já conhecidas, e em classificadores não-supervisionados, em que os agrupamentos gerados pelo próprio classificador (QUEIROZ *et al.*, 2004). Para o caso da classificação supervisionada, o critério para a classificação baseia-se na definição de respostas espectrais (padrões) para cada uma das classes de estudo obtidas a partir de amostras de treinamento (BITTENCOURT, 2001). Como exemplos de classificadores supervisionados têm-se: Paralelepípedo, Mínimas Distâncias e Máxima Verossimilhança (MAXVER).

Vários métodos de segmentação de imagens estão disponíveis, com o objetivo de fragmentar a imagem em regiões “homogêneas”, sobre as quais é então processada a classificação. Estes métodos de classificação pós-segmentação, diferentemente dos anteriores denominados *pixel a pixel*, são conhecidos como classificação por regiões (COUTINHO, 1997).

A utilização de diferentes metodologias de classificação de imagens digitais pode levar a resultados diferentes. FIGUEIREDO e CARVALHO (2007) destacam situação assim ao avaliarem as metodologias de classificação adotadas por diferentes organizações governamentais e não governamentais, o que resultou em diferentes índices de desmatamento no estado do Acre. Esse tipo de discrepância dificulta a implementação de políticas públicas de controle ambiental e o desenvolvimento sustentável. Portanto, o método de classificação deve ser escolhido e avaliado com os devidos cuidados, evitando a subestimativa ou superestimativa de áreas. FIGUEIREDO e CARVALHO (2007) avaliaram o efeito do uso das metodologias MAXVER, ISODATA e árvore de decisão na classificação de imagens Landsat do município de Capixaba (AC). Os dados obtidos indicaram que os métodos foram eficientes para o mapeamento de uso e ocupação do solo apresentando excelente resultados na classificação, com a técnica MAXVER sendo superior às demais técnicas de classificação avaliadas. A classificação por árvore de decisão, por sua vez, demonstrou potencial no mapeamento das classes selecionadas, visto que, em dois dos três anos analisados, proporcionou eficiência semelhante à classificação por MAXVER.

2.4.1.1. Método da Árvore de Decisão

Método de classificação que utiliza um algoritmo recursivo que subdivide o conjunto de treinamento até que uma partição seja composta inteiramente, ou predominantemente, de casos pertencentes a uma mesma classe, ou até que algum critério de parada seja alcançado. É formada por nodos, definidos como pontos de encontro de duas ou mais informações que culminam para uma decisão, que representam os atributos; por arcos, provenientes daqueles e que recebem os valores possíveis para estes atributos e de nodos folha que representam as diferentes classes de um conjunto de treinamento (INGARGIOLA, 2008; ALMENTERO *et al.*, 2007). No esquema de aplicação do método da árvore de decisão (Figura 7), o quadrado indica um ponto de decisão, os círculos indicam os pontos de chance e os triângulos indicam os desfechos quantitativos (medidos em utilidades). Os números entre parênteses indicam a probabilidade da ocorrência de cada desfecho possível, fator calculado pelo *software* utilizado baseado na metodologia que foi escolhida para a classificação. Desta forma, para cada metodologia há funções e logaritmos específicos envolvidos para efetivar as decisões e apontar a classe final.

O método da árvore de decisão necessita de grande estrutura de dados para classificar situações complexas, podendo ser construídas em comandos SQL. (*Structured Query Language*). Esse algoritmo gera uma estrutura de árvore que ajuda na classificação e predição das amostras desconhecidas com base nos registros do conjunto de treinamento, sem necessariamente testar todos os valores dos seus atributos (PICHILIANI, 2008).

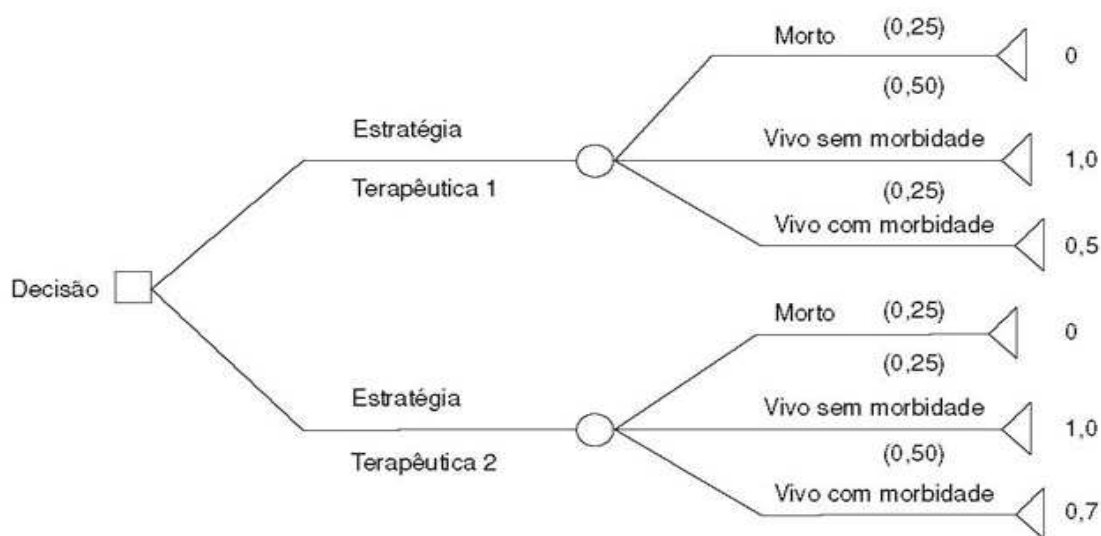


Figura 7 – Representação da classificação pela metodologia da árvore de decisão. No exemplo o uso da metodologia foi para análise de decisão na área da saúde médica. Fonte: CAMPOLINA e CICONELLI (2006).

As árvores de decisão baseiam-se em mecanismos de categorização por meio de divisões hierárquicas dos dados para se alcançar subdivisões que representem as classes temáticas. O método é não-paramétrico, podendo ser utilizados tanto dados contínuos como nominais. São geradas regras de classificação fáceis de serem interpretadas, sendo ainda rápido e geralmente tão preciso quanto os demais classificadores normalmente utilizados (CARVALHO *et al.*, 2005).

Muitos são os algoritmos de classificação que formam as árvores de decisão. Não existe uma maneira de se determinar qual é o melhor algoritmo, sendo que um pode ter melhor desempenho em determinada situação e, outro algoritmo pode ser mais eficiente em outros tipos de situações. Após a construção de uma árvore de decisão é importante avaliá-la. Esta avaliação é realizada utilizando-se dados que não tenham sido usados no treinamento. Esta estratégia permite estimar como a árvore generaliza os dados e se adapta a novas situações, podendo, também, estimar a proporção de erros e acertos ocorridos na construção da árvore (BRAZDIL, 1999). A partir de uma árvore de decisão é possível derivar regras. As regras são escritas considerando o trajeto do nodo raiz até uma folha da árvore. Devido ao fato de as árvores de decisão crescerem muito em complexidade, em algumas aplicações, elas podem ser substituídas pelas regras. Isto acontece em virtude das regras poderem ser facilmente nodularizadas. Uma regra pode ser compreendida sem que haja a necessidade de se referenciar outras regras (INGARGIOLA, 2008).

A árvore de decisão não assume nenhum modelo estatístico *a priori*, sendo a divisão do espaço de atributos feita de acordo com as amostras provenientes do treinamento. Assim, no espaço RGB, as classes são separadas por planos que as delimitam (HOLSHEIMER e SIEBES, 1994; BRAZDIL, 1999).

Com o objetivo de captar variações fenológicas que ocorrem nas formações vegetais de determinada região, CARVALHO *et al.* (2005) utilizaram imagens provenientes de tomadas de até três épocas diferentes do ano (primavera, verão e inverno). As imagens apresentavam correções geométricas e possíveis erros devido ao efeito do terreno foram corrigidos utilizando-se um modelo digital de terreno, sendo o resultado final registrado em um mesmo sistema de coordenadas. Os autores utilizaram o procedimento da reamostragem das imagens para um tamanho de *pixel* de 30 metros, com o algoritmo do vizinho mais próximo, sendo feitas correções radiométricas que incluem a remoção de ruídos de sensibilidade dos detectores, calibração para unidades de radiância, e posterior conversão para números digitais (ou valor de brilho). Os números digitais foram convertidos novamente para radiância aparente (aquela que chega ao sensor após haver interagido com a atmosfera),

conforme a Equação 2.1 e, posteriormente, para reflectância aparente, usando a equação 2.2, de acordo com o Serviço Geológico dos Estados Unidos (USGS).

$$L_{\lambda} = ((LMAX_{\lambda} - LMIN_{\lambda}) / 255) \cdot ND + LMIN_{\lambda} \dots\dots\dots (2.1)$$

$$\rho_{\lambda} = \pi \cdot L_{\lambda} \cdot d^2 / ESUN_{\lambda} \cdot \sin \theta_s \dots\dots\dots (2.2)$$

onde:

- λ = comprimento de onda
- L_{λ} = radiância espectral aparente
- ND = valor do pixel calibrado, dado em número digital
- $LMIN_{\lambda}$ = radiância espectral escalonada para 0
- $LMAX_{\lambda}$ = radiância espectral escalonada para 255
- ρ_{λ} = reflectância aparente
- d = distância entre Terra e o Sol
- $ESUN_{\lambda}$ = irradiância solar exoatmosférica média
- θ_s = ângulo de elevação do Sol

No mesmo trabalho (CARVALHO *et al.*, 2005), os autores promoveram a normalização (no escalonamento os dados são colocados entre 1 e -1) das imagens Landsat TM usando os valores de ganhos e viés para o cálculo da radiância aparente. Desta forma, essas imagens passaram a ser tratadas como se fossem imagens Landsat ETM+ (*Enhanced Thematic Mapper Plus*). Na seqüência foi promovido o georreferenciamento, reamostragem, remoção de nuvens e o mosaico das imagens da área estudada. Para compor o banco de dados do procedimento de classificação foi elaborado um Modelo Digital de Terreno (MDE), utilizando-se curvas de nível e pontos cotados. O MDE foi convertido para o formato *raster* por interpolação linear.

Os dados de reflectância foram então re-escalados, normalizados e convertidos para 8 *bits*, e depois utilizados no cálculo dos índices *brightness*, *greenness* e *wetness* da transformação *Tasseled Cap*, usando os coeficientes específicos para dados convertidos para reflectância aparente. A transformação linear *Tasseled Cap* foi efetuada mediante rotações e transformações dos dados, estabelecendo-se novos eixos no domínio espectral que captam a maior parte da informação contida nos dados em três novas variáveis diretamente relacionadas com características físicas da cena. Desta forma, a variável *brightness* passa a ser relacionada com a quantidade de vegetação verde presente na cena e, o *wetness*, com a umidade do solo e do dossel. O método de classificação, conforme destacado

pelos autores, foi supervisionado, com o algoritmo de árvores de decisão. Esse método possibilitou que dados auxiliares, como as derivativas de um modelo de elevação, pudessem ser completamente integrados no processo de classificação. Além disso, o método é não-paramétrico e, portanto, independe do formato da distribuição das assinaturas das classes.

2.4.1.2. Método da Máxima Verossimilhança

O método da Máxima Verossimilhança (MAXVER) é mais comumente utilizado quando é necessária a obtenção de classes informacionais a partir de imagens de sensores remotos. A distribuição espectral das classes de uso do solo é considerada como sendo gaussiana ou normal (RIBEIRO *et al.*, 2007), isto é, objetos pertencentes à mesma classe apresentam resposta espectral próxima à média de valores para aquela classe.

O MAXVER considera a ponderação das distâncias, utilizando parâmetros estatísticos de distribuição dos pixels dentro de uma determinada classe. Para a obtenção de resultados adequados com esta classificação é necessária a escolha de um número razoavelmente elevado de *pixels* para cada amostra de treinamento da classe, e que estes tenham uma distribuição estatística próxima da distribuição normal (CRÓSTA, 1993).

Este método de classificação parte do pressuposto que o usuário conheça previamente a área estudada, bem como a distribuição das classes, para que desta forma, quando da aplicação da classificação, a seleção de amostras de “treinamento” (calibragem) possa ser o mais eficiente possível (CRÓSTA, 1993).

O método MAXVER é o mais utilizado em Sensoriamento Remoto dentro da abordagem estatística, já que envolve parâmetros (vetor média e matriz de covariância) da distribuição gaussiana multivariada, e ainda é supervisionado, pois estima estes parâmetros através das amostras de treinamento (QUEIROZ *et al.*, 2004).

2.4.1.3. Método das Redes Neurais Artificiais

Redes Neurais Artificiais (RNA's) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que podem “adquirir” conhecimento através da experiência. As RNA's são sistemas com processamentos paralelos distribuídos, compostos por unidades de processamento simples (nodos) que computam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos

modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. O funcionamento destas redes é inspirado em uma estrutura física concebida pela natureza, o cérebro humano. Segundo BRAGA *et al.* (1998), as RNA's tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento básico e sua dinâmica. O grande diferencial deste novo método, segundo GALO (2002), é que ele utiliza sistema de amostragem, não requerendo a natureza paramétrica da distribuição estatística dos dados, nem o conhecimento prévio desta distribuição.

Um tipo de RNA bastante utilizado para problemas não lineares é a MLP (*Multilayer Perceptron*), que são redes que apresentam pelo menos uma camada intermediária ou escondida (Figura 8), sendo o algoritmo mais utilizado neste caso o *back-propagation* (ou retropropagação).

No esquema representado, as camadas de entrada são onde os padrões são apresentados à rede, e onde cada nó representa as variáveis discriminantes. As camadas intermediárias (ou escondidas) são onde é feita a maior parte do processamento, via conexões ponderadas, sendo consideradas como extratoras de características. E, por fim, a camada de saída é o local em que o resultado final é concluído e apresentado e onde cada neurônio representa uma classe informacional.




Figura 8 – Esquema representativo de uma arquitetura neural MLP (*Multilayer Perceptron*) dentro do contexto de Redes Neurais Artificiais (modificado de BRAGA *et al.*, 1998).

As redes MLP apresentam um maior diferencial do que as redes que não possuem camadas intermediárias, pelo fato de serem capazes de implementar qualquer função, seja linearmente separável ou não. Atualmente existem vários algoritmos para treinar uma MLP, destacando-se aqueles supervisionados, dentre os quais o mais utilizado é o *back-propagation* ou de retro-propagação, que utiliza pares (entrada e saída desejadas) e um mecanismo de correção de erros, para ajustar pesos da rede nas conexões. Desta forma, o aprendizado ocorre pelo ajuste dos pesos entre nós ou neurônios, de forma a minimizar as diferenças entre a ativação do nó de saída calculado e a saída desejada. O erro é retropropagado através da rede e o ajuste do peso é feito usando um método recursivo, sendo usado para melhorar a performance de análise de dados não-lineares (BRAGA *et al.*, 1998).

O treinamento neste algoritmo ocorre em duas fases, sendo cada uma delas em um sentido. A primeira é utilizada para definir a saída da rede para um dado padrão de entrada, sendo denominada de *forward* e, a segunda, de *backward*, a qual se utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões (BRAGA *et al.*, 1998).

O algoritmo *back-propagation* é o mais difundido para treinamento de redes multi-camadas. O erro de uma RNA pode ser calculado como a diferença entre a saída real gerada pela rede e a saída desejada, fornecida em um ensino supervisionado, como por exemplo:

$$e_k = d_k - y_k \dots\dots\dots(2.3)$$

onde, para um estímulo k, tem-se:

- e = sinal de erro;
- d = saída desejada apresentada durante o treinamento;
- y = saída real da rede após a apresentação do estímulo de entrada.

O algoritmo *back-propagation* é constituído inicialmente por uma propagação, ou seja, depois de apresentado o padrão de entrada, a resposta de uma unidade é “propagada” como entrada para as unidades da camada seguinte, até a camada de saída, onde é obtida a resposta da rede e o erro é calculado. Na seqüência, tem-se a retropropagação (*back-propagation*), onde desde a camada de saída até a camada de entrada, são feitas alterações nos pesos sinápticos.

