

EDGLEY PEREIRA DA SILVA

**GEOPROCESSAMENTO NA DISCRIMINAÇÃO DE PASTAGENS  
DEGRADADAS UTILIZANDO REDE NEURAL ARTIFICIAL EM  
IMAGEM IKONOS II**

Tese 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 *Doctor Scientiae*.

VIÇOSA  
MINAS GERAIS - BRASIL  
2006

EDGLEY PEREIRA DA SILVA

**GEOPROCESSAMENTO NA DISCRIMINAÇÃO DE PASTAGENS  
DEGRADADAS UTILIZANDO REDE NEURAL ARTIFICIAL EM  
IMAGEM IKONOS II**

Tese 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 *Doctor Scientiae*.

APROVADA: 25 de agosto de 2006.

---

Prof. Elpídio Inácio Fernandes Filho  
(Co-Orientador)

---

Prof. Dilermando Miranda da Fonseca  
(Co-Orientador)

---

Prof. José Marinaldo Gleriani

---

Prof. José Alexandre Melo Demattê

---

Prof. Reinaldo Bertola Cantarutti  
Orientador

*A meus queridos pais Egídio Apolinário da Silva (in memoriam) e Maria Auxiliadora Pereira da Silva e aos meus irmãos Tânia, Auxileide, Simonete, Clodoaldo e Petrônio.*

Dedico

## AGRADECIMENTOS

A Deus, onipotente, criador de todas as coisas, Senhor de meus passos. Dele emana toda a energia que me fortalece, que me faz vencer, derramar lágrimas e chorar de alegria.

A Nossa Senhora, rainha da paz, bendita entre as mulheres. Luz do meu caminho, doçura plena, esperança de vida e advogada dos homens.

Ao professor Reinaldo Bertola Cantarutti, pela orientação séria, criteriosa e paciente, sobretudo pela confiança depositada e incentivo durante as diferentes fases de desenvolvimento deste trabalho.

Ao professor Elpídio Inácio Fernandes Filho, pelo apoio e estímulo.

À Universidade Federal de Viçosa - UFV pela oportunidade oferecida para a realização do Curso.

Ao CNPq pela concessão de bolsa de estudo.

Ao professor Dilermando Miranda da Fonseca pelas valiosas sugestões.

Aos professores Vicente Paulo Soares e José Marinaldo Gleriani pela preciosa atenção dispensada.

Ao professor José Alexandre Demattê, pelas críticas e correções.

Ao Departamento de Solos e Nutrição de plantas da UFV, professores e funcionários pelo carinho e amizade.

A todas as pessoas e amigos que contribuíram para a realização deste trabalho em especial a Rafael Mendes Pereira pelo companheirismo e a Roseli Freire de Melo, Eliana de Souza, Eliane Clemente, Ademilso Sampaio, Marcos Antônio e Elton Valente pela preciosa amizade.

Aos colegas de pós-graduação.

## BIOGRAFIA

EDGLEY PEREIRA DA SILVA, filho de Egídio Apolinário da Silva e Maria Auxiliadora Pereira da Silva, nasceu em 20 de setembro de 1973, no município de Esperança, Paraíba.

Graduou-se pela Universidade Federal da Paraíba, em setembro de 1999. Premiado no VII Encontro de Iniciação Científica (Prêmio Jovem Pesquisador) com o trabalho "Levantamento integrado dos recursos naturais de parte da região homogênea de Sousa-PB, utilizando técnicas de sensoriamento remoto e Sistema de Informação Geográfica" decorrente do projeto de Iniciação Científica desenvolvido sob a orientação do professor Leonaldo Alves de Andrade.

Em agosto de 2002, concluiu o curso de Mestrado em Engenharia Agrícola, com área de concentração em Irrigação e Drenagem, linha de pesquisa: Sensoriamento remoto sob a orientação do Professor Marx Prestes Barbosa, desenvolvendo a dissertação "Estudo na vulnerabilidade sócioeconômico-ambiental e dos riscos a desastre ENOS (El Niño Oscilação Sul) no município de Picuí – Paraíba: um estudo de caso".

Iniciou o curso de Doutorado em Março de 2003, na Universidade Federal de Viçosa, sob a Orientação do Professor Reinaldo Bertola Cantarrutti desenvolvendo a tese "Geoprocessamento no mapeamento de pastagens, utilizando rede neural artificial em imagem Ikonos", com defesa em 25 de agosto/2006.

## CONTEÚDO

LISTA DE FIGURAS.....	vi
LISTA DE QUADROS.....	vii
RESUMO.....	ix
ABSTRACT.....	xi
INTRODUÇÃO GERAL.....	1
<b>CAPÍTULO I – TÉCNICAS DE GEOPROCESSAMENTO NO DIAGNÓSTICO DE PRODUTIVIDADE DAS PASTAGENS, UTILIZANDO IMAGEM IKONOS</b>	
<b>RESUMO.....</b>	<b>3</b>
<b>1. INTRODUÇÃO.....</b>	<b>4</b>
<b>2. MATERIAL E MÉTODO.....</b>	<b>11</b>
2.1. Aspectos fisiográficos e climáticos da área de estudo.....	11
2.2. Alocação e caracterização das parcelas de observação.....	14
2.3. Trabalho de campo.....	15
2.4. Imagem do satélite Ikonos II.....	17
2.5. Processamento da imagem.....	18
<b>3. RESULTADOS E DISCUSSÃO.....</b>	<b>22</b>
3.1. Caracterização física do ambiente da área de estudo.....	22
3.1.2. Caracterização das pastagens.....	26
3.2. Avaliação da degradação de pastagem.....	26
3.3. Discriminação de espécies forrageiras cultivadas.....	33
3.4. Uso e Cobertura do solo.....	35
3.5. Modelo Digital de Elevação – MDE.....	40
<b>4. CONCLUSSÕES.....</b>	<b>41</b>
<b>5. REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>42</b>
<b>CAPÍTULO II - AVALIAÇÃO DA REDE NEURAL ARTIFICIAL NO MAPEAMENTO DE PASTAGEM EM DIFERENTES ESTÁGIOS DE DEGRADAÇÃO</b>	
<b>RESUMO.....</b>	<b>46</b>
<b>1. INTRODUÇÃO.....</b>	<b>47</b>
<b>2. MATERIAL E MÉTODO.....</b>	<b>54</b>
2.1. Localização e caracterização da área.....	54
2.2. Imagem do satélite.....	54
2.3. Trabalho de campo.....	55
2.4. Classificação da imagem.....	55
2.5. Coleta das amostras de treinamento e validação para processamento da rede neural .....	56
2.5.1. Separação de classes de solos expostos usando rede neural...	58
<b>3. RESULTADOS E DISCUSSÃO.....</b>	<b>60</b>
3.1. Análise quantitativa.....	60
3.2. Análise qualitativa.....	63
3.3. Quantificação do solo exposto e cobertura vegetal das pastagens.....	68
<b>4. CONCLUSÕES.....</b>	<b>72</b>
<b>5. REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>73</b>
<b>CONCLUSÕES GERAIS.....</b>	<b>75</b>
<b>APÊNDICE.....</b>	<b>76</b>

## LISTA DE FIGURAS

Figura 1	Integração entre sensoriamento remoto e sistema de informação geográfica (SIG).....	7
Figura 2	Representação dos planos de informação em um Sistema de Informação Geográfica.....	8
Figura 3	Localização do município de João Pinheiro, com destaque da área de estudo, vista pela imagem do satélite Ikonos II.....	11
Figura 4	Mapa de solos semidetalhado de parte da Fazenda São Geraldo, no município de João Pinheiro, MG. Fonte: AGRO-AMBIENTAL ASSESSORIA, na escala de 1:40.000, em 2004.....	13
Figura 5	Mapa da área da imagem com indicação dos pontos de correlação empregados na correlação das parcelas.....	16
Figura 6	Imagem Ikonos II obtida em 14 de abril/2005 de uma área de 100 km <sup>2</sup> da Fazenda São Geraldo localizada no município de João Pinheiro, MG.....	17
Figura 7	Imagem do satélite Ikonos II em sua composição 1B2G3R (A) e 1B2G4R.....	20
Figura 8	Micromorfologia das amostras indeformadas na confecção de lâminas delgadas obtida pelo método proposto por Jongerius & Heintzberger (1963), utilizando resina de poliéster na impregnação. (A) cerrado, (B) pastagem com nula degradação, (C) pastagem com, baixa degradação, (D) pastagem com média degradação e (E) pastagem com intensa degradação.....	23
Figura 9	Condutividade hidráulica do solo em diferentes coberturas vegetais: cerrado (1); pastagem com nula degradação (2); pastagem com baixa degradação (3); pastagem com média degradação (4) e pastagem com intensa degradada (5) Para cada profundidade barras seguida por mesma, letra às médias não diferiram pelo teste de a Tukey a 5 %.....	24
Figura 10	Matéria seca acumulada (A) e cobertura vegetal (B). Pastagem com nula degradação (1); pastagem com baixa degradação (2); pastagem com média degradação (3) e pastagem com intensa degradação (4) Linhas verticais correspondem ao desvio padrão.....	26
Figura 11	Mapa das classes de degradação das pastagens, obtida pela interpretação visual da Imagem Ikonos de uma área de 100 km <sup>2</sup> , na fazenda São Geraldo, município de João Pinheiro, MG, obtida em 14 de abril/2005.....	28
Figura 12	Fotos e imagens de pastagem com estágios de degradação, pastagem produtiva (A), pastagem com baixa degradação (B), pastagem com média degradação (C) e pastagem degradadas (D).....	30
Figura 13	Mapa das classes de gramíneas presentes nas pastagens, obtida pela interpretação visual da Imagem Ikonos de uma área de 100 km <sup>2</sup> , na fazenda São Geraldo, município de João Pinheiro, MG, obtida em 14 de abril/2005.....	34
Figura 14	Mapa de uso e cobertura do solo, obtida pela interpretação visual da Imagem Ikonos de uma área de 100 km <sup>2</sup> , na fazenda São Geraldo, município de João Pinheiro, MG, obtida em 14 de abril/2005.....	36
Figura 15	Imagem Ikonos, perfil e descrição das diferentes coberturas vegetais na Fazenda São Geraldo, município de João Pinheiro-MG.....	38

Figura 16	Modelo Digital de Elevação – MDE, obtido a partir da base cartográfica da Fazenda São Geraldo com equidistância das curvas de nível de 5 metros em escala de 1:25:000, 1999.....	40
Figura 17	Princípio de método por máxima verossimilhança.....	50
Figura 18	Organização da rede neural artificial em camadas.....	51
Figura 19	Imagem Ikonos II, de parte da Fazenda São Geraldo localizada no município de João Pinheiro, MG, obtida em 14 de abril/2005.....	55
Figura 20	Representação gráfica da Rede Neural Artificial utilizada com 4 neurônios na camada de entrada, 23 neurônios na camada oculta e 7 neurônios na camada de saída e suas conexões, como se apresenta no software JavaNNS.....	58
Figura 21	Recortes extraídos das áreas de pastagem com diferentes intensidades de degradação para serem classificadas pela RNA.....	59
Figura 22	Imagem temática resultante da classificação pelo método de Máxima Verossimilhança – MaxVer, filtrada.....	64
Figura 23	Imagem temática resultante da classificação pelo método Rede Neural Artificial– RNA, filtrada.....	65
Figura 24	Imagem temática resultante da classificação pelo método ISODATA, filtrada.....	66
Figura 25	Imagem temática da cobertura do solo em pastagem – produtiva (A); com baixa degradação (B); com forte degradação (C) e degradada (D), resultante da aplicação da RNA. Recorte da imagem Ikonos (1), imagem temática (2) e imagem temática filtrada (3).....	71

## LISTA DE QUADROS

Quadro 1	Área e distribuição relativa dos principais classes de solos encontrados na área de estudo.....	12
Quadro 2	Caracterização do estado de degradação de pastagens segundo critérios adaptados de Spain & Gualdrón (1988).....	14
Quadro 3	Características das bandas do satélite Ikonos.....	18
Quadro 4	Valores do índice Kappa (K) utilizados.....	21
Quadro 5	Densidade do solo e de partículas, macro e microporosidade e porosidade no solo da mata e de pastagens com diferentes intensidades de degradação.....	22
Quadro 6	Características químicas de amostras coletadas de 0 a 20 cm do solo de diferentes cobertura vegetal.....	25
Quadro 7	Área e distribuição relativa das classes de uso do solo, na fazenda São Geraldo, município de João Pinheiro, MG, estimadas a partir da interpretação visual de imagem Ikonos II, capturada em 14 de abril de 2004.....	29
Quadro 8	Classes de uso da terra e características descritivas observadas na imagem do satélite Ikonos II.....	32

Quadro 9	Área ocupada e distribuição relativa das forrageiras cultivadas nas pastagens, na Fazenda São Geraldo, município de João Pinheiro, MG, estimadas por meio da imagem Ikonos II, capturada em 14 de abril de 2004.....	33
Quadro 10	Ocupação por diferentes classes de uso e cobertura vegetal natural na área coberta pela imagem Ikonos II.....	35
Quadro 11	Índices Kappa, suas variâncias e valores de Z, para cada método de classificação testado.....	61
Quadro 12	Matriz de confusão gerada pelo algoritmo método MaxVer e proporção de acerto para cada classe.....	62
Quadro 13	Matriz de confusão gerada pela rede neural artificial e proporção de acerto para cada classe.....	62
Quadro 14	Matriz de confusão gerada pelo método ISODATA.....	63
Quadro 15	Distribuição em percentagem das classes de uso, obtida pela aplicação dos métodos de classificação.....	67
Quadro 16	Índices Kappa, suas variâncias e valores de Z, aplicado a diferentes produtividade de pastagem na classificação de solo exposto e cobertura vegetal pelo método RNA.....	68
Quadro 17	Matriz de confusão gerada pela RNA para as classes solo exposto e cobertura vegetal nas diferentes categorias de pastagens.....	69
Quadro 18	Cobertura vegetal e proporção de solo exposto em pastagens com diferentes graus de degradação estimada a partir da classificação realizada pelo algoritmo RNA.....	70

## RESUMO

SILVA, Edgley Pereira da, D.S., Universidade Federal de Viçosa, agosto de 2006. **Geoprocessamento na discriminação de pastagens degradadas utilizando rede neural artificial em imagem Ikonos II.** Orientador: Reinaldo Bertola Cantarutti. Co-orientadores: Elpídio Inácio Fernandes Filho e Dilermando Miranda da Fonseca.

A pecuária brasileira atingiu a partir da década de 60, uma crescente expansão e conseqüentemente um aumento em áreas pastagem. Todavia, a perda gradual da capacidade produtiva destas pastagens após alguns anos, tem sido uma constante, principalmente em áreas de exploração extensivas. A recuperação de pastagens degradadas é de difícil implementação devido à falta de informações atualizadas e detalhadas a respeito da sua distribuição espacial. A utilização do sensoriamento remoto por ser uma tecnologia cujos dados podem ser obtidos a baixo custo, com repetitividade e numa escala compatível com a dimensão do problema, pode contribuir em muito para a solução deste problema. A área de estudo localiza-se no município de João Pinheiro, noroeste do estado de Minas Gerais, abrangendo uma área de 100 km<sup>2</sup>. Os objetivos deste estudo foram: a) diagnosticar e quantificar a área quanto aos sistemas de uso e quanto ao estágio de produtividade das pastagens e b) aplicar métodos de classificação automática em imagem de alta resolução utilizando Redes Neurais Artificiais. Foi utilizada imagem do satélite Ikonos II com resolução espacial de um m. A exatidão do mapeamento foi verificada utilizando-se o índice Kappa. A interpretação visual da imagem e trabalho de campo possibilitou a identificação de pastagens nas seguintes categorias de degradação: nula degradação, baixa degradação, média degradação e intensa degradação. As pastagens presentes na área eram predominantemente de *Brachiaria brizantha* (1.693 ha), *Andropogon gayanus* (192 ha) e *Panicum maximum* (231 ha). De acordo com o índice Kappa, a classificação visual de imagem Ikonos II tem alto potencial para diagnosticar a produtividade das pastagens. As técnicas de classificação em imagens Ikonos II, mostraram-se eficientes na discriminação dos níveis de degradação das

pastagens. Os métodos de Máxima verossimilhança e RNA não diferiram estatisticamente e, portanto apresentam alto potencial para classificação de imagem de alta resolução espacial. A avaliação qualitativa dessas imagens mostrou um resultado satisfatório. O método ISODATA foi estatisticamente inferior para imagem de alta resolução espacial. Com os resultados alcançados, abrem-se novas perspectivas para trabalhos futuros, utilizando RNA e situações diferentes, contribuindo para o desenvolvimento do processamento digital de imagem.