Ao comparar o método de classificação MAXVER com o de RNA's para a classificação de imagens CBERS, RIBEIRO *et al.* (2007) verificaram que em ambos os

classificadores ocorreram confusões entre as áreas de desmatamento e não-floresta. Os autores, nesse mesmo estudo, atribuíram tal observação ao fato de os valores do nível de cinza dos pixels dessas duas classes serem bastante próximos. Por outro lado, neste mesmo estudo verificou-se alta taxa de acertos dos dois métodos para as classes água e floresta nativa. O classificador RNA mostrou-se eficiente para a classificação efetuada, merecendo dos autores reconhecimento por constituir um método adequado para a classificação de imagens de satélite.

No intuito de avaliar a capacidade de métodos quanto ao reconhecimento de caracteres manuscritos, BERGAMINI *et al.* (2006) testaram três algoritmos de classificação: RNA's, árvore de decisão e k-NN (*k Nearest Neighbor*, ou k vizinhos mais próximos). Os resultados obtidos indicaram que as RNA's apresentaram os melhores resultados comparadas com os demais modelos estudados. O modelo de aprendizagem baseada em instâncias k-NN também apresentou resultados satisfatórios para o problema de classificação de caracteres manuscritos em um grande banco de dados. Já o modelo de aprendizagem baseado em árvores de decisão não apresentou bons resultados, uma vez que utiliza um conjunto de treinamento exponencialmente grande, o que implica na necessidade de criação de uma árvore também exponencialmente grande. Devido ao tamanho da árvore, este modelo generaliza melhor (capacidade de reconhecer um padrão mesmo que não tenha visto anteriormente; faz inferência ou emite uma probabilidade com base nas informações que possui), e não apresenta uma boa precisão para classificação dos elementos.

Segundo CRUZ (2003), existem vários modelos de RNA's disponíveis e desenvolvidos para as mais diversas aplicações; Dentre eles, destaca-se a “rede neural de *perceptron* multicamadas”, que assume na análise regiões de decisão semelhantes àsquelas formadas por um classificador estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados. Além disso, essas redes podem ser bem treinadas por um algoritmo iterativo de aprendizagem, chamado *back-propagation* que as habilita a desenvolver um comportamento associativo correto quando confrontadas com situações de características similares. Para GALO (2000), após o aprendizado da rede, ela é capaz de classificar os padrões de interesse usando o conjunto dos pesos ajustados durante a fase de treinamento e calculando para cada padrão de entrada, os valores de saída associados a cada classe.

2.4.1.4. Validação da classificação de imagens

Uma classificação deve ter validade após sua execução, o que pode ser obtido por meio de índices de exatidão. Em estudo de classificação digital supervisionada de povoamentos florestais implantados e nativos em Cachoeira do Sul (RS), BOLFE *et al.* (2004) avaliaram três índices de acurácia, a partir de dados obtidos de uma imagem formada pelas bandas espectrais 3, 4 e 5 do sensor TM do Landsat. Os resultados obtidos indicaram haver diferenças referentes à reflectância das florestas plantadas, uma vez que o município apresenta áreas heterogêneas de reflorestamento, com áreas de *Pinus* sp. e *Eucalyptus* sp., alternadas por vegetação de mata ciliar. Os índices Exatidão Global, Kappa e Tau indicaram acerto de 85,23, 84,90 e 77,74 % de acurácia, respectivamente, atestando não ter havido confusões expressivas, principalmente, entres as classes de florestas nativas e plantadas.

Para a avaliação da exatidão da classificação é necessário comparar o mapa obtido por meio da classificação com dados de referência (JENSEN, 1996) ou de campo. A relação entre estes dois conjuntos informacionais geralmente é resumida em uma matriz de confusão, matriz de erros ou matriz de contingência (LILLESAND & KIEFER, 1994) (Quadro 4).

BRITES (1996) sugeriu o índice Kappa como um dos procedimentos de escolha para mensurar a exatidão das classificações temáticas por representar inteiramente a matriz de confusão, na qual, segundo COHEN (1960) é possível analisar as variações de erros de omissão e inclusão.

Quadro 4 – Exemplo de uma matriz de erros

Classe	Amostra de referência				Total incluído	Total linha (x_{i0})	Erro de comissão (%)
	A	B	C	D			
A	65	4	22	24	50	115	43
B	6	81	5	8	19	100	19
C	0	11	85	19	30	115	26
D	4	7	3	90	14	104	13
Total omitido	10	22	30	51	113	434	
Total coluna (x_{ei})	75	103	115	141			26,04
Erro de omissão (%)	13	21	26	36	Erro Global (%)		

Fonte: Adaptado de KHOURY (2004).

A grande vantagem do índice Kappa é que para o seu cálculo não se incluem somente os elementos da diagonal principal e sim todos os elementos da matriz (MOREIRA, 2001), como indicado na Equação 2.4. A matriz representa a distribuição de percentagens de pixels classificados de forma correta ou erroneamente, tornando possível identificar o erro global da classificação para cada categoria (CONGALTON, 1991; BRITES, 1996).

$$\hat{K} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} x_{+i}} \dots\dots\dots(2.4)$$

onde:

- \hat{K} = estimativa do coeficiente Kappa;
- x_{ii} = valor na coluna, representando a linha i e coluna i ;
- x_{i+} = soma da linha i da matriz de confusão;
- x_{+i} = soma da coluna i da matriz de confusão;
- N = número total de amostras e,
- c = número total de classes.

O índice Kappa (\hat{K}) varia entre -1 e 1, com o valor máximo (1) representando a completa concordância entre a imagem classificada e o dado de referência. Alguns erros podem então ser definidos. O erro de omissão ocorre quando há omissão no mapa de determinada feição constatada em campo. Já o erro de comissão se verifica quando é atribuída no mapa determinada feição a uma classe à qual a mesma não pertence, segundo levantamento de campo (CAMPBELL, 1996).

Deve-se entender por valor total observado a porcentagem correta, ou seja, a exatidão global definida pela soma dos elementos da diagonal da matriz dividida pelo número total de amostras. O valor total esperado é calculado usando os totais marginais de linha e coluna. Os produtos entre as marginais de linha e coluna estimam o número de *pixel* atribuído a cada célula da matriz, sendo os *pixels* atribuídos por chance a cada categoria (CAMPBELL, 1996).

2.4.2. Sensor TM Landsat

As imagens do sensor TM (*Thematic Mapper*) possuem resolução temporal de 16 dias e uma resolução espectral que abrange sete bandas (MOREIRA, 2003). Cada uma dessas bandas possui uma característica que deve ser levada em consideração para realização de pesquisas de acordo com o objetivo desejado (Quadro 5).

Quadro 5 – Caracteres e aplicações das bandas do sensor TM do Landsat -5

Banda	Faixa espectral (µm)	Região do Espectro	Principais aplicações das bandas TM do Landsat
1	0,45 – 0,52	Azul	Penetra em corpos d'água, é absorvido pela clorofila e outros pigmentos da planta, sensível às plumas de fumaça oriundas de queimadas ou de atividade industrial. Pode apresentar atenuação atmosférica.
2	0,52 – 0,60	Verde	Sensibilidade à presença de sedimentos em suspensão, possibilita análise quanto à quantidade e qualidade da água. Boa penetração em corpos d'água.
3	0,63 – 0,69	Vermelho	Forte absorção pela vegetação verde. Contrasta áreas com e sem vegetação e diferentes tipos de vegetação. Permite análise litológica em locais com pouca vegetação. Permite o mapeamento de rede de drenagem em regiões com pouca cobertura vegetal. É a banda mais utilizada para delimitar a mancha urbana.
4	0,76 – 0,90	IV próximo	Forte absorção da energia nesta região pela água. Vegetação verde, densa e uniforme reflete muita energia. Sensível à morfologia do terreno. Distingue áreas ocupadas com vegetação que foram queimadas.
5	1,55 – 1,75	IV médio	Sensível ao teor de umidade das plantas. Esta banda sofre perturbações em caso de ocorrência de chuvas antes da obtenção da imagem pelo satélite.
6	10,4 – 12,5	IV termal	Sensível aos fenômenos relativos aos contrastes térmicos detectando propriedades termais de rochas, solos, vegetação e água.
7	2,08 -2,35	IV médio	Sensível à morfologia do terreno. Útil em identificar minerais com íons hidroxilas. Favorável à discriminação de produtos de alteração hidrotermal.

Fonte: Moreira (2003).

3. MATERIAL E MÉTODOS

3.1. Localização da Área de Estudo e Caracterização Geral

O município selecionado para o presente estudo foi Araponga, localizado na Zona da Mata mineira (Figura 9), com 304,421 km² e cerca de 7.947 habitantes. Seu IDH é 0,657 e seu PIB é R\$ 20.134.435,00 (IBGE, 2007). A economia do município é baseada essencialmente na agricultura, mais precisamente na produção de café, com uma área plantada de aproximadamente 3.420 hectares, produto este que vem sendo classificado dentre as melhores bebidas do país em concursos nacionais. Entretanto, a presença da UC Parque Estadual da Serra do Brigadeiro (PESB) e de Áreas de Preservação Ambiental (APA), Araponga também vem obtendo incentivos ambientais que impulsionam a economia do município.




Figura 9 – Localização da área de estudo correspondente ao município de Araponga (MG) com destaque para o Parque Estadual da Serra do Brigadeiro.

A principal formação vegetal do município é a Floresta Semidecídua, seguida dos Campos de Altitude e Ombrófila, sendo essas duas últimas mais evidentes na área do Parque Estadual da Serra do Brigadeiro (PESB), onde se encontram as partes mais elevadas do município. No entanto, as áreas de floresta são, em sua grande maioria, secundárias, devido ao grande desmatamento ocorrido. Florestas primárias ocupam apenas as áreas mais inacessíveis do PESB. Esta UC é de proteção integral e se localiza entre os meridianos 42° 40' e 40° 20' Oeste e os paralelos 20° 33' e 21° 00' Sul, ao extremo norte da Serra da Mantiqueira. O parque possui inúmeras nascentes que contribuem para a formação de duas importantes bacias hidrográficas de Minas Gerais, a do Rio Doce e a do Rio Paraíba do Sul.

3.2. Materiais e Bases de Dados

Foram utilizados os seguintes materiais:

- a) Imagem Landsat: com sete bandas correspondendo à cena 217/74, de 22/06/2004 e de 16/11/2005. Para as metodologias MAXVER e RNA's foram utilizadas as bandas de 1 a 7, com exceção da banda 6 termal. No método da Árvore de Decisão (CARVALHO *et al.*, 2005), utilizado para comparação, foram utilizadas imagens da área de três épocas do ano (primavera, verão e inverno), utilizando as bandas de 1 a 5 e a banda 7. Todas as imagens foram obtidas junto ao Instituto Nacional de Pesquisas Espaciais (INPE);
- b) Arquivos digitais em formato “.shp” com as classes da cobertura floresta produzidos durante o “Mapeamento e Inventário da Flora Nativa e dos Reflorestamentos de Minas Gerais”, efetuado em 2005 utilizando a metodologia de Árvores de Decisão (CARVALHO *et al.*, 2005). Esses arquivos foram utilizados na comparação das ferramentas e metodologias utilizadas no presente estudo. Os dados foram fornecidos pelo Instituto Estadual de Florestas (IEF-MG), Universidade Federal de Lavras (UFLA) e Programa de Proteção da Mata Atlântica (PROMATA-MG), parceiros no referido mapeamento;
- c) Arquivos digitais de curvas de nível, limites municipais e das unidades de conservação, estradas, hidrografia, dentre outros: obtidas de várias fontes, destacando-se o IBGE, o Projeto GEOMINAS, o Instituto Mineiro de Gestão das Águas (IGAM-MG), todos esses atualmente de posse do IEF-MG, os quais foram utilizados para elaboração dos mapas e do Modelo Digital de Terreno;
- d) Suporte computacional: disponibilizado pelo IEF-MG, nas instalações do Centro de Estudo e Desenvolvimento Florestal (CEDEF), ligado à Gerência de Monitoramento e Geoprocessamento (GEMOG/IEF-MG). No caso do “Mapeamento e Inventário da

Flora Nativa e dos Reflorestamentos de Minas Gerais” (CARVALHO *et al.*, 2005) foram utilizados equipamentos da Universidade Federal de Lavras (UFLA) e do Programa de Proteção da Mata Atlântica (PROMATA-MG);

e) GPS Garmin 76: para levantamento de campo das classes que se buscava na classificação por meio das RNA's e MAXVER. Na técnica de árvores de decisão foram utilizados equipamentos de videografia, fotografia digital e GPS adaptados em aeronave;

f) Imagem ÍKONOS: imagem de 2005 do PESB e pertencente ao IEF, usada para a utilização na comparação e verificação com os dados obtidos com as metodologias aqui executadas e testadas.

3.3. Softwares Utilizados

Para os procedimentos na preparação dos dados foi utilizado-se o Sistema de Informações Geográficas SPRING nas versões 4.3 e 5.0, desenvolvido e disponibilizado pelo Instituto Nacional de Pesquisas Espaciais – INPE (CÂMARA *et al.*, 1996). Trata-se de um software gratuito e que foi usado para a combinação das bandas e/ou tratamentos necessários na imagem, como georreferenciamento e ajuste RGB, e na execução da classificação por MAXVER.

Para processamento das atividades de montagem da arquitetura e execução da classificação com as redes neurais foram utilizados os arquivos executáveis (VIEIRA, 2000):

a) *Kappa* – para efetivar a estatística de averiguação de mínimo de amostras (quantidade de *pixels*) necessárias para a classificação, para tanto, foram utilizadas as informações sobre a proporção de erro admitida de 0,5 e a porcentagem de confiabilidade 95% e cinco por cento de Precisão;

b) *Transform* – utilizando-se dos dados anteriores, este procedimento foi executado tanto para coletar amostras para treinamento (calibragem) da rede, quanto para averiguação, gerando a matriz de confusão;

c) *Funcpow* - utilizado para gerar uma imagem que possa ser reconhecido em outros SIG's a partir dos resultados gerados nos procedimentos dessa metodologia;

d) *Software JAVA-SNNS (Stuttgart Neural Network Simulator)* - este consiste de um simulador de Redes Neurais desenvolvido pelo *Institute for Parallel and Distributed High Performance Systems*, da Universidade de Stuttgart. Depois de pesquisado neste aplicativo a melhor arquitetura MLP a ser utilizada para classificar as cenas, foi feito a “calibragem” (treinamento) da rede, fase na qual foram ajustados, automaticamente, os pesos das conexões à medida que se rodava os ciclos, evitando a saturação prematura.

Para a formação do banco de dados SIG, reescalonamento e ajuste das imagens de satélite e na finalização das atividades foi utilizado o *software* ArcGis 9.0. O mesmo *software* foi usado após a obtenção das classes vegetacionais para a elaboração dos *layouts* (mapas).

3.4. Trabalho de Campo

Para o início do processo de classificação supervisionada prepararam-se mapas de trabalho. Tais mapas foram formados pela imagem de satélite que foi utilizada (Figura 10), bem como dados dos limites do município, da localização das estradas, da hidrografia, e com a indicação de alguns pontos para visita e averiguação. Dados em extensão “.shp”, definindo o limite do município, limite do PESB e alguns pontos para averiguação, foram transferidos para um aparelho receptor GPS para servir como guia no campo.




Figura 10 – Imagem do satélite Landsat5 TM de 16/11/2005, destacando-se o município de Araponga (MG), formada a partir da combinação das bandas 3/4/5.

Com a finalidade de se coletar as coordenadas geográficas dos pontos para treinamento e validação dos classificadores foram realizadas três visitas de campo, cada uma durante um período de três dias. As visitas foram efetuadas em diferentes partes do município de Araponga e em alguns pontos específicos de interesse para a validação de algumas respostas espectrais da imagem, como por exemplo, para se localizar campos de altitude no PESB.

Uma imagem de alta resolução (IKONOS), da mesma época da imagem Landsat, também foi utilizada para se averiguar os resultados obtidos, guiando desta forma a seleção das amostras e para averiguação visual das classes de saída.

Na metodologia por Árvore de Decisão (CARVALHO *et al.*, 2005), as informações de campo foram obtidas mediante incursões aéreas com helicóptero, visando retratar amostras das diversas formações vegetais da área e para se verificar a acurácia do trabalho.

A principal imagem utilizada para a classificação foi a cena 217/74 do Landsat5 TM, adquirida em 16/11/2005. As coletas de campo foram realizadas no mesmo período do ano (mês) em que a imagem orbital foi obtida, de forma a se tentar uma avaliação mais adequada da situação.

Nas visitas a campo foram avaliados os tipos predominantes de cobertura do solo, selecionando pontos em locais com diferentes usos a pequenas distâncias, como pastagens (conservadas e degradadas), café, Floresta Ombrófila, Floresta Semidecídua, eucalipto e outros (afloramento rochoso, área urbana, solos expostos, estradas, outras culturas e etc). Esses usos objetivaram solucionar possíveis “confusões” do classificador. Nestas visitas foram obtidas também as coordenadas geográficas dos pontos e tomados arquivos fotográficos que representassem cada feição de interesse na classificação da imagem.

As coordenadas geográficas foram tomadas na parte central das áreas de interesse, buscando minimizar o erro do GPS de navegação utilizado (modelo 76 da Garmin), que possui um erro médio estimado de 10 metros. Uma vez no interior e centro da área de interesse, o erro associado é reduzido, situação não verificada quando se obtém dados muito próximos às bordas das classes em estudo. As precisões apontadas pelo GPS para cada ponto obtido, bem como a altitude e a classe a ele associada, além de outras observações relevantes, foram anotadas.

3.5. Trabalho de laboratório

As seguintes classes vegetacionais foram previamente selecionadas para o presente estudo: Floresta Ombrófila, Floresta Semidecídua, Campo de Altitude, eucalipto, café e pastagem. Essa seleção prévia serviu de base para a definição dos pontos de coleta em campo.

Finalizada a coleta de dados em campo, foi elaborado um banco de dados dos pontos coletados, ao qual foram agregados dados de: classe vegetacional, altitude, precisão, coordenadas, município e observações. O banco de dados foi utilizado para auxiliar na detecção das feições na imagem e para facilitar a confecção das legendas dos mapas.

Na seqüência foram escolhidas as amostras de treinamento, que foram definidas dentro de determinados polígonos com o auxílio do software ArcGis 9.0. Esses polígonos foram traçados sobre a imagem em áreas com manchas de padrões semelhantes em função da cor apresentada. Desta forma, foram delimitadas visualmente as classes de cobertura vegetal. Posteriormente tais informações foram convertidas para dados matriciais com as mesmas características das bandas da imagem de satélite utilizada para a classificação, ou seja, padronizando-se o tamanho de cada imagem e *pixel*. A posição geográfica também foi ajustada, utilizando-se para isto o *software* ArcGis 9.0.

Para a delimitação dos polígonos foi utilizado GPS, além da imagem de alta resolução IKONOS para confirmação das mesmas. No programa SPRING promoveu-se uma composição RGB, a partir das bandas 3, 4 e 5 da imagem Landsat, na busca de uma melhor visualização das classes. Nessa operação, para o canal 3 adotou-se a cor azul, para o canal 4, a verde e, para o canal 5, a vermelha.

Na aplicação dos métodos RNA e MAXVER, as seis bandas da imagem Landsat utilizadas (1, 2, 3, 4, 5 e 7) foram georreferenciadas e reamostradas para tamanho de pixel 30 por 30 metros. As bandas 3, 4 e 5 foram mosaicadas (fundidas/combinadas) no *software* SPRING para servir como guia na seleção das amostras de cada classe de interesse e para a utilização na classificação pelo método da Máxima Verossimilhança, etapa realizada posteriormente neste mesmo programa.

Concluída esta etapa, os pontos coletados com GPS foram sobrepostos na imagem combinada das bandas citada anteriormente. Este procedimento permitiu a avaliação da distribuição e do georreferenciamento dos pontos de campo, bem como se os mesmos estavam coerentes com a imagem.

3.5.1. Preparação dos Dados para Utilização no Método da Máxima Verossimilhança

Da mesma forma que nas redes, o primeiro passo foi selecionar quais e quantas classes que se pretendia obter e, posteriormente, foram utilizados os mesmos polígonos que foram criados sobre a imagem formada pela combinação das bandas 3, 4 e 5 para cada classe selecionada. Os polígonos serviram de guia para a classificação, utilizando-se assim os mesmos dados utilizados no procedimento anterior. Utilizando-se a ferramenta do software SPRING 5.0 e as bandas 1 a 7, com exceção da banda 6, foi promovida a classificação pelo método da Máxima Verossimilhança.

No software SPRING foi efetuado o mosaico correspondente às seis bandas do sensor Landsat (1 a 5 e 7) e, à continuação, foi criada uma categoria classes, com as seguintes classes temáticas: Floresta Ombrófila, Floresta Estacional Semidecídua, Campo de Altitude, café, eucalipto e , pastagem), as quais serviriam de referência para esta classificação. Como essas classes já haviam sido delimitadas anteriormente e estavam disponíveis em formato “.shp”, elas foram separadas em arquivos independentes, ou seja, cada uma em um arquivo específico para cada classe. Posteriormente, os arquivos foram importados para o projeto no SPRING, sendo formatados cada plano de informação, conforme exigência deste software.

No menu “Imagem” do SPRING foi usada a ferramenta “classificação” nas informações de pixel das três bandas já citadas, sendo criado um contexto para efetivar a classificação por MAXVER. Concluída tal fase, cada amostra de treinamento (classes) foi importada, sendo posteriormente salvas. De volta à janela de classificação, optou-se pela ferramenta classificação, sendo dado um nome para a imagem de saída. Nesta mesma janela foi escolhido a opção MAXVER e o limiar de aceitação para esta classificação (99%). Na seqüência as amostras foram analisadas, sendo executada também a matriz de confusão entre as classes e as próprias amostras para cada classe.

Completada as ações descritas anteriormente, foi executada a classificação propriamente dita, a partir da qual é gerada uma imagem temática classificada (saída), assim como pode ser visualizado nos resultados.

3.5.2. Preparação dos Dados para Entrada na Rede

Durante a revisão de literatura foram verificadas diferentes maneiras de se preparar os materiais e, até mesmo, vários procedimentos de classificação utilizando as RNA's. Além de procedimentos diferenciados de preparação da entrada na rede, torna-se relevante testar o que deve ser utilizado na entrada de dados para se obter melhores resultados, o que varia conforme o objetivo esperado do estudo, seja ele a avaliação da cobertura vegetal ou do uso do solo, por exemplo. Esse procedimento pode ser demorado, pois em grande parte é feito por tentativa e erro.

Nesse procedimento podem ser utilizados desde apenas algumas bandas do sensor até planos de informações diferentes, como altitude e tipo de solos. Neste contexto, no presente estudo optou-se por utilizar seis bandas do sensor Landsat 5 TM (1, 2, 3, 4, 5 e 7), adicionando mais um plano de informação com dados de altitude (MDE) (Figura 11). Esse último objetivou auxiliar na delimitação das áreas que possuem a classe Campo de Altitude, já que estas são encontradas acima de 1.000 metros de altitude. Desta forma, o plano de informação MDE foi reescalado para duas classes (0 e 250), passando a existir de forma normalizada apenas com os valores de 0 e 1, correspondentes a altitude menores que 1.000 metros e maiores que 1.001 metros, respectivamente.

Primeiramente ajustaram-se todos os planos de informações disponíveis nas mesmas características, ou seja, adequando todos ao mesmo tamanho de imagem e *pixel*, e ao posicionamento geográfico. No *software* ArcMap foi gerado a partir do comando *Composite Bands*, a união das bandas a serem classificadas adicionando-se a altitude, e salvando-se a composição de bandas no formato “.img”. Esse formato de arquivo é o nativo do *software* ERDAS IMAGINE. Posteriormente o arquivo foi salvo em formato bruto, (“.i”), que é por sua vez, *generic binary* (sem informações iniciais na imagem), formato este necessário para o reconhecimento em procedimentos posteriores.

As amostras coletadas em formato de polígono foram rasterizadas ajustadas para as mesmas características dos outros planos de informação. A ferramenta *Raster To Other Format (multiple)*, do *software* ArcMap, foi utilizada para transformar as amostras de classificação no formato “.img”, e também para renomear para o formato “.i” obtendo assim, a imagem de referência, processo semelhante ao anterior.





Figura 11 – Modelo digital de elevação (MDE) da área estudada.

Posteriormente, utilizando-se o executável “Kappa”, foram efetuados os procedimentos estatísticos para se averiguar quantas amostras seriam necessárias para se efetivar a classificação, baseado no número de *pixels* da imagem e no número de classes pretendidas. Os cálculos foram promovidos com a ferramenta *Compute Sample Size*, sendo utilizadas as informações sobre a proporção de erro admitida (0,5), a porcentagem de confiabilidade (95%) e considerando-se 5 % de precisão. O resultado obtido para cada classe do presente estudo foi de, no mínimo, 120 amostras para a classificação e 120 amostras para a verificação do resultado, gerando-se desta forma a matriz de confusão em procedimento posterior.

Seguiu-se o procedimento com a obtenção das amostras de treinamento e de teste da rede. Com o *software* Transform foram gerados arquivos em formato “.*coo*” com amostras aleatórias (120) para cada classe, retiradas da imagem de referência.

Em outra etapa seguinte foi executado no mesmo *software* a transformação dos arquivos “.*i*” e “.*coo*” - gerados com a composição dos planos de informação anterior e a imagem de referência, para a extensão “LS.NOR”. Para isto, foi necessário fornecer as seguintes informações: nome do arquivo da imagem (composição das bandas); o número de linhas e colunas destas imagens (1491 e 1278, respectivamente); número de bandas (sete, sendo seis do sensor Landsat e uma a informação de altitude); fator de normalização (255, referente à escala de tons de cinza), onde as informações são reescaladas para o intervalo de 0-1; nome do arquivo gerado com a coleta das amostras aleatórias em extensão “.*coo*” e, por fim, o nome de saída do arquivo com extensão “LS.NOR”. Esse procedimento foi executado tanto para o arquivo de treinamento quanto para o de teste.

Na seqüência foram gerados os arquivos de dados (teste e treinamento) com extensão “.PAT”, utilizando-se ainda o *software* Transform. Este formato de arquivo é reconhecido pelo *software* JAVA SNNS utilizado para treinar (calibrar) as redes. Depois de uma pesquisa no aplicativo SNNS pela melhor arquitetura MLP a ser utilizada para classificar as cenas promoveu-se o treinamento da rede, fase na qual foram ajustados, automaticamente, os pesos das conexões à medida que se rodavam os ciclos, evitando-se assim, a saturação prematura da mesma.

O algoritmo utilizado nas Redes Multi-camadas foi o de *Back-propagation* (Retropropagação), que se baseia no “Aprendizado Supervisionado por Correção de Erros”. Por tentativa e erro foi determinado o melhor número de camadas ocultas (duas) e o número de neurônios em cada uma delas (22), ambos definidos a partir dos parâmetros e entradas da rede, como MDE e as bandas da imagem Landsat (1, 2, 3, 4, 5 e 7). Depois de completado o procedimento, foi promovido o teste da rede, a partir de um conjunto de dados que não foram previamente utilizados. Desta forma,

promoveu-se a validação com o arquivo “teste”, gerando um arquivo em formato “.res” (matriz de erros). Finalmente, com a rede treinada (calibrada) e avaliada, por meio do resultado *Kappa*, que se apresentava, após varias tentativas e erros, aproximadamente 0,78 como valor maior, a mesma foi integrada ao sistema do ambiente operacional da aplicação utilizado (JAVA SNNS).

Novamente com o *software* Transform, o arquivo gerado no passo anterior foi transformado para um arquivo “.cln”, ou seja, na matriz de erros efetiva, que neste formato pode ser aberta com um editor de textos, como por exemplo, bloco de notas do *Windows*. Esse arquivo apresenta somente se o resultado do treinamento foi adequado ou não, sendo um passo prévio para a classificação definitiva da imagem estudada.

Finalizados todos os procedimento anteriores, a imagem em formato “.i” foi transformada, por meio do *software* Transform, para a extensão “.NOR” e, posteriormente, para “.PAT”. Esse último arquivo foi então adicionado ao *software* “JAVA SNNS”, passando pela rede previamente treinada (calibrada), gerando um arquivo em formato “.res”.

No *software* Funcpow, utilizando-se a ferramenta “gera imagem from files .RES” (arquivo de resultado), o arquivo “.res” gerado previamente foi transformado para uma imagem temática, que pode ser acessada em outros programas de SIG.

4. RESULTADOS

Os dados da cobertura vegetal da área de estudo, obtidos a partir da classificação da imagem do Landsat 5 TM de 16/11/2005, cena 217/74, e estimados com a aplicação das metodologias de classificação MAXVER e RNA em comparação às utilizadas pelo inventário da Flora Nativa e dos Reflorestamentos do Estado de Minas Gerais para o ano de 2005 (método de Árvores de Decisão, CARVALHO *et al.*, 2005) são apresentados no Quadro 6.

No inventário realizado em 2005 (CARVALHO *et al.*, 2005) foram identificadas as seguintes classes para o município em estudo: Campo Rupestre, Floresta Estacional Semidecídua e Campos (Quadro 6, Figura 12). Com a quantificação da cobertura florestal classificada naquela oportunidade, utilizando-se a metodologia de Árvores de Decisão, obteve-se um coeficiente Kappa de 0,89 e, um índice de exatidão global de 90,8 %, lembrando-se que estes índices foram estipulados com resultados de todo o estado de Minas Gerais.

Quadro 6 – Distribuição das classes de cobertura vegetal no município de Araponga (MG) obtida pela classificação pelos métodos de Árvores de Decisão, Máxima Verossimilhança (MAXVER) e Redes Neurais Artificiais (RNA) considerando imagem Landsat do ano de 2005

CLASSES	Área (ha)		
	ÁRVORES ⁽¹⁾	MAXVER	RNA
Campo de Altitude	267,00	2.878,40	2.007,92
Campo Rupestre	6,00	0,00	0,00
Floresta Estacional Semidecídua	7.118,00	6.831,51	2.540,46
Floresta Ombrófila	0,00	3.924,14	3.181,99
Café	0,00	4.348,09	7.882,11
Pastagem	0,00	11.119,25	2.540,46
Total de vegetação nativa ⁽²⁾	7.391,00	13.634,05	7.730,37
Total de vegetação manejada ⁽³⁾	0,00	15.467,34	10.422,57
Área total vegetada	7.391,00	29.101,38	18.152,95
Área total não vegetada	23.000,54	1290,16	3.019,57
Área total do Município	30.391,54	30.391,54	30.391,54

(1) CARVALHO *et al.* (2005)

(2) Total de vegetação nativa = florestas + campos

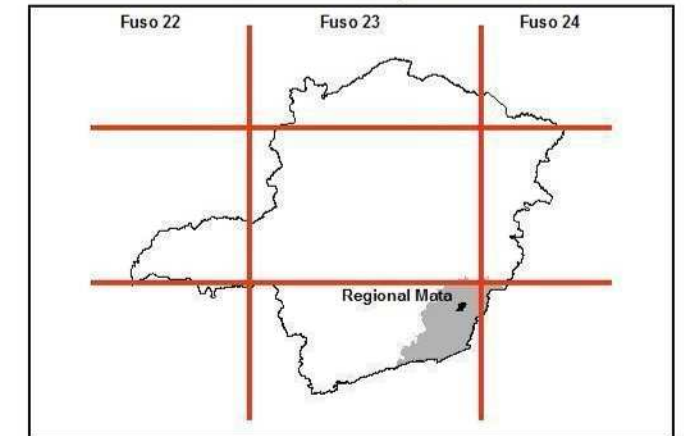
(3) Total de vegetação manejada = eucalipto + café + pastagem




ARAPONGA - MG

MAPA DA FLORA NATIVA E DOS REFLORESTAMENTOS DE MINAS GERAIS

Localização do Município no Estado



Classes	2003		2005		Diferença da cobertura vegetal no	
	Área (ha)	%	Área (ha)	%	Área (ha)	%
Campo	267,00	0,88	267,00	0,88	0,00	0,00
Campo Rupestre	6,00	0,02	6,00	0,02	0,00	0,00
Campo Cerrado	0,00	0,00	0,00	0,00	0,00	0,00
Cerrado Sensus Stricto	0,00	0,00	0,00	0,00	0,00	0,00
Cerradão	0,00	0,00	0,00	0,00	0,00	0,00
Vereda	0,00	0,00	0,00	0,00	0,00	0,00
Floresta Estacional Decidual	0,00	0,00	0,00	0,00	0,00	0,00
Floresta Estacional Semidecidual	7.118,00	23,44	7.117,00	23,44	-1,00	0,00
Floresta Ombrófila	0,00	0,00	0,00	0,00	0,00	0,00
Eucalipto	0,00	0,00	0,00	0,00	0,00	0,00
Pinus	0,00	0,00	0,00	0,00	0,00	0,00
Área Total Vegetada	7.391,00	24,34	7.390,00	24,34	-1,00	0,00
Área Total não Vegetada	23.000,54	75,66	23.001,54	75,66	1,00	0,00
Área Total do município	30.391,54	100,00	30.391,54	100,00	0,00	0,00



Legenda

- PONTOS COTADOS
- SEDES MUNICIPAIS
- RODOVIAS
- HIDROGRAFIA
- CURVAS DE NÍVEL
- UNIDADES DE CONSERVAÇÃO
- LIMITES MUNICIPAIS
- URBANIZAÇÃO
- REPRESAS
- VEGETAÇÃO
- Campo
- Campo cerrado
- Campo rupestre
- Cerrado
- Cerradão
- Eucalipto
- Floresta estacional decidual
- Floresta estacional semidecidual
- Floresta Ombrófila
- Pinus
- Veredas
- Áreas de mudanças na vegetação - 2003/2005



1:125.000
Projeção: UTM (Universal Transversa de Mercator)
GCS (Graus' minutos' e segundos")
Datum: SAD 69

LIMITES BASEADOS NA REGIONALIZAÇÃO DO IEF,
CONFORME PORTARIA N° 157, DE 9 DE NOVEMBRO DE 2006.