## ABSTRACT

SILVA, Edgley Pereira da, D.S., Universidade Federal de Viçosa, August 2006.  
**Geoprocessing in the discrimination of degraded pastures using artificial neural network in image Ikonos II.** Adviser: Reinaldo Bertola Cantarutti. Co-adviser: Elpídio Inácio Fernandes Filho and Dilermando Miranda da Fonseca.

The cattle in Brazil reached from 60s, an increasing expansion and consequently an increase in areas of pastures. However, the gradual loss of the productive capacity of these pastures after some years has been a constant, mainly in extensive areas of exploration. The recovery of degraded pastures is hard to implement due to lack of information brought up to date and detailed regarding its space distribution. The use of the remote sensing, a technology whose data can be gotten to the low cost, with repetitivity and in a compatible scale with the dimension of problem, can highly contribute for the solution of this problem. The area of study is located at the city of João Pinheiro, in the northwest of the state of Minas Gerais, enclosing an area of 100 km<sup>2</sup>. The aims of this study were: a) the diagnosis and the quantification of the area according to the systems of use and the stadium of productivity of pastures and b) the application of methods of automatic classification in high-resolution imagery using Artificial Neural Networks. Image of the satellite Ikonos II with space resolution of one meter was used. The exactness of the mapping was verified using the Kappa index. The visual interpretation of the image and field-work made possible the identification of pastures in the following categories of productivity: productive, low degradation, average degraded, and degraded. The present pastures in the area were predominantly of *Brachiaria brizantha* (1,693 ha), *Andropogon gayanus* (192 ha) and *Panicum maximum* (231 ha). In accordance with the Kappa index, the visual classification of image Ikonos II has high potential to diagnosis the productivity of the pastures. The techniques of classification in images Ikonos II had revealed efficient in the discrimination of the levels of degradation of the pastures. The methods of maximum likelihood and ANN had not differed statistically; therefore, they present high potential for

classification of high-resolution imagery. The qualitative evaluation of these images showed a satisfactory result. The method ISODATA was statistically inferior to the high-resolution imagery. With the reached results, new perspectives for future works confide, using ANN and different situations, contributing to the development of the digital image processing.

## INTRODUÇÃO GERAL

O cerrado tem um grande potencial para produção pecuária, sendo, atualmente, responsável por 55 % da produção de carne no País. Apesar disso, a produtividade e a rentabilidade da pecuária no cerrado é baixa, o que, em parte, é atribuído à degradação das pastagens. Estima-se que mais de 60 % das pastagens cultivadas no cerrado estão degradadas ou em processo de degradação (Macedo et al., 2000; Zimmer et al., 2002).

A degradação das pastagens é um processo de perda progressiva do vigor da forrageira, comprometendo a sua capacidade de rebrota, de reagir ao estresse causado por pragas e doenças, de competir com plantas espontâneas e culmina com queda na produção e qualidade da forragem (Sneath, 1998). O início do processo é de difícil percepção, sendo detectado, na maioria das vezes, quando a produção de forragem já esta comprometida (Nascimento Júnior et al. 1994). De modo geral, a degradação deve-se a fatores relacionados com a fase de estabelecimento e com o manejo das pastagens.

A degradação das pastagens é um fato e tem sido apontada como um dos limitantes para a consolidação de uma pecuária econômica, social e ambientalmente sustentável nas áreas de domínio deste bioma. Considerando apenas a recria e a engorda, por exemplo, a produção animal em pastagens degradadas pode ser seis vezes menor do que em pastagens em bom estado de manutenção (Macedo et al., 2000).

Técnicas de geoprocessamento com o uso de dados coletados por sensores imageadores possibilitam o diagnóstico e a geração de mapas de forma dinâmica. Os sensores dos satélites captam imagens da terra de modo contínuo, abrangendo extensas áreas e fornecendo informações atualizadas, que são extraídas por meio de técnicas de interpretação visual e de processamento automático das imagens (Iwai, 2003). Dentre as técnicas destacam-se os Sistemas de Informações Geográficas (SIG) pela possibilidade de integrarem dados de levantamentos de campo, dados orbitais, dados do Sistema de Posicionamento Global (GPS), dados cartográficos e ainda cadastros de informações sócio-econômicos (Fernandes, 1997).

As informações adquiridas pelo sensoriamento remoto têm sido importantes, no monitoramento agrícola. Assad et al. (1991) destacaram a eficiência do sensoriamento remoto na avaliação espaço-temporal das pastagens de forma precisa e rápida, tanto quantitativa para caracterizar extensão e produção de biomassa, como qualitativa para diagnóstico das espécies cultivadas.

O uso combinado de técnicas de realce e de geoprocessamento, aplicadas às imagens Ikonos, fornece um diagnóstico sobre a dinâmica de ocupação do solo e, conseqüentemente, permite qualificar e quantificar a extensão das áreas de pastagens degradadas. A classificação automática de imagens emprega recursos matemáticos (algoritmos), possibilitando uma interpretação mais precisa. As redes neurais têm sido utilizadas principalmente com a finalidade de classificação. Entre as muitas vantagens são classificadores que integram com facilidade dados multisensores (Gleriani, 2004).

O levantamento e monitoramento dinâmico em pastagens são possíveis por meio de técnicas de geoprocessamento que pela interpolação dos dados de imagens orbitais, possibilita o diagnóstico e a geração de mapas. Neste sentido o objetivo deste trabalho foi: a) diagnosticar e caracterizar os sistemas de uso do solo e estádios de degradação de pastagens e b) avaliar a utilização da Rede Neural Artificial na classificação automática de pastagens com diferentes categorias de degradação utilizando imagem de alta resolução espacial.

## CAPÍTULO I

### **Geoprocessamento e Sensoriamento remoto no diagnóstico de produtividade das pastagens, utilizando imagem Ikonos II**

#### **RESUMO**

As pesquisas sobre pastagens exigem conhecimentos de clima, solo, planta, nutrição animal, métodos estatísticos, entre outros. Devido à complexidade deste sistema, é recomendável que especialistas dos vários campos da ciência trabalhem em equipe e que recorram a diferentes técnicas de pesquisa. Entre elas, destaca-se o geoprocessamento que permite a interpolação dos mapas temáticos obtidos por sensores imageadores que são úteis para o planejamento agrícola. Este trabalho utilizou técnicas de geoprocessamento por meio dados de satélite de alta resolução espacial com o objetivo de diagnosticar e caracterizar os estágios de degradação de pastagens. A área em estudo localiza-se no município de João Pinheiro, noroeste do estado de Minas Gerais, abrangendo uma área de 100 km<sup>2</sup>. Para realização deste trabalho, foi utilizada imagem do satélite Ikonos II com resolução espacial de 1m. O levantamento de campo juntamente com a interpretação visual da imagem possibilitou a identificação de pastagens em quatro categorias de degradação: nula, baixa, média e intensa. As pastagens na área eram predominantemente de *Brachiaria brizantha* (1.693 ha) e de *Andropogon gayanus* (192 ha) e *Panicum maximum* (231 ha). A classificação visual da imagem Ikonos II possibilitou discriminar as pastagens quanto à categoria de produtividade e as forrageiras dominantes nas pastagens. De acordo com o índice Kappa (0,85) obtido a classificação visual de imagem Ikonos II tem alto potencial para diagnosticar a produtividade das pastagens.

Palavras chaves: pastagem, ikonos, geoprocessamento, sensoriamento remoto e pastagem degradada.

## 1. INTRODUÇÃO

No Brasil, o modelo extrativista adotado na pecuária deflagrou processos de degradação dos solos, condicionando a redução da capacidade produtiva das pastagens. Essa extensa área de pastagem com capacidade de produção reduzida ou degradada faz com que as produções por animal e por hectare sejam próximas às das pastagens naturais (Barcelos, 1996). A reversão deste processo inicia-se pela melhoria da qualidade dos solos, tendo como etapa inicial a identificação do grau de degradação. Assim, o entendimento do processo de degradação de pastagem e as suas causas são essenciais para formular estratégias de recuperação da produtividade dessas áreas, reduzindo, assim, as pressões sobre os ambientes naturais para a expansão das pastagens (Dias Filho, 1998).

A degradação é um problema antigo, e sua reversão tem sido tentada pelos produtores brasileiros ao longo de muito tempo na maior parte das vezes, empiricamente (Dutra & Dutra, 1999). A degradação das pastagens está associada a fatores ligados ao estabelecimento da forrageira e ao manejo das pastagens. Entre as causas mais importantes aponta-se: escolha inadequada da espécie forrageira; má formação inicial; preparo do solo inadequado; falta do uso de corretivos e fertilizantes; ocorrência de pragas, doenças e plantas invasoras; manejo animal inadequado e a ausência ou aplicação incorreta de práticas de conservação do solo (Meirelles, 1993 & Nascimento Júnior et al. 1994).

Com o avanço do processo de degradação das pastagens a produção de forragem diminui, observando-se redução na qualidade e quantidade de forragem mesmo nas épocas favoráveis ao seu crescimento, assim como o aumento na frequência de plantas invasoras, e a queda na proporção de solo coberto pelas plantas desejáveis. Estes indicadores podem ser utilizados para a escolha do método adequado de recuperação, reforma ou da renovação das pastagens (Embrapa, 2000). A expansão das áreas de pastagens cultivadas nas regiões tropicais e subtropicais tem despertado o interesse de muitos

profissionais para o problema da degradação e os métodos para sua recuperação (Carvalho, 1998).

Segundo Nascimento Júnior et al. (1994), estabelecer critérios para diagnóstico da degradação das pastagens cultivadas é tarefa difícil, tendo em vista a diversidade das espécies quanto as suas características morfológicas e a diversidade dos ecossistemas em que são cultivadas. No entanto, alguns estádios da degradação podem ser facilmente identificados e são característicos na maioria das pastagens degradadas: distúrbio fisiológico da espécie forrageira; mudança na composição botânica; e invasão por novas espécies (Stoddart et al., 1975). Assim, qualquer critério que seja proposto para avaliar a degradação deve, necessariamente, considerar esses dois indicadores: diminuição da produção e mudança na composição botânica. Um terceiro indicador, quando a degradação se apresenta em grau mais avançado, é a estabilidade do solo ou grau de erosão (Nascimento Júnior et al., 1994).

Existem vários critérios que podem ser adotados para avaliação do processo de degradação das pastagens. Barcellos (1986) citado por Nascimento Júnior et al., (1994), estabeleceu uma escala de degradação que varia de 1 a 4, onde o menor estágio seria o grau 1, ocorrendo somente a característica 1, e os demais graus seriam criados com somatório das características ( $1+2 = \text{grau } 2$ ;  $1 + 2 + 3 = \text{grau } 3$ ;  $1 + 2 + 3 + 4 = \text{grau } 4$ ). Estas características são: (1) redução na produção de forragem, na qualidade, altura e volume, mesmo nas épocas favoráveis ao crescimento; (2) diminuição da área vegetada e pequeno número de plantas provenientes da ressemeadura natural; (3) aparecimento de espécies invasoras de folhas largas e início de processos erosivos pela ação das chuvas; (4) presença de plantas invasoras em grande proporção, colonização da pastagem por gramíneas nativas e processos erosivos acelerados. Diante do exposto, fica evidente que o processo de degradação das pastagens pode ser reversível quando medidas, tais como, redução na taxa de lotação, exclusão da pastagem em épocas estratégicas, controle de invasoras, entre outras, são tomadas logo após o surgimento dos primeiros sinais de degradação (Carvalho, 1993). O manejo sustentável das pastagens deve envolver a aplicação de planos de manejo

estratégicos adequados, de modo que a produtividade seja economicamente viável sem influenciar a integridade ecológica, isto é, a sobrevivência das forrageiras a longo prazo (Santos, 2001).

Existe hoje uma necessidade de identificar os diferentes níveis de degradação das pastagens cultivadas, que fornecerão subsídios para possíveis intervenções com o objetivo de recuperá-las. Nesse aspecto, as técnicas de sensoriamento remoto hoje disponível, podem auxiliar no mapeamento desses diferentes níveis de degradação das pastagens, por meio da interpretação de imagens de satélite associada ao levantamento de campo.

O sensoriamento remoto é a tecnologia que permite obter imagens e outros tipos de dados, da superfície terrestre, através da captação e do registro da energia refletida ou emitida pela superfície (Florenzano, 2002). Permite a aquisição de informações sobre um objeto, a partir de medidas feitas por um sensor que não se encontra em contato físico direto com ele. Visto como um sistema de aquisição de informações pode ser dividido em duas etapas: coleta de dados e análise de dados (Novo, 1992).

O solo, a vegetação e água constituem os principais alvos da superfície terrestre. Esses alvos absorvem, refletem e emitem Radiação Eletromagnética (REM) de forma diferenciada, ao longo do espectro eletromagnético, em função de suas propriedades específicas. Assim, o entendimento do comportamento espectral da cobertura vegetal e dos solos é importante para uma aplicação do sensoriamento remoto.

Diante da necessidade de agilizar a obtenção e o processamento de informações e a produção dos resultados relativos aos levantamentos de recursos naturais, tem-se recorrido aos recursos computacionais e softwares específicos, que proporcionam resultados satisfatórios (Burrough, 1996).

Segundo Assad (1998) o termo geoprocessamento denota uma disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento de informações geográficas. Há influência crescente dessa tecnologia em várias áreas (Agricultura, Cartografia, Análise de Recursos Naturais, etc), principalmente em regiões de grandes dimensões e com carência de informações adequadas para tomadas de decisão. Ainda segundo os autores, os instrumentos computacionais do geoprocessamento, chamados de Sistemas de Informações Geográficas (SIGs).

Dentre as técnicas eficientes disponíveis, destacam-se os SIGs (Figura 1). SIG é um ambiente capaz de integrar dados provenientes de diferentes fontes de informações (resultados de levantamentos de campo, dados orbitais e do Sistema de Posicionamento Global-GPS, dados cartográficos de referencia, cadastros de informações sócio-econômicos). Ele possibilita a tomada de decisões em diferentes níveis, permitindo desta forma as análises de dados geográficos pertinentes a diversos contextos (Fernandes, 1997).

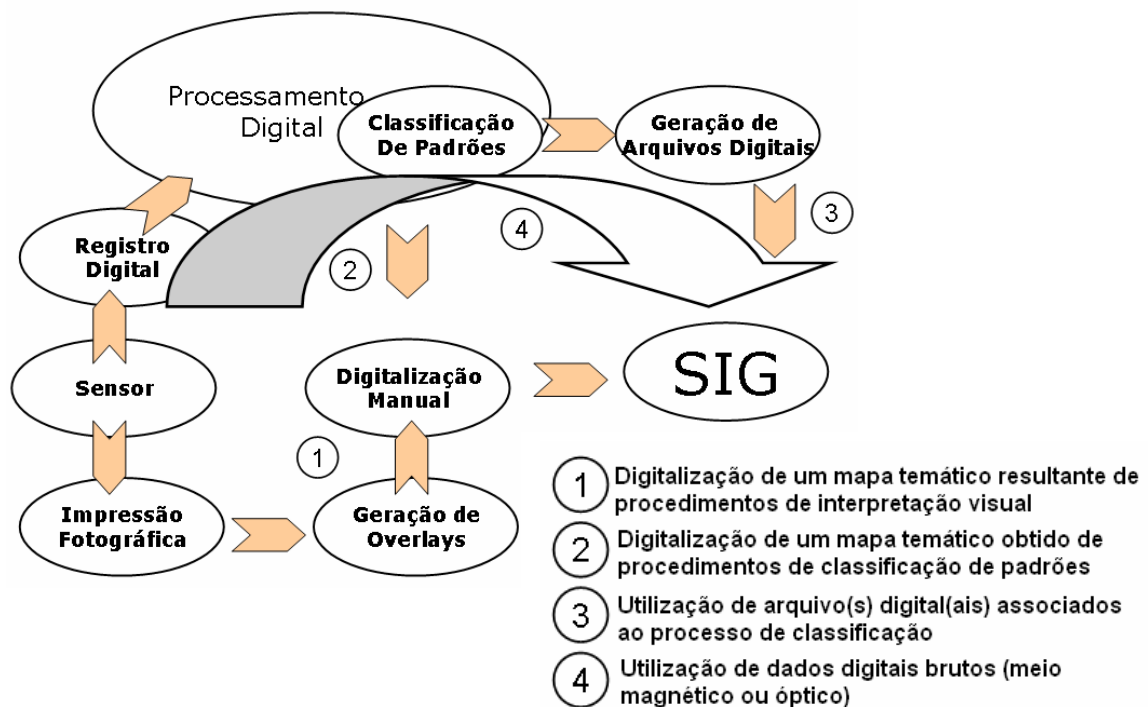


Figura 1. Integração entre sensoriamento remoto e sistema de informação geográfica (SIG). Fonte Fernandes (1997).