FONTES DE REFERÊNCIA:
MAPEAMENTO DA FLORA NATIVA E DOS REFLORESTAMENTOS DE MINAS GERAIS - 2005 SETOR
DE GEOPROCESSAMENTO E ANÁLISES DE IMAGENS LABORATÓRIO DE ESTUDOS E PROJETOS
EM MANEJO FLORESTAL (LEMAF/DCF/UFLA)

EXECUÇÃO:
COORDENADORIA DE MONITORAMENTO - CM/CEDEF

EDIÇÃO: JANEIRO / 2007

O IEF AGRADECE A GENTILEZA DA COMUNICAÇÃO DE FALHAS OU OMISSÕES
VERIFICADAS NESTA FOLHA.



Figura 12 - Cobertura vegetal do município de Araponga (MG),
segunda a classificação automatizada por Árvores de Decisão.

Com as metodologias utilizadas no presente estudo (RNA e MAXVER, apresentadas nas Figuras 13 e 14, respectivamente), foram diagnosticadas um maior número de classes de vegetação, sendo estabelecidas seis classes de cobertura vegetal (Floresta Estacional Semidecídua, Floresta Ombrófila, Campo de Altitude, café, eucalipto e pastagem). Neste sentido, verifica-se um detalhamento mais adequado proporcionado por tais técnicas à realidade verificada na paisagem do município de Araponga, em especial pelo fato de considerarem culturas comerciais como são os casos do eucalipto, pastagem e café, importantes atividades agrosilvipastoris da região. No entanto, pela dificuldade de delimitar as amostras de eucalipto, aliada ao fato da semelhança de sua reflectância com a de outras classes de vegetação nativa, tais como a Semidecídua e a Ombrófila, e também, pelo fato de essa classe se apresentar em pequenas áreas no município de Araponga, ficando pouco evidente na representação na imagem utilizada para a classificação, a classe eucalipto acabou não sendo considerada individualmente.

Por outro lado, as metodologias propostas não resultaram em maiores coeficientes *Kappa* para a classificação efetuada. Enquanto o método da Máxima Verossimilhança permitiu a obtenção de um índice de 0,87, a RNA, igualmente considerando um total de 600 *pixels* utilizados para as cinco classes de saída, proporcionou um coeficiente de 0,72. Esses valores, para ambas as metodologias, são indícios de um bom resultado para a classificação, tendo em vista que o valor máximo admitido para o *Kappa* é de 1.

Na comparação das metodologias, verifica-se que as classificações por MAXVER e RNA identificaram uma maior cobertura vegetal na área em comparação com os resultados obtidos pelo método de Árvores de Decisão (Quadro 6). Isto foi mais evidente para a Floresta Ombrófila e, principalmente, para os Campos de Altitude, classes vegetacionais que foram detectadas em expressiva extensão no município com as metodologias avaliadas no presente estudo.

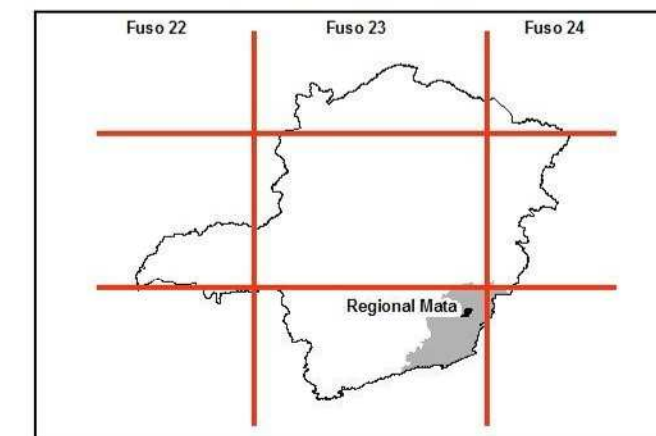
Como já indicado, nas classificações efetuadas o eucalipto foi desconsiderado e as culturas comerciais (pastagem e café) foram incorporadas à cobertura vegetal da área. No caso das plantações comerciais, sua inclusão e análise no conjunto da paisagem são importantes do ponto de vista do planejamento, já que podem ser considerados os impactos de tais atividades na área ambiental.



ARAPONGA - MG

Cobertura vegetal do município de Araponga (MG),
segunda a classificação automatizada por
Máxima Verossimilhança."


Localização do Município no Estado



CLASSES	Área (ha)	%
Campo de Altitude	2878,40	9,47
Floresta Estacional Semidecídua	6831,51	22,48
Floresta Ombrófila	3924,14	12,91
Eucalipto	0,00	0,00
Café	4348,09	14,31
Pastagem	11119,25	36,59
Área total vegetada	29101,38	95,75
Área total não vegetada	1290,16	4,25
Área total do Município	30391,54	100,00

LEGENDA

×	PONTOS COTADOS	Vegetação
●	SEDES MUNICIPAIS	Campo de Altitude
—	RODOVIAS	Eucalipto
—	HIDROGRAFIA	Café
—	CURVAS DE NÍVEL	Floresta estacional semidecidual
—	UNIDADES DE CONSERVAÇÃO	Floresta Ombrófila
—	LIMITES MUNICIPAIS	Pastagem
—	URBANIZAÇÃO	Outros (Nuvens, Sombras, Área Urbana, Solo Exposto...)
—	REPRESAS	



1:125.000

Projeções: UTM (Universal Transversa de Mercator)
GCS (Graus° minutos' e segundos")
Datum: SAD 69

LIMITES BASEADOS NA REGIONALIZAÇÃO DO IEF,
CONFORME PORTARIAN° 157, DE 9 DE NOVEMBRO DE 2006.

FONTES DE REFERÊNCIA:
RESULTADOS OBTIDOS UTILIZANDO O MÉTODO DE CLASSIFICAÇÃO POR MÁXIMA
VEROSSIMILHANÇA (MAXVER), UTILIZANDO IMAGENS LANDSAT-5 SENSOR TM.


EXECUÇÃO:
CENTRO DE ESTUDOS E DESENVOLVIMENTO FLORESTAL
(CEDEF / UFV)

EDIÇÃO: AGOSTO / 2008

O CEDEF AGRADECE A GENTILEZA DA COMUNICAÇÃO DE FALHAS OU OMISSÕES
VERIFICADAS NESTA FOLHA (cedef@meioambiente.mg.gov.br).



Figura 13 - Cobertura vegetal do município de Araponga (MG),
segunda a classificação automatizada por MAXVER.


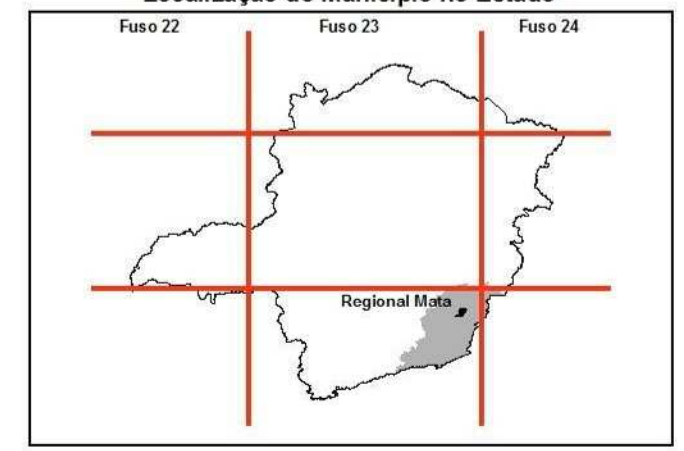




ARAPONGA - MG

Cobertura vegetal do município de Araponga (MG),
segunda a classificação automatizada por
Redes Neurais Artificiais


Localização do Município no Estado



CLASSES	Área (ha)	%
Campo de Altitude	2007,92	6,61
Floresta Estacional Semidecídua	2540,46	8,36
Floresta Ombrófila	3181,99	10,47
Eucalipto	0,00	0,00
Café	7882,11	25,94
Pastagem	2540,46	8,36
Área total vegetada	18152,95	59,73
Área total não vegetada	3019,57	9,94
Área total do Município	30391,54	100,00

LEGENDA

×	PONTOS COTADOS		Vegetação	Campo de Altitude
●	SEDES MUNICIPAIS		Eucalipto	
	RODOVIAS		Café	
	HIDROGRAFIA		Floresta estacional semidecidual	
	CURVAS DE NÍVEL		Floresta Ombrófila	
	UNIDADES DE CONSERVAÇÃO		Pastagem	
	LIMITES MUNICIPAIS		Outros (Nuvens, Sombras, Área Urbana, Solo Exposto...)	
	URBANIZAÇÃO			
	REPRESAS			



Projeções: UTM (Universal Transversa de Mercator)
GCS (Graus° minutos' e segundos")
Datum: SAD 69

LIMITES BASEADOS NA REGIONALIZAÇÃO DO IEF.
CONFORME PORTARIANº 157, DE 9 DE NOVEMBRO DE 2006.

FONTES DE REFERÊNCIA:
RESULTADOS OBTIDOS UTILIZANDO O MÉTODO DE CLASSIFICAÇÃO POR REDES NEURAIS ARTIFICIAIS (RNA), UTILIZANDO IMAGENS LANDSAT-5 SENSOR TM.

EXECUÇÃO:
CENTRO DE ESTUDOS E DESENVOLVIMENTO FLORESTAL (CEDEF /UFV)

EDIÇÃO: AGOSTO / 2008

O CEDEF AGRADECE A GENTILEZA DA COMUNICAÇÃO DE FALHAS OU OMISSÕES VERIFICADAS NESTA FOLHA (cedef@meioambiente.mg.gov.br).



Figura 14 - Cobertura vegetal do município de Araponga (MG), segunda a classificação automatizada por Redes Neurais Artificiais.

Uma maior detecção de vegetação diretamente ligada ao patrimônio natural da área, associado às formações Floresta Semidecídua e Ombrófila e pelos Campos de Altitude, como ocorrido nos testes aqui realizados, é interessante para o município de Araponga, pois destaca sua responsabilidade para com a preservação do meio natural, bem como amplia as possibilidades de o mesmo obter benefícios decorrentes desse patrimônio, como ICM Ecológico e, conseqüentemente, qualidade ambiental.

Considerando as cinco classes de saída e as 120 amostras coletadas para uso nas metodologias aqui testadas (Floresta Estacional Semidecídua, Floresta Ombrófila, Campo de Altitude, Café e Pastagem), no total foram consideradas 600 amostras (*pixels*) na classificação. A mesma quantidade de *pixels* foi coletada para ser utilizada no teste de comparação, que se apresenta nas Matrizes de Erros (Quadro 7 e 8), nas quais se evidenciam os erros de omissão e comissão para cada classe, ou seja, para cada classe tem-se o quanto de amostras foram classificadas em outras classes, e o quanto de outras classes foi direcionado para essa determinada classe, respectivamente. Como indicado, no presente estudo não foram utilizadas as mesmas amostras para a classificação e a validação, o que pode produzir uma resposta mascarada, com um elevado, mas não realista índice *Kappa*.

Quadro 7 – Matriz de erros obtida na avaliação da distribuição de classes de cobertura vegetal no município de Araponga (MG) para a classificação efetuada utilizando-se o método de Máxima Verossimilhança – MAXVER

Classe de referência Classe produzida	Classe de referência					Amostras classificadas	Erro de Comissão
	Ombrófila	Campo	Pastagem	Semidecídua	Café		
Ombrófila	115	12	0	53	28	208	55,1
Campo	0	103	0	0	0	103	99,4
Pastagem	0	3	119	1	0	123	96,5
Semidecídua	4	2	1	62	13	82	75,3
Café	1	6	0	4	78	84	86,6
Amostras coletadas	120	120	120	120	120	600	
Erro de Omissão	96,3	80,1	99,3	51,5	76,2		

Quadro 8 – Matriz de erros obtida na avaliação da distribuição de classes de cobertura vegetal no município de Araponga (MG) para a classificação efetuada utilizando-se o método de Redes Neurais Artificiais – RNA

Classe de referência Classe produzida	Classe de referência					Amostras classificadas	Erro de Comissão
	Ombrófila	Campo	Pastagem	Semidecídua	Café		
Ombrófila	88	2	0	13	6	109	80,7
Campo	0	105	3	3	3	114	92,1
Pastagem	0	1	111	0	0	112	99,1
Semidecídua	14	1	0	89	23	127	70,1
Café	5	3	3	4	70	85	82,4
Amostras coletadas	120	120	120	120	120	600	
Erro de Omissão	73,3	87,5	92,5	74,2	58,3		

Nos Quadros 7 e 8 são apresentados as Matrizes de Erros para as classificações executadas no presente estudo. Esses resultados mostram para cada classe, comparando-se as amostras de entrada para a classificação (nas linhas) com as amostras para a verificação (nas colunas), todas as informações sobre as confusões verificadas na execução das metodologias avaliadas. Com esse tipo de quadro pode-se analisar em qual classe foram coletadas um certo número de amostras e o quanto dessas amostras foram corretamente atribuídas à respectiva classe. Assim, por exemplo, tomando o Quadro 7, para a classe Ombrófila foram coletados 120 amostras para a classificação e mais 120 para a verificação. Este último não aparece no quadro, mas é utilizado na comparação do resultado da classificação com amostras da mesma classe para verificar se coincidem as respostas, como por exemplo, no final da avaliação, 115 amostras foram consideradas como efetivamente pertencentes à classe Ombrófila, valor que pode ser verificado na linha diagonal destacada pela cor cinza nas Matrizes de Erros. Desta forma, cinco amostras foram omitidas, sendo quatro classificadas como Semidecídua e uma como café. Essas cinco amostras são o resultado da diferença entre as 120 amostras coletadas e as 115 classificadas como Ómbrofilas. Neste caso, a linha que apresenta a porcentagem do Erro de Omissão nas Matrizes de Erros, pode levar a quem a está analisando pensar que é um valor alto, já que foram omitidas, a exemplo da classe Ombrófila no Quadro

7, apenas 5 amostras das 120 e o Erro de Omissão apresenta um resultado para essa classe de 96,3%. No entanto, a leitura deve ser feita que aproximadamente 3,7% (100% - 96,3%) foi omitido para essa classe, o que dentro de 120 amostras, corresponde as cinco, ou seja, as amostras omitidas descritas anteriormente, o mesmo deve ser feito para o Erro de Comissão. Outros erros foram associados ao fato de amostras de outras classes (Campo, pastagem, Semidecídua e café) serem adicionadas (comissão) à classe Ombrófila, o que permite alcançar um total de 208 amostras classificadas com este tipo vegetacional. Isto denota que grande parte da área de outras classes foram consideradas como Ombrófila, como pode ser observado ao se analisar individualmente os outros tipos vegetacionais.

Por outro lado, na classificação por RNA (Quadro 8) para a mesma classe Ombrófila, verificou-se um número de amostras classificadas com esta tipagem vegetacional (109) inferior ao próprio número de amostras tomadas (120) para supervisionar a classificação. Isto indica que grande parte (32) das amostras tomadas (120) para a classificação era incompatível com as amostras de verificação (120), gerando tais erros, pois mesmo com a adição de outras classes nesta (Erro de Comissão), ou seja, 2 da classe campo, 13 da classe semidecídua e 6 da classe café, o número de amostras classificadas no final ainda é menor que o número de amostras coletadas (120).

A Matriz de Erros, efetuada para todas as classes pretendidas na classificação, representa uma análise das amostragens e seu resultado final, que abrange toda a área em estudo, se comprometido, não representa a realidade. Isto frequentemente ocorre pela similaridade entre as respostas espectrais ou por erros no momento da coleta das amostras, havendo assim omissão e comissão entre as classes que se pretende espacializar. Esses são problemas normais em um procedimento de classificação automatizada, mas que se deve buscar evitar ou minimizar com o uso de imagens de melhor definição e uma coleta de amostras mais restrita e adequada à cada classe.

5. DISCUSSÃO

Um das qualidades da imagem Landsat, e também da maioria dos satélites, é a sua repetitividade, uma vez que deste sensor monitora a mesma área superfície terrestre a cada 16 dias. Outro ponto importante é o fato de que qualquer área de interesse no planeta pode ser solicitada a um custo bastante acessível, além do que imagens mais antigas são disponibilizadas gratuitamente. Quando submetida a adequados procedimentos de processamento, essa imagem pode fornecer resultados bastante reveladores e de grande utilidade, muito embora o domínio de conhecimentos em sensoriamento remoto seja necessário para a execução dos processamentos exigidos. Caso sejam demandados dados mais precisos, tanto qualitativamente como quantitativamente, outras ferramentas e materiais podem ainda ser considerados utilizando-se essa mesma imagem.

No uso das imagens Landsat, o mapeamento temático efetuado a partir de cada uma de suas bandas é dependente das características da área em estudo (região plana ou acidentada); época do ano (inverno, verão e primavera); ou de variações regionais (Nordeste, Sudeste, Sul e etc), além das diferenças que podem ocorrer no terreno, como por exemplo, aquelas proporcionadas pelas variações intrínsecas a diferentes Biomas.

A distribuição espacial e temporal da cobertura vegetal de uma região é fortemente influenciada por um conjunto de fatores ambientais que incluem condições climáticas, topografia, solos e suas propriedades associadas. Esta variação emite uma reflectância diferenciada, podendo confundir o analista na hora da classificação. O conhecimento das respostas espectrais, dos comprimentos de onda e das faixas nas quais estas respostas podem ser mais bem exploradas é importante no momento da escolha da imagem e das bandas para a classificação, pois permite evidenciar o alvo desejado com maior facilidade.

Nos trabalhos de interpretação de imagens, o conhecimento prévio da realidade de campo é um interessante facilitador dos procedimentos a serem adotados. Isso contribui sobremaneira para com as etapas de reconhecimento e levantamento de pontos de apoio para a classificação.

Essa breve introdução busca despertar o leitor para possíveis intenções de extrapolação dos dados obtidos no presente estudo, para outras áreas e Biomas. O mesmo procedimento de classificação aqui adotado, se aplicado a outros Biomas que não o da Mata Atlântica, deve ser tomado com ressalvas, haja vista que as condições climáticas ou mesmo do substrato serão diferenciados, afetando diretamente a

fisiologia das plantas e, conseqüentemente, a resposta espectral da cobertura vegetal.

O fato de a área em estudo encontrar-se em relevo acidentado, com altitudes alcançando mais de 1.000 m, associado à exposição voltada para o mar de parte da Serra do Brigadeiro, faz com que grandes massas de umidade cheguem a serra, e nesse contato, venham a formar nuvens e chuvas orográficas. Se essa peculiaridade regional é interessante para garantir o aparecimento de formações típicas de locais de altitude com umidade, como por exemplo, da Formação Florestal Ombrófila, ela por outro lado, dificulta o trabalho do classificador. Isto ocorre, pois a nebulosidade afeta diretamente a obtenção e, portanto, a qualidade das imagens obtidas. Para situações como essa, torna-se difícil encontrar dia e momento em que as imagens do satélite não sejam prejudicadas pela presença de nuvens, principalmente em períodos de chuva.

A presença de nuvens impediu ainda que outra fonte de informação fosse utilizada. Era pretensão desse estudo avaliar também imagens do sensor AVNIR-2, proveniente do satélite ALOS, pertencente à Agência Espacial Japonesa (JAXA). Essas imagens apresentam como vantagem o fato de poderem ser adquiridas a baixo custo comercial, e preço ainda mais acessível quando destinadas à pesquisa. No entanto o plano de cobertura efetuado anualmente por este satélite passa poucas vezes sobre a área de interesse e a única imagem disponível em estoque, correspondente à mesma época do ano da imagem Landsat, contava com mais de 90% da área imageada tomada por nuvens.

Na classificação de imagens, após a definição das classes, o foco é centrado na seleção de variáveis discriminantes, ou seja, na escolha da melhor combinação de dados obtidos do(s) sensor(es) remoto(s), atributos de terreno e outros dados que sejam consideradas relevantes para a classificação, tais como, outras informações da superfície que não as oferecidas pela imagem, como por exemplo, as classes de solos. Essas são informações importantes, principalmente, para os classificadores que não se baseiam somente em dados de reflectância do *pixel*, a exemplo as RNA's. Neste sentido, e como exemplo, para a detecção do Campo de Altitude do presente estudo, foram utilizadas as características deste tipo de vegetação, indicadas até pela própria denominação ("de altitude"). Como ocorrem em cotas iguais ou superiores a 1.000 m e, em solos rasos ou afloramentos rochosos, a delimitação da área ocupada por estes foi facilitada. Exceto com relação à luz, os Campos de Altitude ocorrem em áreas com restrição a praticamente todos os demais fatores ambientais essenciais ao desenvolvimento de plantas, tais como água, nutrientes e temperatura. Neste contexto, as escolhas das variáveis discriminantes para esta tipagem vegetal

aliou a resposta espectral e o conhecimentos dos atributos de terreno e das condições ambientais no espaço geográfico avaliado.

Considerando os resultados do presente estudo, talvez a primeira discussão que se cabe é acerca do coeficiente *Kappa* obtido. Parte-se do pressuposto que um valor obtido próximo à unidade revela uma adequada classificação. Entretanto, sabe-se que mesmo com um *Kappa* próximo a 1 não garante um resultado de classificação sempre condizente com a realidade. A análise visual das imagens geradas em comparação com os conhecimentos de campo associada à análise da imagem ÍKONOS - discutida mais adiante e utilizada para a checagem dos resultados, indicam uma não conformidade com a realidade. Essa comparação com dados mais precisos, como os proporcionados por imagens de alta resolução como a ÍKONOS, mostram ainda os desafios e a necessidade de uma maior evolução dessas metodologias automatizadas para melhor representarem a paisagem.

De qualquer forma o menor *Kappa* obtido no presente estudo para as classificações com MAXVER e RNA's, em comparação com a obtida por CARVALHO *et al.* (2005), pode ser relacionado à opção de se retratar mais classes vegetacionais, ainda que a diferença não tenha sido muito expressiva entre os resultados desses índice para todas essas classificações. Como o trabalho realizado com as Árvores de Decisão avaliou menos classes, isto se reflete em uma menor variabilidade de resultados, portanto, podendo permitir um maior grau de acerto. Obviamente que deve ser considerado também o fato de que tal classificação não tenha se restringido somente a um município como o realizado no presente estudo, e sim se estendendo a todo o Estado de Minas Gerais. Mas também é notório que o incremento do número de classes aumenta as possibilidades de confusões e, portanto, pode potencializar a obtenção de menores índices de avaliação.

Outro fator a ser considerado é o fato de que o elevado índice *Kappa* obtido nas metodologias avaliadas poder ter sido devido à grande presença de nuvens e sombras na imagem. Como esses artefatos possuem uma resposta espectral bem definida e totalmente divergente das respostas dos outros alvos avaliados (vegetação), pois nuvens e sombras possuem na imagem os extremos na escala de cinza (0 e 255 respectivamente), isto facilita a sua delimitação, incrementando-se desta forma, o valor do referido índice, já que ele não é verificado classe a classe, e sim para as classes como um todo. Caso uma ou mais das classes sejam bem representativas na imagem, sua delimitação é facilitada, proporcionando assim melhores resultados, tanto visual como a partir de índices. Posteriormente, quando se analisa o conjunto das classes, o resultado final será influenciado por estes melhor avaliados, elevando-se o índice de avaliação obtido. O que indicaria um melhor resultado de classificação para todas as

classes pode, na verdade, ser mais a contribuição expressiva de uma ou mais classes, afetando desta forma, o resultado final obtido que, por isto, deve ser sempre analisado sob ressalvas.

Neste contexto, na seqüência, buscou-se comparar e analisar individualmente as classes de vegetação selecionadas no presente estudo, a partir de diferentes imagens (Landsat e ÍKONOS) e das respostas dos diferentes métodos de classificação (Árvores de Decisão; Máxima Verossimilhança e Redes Neurais Artificiais) aqui considerados. Para essa avaliação foi necessária a padronização de uma legenda de cores, como apresentada na Figura 15.



Figura 15 – Legenda de cores usada na comparação das classes de vegetação obtidas em imagens de diferentes sensores e na avaliação da classificação efetuada por diferentes ferramentas de geoprocessamento.

5.1. Floresta Estacional Semidecídua

Essa formação florestal (Figuras 16, 17 (a) e 17 (b)) é a mais abundante em relação às demais classes florestais avaliadas, assim como indicado nos resultados quantitativos das classificações executadas com as metodologias MAXVER e RNA (Quadro 6). A maior expressividade desta classe só não é maior que pastagem, classe vegetacional que se verifica principalmente após a barreira da serra, em direção ao interior do continente, onde está contida a maior parte do município de Araponga.

A confusão com outras classes e a certa superestimativa dessa tipologia vegetal na classificação executada por Árvores de Decisão (CARVALHO *et al.*, 2005) (Figura 18) é bem evidente quando se sobrepõe os dados da referida classificação sobre a imagem Landsat (Figura 17 (b)), e ainda muito mais evidente quando se utiliza a imagem ÍKONOS (Figura 17 (b)), sendo principalmente associada em detrimento da formação Florestal Ombrófila.



Figura 16 – Tipologia vegetacional Floresta Estacional Semidecídua presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).




Figura 17 – Imagens (a) ÍKONOS e (b) Landsat, destacando-se a área com Floresta Estacional Semidecídua.




Figura 18 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO *et al.*, 2005) com enfoque na Floresta Estacional Semidecídua.

Embora se assuma que a Floresta Estacional Semidecídua tenha sido melhor delimitada na classificação por MAXVER (Figura 19 (a)), confusões ocorreram com outras classes, principalmente devido aos diferentes estágios sucessionais desta formação. Essas confusões foram verificadas (Figuras 17, 18, 19 (a) e 19 (b)) com Floresta Ombrófila em seu estágio inicial, e também com eucalipto e café, devido às semelhanças em termos de resposta espectral. A pressuposição de melhor estimativa pelo MAXVER foi tomada com base na comparação direta com a imagem que foi utilizada para a classificação, bem como pelo conhecimento de campo.




Figura 19 – Imagem da Figura 17 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com Floresta Estacional Semidecídua.

Os dados quantitativos (Quadro 6) obtidos mostraram que os resultados para essa tipologia florestal, nos métodos da Árvores de Decisão e do MAXVER, não apresentaram grande discrepância. Entretanto, as RNA's, indicaram uma área para essa classe de vegetação em torno de 50% menor do que a determinada por essas duas outras técnicas.

Um comentário que merece destaque é o fato de que a desconsideração da tipologia pastagem na classificação efetuada pelo método da Árvore de Decisão - ainda que tenha sido objetivo daquele estudo, ignora um elemento da paisagem importante dentro de um contexto de preservação e conservação do meio natural. Essas áreas, se identificadas, constituem importantes locais com potencial de, eventualmente, virem a compor programas oficiais de recomposição de florestas, a partir da união de fragmentos já existentes, como indicado nas Figuras 19 (a) e 19 (b).

A cobertura de nuvens prejudicou a detecção de parte dessa formação, já que na época de obtenção da imagem, coincidente com a estação chuvosa, a presença desses componentes atmosféricos é muito comum.

5.2. Floresta Ombrófila

Diferentemente do verificado na classificação por meio das Árvores de Decisão (Quadro 6), a classe Floresta Ombrófila (Figuras 20, 21 (a), 21 (b) e 22) foi detectada nos outros dois métodos utilizados neste estudo (Figuras 23 (a) e 23 (b)). Essa formação tem sua ocorrência definida por características tanto climáticas quanto relacionadas ao seu substrato, que por fim, estão intimamente relacionados. De uma forma geral, ocorre em ambientes bastantes úmidos, o que para a área em estudo é garantido pelo fato de a Serra do Brigadeiro ter uma de suas vertentes voltada para o oceano e pela própria morfologia da paisagem. As entradas e feições côncavas da serra permitem o acúmulo de material orgânico, o que incrementa o acúmulo de umidade no solo. Estas características da paisagem fornecem condições para que esta formação sobressaia melhor que em outras áreas e isto, cria parâmetros para a sua delimitação, que se apresenta evidente na imagem devido à sua resposta espectral ser diferenciada em relação às outras áreas, como facilmente perceptível nas imagens ÍKONOS e Landsat (Figuras 21 (a) e 21 (b)). Os dados de sua localização típica também servem de planos de informação auxiliares para a melhor definição de sua delimitação.



Figura 20 – Tipologia vegetal Floresta Ombrófila presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).




Figura 21 – Imagem (a) ÍKONOS e (b) Landsat destacando a área com Floresta Ombrófila.



Figura 22 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO *et al.*, 2005) com enfoque na área ocupada efetivamente pela Floresta Ombrófila.




Figura 23 – Imagem da Figura 21 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com Floresta Ombrófila.

Na classificação por MAXVER (Quadro 6), essa formação florestal foi muito confundida com outras classes, principalmente com semidecídua e café, como pode ser verificado na Figura 13. A distribuição atribuída à formação Ombrófila pelas Redes Neurais parece se equiparar mais à realidade, considerando a análise da imagem utilizada para a classificação (Figura 21 (b)) e também com base na imagem ÍKONOS (Figura 21 (a)), além de dados de literatura. Tais informações indicam que esse tipo de floresta ocorre freqüentemente em vertentes voltadas para o mar, e na classificação proposta pela referida metodologia, essa classe foi indicada para vários locais além da serra, onde não há evidências que suportam sua ocorrência. No entanto, como pode

ser visualizado na classificação automatizada por MAXVER” (Figura 13), as áreas delimitadas para essa classe extrapolaram a área de abrangência da serra.

A detecção dessa classe foi também afetada pela presença constante de nuvens, uma vez que sua localização coincide com ambientes mais propícios à formação das mesmas.

A resposta espectral dessa formação, principalmente em seus estágios iniciais de sucessão, pode ser confundida com outras formações, principalmente com a Floresta Semidecídua, mas também com café e eucalipto, dada a similaridade de resposta espectral na imagem de satélite. No entanto, freqüentes relatos indicam que, em grande parte, essa formação pode ser mais facilmente delimitada, pelo fato de ela abrigar um elevado número de epífitas e lianas, e contar com um alto dossel. Tais características proporcionam a ocorrência de uma vegetação mais densa, com resposta espectral típica. Entretanto, como destacado, quando se encontra em seu estágio sucessional inicial, as dificuldades aumentam na classificação.

5.3. Campo de Altitude

A formação Campo de Altitude (Figuras 24 e 25 (a) e 25 (b)) foi o melhor exemplo de confusões entre as classes no presente estudo. Para a classificação por meio da metodologia Árvores de Decisão aplicado no trabalho de CARVALHO *et. al* (2005), essa classe foi pouco detectada, como pode ser visualizado na Figura 26. O fato de essa formação vegetacional ocupar áreas de solos jovens e afloramentos rochosos (feições com respostas espectrais similares a outras porções da imagem) é um complicador. Isto faz com que essa tipologia, que só ocorre em altitudes superiores a 1.000 metros e, que no caso do PESB estão presentes quase que totalmente acima de 1.250 metros, seja detectado em áreas de menor cota pelos classificadores que se baseiam apenas na resposta espectral, a exemplo da metodologia MAXVER (Figura 27 (a)). Como esse classificador não considera outros planos de informação, a exemplo das RNA's (Figura 27 (b)), como a altitude para esse caso, a delimitação dessa classe foi prejudicada e superestimada (Quadro 6), uma vez que solos jovens e afloramentos rochosos não são restritos a elevadas altitudes, como ocorre na área em estudo.