Um SIG (Figura 2) pode ser entendido como qualquer conjunto de procedimentos, manuais ou computacionais para armazenar e manipular dados geograficamente referenciados. Queiroz (1996) apresenta um SIG como uma série de *overlays* de uma determinada região, representando dados brutos ou de informações temáticas que compartilham atributos geográficos comuns, assim como coordenadas geográficas. Os dados de origens diversas podem ser integrados, visualizados e processados como um conjunto de planos de informações gráficas superpostas, embora seja de fato armazenado

isoladamente sob a forma digital, adequada para análise em sistemas computacionais.

No campo das aplicações dos dados primários gerados por estes instrumentos, a multiplicidade de opções também é grande. À medida que aumenta a resolução espacial, espectral e temporal, e novos recursos tecnológicos, tornam-se disponíveis, as imagens orbitais obtidas por sensores modernos, passam a constituir poderosos instrumentos para os estudos de monitoramento dos recursos naturais (Florenzano, 1998).

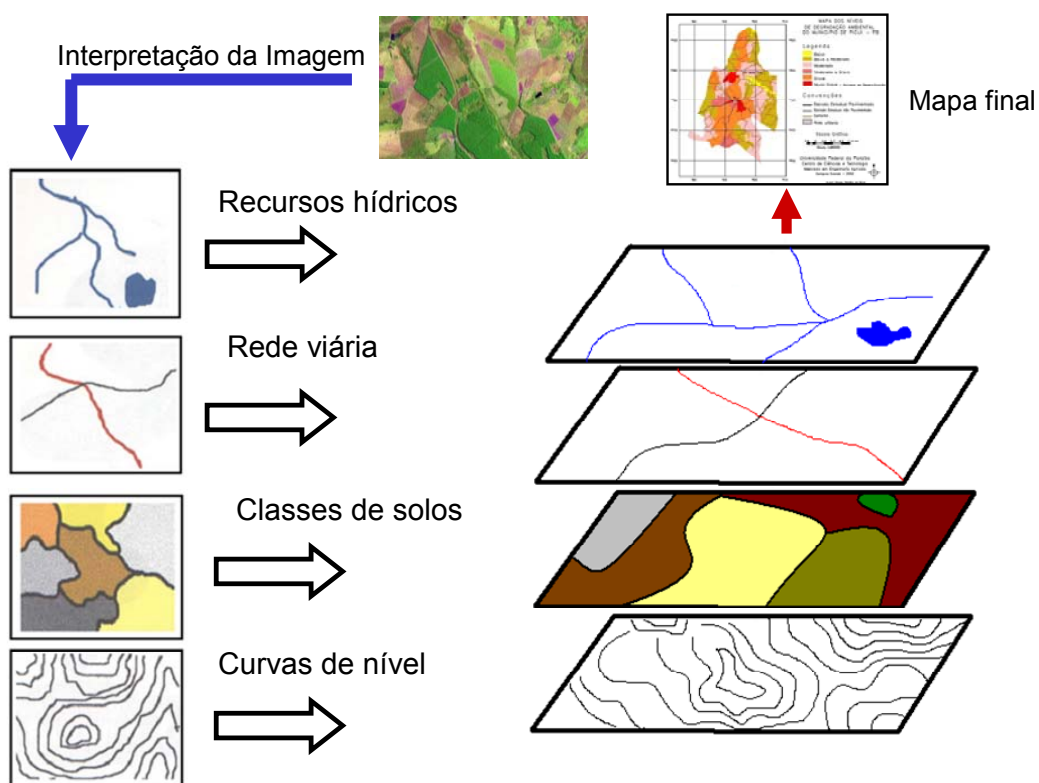


Figura 2. Representação dos planos de informação em um Sistema de Informação Geográfica. Fonte: Fernandes (1997) modificado.

Assad et al. (1991) destacam que o uso de técnicas de sensoriamento remoto na avaliação de áreas de pastagens, tanto do ponto de vista de extensão de produção, qualidade, tipo de pastagem, quanto de sua extensão, constitui um instrumento de múltiplas utilidades, permitindo estudos espaço-temporais. No entanto, antes da utilização das imagens de satélites, são necessários estudos radiométricos de campo para identificar o comportamento espectral dos alvos estudados. No caso de pastagens, a assinatura espectral

pode permitir a diferenciação de espécies que apresentam arquiteturas e comportamentos fisiológicos diferenciados. A reflectância das espécies, em fases fenológicas distintas, pode ser usada como referência para a classificação destas nas imagens de satélites.

Na literatura relatam estudos radiométricos em diferentes tipos de pastagens, principalmente as naturais. Ihse & Rose (1985) utilizaram radiômetros de campo e encontraram alta correlação entre reflectância e biomassa para comunidades vegetais na Suécia dominadas pela espécie *Arrhenatherum pratense* e baixa correlação quando a espécie dominante era *Festuca ovina*. Os autores concluíram que a diversidade da comunidade, a fenologia, a cobertura vegetal e a cor das flores, foram os fatores que mais favoreceram os resultados obtidos.

Assad et al. (1991) utilizaram padrões radiométricos com o objetivo de avaliar o comportamento espectral das *Brachiaria decumbens*, *Brachiaria humidicola*, *Andropogon gayanus* e *Brachiaria ruzizienses*, e verificar a possibilidade de diferenciá-las espectralmente, além de estudar as possíveis relações entre produção de biomassa e reflectância. A análise de componentes principais e os estudos de classificação hierárquica permitiram a distinção de dois grandes grupos a partir das medidas de reflectância: grupo 1 - *Brachiaria humidicola* e *Andropogon gayanus*; grupo 2 - *Brachiaria decumbens* e *Brachiaria ruzizienses*. Segundo os autores, os resultados obtidos abrem perspectiva para utilização de sensores remotos na diferenciação espacial de espécies forrageiras.

Kury & Vieira (2002) desenvolveram uma metodologia para classificação automática de imagens de alta resolução espacial utilizando regiões como unidades de classificação, sendo usada uma imagem do satélite Ikonos II de uma área próxima à cidade de Lascano, no Uruguai. A imagem foi dividida em regiões espectrais homogêneas e foi realizada a classificação automática por regiões, utilizando-se o algoritmo da máxima verossimilhança. Algumas regiões foram classificadas incorretamente, devido à semelhança entre os dois tipos de vegetação. Obteve-se um índice de exatidão global igual a 96,4%.

Sugumaran & Zerr (2001) avaliaram o potencial das imagens do satélite Ikonos II para uso pela administração da cidade de Columbia, Missouri,

e pelo governo local. A exatidão global da imagem classificada utilizando diferentes métodos estatísticos variou entre 87 e 91 %. Ocorreu confusão entre algumas classes, o que influenciou a exatidão da classificação. Áreas de floresta decídua foram classificadas como milho. Concluiu-se que muitos dos problemas encontrados durante a classificação podem ser minimizados na fase de aquisição dos dados, especificando o azimute de aquisição dos dados para reduzir sombras e adquirindo imagens da mesma área em datas diferentes. Os mesmos autores citam como principal problema no uso de imagem do satélite Ikonos II a baixa resolução espectral. Sugerem ainda que, estudos sejam realizados com o intuito de comparar diferentes métodos de classificação aplicados às imagens do satélite Ikonos II.

Mangabeira et al. (2003) utilizaram imagem do satélite Ikonos II para identificação de uso da terra em área com intensa ocupação fundiária, localizada no município de Holambra no Estado de São Paulo. Resultados parciais mostraram que o principal produto obtido foi o mapa de uso das terras, cuja interpretação visual permitiu identificar 26 categorias. Os dados do satélite de alta resolução como o Ikonos II pode mapear detalhes que antes não eram possíveis.

Ribeiro (2004) utilizou os algoritmos da Mínima Distância, da Máxima Verossimilhança e de Redes Neurais Artificiais, em uma imagem do satélite Ikonos II com 4 metros de resolução espacial para o mapeamento da cobertura terrestre no município de Serra do Salitre, Estado de Minas Gerais. Os métodos que mostraram melhor desempenho foram Redes Neurais Artificiais e Máxima Verossimilhança, ambos por regiões não apresentando diferença estatística significativa a 95 % de probabilidade pelo teste Z.

Diante da necessidade de quantificar as áreas de pastagens cultivadas em diferentes graus de degradação, para subsidiar intervenções objetivando recuperá-las. As técnicas de sensoriamento remoto hoje disponível podem ser de grande utilidade por meio da interpretação de imagens de satélite associada a levantamentos de campo. Neste contexto, desenvolveu-se o presente trabalho que utilizando técnicas de geoprocessamento para avaliar o uso de imagens de alta resolução no diagnóstico e quantificação de área quanto aos sistemas de uso e quanto ao estágio de degradação das pastagens.

## 2. MATERIAL E MÉTODOS

### 2.1. Localização, aspectos fisiográficos e climáticos da área de estudo

A área em estudo envolve parte da Fazenda São Geraldo, localizada no município de João Pinheiro (Figura 3) noroeste do estado de Minas Gerais ( $16^{\circ} 56' 27''$  S e  $46^{\circ} 12' 22''$  O) e altitude em torno de 532 m.




Figura 3. Localização do município de João Pinheiro, com destaque da área de estudo, vista pela imagem do satélite Ikonos II.

A precipitação pluviométrica média anual é de aproximadamente 1.200 mm. A temperatura média anual é de 22,6<sup>0</sup> C (Antunes, 1986). Segundo a classificação de Köppen, a área de estudo está inserida no clima Aw – tropical úmido de savana, com inverno seco e verão chuvoso.

O relevo constitui-se, basicamente, de extensos planaltos e amplas depressões, dispostas na direção dos principais cursos d'água. A vegetação predominante caracterizada por paisagem e fisionomia peculiar ao Cerrado, com indivíduos de porte atrofiado, troncos retorcidos, cobertos por casca espessa e fendilhada e copas assimétricas (Ribeiro et al., 1983).

As classes de solos (Figura 4) predominantes na área são: Latossolo Vermelho-Amarelo Distrófico, Latossolo Vermelho Distrófico, ocorrendo ainda Neossolo Quartzarênico, Neossolo Flúvico e Gleissolo (Quadro 1). De acordo com AGRO-AMBIENTAL ASSESSORIA (2004).

Quadro 1. Área e distribuição relativa dos principais classes de solos encontrados na área de estudo

Solos	Área	
	(ha)	(%)
Neossolo Flúvico	29,59	0,7
Neossolo Flúvico e Gleissolo	197,49	1,9
Neossolo Quartzarênico	183,25	1,8
Gleissolo Álico	246,34	2,4
Gleissolo e Neossolo Flúvico	240,47	2,3
Latossolo Vermelho Álico	2.759,42	27,2
Latossolo Vermelho Álico e Latossolo Vermelho Amarelo Álico	734,94	7,2
Latossolo Vermelho Amarelo Álico	5.693,04	56,2
Total	10.081,53	100,0

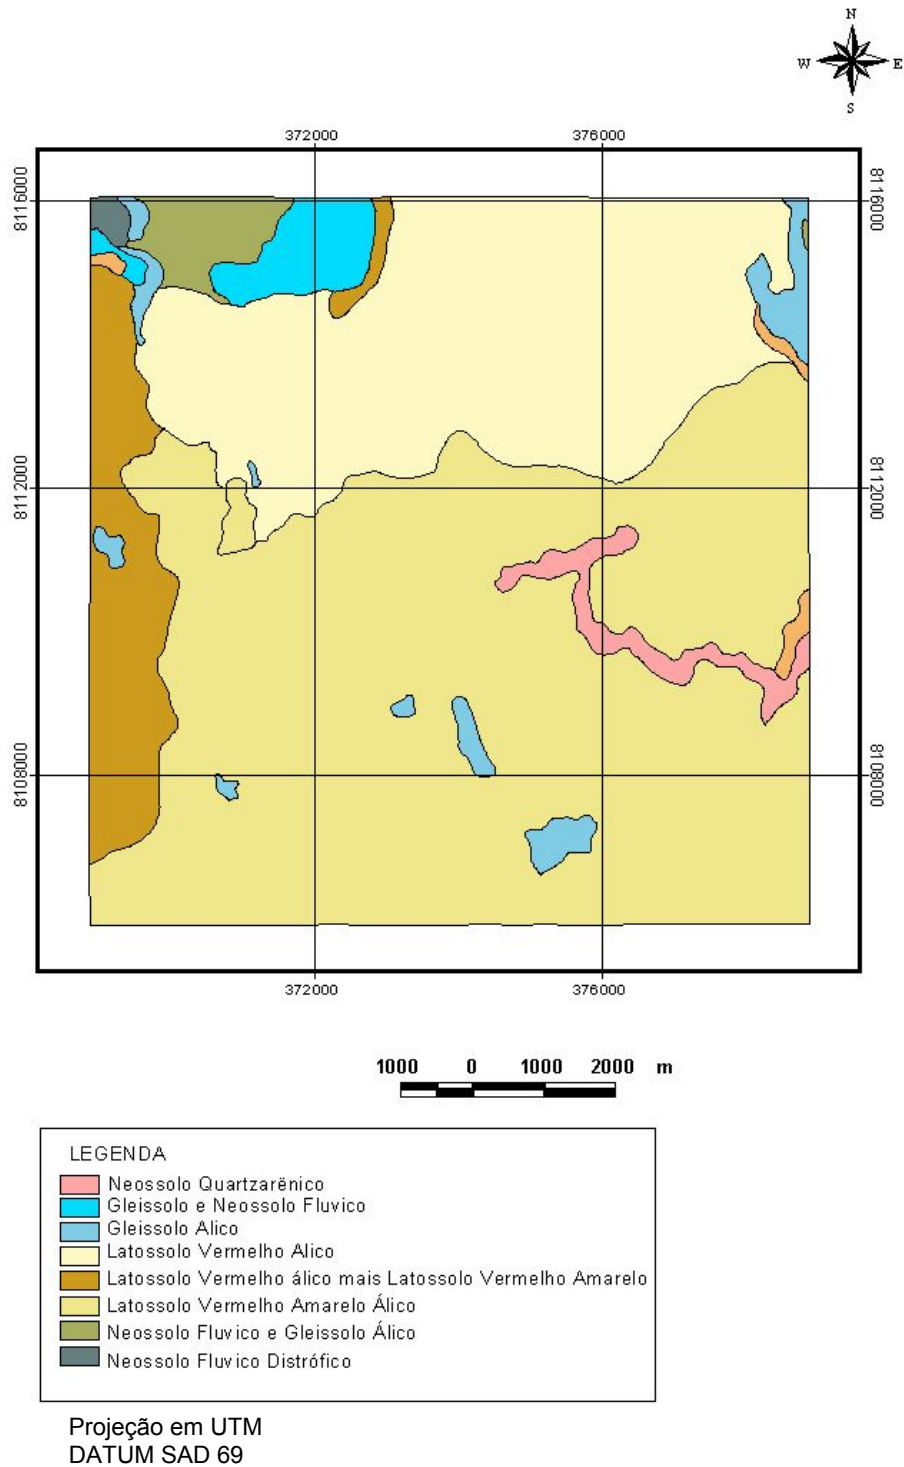


Figura 4. Mapa de solos semidetalhado de parte da Fazenda São Geraldo, no município de João Pinheiro, MG. Fonte: AGRO-AMBIENTAL ASSESSORIA, na escala de 1:40.000, em 2004.

## 2.2. Alocação e caracterização das parcelas de observação

Foram escolhidas pastagens que abranjessem todas as categorias de degradação presentes na área. Foram delimitadas e georreferenciadas parcelas de aproximadamente um hectare, sendo o mais representativas das condições de cada pastagem. Nestas parcelas estimou-se a forragem disponível e a participação de plantas espontâneas, a ocorrência de termiteiros e a cobertura de solo. Com referência a pastagem com nula degradação as demais foram categorizadas quanto à degradação segundo critério proposto por Spain & Gualdrón (1988) (Quadro 2).

Quadro 2. Caracterização do estado de degradação de pastagens segundo critérios adaptados de Spain & Gualdrón (1988)

<b>Indicadores de degradação</b>	<b>Estágio de degradação</b>
Alto vigor e boa qualidade	Nulo
Baixo vigor, baixa qualidade e baixa população	Baixo
Baixo vigor, baixa qualidade e baixa população, associado com a presença de invasoras e/ou termiteiros	Médio
Baixo vigor, baixa qualidade e baixa população, associado com a presença de plantas invasoras, termiteiro e solo descoberto	Intensa

Em cada parcela foram obtidas amostras de solo compostas de 20 amostras simples coletadas na camada de 0 a 20 cm. As amostras foram submetidas à análise química para caracterização da fertilidade do solo (Defelipo & Ribeiro, 1997) e análise física para caracterizar a densidade de partículas, porosidade total, macro e micro e condutividade hidráulica (Ruiz, 2005). Em cinco perfis foram coletadas amostras com anel volumétrico para determinar a densidade do solo e condutividade hidráulica.

A forragem disponível foi quantificada por meio do método da dupla amostragem (Mendonza & Lacano, 1985).

Para a análise da micromorfológica do solo, amostras indeformadas foram coletadas com auxílio de caixas de Kubiena para confecção de lâminas delgadas com dimensões de 10,0 x 6,5 x 5,0 cm. Foi empregado o método proposto por Jongerius & Heintzberger (1963), sendo utilizada resina de poliéster na impregnação.

### **2.3. Trabalho de campo**

As informações da imagem do satélite foram correlacionadas com as de campo, baseando-se em um reconhecimento geral da área, por meio de um roteiro pré-estabelecido, quando foram descritos relevo, vegetação natural, erosão, declividade e uso atual das terras. Os principais objetivos foram:

- Correlacionar os padrões interpretativos de tonalidades de cores, e de textura, obtidos na interpretação visual da imagem Ikonos II;
- Identificar os padrões de nível digital para cada classe de uso e produtividade de pastagem;
- Identificar as unidades de mapeamento, visando à determinação dos diferentes tipos de usos;

A área foi percorrida em três visitas (Figura 5). A primeira em maio de 2004, para o reconhecimento geral da área a ser estudada; a segunda em maio de 2005, para coleta de materiais para análise e coleta dos pontos de controles (PI's) definidos por GPS e a terceira em agosto/2005 para correlacionar e coletar pontos para gerar os índices Kappa.

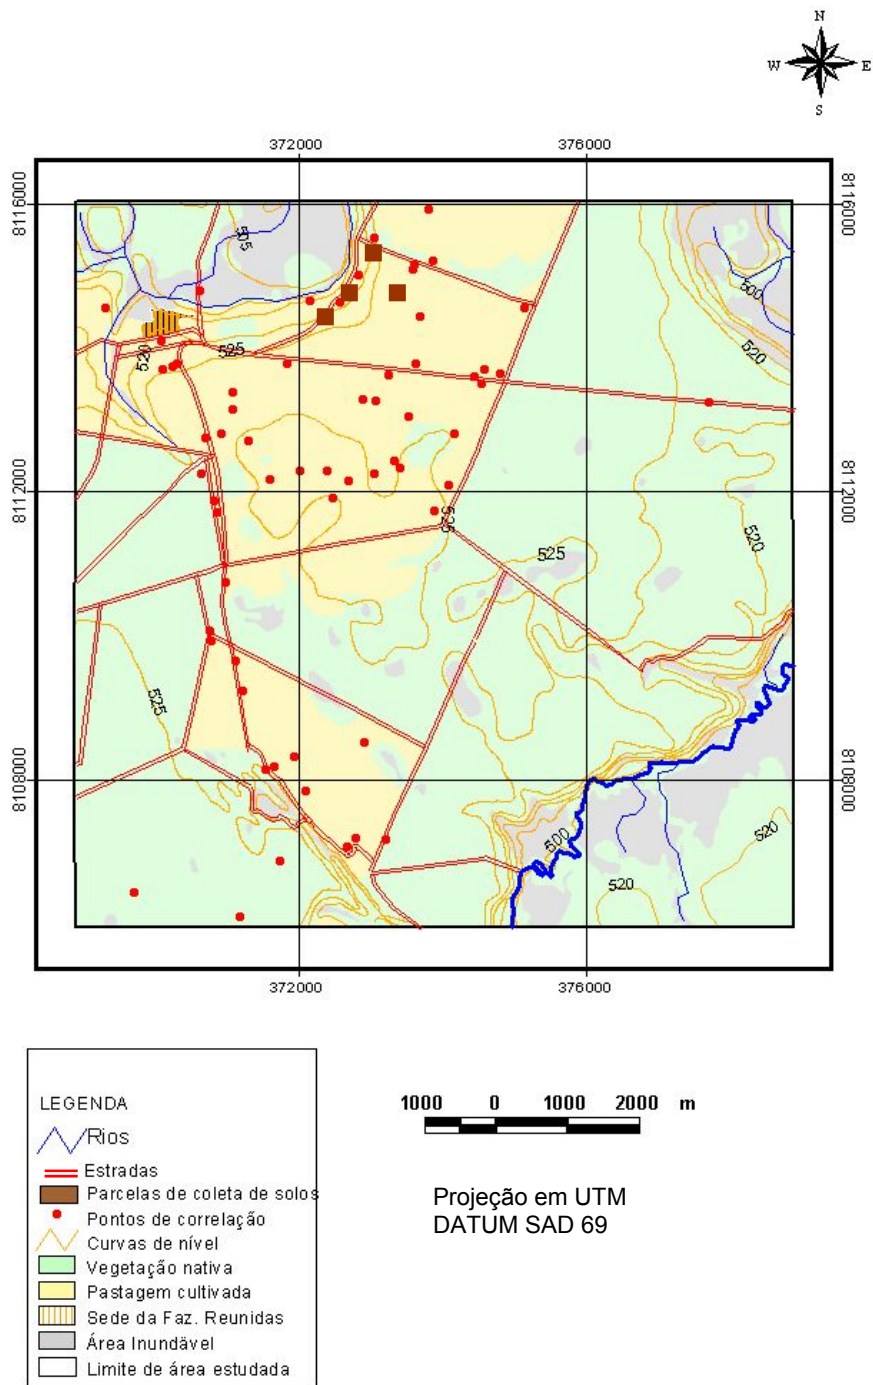


Figura 5. Mapa da área da imagem com indicação dos pontos de correlação empregados na correlação das parcelas.

## 2.4. Imagem do satélite Ikonos II

Para realização deste trabalho foi utilizada imagem do satélite Ikonos II com 100 km<sup>2</sup>, resolução espacial de 1 m, com 11 bits (2.048 níveis de cinza) obtida 14 de abril de 2005 (Figura 6) na composição 1B2G3R e 1B2G4R (Quadro 3).




Figura 6. Imagem Ikonos II obtida em 14 de abril/2005 de uma área de 100 km<sup>2</sup> da Fazenda São Geraldo localizada no município de João Pinheiro, MG.

Quadro 3. Características das bandas do satélite Ikonos. Fonte Space Imaging (2002)

<b>Bandas</b>	<b>Comprimento de onda (<math>\mu\text{m}</math>)</b>
1 (azul)	0,45-0,52
2(verde)	0,51-0,60
3(vermelho)	0,63-0,70
4(infravermelho)	0,76-0,85

## 2.5. Fotointerpretação

O método utilizado foi à análise visual preliminar da imagem com base na identificação dos alvos vegetação natural, solo exposto, pastagens, entre outros a partir dos elementos fotointerpretativos como:

a) Drenagem – que resulta de uma série de manifestações naturais, como relevo, geologia e cobertura vegetal. O modelo de drenagem seria o arranjo planimétrico dos cursos d'água, sugerindo uma tendência de arranjo, que pode ser: dendrítico, treliça, radial, paralelo, anular e retangular;

b) Relevo – possibilita identificar formas fisiográficas construcionais, tais como cones vulcânicos, dunas, terraços fluviais, depósitos glaciais e dobras alternadas;

c) Forma - refere-se à forma geral como o objeto se apresenta, podendo ser um indício importante para a sua identificação. Polígonos de formas irregulares caracterizam áreas de florestas naturais. Formas com bordas retas sugerem cidades ou campos agrícolas. Linhas extremamente retas podem significar linhas de transmissão ou estradas.

d) Tonalidade – refere-se ao brilho relativo ou a cor de objetos em uma imagem. Geralmente é o elemento fundamental para se distinguir entre objetivos específicos ou outras feições e também permitem a distinção de outros elementos como forma, textura e padrão de objetos.

e) Textura – é um dos elementos mais importantes para identificação de objetos e refere-se ao arranjo e frequência de variações tonais em áreas particulares de uma cena. Os tipos litológicos podem ser delimitados espacialmente através da variação de textura, possibilitando delimitar limites de contato.

f) Padrão - é o arranjo repetitivo de objetos visíveis na cena, como por exemplo, cursos de água, apresentando ângulos retos tanto no curso principal como nos tributários, o que define padrão de drenagem retangular.

g) Tamanho - O tamanho como se apresentam os objetos em uma fotografia é principalmente função da escala. É importante ser avaliado o tamanho de um objeto em relação aos demais existentes;

h) Associação - refere-se à associação entre certos objetos em uma cena. A identificação de associações em uma área pode auxiliar na interpretação de vários aspectos, como por exemplo, a presença de determinado tipo de vegetação sempre associada a aluviões com maior teor de salinidade.

Os critérios adotados na fotointerpretação para identificar as classes de uso e cobertura foram:

Relevo – Padrão: plano (p); suave ondulado (so); ondulado (o); forte ondulado (fo) e montanhoso (m). Grau de dissecação: muito alto (ma); alto (a); médio (m); baixo(b) e muito baixo (mb). Linhas de crista: nítidas (n); difusas (d) e ausentes (a).

Drenagem – Padrão: dendrítico (d); paralelo (p); retangulares (r) e ausentes (a). Densidade: alta (a); média (m); baixa (b) e muito baixa (mb).

Textura – grosseira (g); média (m); fina (f) e ausente (a).

Tonalidade - clara (c); muito clara (mc); média (m); escura (e) e muito escura (me).

Uso da terra – Tipo: vegetação natural (vc); ocupação agrícola (a); solo exposto (se) e outros (o). Intensidade de uso: alta (a); muito alta (ma); média (m); baixa (b) e muito baixa (mb).

O processamento da imagem foi realizado primeiramente pela composição da imagem com bandas espectrais 1B2G3R e 1B2G4R. (Figura 7).

Posteriormente foi submetida à interpretação visual para identificação e separação das classes de uso e cobertura do solo. As informações foram digitalizadas no *software* ArcInfo e processadas no *software* ArcView.




Figura 7. Imagem do satélite Ikonos II em sua composição 1B2G3R (A) e

Os resultados obtidos com a classificação da imagem foram trabalhados no ArcView, visando à edição final do mapa. Foram obtidas observações de campo em pontos georreferenciados (GPS) escolhidos aleatoriamente nas pastagens com diferentes produtividades com o objetivo de verificar a exatidão do mapeamento, utilizando-se o índice Kappa.

O índice Kappa (K) é um método estatístico utilizado na avaliação da concordância entre a condição real da área mapeada e os resultados encontrados no mapa temático obtido a partir da interpretação da imagem de satélite (Moreira, 2003) calculado mediante a aplicação da seguinte equação (Congalton & Green, 1998).

$$K = \frac{n \sum_{i=1}^M x_i - \sum_{i=1}^M (x_{i+} \cdot x_{+i})}{n^2 - \sum_{i=1}^M (x_{i+} \cdot x_{+i})}$$

em que:

$n$  = número total de observações;

$x_{i+}$  e  $x_{+i}$  = somatório dos pixels da linha e na coluna contidos na matriz de confusão e

$M$  = número de classes mapeadas.

Com base nos valores obtidos após a análise da classificação por meio do índice Kappa, estabeleceu-se o critério de exatidão (Quadro 3).

Quadro 4. Valores do índice Kappa (K) utilizados

<b>Índice Kappa</b>	<b>Critério de exatidão</b>
$K \leq 0,2$	Ruim
$0,2 < K \leq 0,4$	Razoável
$0,4 < K \leq 0,6$	Boa
$0,6 < K \leq 0,8$	Muito Boa
$0,8 < K \leq 1$	Excelente

### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Caracterização física do ambiente da área de estudo

Os valores de densidade do solo encontrados nas profundidades de 0 a 5 e de 5 a 10 cm não apresentaram diferença expressivas (Quadro 5), embora constata-se um pequeno aumento (16 %) com a intensidade de degradação das pastagens na profundidade de 5 a 10 cm. A porosidade, micro, macro e total na camada de 0 a 5 cm do solo nas diferentes condições de cobertura vegetal não apresentou variação expressiva. Em termos gerais não houve grande diferença da porosidade total entre as camadas de 0 a 5 cm ( $0,41 \text{ m}^3 \text{ m}^{-3}$ ) e 5 a 10 cm ( $0,45 \text{ m}^3 \cdot \text{m}^{-3}$ ).

Quadro 5. Densidade do solo e de partículas, macro e microporosidade e porosidade no solo da mata e de pastagens com diferentes intensidades de degradação

Cobertura vegetal	Densidade		Porosidade		
	Solo	Partícula	Micro	Macro	Total
	----kg dm <sup>-3</sup> ----		----- m <sup>3</sup> m <sup>-3</sup> -----		
	Profundidade 0 - 5				
Cerrado <sup>1/</sup>	1,53 bc	2,65 ab	0,28 a	0,14 a	0,42 ab
Past. nula degradação	1,64 ab	2,68 b	0,26 a	0,13 a	0,39 b
Past. baixa degradação	1,47 c	2,62 a	0,29 a	0,15 a	0,44 a
Past. média degradação	1,65 a	2,67 a	0,27 a	0,11 a	0,38 b
Past. Intensa degradação	1,53 c	2,66 ab	0,29 a	0,14 a	0,42 ab
C.V (%)	2,5	1,5	10,7	30,3	4,0
	Profundidade 5 - 10				
Cerrado <sup>1/</sup>	1,41 b	2,68 a	0,25 a	0,22 a	0,58 a
Past. nula degradação	1,53 ab	2,72 a	0,22 a	0,22 a	0,44 ab
Past. baixa degradação	1,51 ab	2,71 a	0,28 a	0,16 ab	0,44 ab
Past. média degradação	1,63 a	2,71 a	0,22 a	0,18 ab	0,40 b
Past. intensa degradação	1,64 a	2,72 a	0,30 a	0,19 b	0,39 b
C.V (%)	4,7	1,4	13,4	25,5	5,6

<sup>1/</sup> Área contígua às áreas das pastagens.

Para cada profundidade, na coluna, médias seguidas de mesma letra não diferiram pelo teste de Tukey a 5 %.

No entanto, a macroporosidade foi, em média, 31 % maior na camada subsuperficial. Considerando que a macroporosidade está diretamente associada à capacidade da infiltração da água, esta menor porosidade total na camada subsuperficial pode contribuir para um maior escoamento superficial da água na pastagem degradada.

A micromorfologia das amostras (Figura 8) expressa a porosidade presente nos solos estudados. De um modo geral as amostras de solos da classe dos Latossolos, apresentam uma textura mais arenosa.




Figura 8. Micromorfologia das amostras indeformadas na confecção de lâminas delgadas obtida pelo método proposto por Jongerius & Heintzberger (1963), utilizando resina de poliéster na impregnação. (A) cerrado, (B) pastagem com nula degradação, (C) pastagem com baixa degradação, (D) pastagem com média degradação e (E) pastagem com intensa degradação.

Apesar da pequena diferença quanto à porosidade, o solo sob cerrado apresentou maior condutividade hidráulica, sobretudo na camada de 5 a 10 cm (Figura 9). A maior macroporosidade refletiu em maior condutividade hidráulica no solo da camada de 5 a 10 cm. No entanto, a despeito da diminuição na porosidade total com a intensidade de degradação das pastagens não constatou a mesma tendência para a condutividade hidráulica.

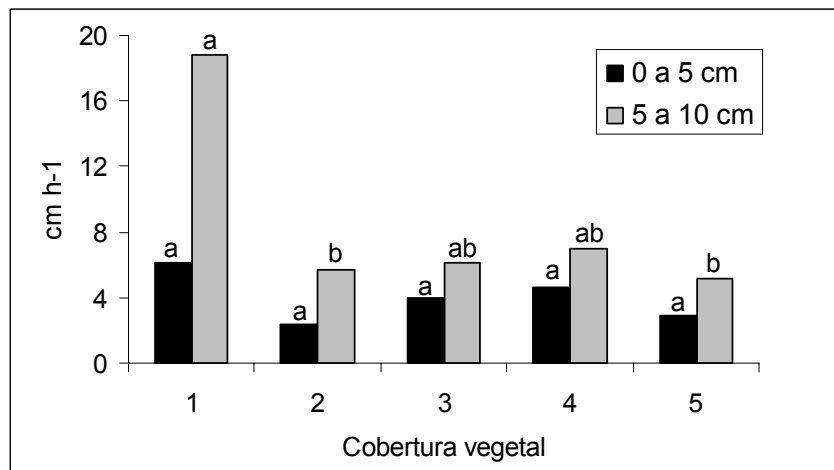


Figura 9. Condutividade hidráulica do solo em diferentes coberturas vegetais: cerrado (1); pastagem com nula degradação (2); pastagem com baixa degradação (3); pastagem com média degradação (4) e pastagem intensa degradação (5). Para cada profundidade barras seguidas por mesma letra as médias não diferiram pelo teste de Tukey a 5 %.