Figura 24 – Fitofisionomia vegetal Campo de Altitude presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).




Figura 25 – Imagens (a) ÍKONOS e (b) Landsat destacando área com Campo de Altitude.




Figura 26 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO *et al.*, 2005) com enfoque em Campo, considerado no referido trabalho como as formações Campo e Campo Rupestre.




Figura 27 – Imagem da Figura 25 (b) classificada com as metodologias (a) MAXVER e (b) RNA destacando-se a área com Campo de Altitude.

No caso da metodologia RNA, foi possível a incorporação de outros planos de informações como auxiliares na delimitação das classes em uma imagem, como já discutido anteriormente. No entanto a expectativa de melhor classificação com a utilização dos dados de altitude nesta metodologia não se confirmou, como pode ser analisado ao se comparar as Figuras 25 (a), 25 (b) com a 26 e 27 (b). Por outro lado, há de se considerar que os Campos de Altitude, de forma similar à Formação Ombrófila, também foram prejudicados pela presença de nuvens, tendendo a ser subestimados, já que aquelas formações climatológicas são consideradas na classe outros.

Uma discussão interessante que merece destaque é a diferença entre essa formação e a de Campo Rupestre. O termo Campo Rupestre tem sido usado para se referir a uma vegetação formada sobre quartzito e/ou arenito, referente ao Bioma Cerrado. Já Campos de Altitude são considerados como a vegetação que ocorre sobre granitos e, ou, gnaisses e que ocorrem na Floresta Atlântica. Partindo desses conceitos, neste estudo os campos presentes na área foram considerados como Campos de Altitude, e não Campos Rupestre como efetuado no trabalho de CARVALHO *et al.* (2005). Ambas as tipologias são pertencentes aos Complexos Rupestres de Altitude, mas aqui se optou pela distinção previamente indicada.

OLIVEIRA-FILHO e FLUMINHAN-FILHO (1999) afirmam que os Campos de Altitude ocorrem em áreas onde as condições edafoclimáticas são favoráveis, principalmente, na ausência ou incipiência de solo e associados a altitudes entre 1.000 e 2.000 metros. Trata-se de um mosaico de comunidades controlado pela topografia, geomorfologia, microclima, bem como pela natureza geológica e pedológica do substrato.

A Figura 27 indica uma adequada resposta para a classificação executada pela metodologia MAXVER em relação a esta classe vegetacional, diferentemente da resposta proporcionada pelas RNA's.

5.4. Pastagem

A pastagem (Figuras 28, 29 (a) e 29 (b)) foi um dos tipos de cobertura vegetal considerado nas classificações pelas metodologias MAXVER e RNA. Essa classe não foi considerada no trabalho de CARVALHO *et al.* (2005), como pode ser visto na Figura 30. A incorporação de áreas da referida classe é justificada pela sua expressão no município, alcançando cerca de 36% e 8% da superfície do município de Araponga, pelas classificações MAXVER e RNA, respectivamente. Essa discrepância pode ser relacionada ao fato de que grande parte dessa classe ter sido classificada como café pelo classificador RNA, como pode ser visualizado no mapa (Figuras 14) e na Figura 31(b).



Figura 28 – Tipologia vegetacional pastagem presente na área do Parque Estadual da Serra do Brigadeiro, Araponga (MG).




Figura 29 – Imagens (a) ÍKONOS e (b) Landsat destacando área com Pastagem.

As Figuras 30, 31 (a) e 31 (b), indicam claramente que a metodologia das Árvores de Decisão, por não considerar pastagens (principalmente pelos espaços representando pela cor cinza na Figura 30), pode levar à interpretação de que nestas áreas há ausência de cobertura vegetal, o que não corresponde à realidade. Analisando-se as Figuras 29 (a) e 29 (b), ou mesmo as Figuras 31 (a) e 31 (b), que

são resultado da classificação por MAXVER e RNA, percebe-se que grande parte desses espaços estão ocupados por essa classe de vegetação.




Figura 30 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO *et al.*, 2005) com enfoque em pastagem.




Figura 31 – Imagem da Figura 32 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com pastagem.

O resultado das classificações executadas (MAXVER e RNA) (Quadro 6) aponta uma elevada área vegetada, cujo dado é claramente incrementado pela adição da classe pastagem. Isso pode levar à idéia de que todo o município é florestado, mas na verdade pouco mais de 50% da sua área é floresta, ficando o restante ocupado por pastagens e outras classes não vegetais.

A detecção da classe pastagem pode ser considerada como relevante em se tratando da Zona da Mata de Minas Gerais. As pastagens são possivelmente a principal cobertura do solo desta região, exercendo ano após ano grande pressão sobre as áreas ainda ocupadas por florestas. O conhecimento da espacialização dessa tipologia vegetal, e principalmente, seu monitoramento ao longo dos anos, pode permitir tomadas de decisão que disciplinem possíveis avanços das pastagens sobre as florestas e fragmentos restantes. As áreas com pastagens também podem ser úteis em trabalhos de preservação e conservação da biodiversidade, seja ela formada por flora ou fauna, executada a partir de programas e ações de reflorestamento e formações de corredores ecológicos. Como são, em sua maioria, mal manejadas e estarem em estágio avançado de degradação, as pastagens são áreas propícias para a incidência de políticas públicas que incentivem os proprietários rurais a permitir o retorno da vegetação original da região. Outra opção seria a integração das pastagens com árvores, o que tem se mostrado uma alternativa promissora em alguns estudos neste Bioma..

As variadas formas de ocorrência das pastagens, ou seja, seus diferentes graus de degradação, proporcionam reflectâncias diferenciadas em imagens orbitais. Isto dificulta a análise espacial e pode acarretar confusões na detecção por classificação automatizada. Em áreas degradadas, a pastagem pode ser confundida com solo exposto ou mesmo afloramentos rochosos. Ou ainda, quando em estágios de pleno vigor e desenvolvimento podem até se comportar espectralmente como algum outro tipo de vegetação mais arbustiva.

5.5. Eucalipto

As plantações de eucalipto, ainda que tenham sido desconsideradas nas classificações executadas no presente estudo, são importantes no contexto regional e estadual. Sua detecção e espacialização é muito importante, tendo em vista que a mesma é objeto de um grande projeto de fomento florestal executado no Estado e pelo fato de ser uma opção para a diminuição da supressão da floresta nativa.

Grande parte dos plantios de eucalipto (Figura 32, 33 (a) e 33 (b)) em Araponga é formada por pequenos fragmentos, que dada à resolução da imagem utilizada (30 x 30 metros), acabaram não aparecendo no *pixel* de 900 m² de área em campo (Figura 33 (b)). Sob essas condições é comum que essa classe passe despercebida junto ao classificador, seja o operador em classificação manual ou o *software* em classificações automatizadas. A resposta espectral desta vegetação é ainda outro complicador, uma vez que é similar ao de outras formações florestais,

como por exemplo, a Floresta Estacional Semidecídua, principalmente quando comparadas com estágios iniciais de desenvolvimento.




Figura 32 – Tipologia vegetacional eucalipto presente na área do Parque Estadual da Serra do Brigadeiro, Araçuaia (MG).




Figura 33 – Imagens (a) ÍKONOS e (b) Landsat destacando área com eucalipto.

A metodologia Árvore de Decisão (Figura 34) não detectou a presença de eucalipto e as aplicadas no presente estudo (MAXVER e RNA) (Figuras 35 (a) e 35 (b), respectivamente) não se mostraram adequadas, tendo em vista que nas tentativas e erros durante a execução dessas metodologias, elas confundiram essa classe com outras coberturas vegetacionais e ampliaram a sua detecção em toda a área estudada, o que não representava a realidade de campo. Essa mesma situação se apresentou com a classe café, como será indicado mais adiante. Os resultados não adequados para o eucalipto podem ser facilmente comprovados, uma vez que os resultados das classificações mostraram a presença dessa tipologia na área urbana de Araponga e no interior do PESB, o que não corresponde à realidade, principalmente considerado que o mesmo trata-se de uma UC de proteção integral. Embora ocorrências dessa árvore sejam possíveis e decorrentes de períodos prévios ao estabelecimento do parque, ela não é tão extensa como a indicada, por exemplo, pela metodologia RNA.

Para esta classe não há nenhum outro plano de informação que possa ser usado para melhor defini-la e demarcá-la, como é o caso do Campo de Altitude. Mas podem existir outros meios para sua delimitação em detecção via classificação automatizada. Uma das possibilidades de se delimitar esta classe, sem a necessidade de lançar mão de imagens de alta resolução espacial, seria o aproveitamento do banco de dados geográficos do IEF/MG, onde essas áreas deveriam estar registradas. O IEF-MG tem interesse em monitorar tal formação, além de que grande parte das áreas plantadas com eucalipto no Estado tem o auxílio e apoio dessa instituição via programas de fomento florestal.




Figura 34 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO *et al.*, 2005) com enfoque na área de eucalipto.

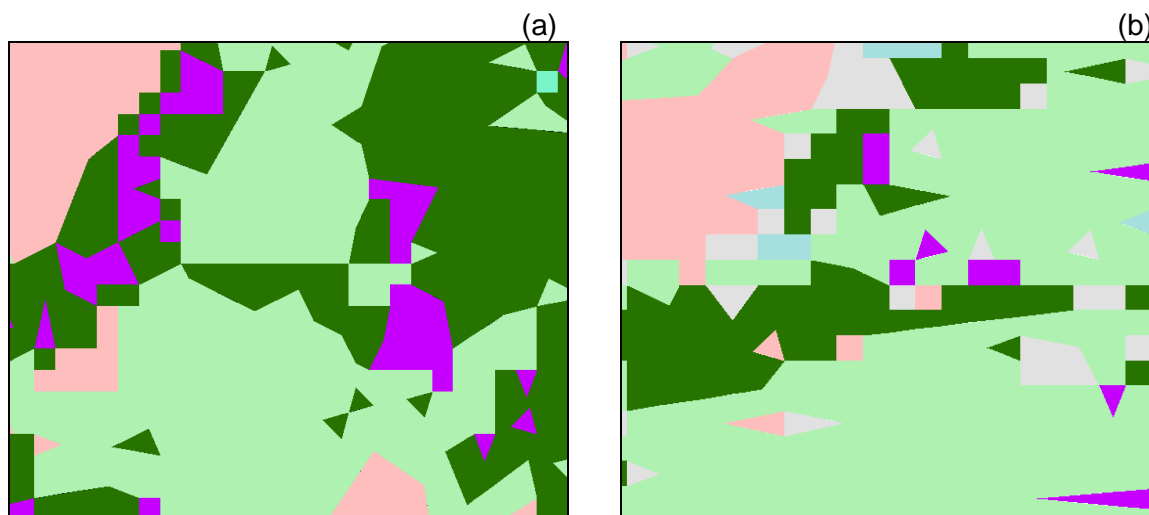


Figura 35 – Imagem da Figura 33 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com eucalipto.

5.6. Café

A classe vegetacional café (Figuras 36, 37 (a) e 37 (b)) também não foi considerada na classificação por Árvores de Decisão (Figura 38), pois não era esse um dos objetivos daquele estudo. No entanto, esta classe merece maior atenção quando se trata da cobertura vegetal do Estado de Minas Gerais e, em especial, da Zona da Mata Mineira, tendo em vista a relevância que esta cultura tem para esses locais. No caso específico de Araponga, merece destaque o fato de a região apresentar grandes áreas ocupadas com a cultura e que o produto ali colhido tem merecido excelentes premiações em concursos nacionais de qualidade. Do ponto de vista do planejamento da região, conhecer a evolução temporal dessas áreas também é relevante, pois com tais premiações verifica-se uma tendência de ampliação das áreas plantadas, com potencial risco às áreas de formações florestais.

Tendo em vista que os cafezais (Figura 36), muitas vezes, ocupam partes do relevo outrora ocupadas pelas formações florestais, é possível que alguma confusão tenha se verificado com a vegetação nativa, como pode ser analisado na Figura 37 (b) e nos dados apresentados nos Quadros 7 e 8 (matriz de erros). Embora bem organizadas espacialmente, com suas típicas ruas e fileiras, como pode ser visualizado na Figura 37 (a), as plantações de café em imagens de baixa resolução (Figura 37 (b)) acabam não sendo perceptíveis para delimitação, principalmente quando são formados por pequenas extensões.



Figura 36 – Plantio de café presente na área de estudo, Araponga (MG).




Figura 37 – Imagens (a) ÍKONOS e (b) Landsat destacando área com café.

Também em classificações automatizadas, sejam elas por Árvores de Decisão (Figura 38), MAXVER (Figura 39 (a)) ou RNA (Figura 39(b)), o resultado pode ser

afetado ainda pelo clima e outros planos de informações, como a textura e declividade, por exemplo. Fatores como altitude e relevo podem influenciar a incidência da luz solar sobre determinadas áreas, projetando sombras ou mesmo ocultando-as, ainda mais em situações onde a inclinação solar na hora da aquisição de determinada imagem esteja desfavorável. Isto embora esteja sendo descrito para essa classe também pode ocorrer com outras coberturas vegetais que se encontram localizadas em vertentes, já que ao imagear determinada área, o sensor pode não conseguir focá-las dado sua posição espacial, localizando-se no lado oposto à vertente exposta.




Figura 38 – Imagem classificada por meio da metodologia de Árvore de Decisão (CARVALHO *et al.*, 2005) com enfoque nas áreas de café.




Figura 39 – Imagem da Figura 37 (b) classificada com as metodologias (a) MAXVER e (b) RNA, destacando-se a área com café.

6. CONSIDERAÇÕES FINAIS

As propriedades estatísticas de uma classe na maioria das classificações não podem ser estimadas. Sendo assim, teoricamente, os métodos que produzem diretamente as funções de decisão por meio de dados de treinamento, como ocorrem nas RNA's, são mais efetivos e adequados. Por outro lado, as expectativas nem sempre se concretizam quando confrontados com a realidade. Os esforços para o treinamento das RNA's, por exemplo, podem não ser compensador, considerando-se as relações entre tempo, custo e benefício. A busca por ferramentas que permitam efetivar uma classificação rápida, eficiente e precisa com a realidade de campo é constante nesta metodologia, construída a partir de horas de dedicação do analista e das máquinas utilizadas.

O modelo de RNA aplicado nesse estudo foi de *perceptron* multicamadas, que segundo BRAGA *et al.* (1998), assume regiões de decisão semelhantes àquelas formadas por classificadores estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados, diferentemente ao classificador MAXVER que é estatístico. Essas redes podem ser “treinadas” (calibradas) por um algoritmo iterativo de aprendizagem, chamado *back-propation* que as habilita a desenvolver um comportamento associativo correto quando confrontados com situações de características similares, como ocorrido na aplicação desta metodologia neste trabalho.

Um dos elementos que afetou o desempenho das Redes Neurais foi a maneira como os elementos de processamento foram organizados. A opção foi adicionar neurônios e camadas ocultas à estrutura da rede, fazendo vários testes com arquiteturas e número de ciclos de processamento diferentes. Cada ciclo corresponde a um processamento completo de “vai e vem” (dados de entrada) (*back-propation*) entre as camadas apresentadas para compor a arquitetura da rede, alterando-se os valores de peso “sináptico”, automaticamente, em cada ciclo,. No final, este peso é utilizado para a decisão na detecção de uma classe durante o processamento da imagem. Neste sentido, os elementos da camada de entrada (dados de entrada) devem ser bem escolhidas e com isso, durante o treinamento, decididas as quantidades de neurônios e de camadas a serem inseridas na arquitetura da rede, na busca de um resultado mais preciso e condizente com a realidade que se busca representar. Destaca-se que o objetivo de uma classificação de imagem é particionar a mesma em classes definidas pelo usuário. No entanto, neste processo de classificação, as maiores deficiências normalmente verificadas tem sido associadas à

resolução do sensor, como é o caso das imagens Landsat utilizada no presente estudo.