No cerrado, refletindo sua condição natural, o solo mostrou-se mais ácido, caracterizado pelo menor pH, maior Al<sup>3+</sup> e mesma soma de bases (Quadro 5). O valor do P rem evidenciou a textura leve do solo. Os baixos teores de P, K e saturação por bases (Alvarez et al., 1999) caracterizaram a baixa fertilidade natural deste solo.

Independentemente da condição de degradação, o solo das pastagens são menos ácidos e tem maiores teores de matéria orgânica e evidenciam uma melhor fertilidade, considerando-se os critérios de diagnóstico descritos por Alvarez et al. (1999). Os altos teores de Ca<sup>2+</sup> e Mg<sup>2+</sup> (Quadro 6) refletem o efeito da calagem e os altos teores de P, o efeito da adubação fosfatada. Ambas são práticas imprescindíveis no estabelecimento de pastagens nos solos de baixa fertilidade natural.

Quadro 6. Características químicas de amostras coletadas de 0 a 20 cm do solo de diferentes cobertura vegetal

Cobertura vegetal	pH H <sub>2</sub> O	P	K+	Ca <sup>2+</sup>	Mg <sup>2+</sup>	Al <sup>3+</sup>	H+Al	SB	t	T	V	m	MO	P rem
		mg dm <sup>-3</sup>	-----cmol <sub>c</sub> dm <sup>-3</sup> -----				-----%-----						dag kg <sup>-1</sup>	mg L <sup>-1</sup>
1	4,6 c	1,0 c	28 c	0,00 d	0,08 e	1,8 a	4,0 a	0,16	1,9	4,2	4	92	1,2 ab	31,4 d
2	5,9 a	35,8 a	29 bc	1,44 c	0,76 c	0,0 b	1,9 c	2,28	2,3	4,2	55	1	1,3 ab	44,8 a
3	5,4 b	25,4 b	24 d	1,43 c	0,59 d	0,2 b	2,8 b	2,07	2,2	4,9	42	7	1,6 ab	32,5 cd
4	5,7 a	21,2 b	41 a	1,78 a	1,04 a	0,0 b	2,1 c	2,92	2,9	5,0	58	1	1,5 ab	40,5 b
5	5,5 b	27,8 ab	33 b	1,67 b	0,89 b	0,1 b	2,9 d	2,64	2,7	5,5	48	3	1,8 a	35,3 c
CV (%)	1,6	15,4	4,4	2,9	2,8	24,0	4,1						10,4	2,9

1-Cerrado; 2-Pastagem com nula degradação; 3-Pastagem com baixa degradação; 4-Pastagem com média degradação e 5-Pastagem com intensa degradação. Nas colunas, médias seguidas de mesma letra não diferiram estatisticamente pelo teste de Tukey a 5 %.

### 3.1.2. Caracterização das pastagens

Por ocasião da alocação das parcelas de observação em maio de 2005, as pastagens apresentaram entre 1.566 e 5.980 kg/ha de matéria seca de forragem, sendo que a cobertura vegetal variava entre 42 a 60 % (Figura 10). Nesta época a região apresentava baixos índices de precipitação, sendo que as forrageiras já apresentavam sintomas de déficit hídrico, mostrando-se predominantemente secas. Os teores de matéria seca da forragem variaram entre 39,2 a 54,3 %.

A forragem acumulada nas pastagens diminuiu com a intensidade de degradação, assim como aumentou a proporção a solo exposto (Figura 10). Apesar desta tendência a pastagem caracterizada com média degradação apresentou menor biomassa acumulada e maior exposição do solo.

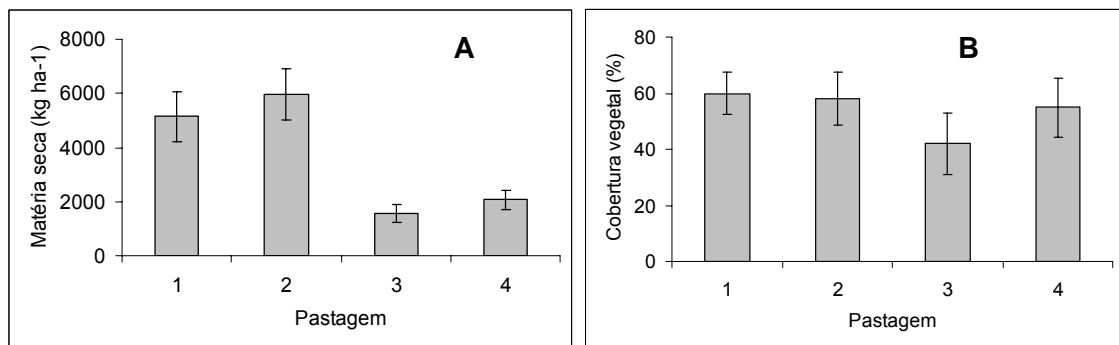


Figura 10. Matéria seca acumulada (A) e cobertura vegetal (B). Pastagem com nula degradação (1); pastagem com baixa degradação (2); pastagem com média degradação (3) e pastagem com intensa degradação (4). Linhas verticais correspondem ao desvio padrão.

### 3.2. Avaliação da degradação de pastagem

O predomínio de pastagens cultivadas na região noroeste de Minas Gerais, originalmente cobertas por uma vegetação de Cerrado, é uma consequência da intensa ação antrópica a que esta região foi submetida. Na década de 1970, houve grande expansão da produção pecuária devido, especialmente, ao baixo valor das terras, a oferta de crédito e o surgimento de espécies forrageiras com alta capacidade de adaptação ao clima e a baixa fertilidade dos solos.

A degradação destas pastagens provocou direta ou indiretamente impactos na região, pois o uso inadequado dos solos provoca rápida degradação física e química. Com a interpretação da imagem Ikonos II foi identificado quatro categorias de pastagens degradadas: nula degradação, baixa degradação, média degradação e intensa degradação (Figura 11). As áreas de solo exposto são utilizadas com a agricultura cobrindo pequenas áreas destinadas ao plantio do sorgo e milho. As pastagens cultivadas destinam-se à alimentação do gado. Áreas de corpos d'água completam o quadro do mapeamento, sendo que os dois principais corpos d'água estão localizados um pouco ao sul e ao norte da área de estudo.

As pastagens que ocupam 20,3 % da área total da imagem apresentam respostas espectrais distintas, em função da presença de invasoras, cupins, solo descoberto e os diferentes estádios de desenvolvimento vegetativo. De um total de 10.081,5 ha (Quadro 7) avaliados, aproximadamente 77 %, correspondem às áreas de vegetação, 2,8 % pertencem à classe de solo exposto que incluem áreas preparadas para cultivo e estradas.

As pastagens com nula degradação caracterizaram-se, pelo vigor da forrageira, ausência de plantas invasoras e, ou cupins, sendo que foram identificados na imagem pela coloração verde e textura homogênea, correspondendo a 3,9 % da área total.

Pastagens com baixa degradação foram caracterizadas, pelo baixo vigor da forrageira, menor cobertura do solo e por apresentar plantas invasoras ou cupins. Estas foram identificadas pela sua coloração verde com pontos brancos e textura um pouco grosseira, sendo que ocupa cerca de 6 % da área total.

As pastagens de média degradação que apresentam intensa presença de espécies invasoras e maior exposição do solo apresentaram coloração marrom com pontos claros e textura variando de lisa a rugosa e corresponderam a 4,5 % da área total.

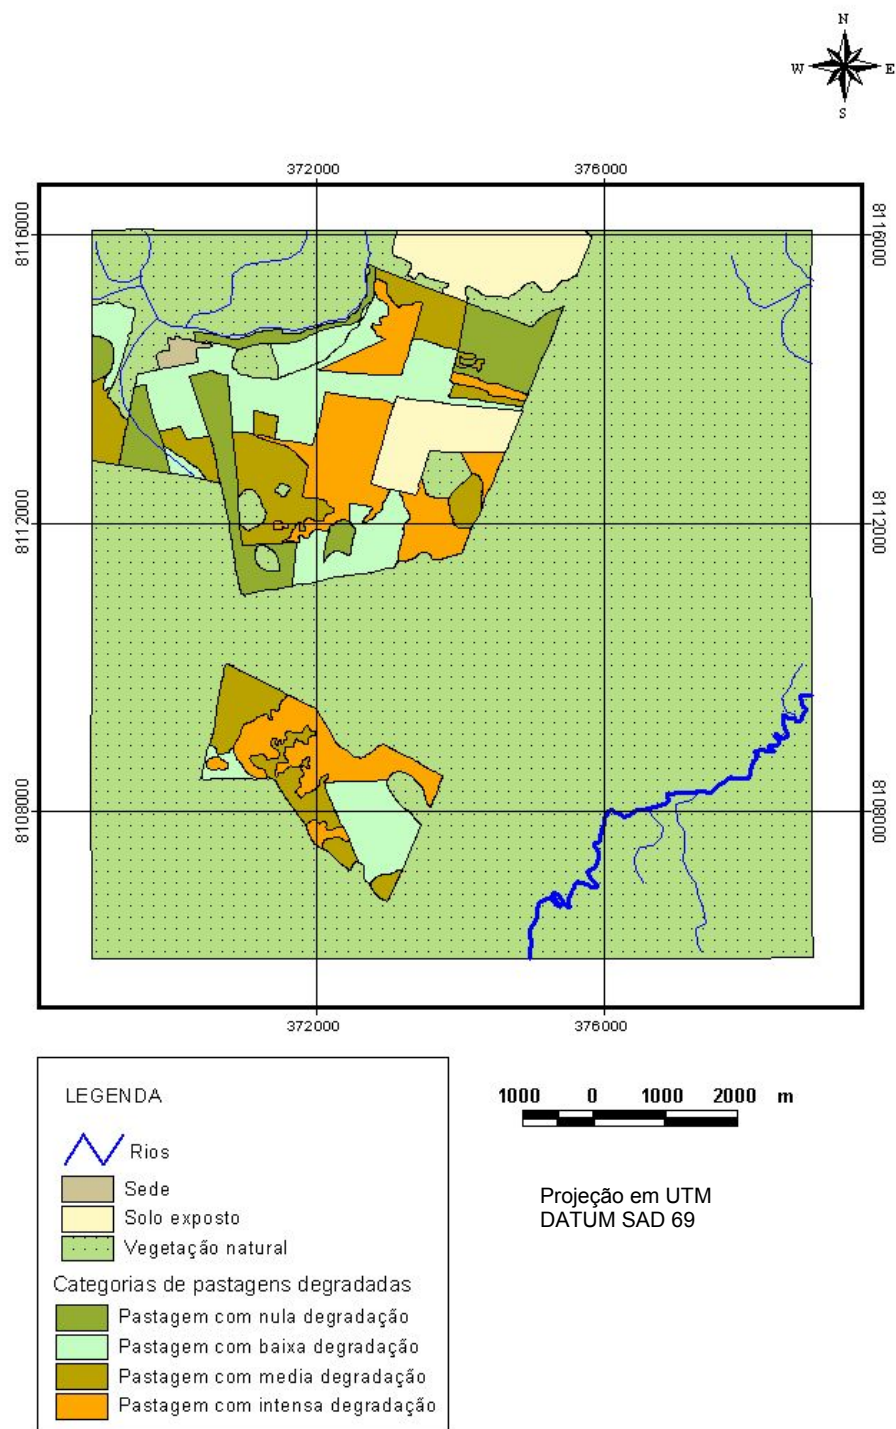


Figura 11. Mapa das classes de degradação das pastagens, obtida pela interpretação visual da Imagem Ikonos de uma área de 100 km<sup>2</sup>, na fazenda São Geraldo, município de João Pinheiro, MG, obtida em 14 de abril/2005.

Quadro 7. Área e distribuição relativa das classes de uso do solo, na fazenda São Geraldo, município de João Pinheiro, MG, estimadas a partir da interpretação visual de imagem Ikonos II, capturada em 14 de abril de 2004

Classes de uso	Área	
	(ha)	(%)
Pastagem com nula degradação	350,16	3,9
Pastagem com baixa degradação	688,84	6,8
Pastagem com média degradação	450,86	4,5
Pastagem com intensa degradação	625,82	5,1
Sede da fazenda	18,80	0,1
Solo exposto	202,50	2,8
Vegetação nativa	7.744,60	76,8
Total	10.081,46	100,0

As pastagens consideradas de intensa degradação caracterizadas pelo baixo vigor da forrageira, intensa exposição do solo, ocorrência de cupinzeiros e intensa infestação de plantas invasoras, foram distinguidas na imagem pela coloração marrom forte e pela textura muito grosseira, ocupando 5,1 % da área total.

Constatou-se que 33 % das pastagens são moderadamente degradadas, e que, cerca de 51 % delas apresentam em estágios mais avançados de degradação.

O mapa de degradação das pastagens apresenta índice Kappa de 0,85. Considerando que  $0,8 < K \leq 1$  é tido como excelente, indicando alta eficiência para classificação das pastagens. Segundo Brites (1996) o índice Kappa é um procedimento utilizado para mensurar a exatidão das classificações temáticas, pois representa a matriz de erros (Anexo Quadro 1) para cada categoria.

A partir da interpretação (Figura 12) da imagem Ikonos II foi possível gerar a seguinte descrição.

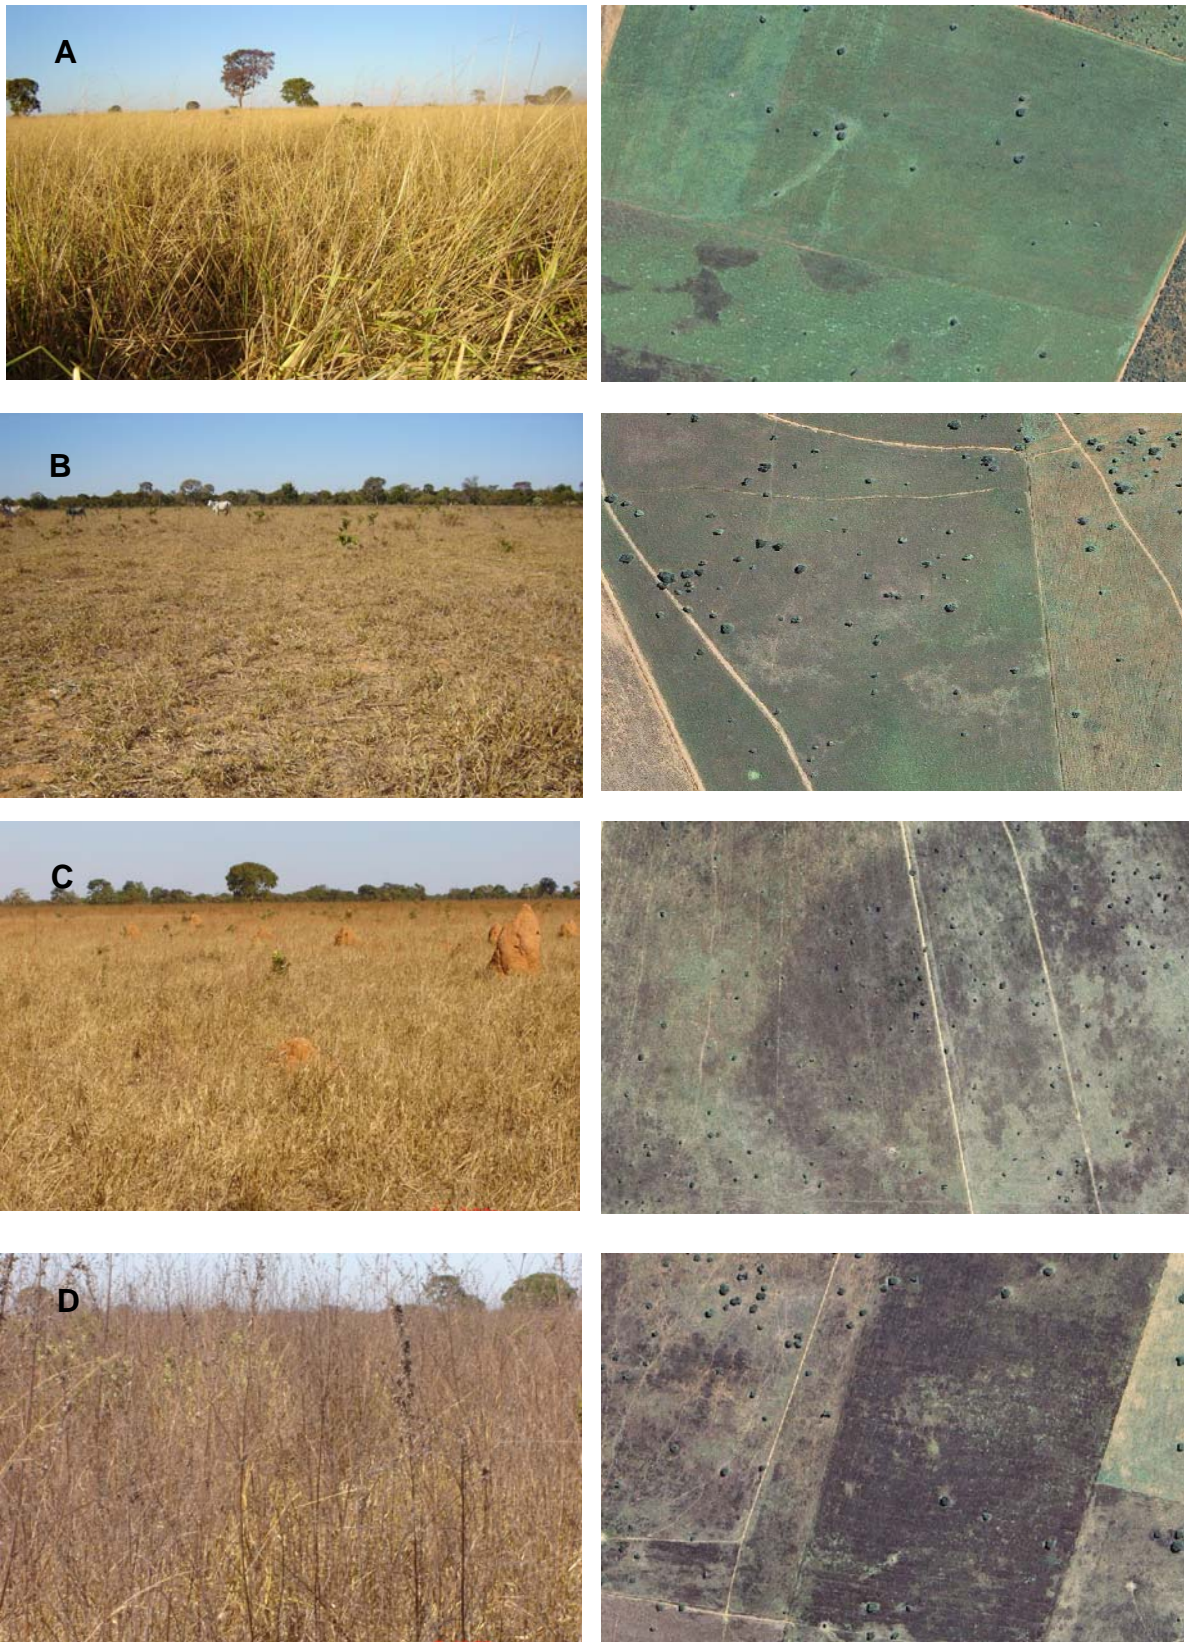


Figura 12. Fotos e imagens de pastagem com diferentes estágios de degradação, pastagem com nula degradação (A), pastagem com baixa degradação (B), pastagem com média degradação (C) e pastagem intensa degradação (D).

Pastagem com nula degradação: apresentada pelas áreas de uso do solo em formatos regulares, com menor influência do solo na resposta espectral do sensor, quando a cobertura graminoíde. Nas pastagens predominam a *Brachiaria brizantha*, *Brachiaria decumbens*.

Pastagem com baixa degradação: como na classe anterior, nesta categoria estão as grandes áreas de formato geométrico, porém, com menor influência do solo na resposta que chega ao sensor, devido ao desenvolvimento das plantas forrageiras e plantas invasoras.

Pastagem com média degradação: de formato geométrico, porém, com maior influência do solo exposto, alta incidência de plantas invasoras. Presença de térmitas em alta proporção, proporcionando a cobertura do terreno.

Pastagem com intensa degradação: nesta categoria encontra-se com alta incidência de plantas invasoras e espécies pioneiras plantas herbáceas, mantendo o solo parcialmente coberto e em alguns pontos solos exposto. A presença da forrageira é praticamente nula.

O estudo e traçado dos padrões de drenagem, relevo, uso da terra e textura fotográfica foram os parâmetros considerados na caracterização das categorias de pastagem e uso do solo (Quadro 8).

Quadro 8. Classes de uso da terra e características descritivas observadas na imagem do satélite Ikonos II

Classes	Uso da terra			Relevo				Textura	Drenagem	
	tipo	tamanho	Intensidade	Forma	Padrão	Dissecação	Crista		Padrão	Densidade
Pastagem c/ nula degradação	pt	m	a	r	so	b	a	f	d	b
Pastagem c/ baixa degradação	pt	m	a	r	p	b	a	m	d	b
Pastagem c/ média degradação	pt	m	a	r	p	b	a	m	d	b
Pastagem c/ intensa degradação	pt	m	a	r	p	b	a	m	d	b
Solo exposto	se	m	a	r	so	b	a	f	d	b
Área inundável	vn	g	su	i	p	b	a	m	d	b
Sede	o	p	a	r	so	b	a	f	d	b

Uso da terra - Tipo: agricultura (a), solo exposto (se), vegetação nativa (vn), pastagem (pt) e outros (o) – Tamanho: pequena (p), média (m) e grande (g) – Intensidade de uso: sem uso (su), muito baixo (mb), baixo (b); médio (m); alto (a) – Forma: irregular (i) e regular (r). Relevo – Padrão: Plano (p), suave ondulado (so), ondulado (o), forte ondulado (fo); Dissecação: baixo (b), médio (m), alto (a); Crista: nítida (n), difusa (d); ausente (a). Textura fotográfica - fina (f), média (m); grosseira (g) e muito grosseira (mg). Drenagem – Padrão: Dendrítico (d); densidade: baixa (b), média (m), alta (a); Grau de uniformidade: baixo (b), médio (m), alto (a).

### 3.3. Discriminação de espécies forrageiras cultivadas

A imagem do sensor Ikonos II, composta pelas bandas 1, 2, 3 e uma banda na região do infravermelho, juntamente com os levantamentos de campo permitiram identificar as principais gramíneas forrageiras presente na área (Quadro 9), gerando o mapa das principais gramíneas forrageiras cultivadas (Figura 13) apresentando um Kappa de 0,89, considerado excelente. O gênero *Brachiaria* foi predominante (1.693,2 ha) e em menor proporção ocorreu o *Andropogon gayanus* (191,7 ha) e o *Panicum maximum* (271,8 ha).

As gramíneas forrageiras proporcionaram resposta espectral distintas, possibilitando separações em classes. A *Brachiaria* apresentou uma coloração mais verde e textura menos rugosa. Para o *Andropogon* houve grande semelhança com *Panicum* quanto à resposta espectral, com textura variando de lisa a rugosa, sendo que o que o distinguiu foi à coloração marrom com pontos claros menos visíveis no *Panicum*.

Quadro 9. Área ocupada e distribuição relativa das forrageiras cultivadas nas pastagens, na Fazenda São Geraldo, município de João Pinheiro, MG, estimadas por meio da imagem Ikonos II, capturada em 14 de abril de 2004

Gramíneas forrageiras	Área	
	(ha)	(%)
<i>Brachiarias (decumbens e brizantha)</i>	1.693,2	80,3
<i>Andropogon gayanus</i>	191,7	9,0
<i>Panicum maximum</i>	230,7	10,7
Total	2.115,6	100,0

A expressiva participação dessas classes na composição da paisagem demonstra o sistema produtivo da região. Isto ocorre devido à importância econômica para a região.

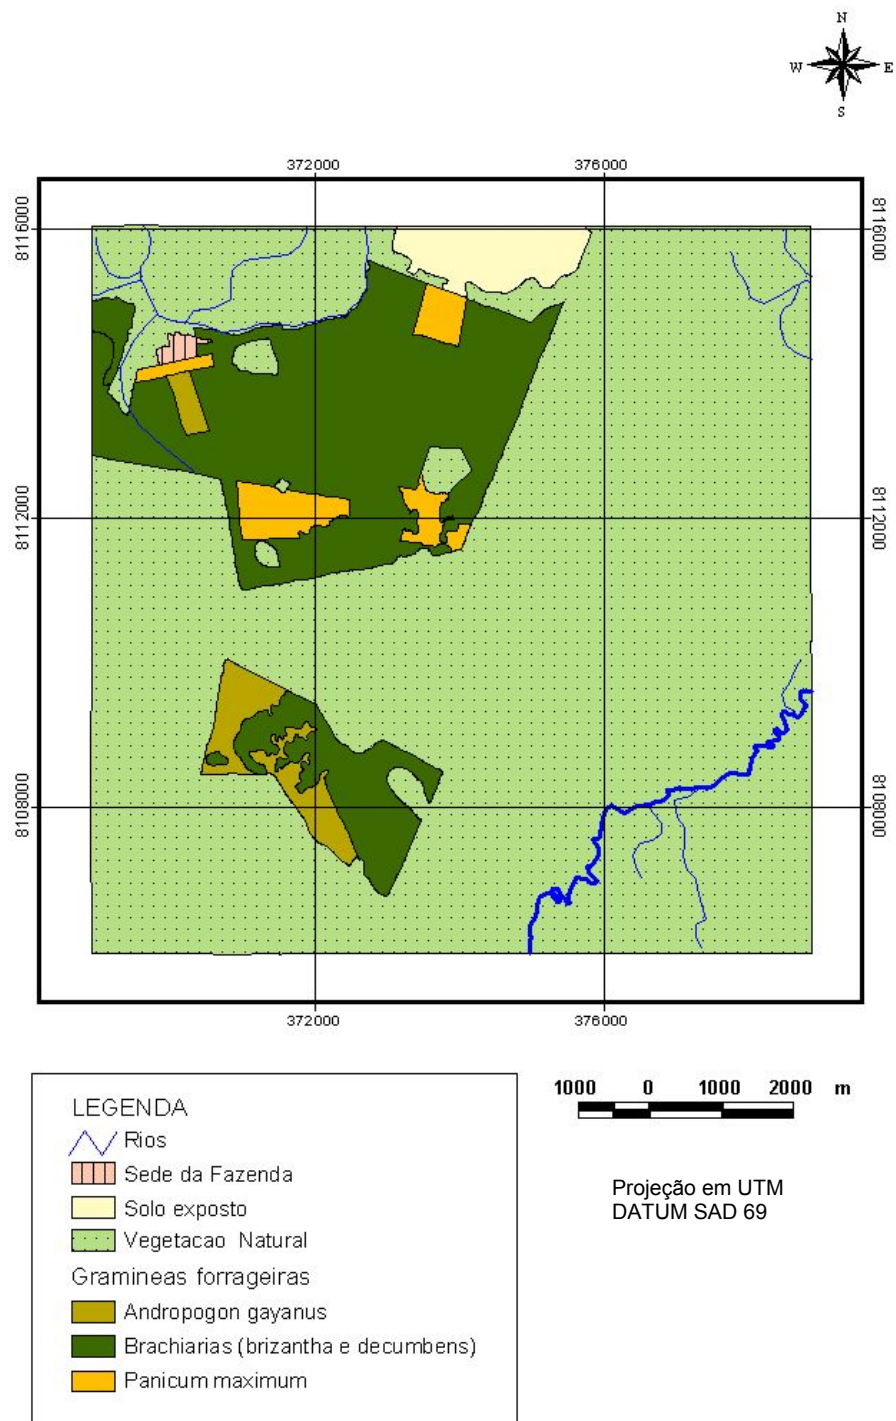


Figura 13. Mapa das classes de gramíneas presentes nas pastagens, obtida pela interpretação visual da Imagem Ikonos de uma área de 100 km<sup>2</sup>, na fazenda São Geraldo, município de João Pinheiro, MG, obtida em 14 de abril/2005.

### 3.4. Uso e Cobertura do solo

Para a análise do uso e cobertura do solo (Quadro 10) utilizou-se a imagem de satélite Ikonos II, mapas planialtimétricos, mapas pré-existent e observações de campo.

As descrições das doze classes no mapeamento do uso e cobertura vegetal (Figura 14) foi obtida pela imagem Ikonos II de resolução de 1 m o que permitiu definir maior detalhamento do mapeamento. Entre estas sete com cobertura vegetal (Cerrado) e as cinco classes restantes correspondem às classes de usos diversos.

Foi possível separar as áreas com vegetação por categorias, sendo distinguíveis visualmente na imagem na região do infravermelho, que realça as árvores presente, áreas de solos parcialmente expostos. Áreas de solo exposto apresentam-se com textura fina e clara e áreas de solo inundável apresentam-se com coloração escura e textura fina, com poucas árvores. As pastagens cultivadas foram visualizadas pelas formas regulares.

Quadro 10. Ocupação por diferentes classes de uso e cobertura vegetal natural na área coberta pela imagem Ikonos II

Classes de uso e cobertura	Área	
	(ha)	(%)
Cerradão	376,91	3,7
Cerrado típico	2.262,97	22,4
Campo limpo	663,60	6,5
Cerrado ralo	1.354,70	13,4
Campo sujo	603,52	5,9
Mata ciliar	245,68	2,4
Mata densa	494,68	3,6
Pastagem natural	362,80	3,2
Pastagem cultivada	2.319,42	23,0
Sede	18,82	0,1
Solo exposto	203,25	2,0
Área inundável	1.175,07	11,6
Total	10.081,46	100,0

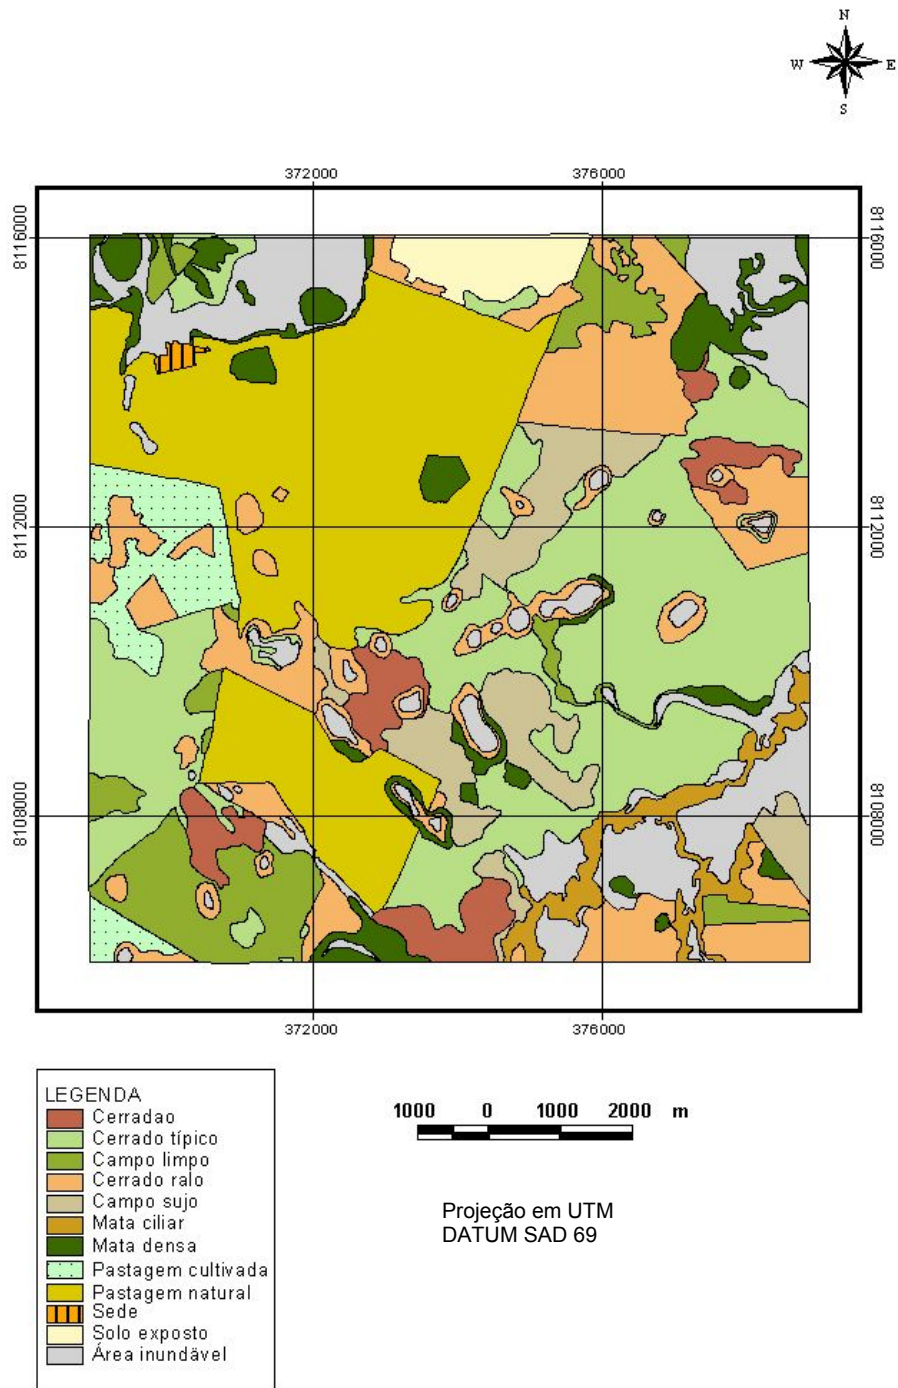


Figura 14. Mapa de uso e cobertura do solo, obtida pela interpretação visual da Imagem Ikonos de uma área de 100 km<sup>2</sup>, na fazenda São Geraldo, município de João Pinheiro, MG, obtida em 14 de abril/2005.