Um dos grandes desafios da classificação por RNA's é a definição do número de camadas escondidas e do número de neurônios que irão compor a rede. Tal situação obriga os analistas a resolver o problema por tentativas e erros, ou pela experiência prévia no domínio de uma dada situação. Entretanto, a experiência com redes pode servir mais como guia, não servindo para aplicações generalizadas em qualquer tipo de situação.

GALO (2000) afirma que a camada de saída no método de Redes Neurais terá tantos neurônios quantas forem às classes a serem separadas, no entanto, outros autores como VIEIRA (2000), afirmam que redes menores generalizam melhor. Mas mesmo se atribuindo o mesmo número de neurônios e classes, as respostas aqui obtidas foram consideradas não satisfatórias, mesmo que o índice *Kappa* tenha sido bom. Isto indica não ser este o problema que tenha causado resultados não condizentes com a realidade de campo e sim, as escolhas e o treinamento da rede. Nas redes, para cada situação tem-se uma análise diferente e, conseqüentemente, toda a sua estrutura será diferenciada. Neste contexto, experiências previamente adquiridas são importantes para um resultado adequado quando se considera o quesito agilidade. Maior bagagem de conhecimento freqüentemente garante menos tentativas para a obtenção de um resultado satisfatório.

Ainda que a avaliação do presente estudo tenha se concentrado em apenas uma época de análise, o domínio do conhecimento demandado para isto pode ser útil para futuras avaliações na mesma área, com impactos positivos para gestão ambiental..

O objetivo final das classificações deve ser sempre buscar a representação da realidade, muito embora qualquer mapeamento temático ou imageamento da superfície da terra represente apenas um modelo estimado da mesma. Mesmo a classificação manual pode apresentar resultados satisfatórios, embora o tempo necessário para sua execução e relação custo-benefício possa não o ser. Suas chances de sucesso são dependentes de habilidade e conhecimento do analista sobre as classes delimitadas, e do conhecimento da área de estudo. Nestes casos, respostas mais condizentes com a realidade podem ser obtidas.

Qualquer que seja a classificação supervisionada, ela exige certo conhecimento *a priori* do tema a ser classificado. Para isto são necessárias visitas a campo ou o uso de informações secundárias confiáveis sobre o tema em estudo. Quando isso não ocorre, uma classificação automatizada, por exemplo, pode apresentar validações indicando uma exatidão inadequada dos seus resultados.

Mesmo que possam ser consideradas como de boa precisão, em função do elevado índice *Kappa*, como foi o caso das metodologias avaliadas neste estudo (MAXVER e RNA), as classificações apresentam alguns problemas espaciais, visto que geralmente os índices de validação como o supracitado são estatísticos e não espaciais. Mesmo que essas metodologias tenham apresentado mais de 70% de acerto estimado, verificaram-se sérios problemas de classificação da imagem de satélite utilizada.

A precisão apontada pelo índice *Kappa*, por exemplo, bem como a Matriz de Confusão (erros), são gerados a partir das amostragens selecionadas pelo analista, embora o programa, em princípio, selecione dentro das áreas delimitadas de forma aleatória, as amostras a serem avaliadas. Mas essa coleta é restrita à polígonos definidos pelo analista para cada classe que se busca e tal seleção afeta diretamente o resultado final do *Kappa*, sendo que, dentro de um mesmo procedimento de classificação, diferentes amostras levam à obtenção de distintos valores desse índice. Embora esse seja o índice mais utilizado para estudos dessa natureza, ainda é patente a necessidade da busca de outros indicadores que melhor traduzam a relação do resultado da classificação com a realidade a campo, quando se utilizam classificações automatizadas.

Alguns fatores devem ser considerados para se explicar o resultado inicial não satisfatório do MAXVER e das Redes Neurais Artificiais na classificação proposta neste estudo. A escolha da imagem, das bandas e dos planos de informações, bem como todos os procedimentos de análise desses quesitos são decisões do analista e, conseqüentemente, subjetivo e inerente ao técnico que executa a classificação. A ausência de meios que possam guiá-lo nas escolhas e na classificação por RNA é uma característica desse procedimento, o que não pode ser ignorado.

As Redes Neurais Artificiais apareceram com o intuito de melhorar a classificação supervisionada de imagens de satélite artificiais, sendo normalmente referenciadas como possuidoras de todas as condições para se atingir bons resultados. A inclusão, de outros planos de informações, sob esse aspecto, é uma de suas principais qualidades. Embora a literatura saliente melhores resultados obtidos com esse algoritmo em detrimento dos demais disponíveis, as Redes Neurais são complexas e de difícil montagem, sendo a obtenção de um resultado final satisfatório condicionada a uma correta modelagem. Ainda assim podem-se obter resultados de classificação não condizentes com a realidade, mesmo que certos índices de avaliação apontem o contrário. Apesar desses problemas, seu uso tem crescido principalmente associado à sua disponibilização em *softwares* comerciais, tais como o

ENVI, que possui forma mais bem estruturada e relativa simplicidade em sua utilização.

Os resultados aqui obtidos por meio da classificação por RNA não indicaram uma superioridade da classificação efetuada via MAXVER e a utilizada pelo MFNR-MG (árvores de decisão), como esperado. Tal resultado pode ser associado à sua complexidade e dificuldades em sua modelagem e treinamento. Caso neste estudo tivessem sido obtidos novos planos de informações, como foi o da altitude para a classe dos Campos de Altitude, os resultados possivelmente teriam sido melhores.

A avaliação da metodologia das Árvores de Decisão indicou algumas ressalvas para sua utilização. O fato de tal procedimento, ao usar uma análise Booleana, não permite que uma terceira opção de decisão seja tomada entre duas classes num mesmo *pixel*, é um complicador para sua utilização.

A proposta de conciliação de variadas metodologias com *softwares* gratuitos para a classificação da cobertura vegetal, como objetivo desse estudo, indicou várias dificuldades operacionais, principalmente na utilização da metodologia RNA. No procedimento adotado com essa técnica, a definição dos parâmetros e seu treinamento foram muito demorados e, possivelmente, a utilização de um *software* comercial tivesse facilitado seu uso. Por outro lado, os custos envolvidos, dentro da proposta de trabalho, aumentariam consideravelmente.

O método de classificação por MAXVER, por sua vez, se mostrou ágil, simples e fácil de ser executado, além de ser executado em ambiente SPRING, *software* de caráter gratuito. Caso não existam planos de informações que permitam definir com clareza determinada classe, sua utilização pode ser recomendada. Além disto, o resultado obtido com essa metodologia quase que independe do operador, diferente das RNA, para as quais se pode considerar que a responsabilidade maior de um bom resultado reside no técnico executor da classificação.

No campo da especulação sobre a utilização de diferentes técnicas, talvez a melhor opção seria, ainda que do ponto de vista teórico, um classificador que aliasse as qualidades e minimizasse as limitações dos classificadores já existentes. Uma classificação combinada aqui não foi testada, o que também poderia ter sido considerado. Neste sentido, o uso do MAXVER de uma forma geral, aliado ao uso das RNA para situação de disponibilidade de um ou mais planos de informações, seria uma alternativa a ser avaliada.

Com todos os problemas verificados, considera-se que a opção de trabalhar com imagens de sensoriamento remoto de baixa e média resolução espacial (30 e 15 metros, respectivamente), pode se mostrar adequada para a detecção da cobertura vegetal, principalmente, ao se considerar sua disponibilidade e custo de aquisição. As

imagens gratuitas do sensor Landsat acabam por ser um material com sua devida importância para o monitoramento da cobertura vegetal, embora suas limitações de resolução espacial limitem as aplicações das classificações que porventura venham a ser obtidas.

Uma das condições para o melhor uso de imagens de satélite de baixa resolução é o seu tratamento. O tratamento efetuado na imagem do sensor Landsat 5 utilizado no presente estudo foi considerado satisfatório, reduzindo em certa parte a perda de informações espaciais no *pixel* de 900 m² disponível.

Cada uma das classes analisadas neste estudo pode possuir uma formatação diferenciada no tempo, seja por interferência das condições climáticas ou pelas ações antrópicas. Assim, a avaliação de imagens de períodos diferentes é interessante em processos de classificação, o que hoje é mais fácil de ser obtido pelas ferramentas disponibilizadas pelo sensoriamento remoto. Acompanhar a evolução temporal dos limites das manchas vegetacionais e de suas modificações fitofisiológicas permite avaliar a velocidade e a forma que tais alterações se processam, o que auxilia no diagnóstico ambiental e subsidia a elaboração de políticas públicas de proteção do meio ambiente.

7. CONCLUSÕES

A comparação dos classificadores testados no presente trabalho com a metodologia adotada no Mapeamento da Flora Nativa e do Reflorestamento de Minas Gerais (MFNR-MG) indicou diferenças expressivas na quantificação das coberturas vegetacionais da área estudada, em especial quanto à formação Florestal Ombrófila, que se mostrou mais expressiva nas classificações aqui executadas (MAXVER e RNA). Embora a metodologia de RNA's seja amplamente aceita como a mais adequada para a classificação de imagens de satélites, a complexidade e o tempo demandado na preparação dos materiais, bem como os vários procedimentos de tentativa e erro requeridos para sua execução dificultam ou mesmo restringem sua utilização, principalmente na demanda comercial. Por sua vez, dada a simplicidade e os resultados alcançados, a classificação por MAXVER desponta como uma opção mais viável em muitas situações, tais como às classes que não são distinguidas por algum outro fator que não seja a reflectância da imagem utilizada. No entanto, as duas metodologias aqui testadas (RNA e MAXVER), bem como a utilizada no MFNR-MG, não apresentaram bons resultados para as duas classes de cobertura vegetal comercial pretendida neste trabalho (eucalipto e café). Esse resultado é associado principalmente a resolução baixa da imagem utilizada para efetivar as classificações neste estudo, ou seja, do sensor Landsat, mas também, as similaridades espectrais dessas classes com outras classes vegetacionais nativas.

A detecção de mudanças na cobertura e uso do solo deve envolver o emprego de conjuntos de dados para discriminar áreas imageadas em diferentes datas. Dentro desse contexto, torna-se necessário a constante necessidade de atualização de mapas para um adequado gerenciamento dos recursos naturais.

Os produtos finais desse estudo estão contidos nos diferentes mapas produzidos. No entanto, o mais buscado no decorrer desse trabalho foram respostas e uma modelagem mais similar possível à realidade que se apresenta na paisagem do município avaliado. Como resultado não apresentado na forma de produto, fica o aprendizado e o acúmulo de experiências que poderão ser aplicados em momentos futuros e em novos desafios. Uma certeza ficou demonstrada após todo esse processo: a necessidade de os órgãos de pesquisa em geotecnologias e de as universidades investirem na pesquisa e na geração de conhecimento nesta área, de forma a tornar todos esses procedimentos de classificação mais ágeis, confiáveis e obtidos a custos não proibitivos.

REFERÊNCIAS BIBLIOGRÁFICAS

- AB'SABER, A.N.. **Os Domínios de Natureza no Brasil**. 3ª edição. Cotia: Ateliê Editorial, 2005.
- AB'SABER, A. N.. **Os domínios morfoclimáticos da América do Sul**. São Paulo: Universidade de São Paulo, 1977. P. 1-22.
- ALMENTERO, B. K.; BAIÃO, F.; MATTOSO, M. L. Q.. **Avaliação do Desempenho de um Algoritmo de Árvore de Decisão usando Processamento Paralelo e Distribuição**. Disponível em <<http://clusterminer.nacad.ufrj.br/TechReport/RT04.pdf>>. Consultado em 15/11/2007.
- ARONOFF, S.. **Geographical Information Systems: A Management Perspective**. Ottawa: WDI Publications, 1989.
- AYRES, J. M.; FONSECA, G. A. B.; RYLANDS, A. B.; QUEIROZ, H. L.; PINTO, L. P.; MASTERSON, D.; CAVALCANTI, R.. **Os corredores ecológicos das florestas tropicais do Brasil**. Belém, PA: Sociedade Civil Mamirauá, 2005. 256p. Disponível em <<http://www.conservation.org.br/publicacoes/files/CorredoresEcologicos.pdf>>. Consultado em 13/12/2007.
- BARBOSA, M. R. V. & THOMAS, W. W.. **Biodiversidade e uso sustentável da Mata Atlântica no nordeste**. In: ARAÚJO, E.L.; MOURA, A.N.; SAMPAIO, E.V.S.B.; GESTINARI, L.M.S. & CARNEIRO, J.M.T (eds.). Biodiversidade, Conservação e Uso Sustentável da flora do Brasil. Recife: UFRPE/Imprensa Universitária. 2002. P. 19-22.
- BATISTA, G. T.; NELSON, W. D.; CASTRO, R. M.; MOREIRA, R. C.. Análise espectral comparativa entre coberturas florestais de essências nativas e exóticas utilizando o sensor aerotransportado hiperespectral HSS (do visível ao infravermelho termal). In: XIII Simpósio Brasileiro de Sensoriamento Remoto, 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. P.6423-6430.
- BENITES, V.M.; CAIAFA, A. N.; MENDONÇA, E. de Sá; SCHAEFER, C. E. & KER, J. K.. Solos e vegetação nos complexos rupestres de altitude da Mantiqueira e do Espinhaço. **Floresta e Ambiente**. V. 10, n.1, p. 76-75, jan/jul 2003.
- BERGAMINI, C. M.; ARAÚJO, P. V.; MOTTER, G.. **Modelos de aprendizagem de máquina na classificação de caracteres manuscritos**. *Synergismus scyentifica*. Pato Branco: UTFPR, 2006. P. 338-348. Disponível em <<http://pessoal.pb.cefetpr.br/eventocientifico/revista/artigos/0603013.pdf>>. Consultado em 20/01/2008.
- BITTENCOURT, H. R.. **Reconhecimento Estatístico de Padrões: O Caso da Discriminação Logística Aplicada a Classificação de Imagens Digitais Obtidas por Sensores Remotos**. In: Congresso Brasileiro de Computação: Brasil, 2001.
- BOLFE, E. L.; PEREIRA, R. S.; MADRUGA, P. R. A.; FONSECA E. L.. **Avaliação da classificação digital de povoamentos florestais em imagens de satélite através de índices de acurácia**. Viçosa: Revista Árvore, v.28, n.1, 2004. P.85-90.
- BRAGA, A. P.. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: DCC/IM, COPPE/ Sistemas, NCE/UFRJ, 1998.
- BRAZDIL, P.. Construção de Modelos de Decisão a partir de dados. 1999. In: SHIBA, M. H.; SANTOS, R. L.; QUINTANILHA, J. A.. **Classificação de imagens de sensoriamento remoto pela aprendizagem por árvore de decisão: uma avaliação de desempenho**. Disponível em: <<http://martedpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.23.11.44/doc/4319.pdf>>. Consultado em 19/10/2007.
- BRITES, R. S. **Verificação de exatidão em classificação de imagens digitais orbitais: efeito de diferentes estratégias de amostragem e avaliação de índices de exatidão**. Viçosa: Universidade Federal de Viçosa, 1996. 101p. (Tese Doutorado)