Constatou-se que a imagem do Ikonos II era composta, predominantemente, por formas irregulares, que correspondem à vegetação natural, seguidas pelas áreas de pastagem com formas regulares. As informações obtidas permitiram verificar que a delimitação das diferentes formas de paisagem pela interpretação da imagem foi bem sucedida, haja vista, que teve a sua exatidão verificada para o mapa da Figura 6, foi caracterizado por um índice Kappa de 0,89 (matriz de confusão - Apêndice Quadro 2).

O cerrado compreende uma vegetação xeromórfica com fisionomia diversa, de arbórea densa, com porte quase florestal até graminoíde, fisionomia essencialmente campestre. Na área estudada, o cerrado é composto pelas fisionomias cerradão, cerrado típico, ralo e campo sujo, limpo, com áreas de terras inundáveis e com usos diversos (Figura 15).

-cerradão tem a fisionomia florestal com aspecto xeromórfico semelhante ao cerrado quanto à composição florística, mas com porte mais alto, verificando-se a presença de espécies florestais. Possui três estratos nítidos: o arbóreo, o arbustivo e o herbáceo rasteiro, composto predominantemente, de gramíneas.

-cerrado típico é um subtipo de vegetação predominantemente arbóreo/arbustivo, com cobertura arbórea de 20 a 50 % com altura entre três a seis metros. É uma fisionomia intermediária entre o cerrado e o cerrado ralo.

-cerrado ralo tem vegetação arbóreo-arbustivo, com cobertura arbórea de 5 a 20 % com altura entre dois a três metros. Representa uma fisionomia mais baixa e menos densa de cerrado típico.

-campo sujo é tipo fisionômico com predominância de vegetação herbáceo/arbustivo, com arbustos e subarbustos esparsos cujas plantas, muitas vezes, são espécies arbóreas de cerrado no sentido restrito.


-campo limpo tem predominantemente plantas herbáceas, com raros arbustos e completa ausência de árvores.

-área inundável apresenta palmeira arbórea, circundadas por campo limpo. A cobertura arbórea varia de 5 a 10 %. Os solos são hidromórficos, saturados durante a maior parte do ano, condicionado ao afloramento de lençol freático. Ocupam os vales ou áreas planas acompanhando linhas de drenagem mal definidas.



20 m -

0 m -



**Mata densa,**  
vegetação primária  
arbustiva, altitude  
de 527 m, relevo  
plano.



18 m -

0 -



**Mata ciliar,**  
vegetação  
primária, altitude  
que varia de 511 a  
494 m, relevo  
suave ondulado.




8m -

0 -



**Cerradão,**  
vegetação arbórea,  
altitude que varia  
entre 533 a 516 m,  
relevo suave  
ondulado.



8 m -


0 -



**Cerrado típico,**  
vegetação  
arbórea/arbustiva,  
altitude que varia  
de 527 a 516 m,  
relevo plano.

Figura 15. Imagem Ikonos, perfil e descrição das diferentes coberturas vegetais na Fazenda São Geraldo, município de João Pinheiro, MG.

Continuação...




**Campo sujo**,  
vegetação  
arbustiva, altitude  
que varia entre  
521 a 527 m,  
relevo plano.



**Cerrado ralo**,  
vegetação  
arbustiva/herbácea,  
altitude que varia  
entre 521 a 527 m,  
relevo plano.



**Campo limpo**,  
vegetação  
herbácea,  
altitude que varia  
entre 521 a 527  
m, relevo plano.



**Pastagem  
natural**, vegetação  
de gramínea,  
altitude que varia  
entre 533 a 524 m,  
relevo plano.

Figura 15. Imagem Ikonos, perfil e descrição das diferentes coberturas vegetais na Fazenda São Geraldo, município de João Pinheiro, MG.

### 3.5. Modelo Digital de Elevação – MDE

O Modelo Digital de Elevação (Figura 16) foi gerado a partir de dados primários de elevação (curvas de nível de 5 metros) por interpolação, resultando numa grade onde as células estavam associadas a um valor que representa a elevação local. Devido a existência de diferentes métodos de interpolação, foram gerados vários MDEs e selecionado o que apresentou melhor ajuste visual.

A partir da identificação das classes de uso e ocupação do solo, torna-se fundamental estabelecer os procedimentos de melhor aproveitamento espacial em áreas de cerrado.

O MDE fornece informações importantes do relevo que associado às Informações de solo, possibilita estabelecer com confiança um manejo adequado de pastagem na área estudada.

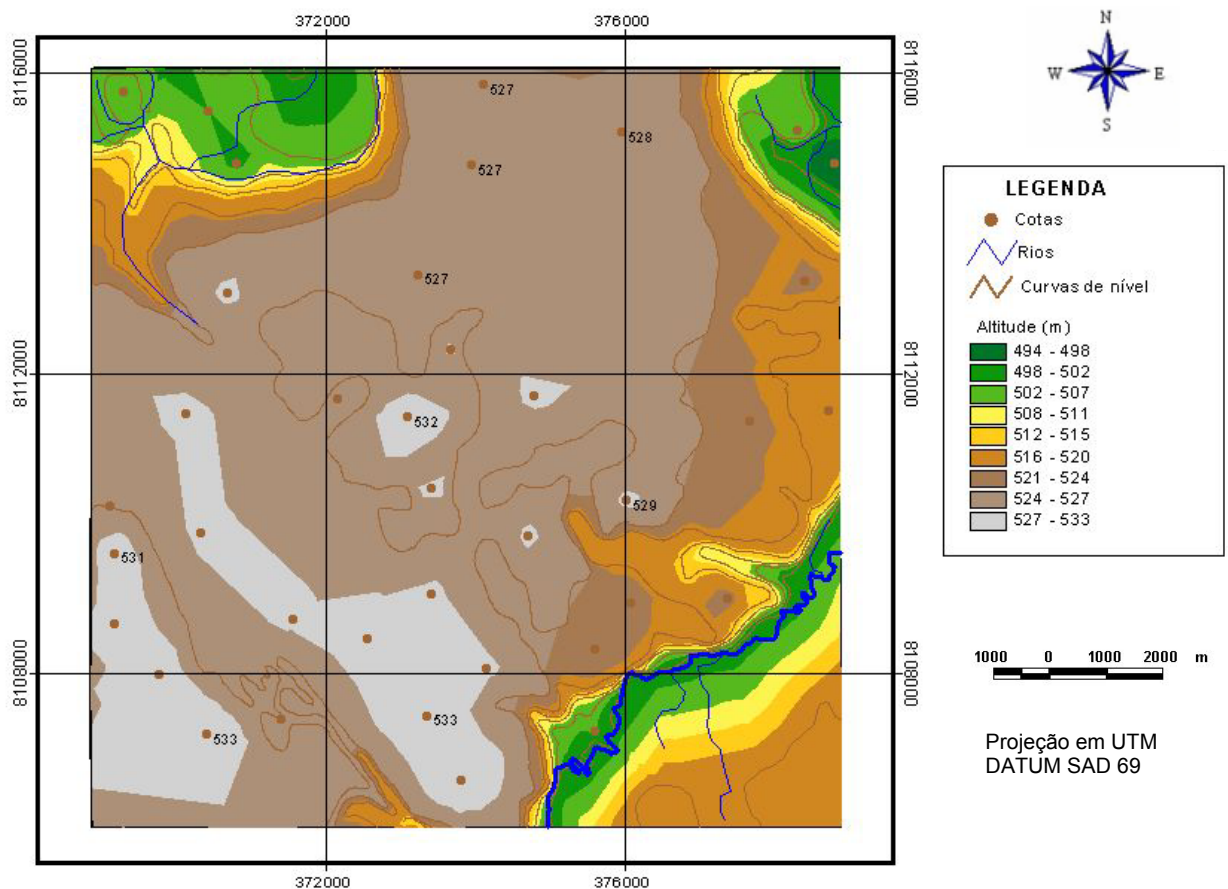


Figura 16. Modelo Digital de Elevação – MDE, obtido a partir da base cartográfica da Fazenda São Geraldo com equidistância das curvas de nível de 5 metros em escala de 1:25.000, 1999.

## 4. CONCLUSÕES

De acordo com os resultados obtidos neste trabalho, concluiu-se que:

A classificação visual da imagem Ikonos II possibilita discriminar as pastagens quanto à categoria de degradação, possibilitando conhecer o comportamento espectral das pastagens.

A amostragem de solo realizada não é capaz de caracterizar o ambiente solo com mais detalhamento.

A resposta da imagem Ikonos juntamente com o trabalho de campo possibilita a separação das principais gramíneas forrageiras encontradas na área, obtendo um Kappa de 0,89 considerado excelente.

De acordo com o índice Kappa obtido, a classificação visual de imagem Ikonos II tem potencial para diagnosticar as categorias de pastagens degradadas.

A cobertura vegetal composta predominantemente por formas irregulares foi facilmente separada em categorias (fitofisionomia) através da resposta espectral facilmente distinguível na imagem na região do infravermelho.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

AGRO-AMBIENTAL ASSESSORIA. **Relatório de impacto ambiental da Fazenda São Geraldo município de João Pinheiro**. SEPLAN/FUNDEP, Brasília. 2004, 256p.

ALVAREZ V., V. H.; NOVAIS, R.F.; BARROS, N.F.; CATARUTI, R.B.; LOPES, A. S. Interpretação de resultados das análises de solos. In: RIBEIRO, A. C.; GUIMARÃES, P.T.G.; ALVAREZ V., V. H. (ed) **Recomendações para uso de corretivos e fertilizantes em Minas Gerais**. Comissão de Fertilidade do solo do Estado de Minas Gerais, 5 aproximação. Viçosa, MG. 1999. 359p.

ANTUNES, F. Z. Caracterização climática do estado de Minas gerais: climatologia agrícola. **Informa Agropecuário**. Belo Horizonte. V. 12, n138, p 9-13. 1986.

ASSAD, E. D.; MADEIRA NETO, J. S. & MOREIRA, L. Uso de padrões radiométricos para separação de quatro espécies de gramíneas em condições de Cerrado. **Pesquisa Agropecuária Brasileira**, Brasília, v.26, n.10, p.1625-1633, 1991.

ASSAD, E. D. **Sistema de Informações geográficas. Aplicações na agricultura** – 2ed. Brasília : Embrapa-SPI/Embrapa-CPAC, 1998, 434p.: il.

BARCELOS, A. de O. **Sistemas extensivos e semi - intensivos de produção: pecuária bovina de corte nos cerrados**. In: SIMPÓSIO SOBRE CERRADO, 8.; INTERNATIONAL SYMPOSIUM ON TROPICAL SAVANNAS, 1., 1996, Brasília, DF. Biodiversidade e produção sustentável de alimentos e fibras no cerrado: anais. Planaltina, DF: EMBRAPA-CPAC, 1996. p. 130-136.

BURROUGH, P.A **Principles of Geographical Information Systems**. Oxford University. Press. Oxford, 1996.

CARVALHO, M. M. Recuperação de pastagens degradadas em áreas de relevo acidentado. In: DIAS, L. E. & MELLO, J. W. V. (eds.). **Recuperação de áreas degradadas**. Viçosa: UFV-DPS/Sociedade Brasileira de Recuperação de Áreas Degradadas, 1998. p.149-161.

CARVALHO, M. M. **Recuperação de pastagens degradadas**. Coronel Pacheco: EMBRAPA-CNPGL, 1993. 51p. (EMBRAPA-CNPGL. DOC. 55).

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

DEFELIPO, B. V. & RIBEIRO, A. C. **Análise Química do solo**. 2ª ed. Viçosa, Universidade Federal de Viçosa, 1997. 26p.

DIAS FILHO, M. B. Pastagens cultivadas na Amazônia oriental brasileira: processos e causas de degradação e estratégias de recuperação. In: DIAS, L. E. & MELLO, J. W. V. (eds.). **Recuperação de áreas degradadas**. Viçosa: UFV-DPS/Sociedade Brasileira de Recuperação de Áreas Degradadas, 1998. p.135-149.

DUTRA, L. G. & DUTRA, A. R. Manejo do solo e recuperação de pastagens. In: PEREIRA, J. C. (ed.). Simpósio de Brasilândia, 1, Brasilândia de Minas, MG, 1999. **Anais...** Brasilândia de Minas, 1999. p.131-146.

EMBRAPA-Embrapa Gado de Corte. Degradação e alternativas de recuperação e renovação de pastagens- Manuel Claudio Motta Macedo ArmindoNeivKichel, Ademir Hugo Zimmer. Comunicado Técnico, nº 62, novembro/2000, p.1-4. [www.embrapa.br](http://www.embrapa.br)

FERNANDES, M. F. **Avaliação da Aptidão Agrícola da Terra de parte do Setor Leste da Bacia do Rio Seridó, usando Sensoriamento Remoto e Geoprocessamento**. Campina Grande, UFPB, 1997. 186p. Dissertação de Mestrado.

FLORENZANO, T. G. Imagens TM-LANDSAT e HRV-SPOT na elaboração de cartas geomorfológicas de uma região do Rio Taquari, MS. **Pesquisa Agropecuária Brasileira**, Brasília, v.33, número especial, p.1721-1727, 1998.

FLORENZANO, T. G. Imagens de satélites para estudos ambientais. São Paulo: Oficina de textos, 2002. 97p.

GLERIANI, J. M. **Redes neurais artificiais para classificação espectral-temporal de culturas agrícolas**. São José dos Campos : INPE, 2004, 198p. : il. Tese (Doutorado em Sensoriamento remoto).

IHSE, M. & ROSE, E. Spectral measurements for estimation of biomass on limestone grassland. In: International Colloquium of Spectral Signatures of Objects in Remote Sensing, 3., 1985, Les Arcs. **Spectral Signatures of Objects in Remote Sensing**. Paris: ESA, 1985. p.455-458 (ESA SP – 247).

IWAI, O. K. **Mapeamento do uso do solo urbano do município de São Bernardo do Campo, através de imagem de satélite**. Ed. Ver. São Paulo, 2003. 127 p.

JONGERIUS, A. & HEINTZBERGER, G. The preparation of mammoth-sized thin sections. Soil survey papers 1. Wageningen: The soil survey Institute, 1963. 37p.

KURY, E. B. & VIEIRA, C.A O. **Classificação automática de imagens de alta resolução.** In NUGEO 2002 – workshop sobre geoprocessamento da UFV. 2002. Viçosa. **Anais...** Viçosa 2002. 4p Disponível em: <http://www.ufv.br/nugeo>. Acesso em: 27 de novembro 2004.

MACEDO, M. C. M.; NEIVKICHEL, & ZIMMER A. H. **Degradação e alternativas de recuperação e renovação de pastagens.** EMBRAPA Gado de Corte. Comunicado Técnico, nº 62, novembro/2000, p.1-4.

MANGABEIRA, J. A. DE C; LAMPARELLI, R. A. C; E AZEVEDO, E. C. Utilização de Imagem IKONOS II para identificação de uso da terra em área com alta estrutura fundiária. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., 2003, Belo Horizonte. **Anais.** São José dos Campos: INPE, 2003. p.165-167. CD ROM.