- BROWN, Jr., K.S.. **Conclusions, synthesis, and alternative hypothesis.** In: Biogeography and quaternary history in tropical Americas. Clarendon Press. Reino Unido: Oxford, 1987. P. 175-196.
- CAIAFA, A. N. **Composição florística e estrutura da vegetação sobre um afloramento rochoso no Parque Estadual da Serra do Brigadeiro, MG.** Viçosa: Universidade Federal de Viçosa, 2002. 55p. (Dissertação Mestrado)
- CÂMARA, G.; SOUZA, R.C. M.; FREITAS, U. M.; GARRIDO, J.. **SPRING: Integrating remote sensing and GIS with object-oriented data modeling.** Computers and Graphics, v.20, 1996. P.395-403.
- CAMPBELL, J. B. **Introduction to Remote Sensing.** 2d ed. New York: Guilford Press. 1996.
- CAMPOLINA, A. G.; CICONELLI, R. M.. **Qualidade de vida e medidas de utilidade: parâmetros clínicos para as tomadas de decisão em saúde.** Rev. Panam. Salud Publica. v. 19, 2006. P. 128-136. Disponível em: <http://www.scielo.org/scielo.php?script=sci_arttext&pid=S1020-49892006000200013&lng=pt&nrm=iso>. Consultado em 05/02/2008.
- CAMPOS FILHO, P.. **Método para apoio à decisão na verificação da sustentabilidade de uma unidade de conservação, usando lógica Fuzzy.** Florianópolis: Universidade Federal de Santa Catarina, 2004. 211 p. (tese doutorado)
- CARVALHO, L. M. T.; SCOLFORO, J. R. S.; OLIVEIRA, A. D.; MELLO, J. M.; OLIVEIRA, L. T.; ACERBI Jr., F. W.; CAVALCANTI, H. C.; FILHO, R. V.. **Mapeamento e Inventário da Flora Nativa e dos Reflorestamentos do Estado de Minas Gerais.** Lavras: UFLA, 2005. 88 p.
- CARVALHO, M. F.; PINA, M. F.; SANTOS, S. M.. **Conceitos Básicos de Sistemas de Informação Geográfica e Cartografia Aplicados à Saúde.** 1. ed. Brasília: OPS/Ministério da Saúde, 2000. 124 p.
- CARVALHO, M.M.. **Arborização de pastagens cultivadas.** Juiz de Fora: EMBRAPA-CNPGL. Documentos, 64, 1998. 37 p.
- COHEN J. **A coefficient of agreement for nominal scales.** Durham: Educational and Psychological Measurement, v.20,1960. P. 37-46.
- COLINVAUX, P.. **Ecology.** Nova York: Wiley, 1993. 688p.
- CONGALTON, R. G.; MEAD R. A. **A review of assessing the accuracy of classifications of remote sensed data.** New York: Remote Sensing of Environment, v.37, n.1, 1991. P.35-46.
- CONSELHO NACIONAL RESERVA DA BIOSFERA DA MATA ATLÂNTICA. **Conceitos e abrangência.** Disponível em: <http://www.rbma.org.br/anuario/mata_02_dma.asp>. Consultado em 19/04/2008.
- COUTINHO, L. M. **O conceito de bioma.** São Paulo: Acta Botanica Brasileira, 2005.
- COUTINHO, A. C.. **Segmentação e classificação de imagens Landsat-TM para o mapeamento dos usos da terra na região de Campinas, SP.** São Paulo: USP, 1997. (Dissertação de Mestrado)
- CRÓSTA, A. P.. **Processamento Digital de Imagens de Sensoriamento Remoto.** Campinas: UNICAMP, 1993.
- CRUS, N. C.da & GALO, M. L. B. T.. **Aplicação de redes neurais artificiais na classificação de imagens multitemporais e multisensor.** III Colóquio Brasileiro de Ciências Geodésicas. São Paulo: UNESP, 2003.
- ENGESAT: **Ficha técnica resumida do sensor áster.** Disponível em: <<http://www.engesat.com.br/?system=news&action=read&id=529>>. Consultado em 14/07/2008.
- FIGUEIREDO, S. M. de M.; CARVALHO, L. M. T.. **Análise comparativa entre técnicas de classificação digital em imagens Landsat no mapeamento do uso e ocupação**

- do solo em Capixaba. **Anais...** Florianópolis: XIII Simpósio Brasileiro de Sensoriamento Remoto, 2007. P. 6729-6736.
- FLEMING, M.D. & HOFFER, R.M.. **Machine processing of Landsat MSS data and DMA topographic data for forest cover type mapping.** In: Machine Processing of Remotely Data Symposium. West Lafayette: West Lafayette: Purdue University, 1979. P. 377-390.
- FLORENZANO, T.G.. **Imagens de Satélites para Estudos Ambientais.** São Paulo: Oficina de Textos, 2002. 97p.
- FRANÇA, M. M.. **Avaliação de classificações supervisionadas com Redes Neurais Artificiais e MAXVER para caracterização do uso da terra no município de Viçosa-MG.** Viçosa: Universidade Federal de Viçosa, 2008. (Monografia)
- FUNDAÇÃO BIODIVERSITAS. **Mapa dos Tipos Vegetacionais.** Belo Horizonte: BIODIVERSITAS, 2000.
- GALO, M. L. B. T. Aspectos relacionados com o fenômeno de mistura espectral e ambiguidade na classificação usando redes neurais artificiais. **Anais.** Presidente Prudente: Simpósio Brasileiro de Geomática, 2002. P. 150-161. (Meio digital).
- GALO, M. L. B. T.. **Aplicação de redes Neurais Artificiais e Sensoriamento Remoto na Caracterização Ambiental do Parque Estadual Morro do Diabo.** São Carlos: Escola de Engenharia de São Carlos da Universidade de São Paulo, 2000. (Tese de Doutorado).
- GURGEL, H. da C.. **Variabilidade espacial e temporal do NDVI sobre o Brasil e suas conexões com o clima.** São José dos Campos: INPE, 2003.
- HOLSHEIMER, M. & SIEBES, A.. **Data Mining: the search for knowledge in databases.** 1994. Disponível em: <<http://portal.acm.org/citation.cfm?id=869322&coll=GUIDE&dl=GUIDE&CFID=81313913&CFTOKEN=84251927>>. Consultado em 04/03/2008.
- INGARGIOLA, G.. **Building Classification Models: ID3 and C4.5.** Disponível em: <<http://www.cis.temple.edu/~ingargio/cis587/readings/id3-c45.html>>. Consultado em 15/05/2008.
- INSTITUTE FOR PARALLEL AND DISTRIBUTED HIGH PERFORMANCE SYSTEMS. **Software livre Stuttgart Neural Network Simulator – SNNS:** simulador de Redes Neurais. *Universidade de Stuttgart.* Disponível em: <<http://www.cs.cmu.edu/afs/cs/project/ai-repository/ai/areas/neural/systems/snns/>>. Consultado em 30/01/2008.
- IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Mapa de Biomas e de Vegetação.** Rio de Janeiro: Fundação Instituto Brasileiro de Geografia e Estatística, 2004.
- IBGE. **Coordenação de Contas Nacionais de 2007.** Disponível em: <<http://www.ibge.gov.br/cidadesat/xtras/perfilwindowat.php?codmun=310370>>. Consultado em 03/06/2008.
- IBGE. **Manual técnico da vegetação brasileira.** Rio de Janeiro: Fundação Instituto Brasileiro de Geografia e Estatística, 1992. 92p.
- IBGE. **Mapa de vegetação do Brasil.** Rio de Janeiro: Fundação Instituto Brasileiro de Geografia e Estatística, 1993.
- KLEIN, R. M.. **Aspectos dinâmicos da vegetação do sul do Brasil.** Sellowia, 1984. P. 5-54.
- JENSEN, J. R. Introductory digital image processing: a remote sensing perspective. 2.ed. New Jersey: Prentice Hall, 1996. 316p.
- KALENSKY, Z.; SCHERK, L. R.. **Accuracy of forest mapping from Landsat computer compatible tapes.** In: International Symposium on Remote Sensing 'of Environment. Michigan: Environment Research Institute of Michigan, v. 2, 1975. p. 1159.

- KRAMER, H.J.. **Observation of the Earth and its Environment. Survey of Missions and Sensors**. Springer. 3rd. Berlin: Edition, 1996. 960p.
- KHOURY JR. J.K. **Desenvolvimento e avaliação de um sistema de visão artificial para classificação de madeira serrada de eucalipto**. Tese de Doutorado. Viçosa, UFV,2004.
- LANDGREBE, D.A.. **Multispectral land sensing: where from, where to?**. In: IEEE Transactions on Geoscience and Remote Sensing. IEEE Geoscience and Remote Sensing. Society of America, Piscataway: New Jersey, USA, 2005. P. 414 - 421.
- LEE, Y. J.; OSWALD, E. T. & HARRIS, J. W. E.. **A preliminary evaluation of ERTS imagery for forest-land management in British Columbia**. In: Canadian Symposium on Remote Sensing. Ottawa: Proceedings... v.1, p.87, 1974.
- LEITE, MARCELO. **Suspense Amazônico – a nota do INPE**. Disponível em: <http://cienciaemdia.folha.blog.uol.com.br/arch2008-07-27_2008-08-02.html>. Consultado em 15/08/2008.
- LILLESAND, T. M., KIEFER, R. W.; Remote sensing and image interpretation. 2.ed. Chichester: John Wiley & Sons, 1994. 750p.
- LIU, W.T.H.. **Aplicações de sensoriamento remoto**. Campo Grande: Ed. UNIDERP, 2006. P. 215 – 242.
- LNCC - LABORATÓRIO NACIONAL DE COMPUTAÇÃO CIENTÍFICA. **Tutorial de Redes Neurais Aplicações em Bioinformática**. Disponível em <http://www.lncc.br/~labinfo/tutorialRN/frm4_backpropagation.htm>. Consultado em 22/10/2008.
- MANTOVANI, W.. **Delimitação do Bioma Mata Atlântica: implicações legais e conservacionista**. In: Ecossistemas brasileiros: Manejo e Conservação. Editora Expressão Gráfica, 2003. 392p.
- MASRY, S.E.; & McLAREN, R.A.. **Digital map revision**. Photogrammetric Engineering and Remote Sensing, . v.45, n.2, 1979. P.183-200.
- MILLER, L.D.; NUALCHAWEE, K.; TOM, C.. **Analysis of dynamics of shifting cultivation in the tropical forests of northern Thailand using landscape modeling and classification of Landsat imagery**. Maryland: NASA, 1978. 19p.(Technical Memorandum).
- MINISTÉRIO DO MEIO AMBIENTE. **Decreto nº 750, de 10 de fevereiro de 1993**. Disponível em <http://www.ibama.gov.br/flora/decretos/750_93.pdf>. Consultado em 19/03/2008.
- MMA – MINISTÉRIO DO MEIO AMBIENTE. **Proposta Projeto Mata Atlântica**. Brasília: Secretaria de Biodiversidade e Florestas, 2004. Disponível em <http://www.rbma.org.br/anuario/pdf/projeto_mata_atlantica.pdf>. Consultado em 09/10/2007.
- MOREIRA, M. A.. **Fundamentos de Sensoriamento Remoto**. São José dos Campos-SP: INPE, 2001.
- MOREIRA, M.A.. **Fundamentos de sensoriamento remoto e metodologias de aplicação**. Viçosa: Universidade Federal de Viçosa, 2003. P.195-204.
- OLIVEIRA-FILHO, A. T. e FONTES, A. L.. **Patterns of floristic differentiation among Atlantic Forests in Southeastern Brazil and the influence of climate**. Biotropica, 2000. P. 793-810.
- OLIVEIRA-FILHO, A.T. e FLUMINHAN-FILHO, M.. **Ecologia da vegetação do Parque Florestal Quedas do Rio Bonito**. Lavras: Cerne, 1999. V.5, N.2. P. 51-64.
- PEIXOTO, A. L. e GENTRY, A. **Diversidade e composição florística da mata de tabuleiro na Reserva Florestal de Linhares - ES, Brasil**. São Paulo: Revista Brasileira de Botânica 13, 1990. P.19-25.

- PICHILIANI, M.. **Data mining na prática: Árvores de Decisão.** Disponível em <http://imasters.uol.com.br/artigo/5130/sql_server/data_mining_na_pratica_arvores_de_decisao/>. Consultado em 22/10/2008.
- QUEIROZ; R. B.; SEVERINO; P. A. da R; RODRIGUES; A. G.; GÓMEZ; A. T.. **Redes Neurais: Um comparativo com Máxima Verossimilhança Gaussiana na Classificação de Imagens CBERS 1.** II Workshop de Tecnologia da Informação aplicada ao Meio Ambiente, 2004.
- RENNÓ, C. D.. **Avaliação das Incertezas nas Classificações de Máxima Verossimilhança e Contextual de Modas Condicionais Iterativas em Imagens Jers na Região de Tapajós, Estado do Pará.** São José dos Campos: INPE, 1998.
- RIBEIRO, J. F.; WALTER, B. M. T.. **Fitofisionomias do Bioma Cerrado.** In: SANO, S. M. & ALMEIDA, S. P. de (org.). Cerrado: ambiente e flora. C Planaltina: Embrapa-CPA, 1998. P.89-166.
- RIBEIRO, R. J. da C.; BAPTISTA, G. M. de M.; BIAS, E. de S.. Comparação dos métodos de classificação supervisionada de imagem Máxima Verossimilhança e Redes Neurais em ambiente urbano. **Anais... XVIII Simpósio Brasileiro de Sensoriamento Remoto.** Florianópolis: INPE, 2007. 3p..
- RICHARDS, J.. **Analysis of remotely sensed data: the formative decades and the future.** In: IEEE Transactionns on Geoscience and Remote Sensing. IEEE Geoscience and Remote Sensing. New Jersey/USA: Society of America, Piscataway, 2004. P. 422-432.
- RIZZINI, C. T. **Tratado de fitogeografia do Brasil, aspectos ecológicos, sociológicos e florísticos.** Rio de Janeiro: Âmbito Cultural Edições, 1997.
- RIZZINI, C. T.. **Tratado de fitogeografia do Brasil: aspectos sociológicos e florísticos.** São Paulo: HUCITEC, v.2, 1979. 374p.
- ROSA, R.. **Geotecnologias na Geografia Aplicada.** Revista do Departamento de Geografia. Universidade Federal de Uberlândia: Uberlândia, 2005. P. 81-90.
- RUSCHI, A. **Fitogeografia do Estado do Espírito Santo: Considerações gerais sobre a distribuição da flora do Estado do Espírito Santo.** Santa Tereza: Boletim do Museu de Biologia Mello Leitão, 1950. P. 1-353.
- RUSSEL, S. & NORVIG, P.. **Inteligência Artificial.** Rio de Janeiro : Campus, 2004.
- SHIBA, M.H.; SANTOS, R. L.; QUINTANILHA, J. A.; KIM, H. Y.. Classificação de imagens de sensoriamento remoto pela aprendizagem por árvore de decisão: uma avaliação de desempenho. **Anais... XII Simpósio Brasileiro de Sensoriamento Remoto.** Goiânia/Brasil: INPE, 2005. P. 4319-4326.
- SILVA, L. I. L. da; BASTOS, M. T.; MANTEGA, G.; SILVA, M. & COSTA, A. A. R.. **LEI Nº 11.428, de 22 de dezembro de 2006.** Brasília: Congresso Nacional, 2006.
- SOS MATA ALÂNTICA. **Atlas da evolução dos remanescentes florestais e ecossistemas associados ao domínio Mata Atlântica no período de 1985-1990.** São Paulo: Fundação SOS Mata Atlântica & INPE, 1993.
- SOUZA, C.C.; MOREIRA, A. de A.; SCHIMITH, R. S.; BRANDÃO, P. C.; SILVA, E.. **Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil – uma revisão bibliográfica.** Santa Maria: Ciência Florestal, v. 17, n. 4, 2007. P. 409-417.
- STEFFEN, C. A.. **Introdução ao Sensoriamento Remoto.** Disponível em <<http://www.herbario.com.br/fotomicrografia07/inntrodsensoramentoremoto.htm>>. Acessado em 04/09/2008.
- TESCHE, T.W. & BERGSTROM, R.W.. **Use of digital terrain data in meteorological and air quality modeling.** Photogrammetric Engineering and Remote Sensing, 1978. V.44, n.12,. P.1549-1559.

- TONHASCA Jr., A.. **Ecologia e história natural da Mata Atlântica**. Rio de Janeiro: Interciência, 2005.
- VELOSO, H. P.; RANGEL FILHO, A L.R.; LIMA, J. C. A.. **Classificação da Vegetação Brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991.
- VIEIRA, C. A. O.. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. Nottingham: University of nottingham, 2000. 352p.. (thesis Doctor of Philosophy)
- WALTER, H.. **Vegetação e Zonas Climáticas**. São Paulo: E.P.U. Ltda, 1986.
- WWF-BRASIL. **Flora na Ecorregião da Serra do Mar**. Disponível em <http://www.rbma.org.br/anuario/mata_06_smar_asp_bio_flora.asp>. Acessado em 15/05/2008.
- YANG, X.. **Use of thematic mapper imagery with a geographic information system for geomorphologic mapping in a large detars lowland environment**. London: International Journal of Remote Sensing, Taylor & Francis Ltda, 1999. P.659-681.
- ZULLO Jr.,J. **Correção Atmosférica de Imagens de Satélite e Aplicações**. (Tese de Doutorado). Campinas: UNICAMP, 1994. 190p.