MEIRELLES, N. M. F. Degradação de pastagens: critérios de avaliação. In: PAULINO, V. T.; ALCÂNTARA, P. B.; BEISMAN, D. A.; ALCÂNTARA, V. B. G. (eds.). Encontro Sobre Recuperação de Pastagens, 1, Nova Odessa, 1993. **Anais...** Nova Odessa: IZ, 1993. p. 27-48.

MENDONZA, P. & LASCANO, C. **Mediciones en la pastura em ensayos de pastoreo.** In; Lascano, C. & Pizarro, E. (Eds.). Evaluación de pasturas com animales. Alternativas Metodológicas. Memórias. Cali, Colombia, pp. 143-165. 1985.

NASCIMENTO JÚNIOR, D.; QUEIROZ, D. S. & SANTOS, M. V. F. Degradação das pastagens e critérios para avaliação. In: PEIXOTO, A. M.; MOURA, J. C.; & FARIA, V. P. (eds.). Simpósio Sobre Manejo de Pastagem, 11, Piracicaba, 1994. **Anais...** Piracicaba: FEALQ, 1994. 325p.

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

QUEIROZ, J. E. R. Fundamentos de sistemas de informação geográfica. Programa de Suporte técnico á recursos hídricos-ABEAS. Curso de especialização em sensoriamento remoto e Sistema de Informação Geográfica. **Módulo 9.** Brasília-DF. 1996. 99p.

RIBEIRO, R. M. P, Avaliação de métodos de classificação de imagens IKONOS II para o mapeamento da cobertura terrestre – Viçosa: UFV, 2004. ix, 53f. : il. ; 29 cm (**Tese de Mestrado**).

RUIZ, H. A. **Incremento da exatidão da análise granulométrica do solo por meio da coleta da suspensão.** R. Bras. Ci. Solo, 29:297-300, 2005.

SANTOS, S. A. **Caracterização dos recursos forrageiros nativos da sub-região da Nhecolândia, pantanal, Mato-Grosso do Sul, Brasil.** Botucatu: UEP/FMVZ, 2001. 199p. Tese (Doutorado em Nutrição e Produção Animal) – Universidade Estadual Paulista/Faculdade de Medicina Veterinária e Zootecnia, 2001.

SNEATH, D. **State policy and pasture degradation in Inner.** Science, 281: 1147-1148. 1998.

SPACE IMAGING IKONOS **Imagery products and product guide**, 2002, 20p.

SPAIN, J. M. & GUALDRÓN, R. **Degradación y rehabilitación de pasturas.** In: VI Reunión del Comité Asesor de la RIEPT. Memórias. Red Internacional de Evaluación de Pastos Tropicales. Veracruz, México 1988. CIAT. p.269-283.

STODDART, L. A.; SMITH, A. D. & BOX, T. W. **Range management.** New York: Mcgraw-Hill Book, 1975. 431p.

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

ZIMMER, A.; SILVA, M. P. R. **Sustentabilidade e impactos ambientais da produção animal em pastagens.** In: PEIXOTO, A.M. et al. (eds.). Inovações tecnológicas no manejo de pastagens. SIMPÓSIO SOBRE MANEJO DA PASTAGEM, 18, Piracicaba, 2002. Anais. Piracicaba: Fealq, 2002.p. 31-58.

## **CAPÍTULO II**

### **Classificação automática em imagem Ikonos no mapeamento de pastagem em diferentes estágios de degradação**

#### **RESUMO**

A classificação automática é talvez, o mais importante passo no processamento de imagens. Os métodos de classificação automática comumente utilizados em imagens de média resolução tem eficiência questionável quando empregado na análise de imagens de alta resolução espacial. Dessa forma, as Redes Neurais Artificiais-RNA são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Com este trabalho objetivou-se avaliar o desempenho da RNA na identificação de pastagens com diferentes estágios de degradação utilizando imagem Ikonos. A área de estudo apresenta 1.305 ha e localiza-se no município de João Pinheiro, noroeste do estado de Minas Gerais. Os métodos de classificação automática de imagem utilizados foram ISODATA, Máxima Verossimilhança (MaxVer) e Redes Neurais Artificiais (RNA). A utilização das técnicas de classificação supervisionada em imagens Ikonos II, mostraram-se eficientes na separação das quatro categorias de degradação das pastagens. Os métodos de MaxVer e RNA apresentaram um Kappa de 0,897 e 0,907, respectivamente, portanto, apresentam alto potencial para classificação de imagem de alta resolução espacial. O método ISODATA foi estatisticamente inferior. As RNAs com 23 neurônios na camada oculta apresentaram um melhor índice Kappa tanto com amostras de treinamento como com amostras de teste.

Palavras chaves: classificação automática, geoprocessamento e pastagem.

## 1. INTRODUÇÃO

Os sensores dos satélites são capazes de captar constantemente, as imagens da terra, abrangendo extensas áreas e fornecendo informações atualizadas, que são extraídas por meio de técnicas de interpretação visual e de processamento automático das imagens (Iwai, 2003). O sensoriamento remoto tem sido utilizado no gerenciamento de recursos renováveis, na classificação e avaliação de recursos terrestres, no mapeamento de uso do solo, no monitoramento de áreas de vegetação e plantações.

O esforço no desenvolvimento de métodos computacionais para distinguir diferentes alvos em imagens digitais resultou em diversos algoritmos de classificação (Souto, 2000). A classificação automática é o mais importante aspecto do processamento de imagens (Crósta, 1996), sendo uma das principais tarefas envolvidas em um sistema de visão computacional. Seu objetivo é obter informações suficientes para distinguir objetos de interesse. O processo de classificação é baseado nos níveis de cinza ou cores, características de forma e textura dos objetos (Nascimento et al., 2003).

De acordo com Souto (2000) os métodos de classificação de imagens podem ser divididos entre aqueles que utilizam de informações das classes (objetos) que devem encontrar na imagem, e aqueles que procuram as classes sem nenhuma informação prévia. A estes adotou-se o termo de não-supervisionados, enquanto que os primeiros são denominados métodos supervisionados.

Os métodos supervisionados baseiam-se na informação de amostras de pixels de cada classe que se queira identificar na cena. Estas amostras contêm atributos que podem ser, por exemplo, o valor médio dos pixels e a sua variância. A partir da informação destes atributos é possível atribuir um pixel da cena a uma classe predeterminada.

Nos métodos não-supervisionados não se tem qualquer informação prévia sobre os alvos presentes na cena. Uma das técnicas utilizadas baseia-se na resposta espectral dos pixels da imagem em uma banda espectral por

meio do seu histograma ou por meio do método de “clustering”. Este método fundamenta-se no agrupamento (“cluster”) de pixels formados a partir da resposta espectral dos mesmos em duas ou mais bandas.

Segundo Novo (1992) as técnicas de classificação automática implicam na implementação de um processo de decisão para que o computador atribua certo conjunto de pontos da imagem (pixels) a uma determinada classe. São gerados neste processo, mapas temáticos ou cartas temáticas correspondentes aos temas de interesse, de acordo com critérios bem definidos.

Diversos métodos de classificação de imagens são utilizados na classificação de imagem, tais como Distância mínima, Máxima verossimilhança, Paralelepípedo, Distância de Mahalanobis, entre outros. Mas com o aparecimento de sensores de alta resolução espacial, a eficiência dos classificadores, comumente usados está sendo questionada, pois o alto grau de detalhe destas imagens torna mais evidente as variações espectrais entre os objetos.

Os algoritmos tradicionalmente usados no processo de classificação consideram normalmente que as classes são linearmente separáveis e utilizam como unidade de medida o pixel. Porém, com o aumento da resolução espacial e espectral das imagens produzidas por estes novos sensores, existe um aumento na variação interna das classes (objetos), e conseqüentemente uma sobreposição das classes no espaço característico, inviabilizando o uso destes procedimentos padrões (Kury & Vieira, 2004).

As maiores deficiências no processo de classificação, estão associadas à resolução do sensor e ao estabelecimento da regra de decisão adotada para designar os pixels à classe. O primeiro conjunto de deficiências está diretamente relacionado com a aquisição dos dados. O segundo conjunto relaciona-se com a estrutura, premissas e hipóteses utilizadas no desenvolvimento do método de classificação. Trabalhos têm sido produzidos com o intuito de sanar essas deficiências (Nishida & Bastos, 1998).

Imagem multiespectral, tipo Ikonos, traz consigo uma gama de dados. A diversidade das feições representadas apresenta um caráter dual. Por um lado, facilita visualmente a detecção das feições por meio de parâmetros fotointerpretativos. Por outro lado, a classificação automática passa a exigir um

maior cuidado do usuário, pois além da pura informação espectral os objetos da imagem possuem outros atributos que podem ser utilizados na classificação tal como forma e textura (Antunes, 2003).

A maioria dos classificadores automáticos baseia-se exclusivamente na detecção do padrão espectral, isto é, padrões de respostas espectrais de classes de cobertura do solo. Neste caso, para que a classificação seja bem sucedida, é necessário que as assinaturas espectrais dos alvos sejam bem definidas e distintas entre si, permitindo a distinção dos alvos com segurança. Os classificadores podem ser divididos em classificadores “pixel a pixel” e classificadores por regiões (Jensen, 2000).

Os classificadores que utilizam amostras de pixel a pixel podem ser separados em métodos estatísticos, que utilizam regras da teoria de probabilidade e determinísticos, que não utilizam probabilidade. Classificadores por regiões utilizam, além das informações espectrais de cada pixel, as informações espaciais que envolvem as relações com seus vizinhos. As áreas homogêneas são agrupadas baseadas nas propriedades espectrais e espaciais das imagens (Iwai, 2003).

A classificação por região é um método alternativo, e que diferentemente da classificação por pixel, onde a variabilidade espacial e a textura natural podem ser usados no processo de classificação. Ao invés de considerar as características espectrais de um determinado pixel no processo de decisão um agrupamento de pixels é selecionado e usado como unidade de classificação.

Entretanto, não há um método genérico ou uma abordagem formal que seja apontada para classificação de imagens de alta resolução espacial. Os métodos propostos ainda são pouco conhecidos e pouco aplicados. No trabalho de Nascimento et al. (2003) aponta um método para classificação de imagens digitais baseada na característica de textura, que é descrita em termos de medidas estatísticas calculadas por meio de matrizes de covariância.

Segundo Lillesand & Kiefer (1994), na classificação por máxima verossimilhança (MaxVer) a distribuição dos valores de refletância em uma área de treinamento é descrita por uma função de densidade de probabilidade, desenvolvida com base na estatística Bayesiana. Esta classificação avalia a

probabilidade de uma determinada pixel pertencer a uma categoria e o na categoria a qual ele tem a maior probabilidade de ser associado (Figura 17).




Figura 17. Equiprobabilidade do método Máxima verossimilhança. Fonte: Lillesand & Kiefer (1994).

A aplicação do método MaxVer pode classifica áreas de pastagens, águas, área agricultável, área urbana, entre outras, propiciando maior facilidade de análise, como também auxilia nas classificações de diversos usos do solo em uma imagem de satélite, facilitando o trabalho e compreensão da imagem (Iwai, 2003).

O uso de tecnologias baseadas em conceitos de Inteligência Artificial (IA) tem se mostrado uma alternativa promissora devido ao seu caráter inovador de análise dos dados. Entre as técnicas de IA as Redes Neurais Artificiais (RNAs) têm sido utilizada, com frequência, para classificação de imagens de sensoriamento remoto (Nishida & Bastos, 1998).

A rede neural consiste em um método de solucionar problemas com inteligência artificial, que simulem o cérebro humano (Lippmann, 1987) inclusive seu comportamento, ou seja, aprendendo, errando (Machado, 1992).

Conforme Dyminski (2000), uma rede neural é constituída por diversos neurônios dispostos em camadas. Usualmente as camadas são classificadas em três grupos: camada de entrada: onde os padrões são apresentados à rede; camadas escondidas: onde é feita a maior parte do processamento; camada de saída: onde o resultado final é concluído e apresentado.

Os neurônios internos são de suma importância na rede neural, pois provou-se que sem estes torna-se impossível a resolução de problemas linearmente não separáveis. Em outras palavras pode-se dizer que uma rede é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões (Brondino, 1999).

A rede neural (Figura 18) passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo a sistemática necessária para executar o processamento desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos. Weigend (1990) comenta que o número de padrões de treinamento deve ser no mínimo dez vezes maior que o número de conexões da rede. O que pode ser uma condição muito restritiva para algumas aplicações.




Figura 18. Organização da RNA em camadas. Fonte: Tatibana & Kaetsu (2006).

As RNAs têm sido extensivamente utilizadas como classificadores em inúmeros segmentos. A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de

acordo com os padrões apresentados. Em outras palavras, elas aprendem por meio de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior (Galo, 2000).

O algoritmo de treinamento ou aprendizagem "*backpropagation*" utilizado para treinar uma rede *Perceptron Multicamadas* é derivado regra Delta generalizada, e se constitui no método mais utilizado para aprendizagem supervisionada. Esse algoritmo permite um ajuste de pesos em cada uma das camadas da rede e é projetado para minimizar a soma do quadrado do erro. O componente essencial desse algoritmo é o método iterativo que propaga regressivamente o erro requerido para adaptar os pesos, a partir dos neurônios da camada de saída para os nós das camadas precedentes (Lippmann, 1987).

Muitas vezes, as propriedades estatísticas de uma classe não podem ser estimadas, de modo que os problemas de teoria de decisão são melhor trabalhado pelos métodos que produzem diretamente as funções de decisão através dos dados de treinamento, sem levar em conta qualquer informação probabilística das classes de interesse (Gonzalez & Woods, 2000).

Uma das maiores vantagens das redes neurais é sua capacidade de generalização, ou seja, uma rede treinada pode classificar dados de treinamento, sem conhecimento prévio de todo o conjunto (Zell, 1995).

As aplicações das RNAs são inúmeras, tais como: análise e processamento de sinais; controle de processos; robótica; classificação de dados; reconhecimento de padrões em linhas de montagem; filtros contra ruídos eletrônicos; análise de imagens; análise de voz e avaliação de crédito (Beluco, 2002).

Na tentativa de superar as limitações inerentes aos métodos de classificação de imagens convencionais, têm-se intensificado pesquisas de redes neurais artificiais aplicadas na classificação de dados por sensoriamento remoto. Tais abordagens de classificação têm apresentado resultados expressivos quando comparados aos métodos tradicionais (Venturieri & Santos, 1998). Tal fato tem levado a uma crescente utilização dessa ferramenta, particularmente das redes multicamadas treinadas com o algoritmo de aprendizagem *backpropagation*.

Atualmente, observam-se avanços na classificação automática de imagem assim como a diversificação crescente de suas aplicações. Diante desse aspecto, essa tecnologia pode ser aplicada como ferramenta que possibilite referenciar espacialmente a cobertura do solo, de acordo com o sistema agrícola de diferentes características. Neste contexto, este trabalho foi desenvolvido com o objetivo de testar métodos de classificação em imagem Ikonos II de alta resolução espacial para o mapeamento de pastagens de diferentes categorias de degradação.

## **2. MATERIAL E MÉTODOS**

### **2.1. Localização e caracterização da área**

A área de estudo localiza-se na Fazenda São Geraldo no município de João Pinheiro, ocupa uma área de 1.305 ha, noroeste do estado de Minas Gerais ( $16^{\circ} 56' 27''$  S e  $46^{\circ} 12' 22''$  O). Possui altitude em torno de 532 m, precipitação pluviométrica anual de aproximadamente 1.200 mm e vegetação predominante de cerrado. O clima é tropical úmido e seco de savana (Aw de acordo com classificação de Köppen), com meses mais seco durante o inverno. O relevo predominante é extensos planaltos. As principais classes de solos encontradas são Latossolos, Neossolos Quartzarênicos, Neossolos Flúvicos e Gleissolos.

A região foi escolhida pela representatividade fisiográfica do bioma cerrado, por ser a pecuária a principal atividade econômica e, ainda, pela possibilidade de apoio logístico da Companhia de Desenvolvimento dos Vales do São Francisco (CODEVASF) por meio de sua Unidade de Bovinocultura de Brasilândia de Minas.

### **2.2. Imagem do satélite**

Na realização deste trabalho, foi utilizada imagem do satélite Ikonos II, resolução espacial de 1 m, com 11 bits (2.048 níveis de cinza) capturada no dia 14 de abril de 2005.

Utilizou-se para fins de apoio a interpretação da imagem dados bibliográficos, tais como: livros, periódicos, dados censitários do IBGE (2001), dissertações, arquivos e mapas diversos e mapas de reconhecimento semidetalhado de solos, e de uso atual das terras em escala de 1:40.000, produzido por pela AGRO-AMBIENTAL ASSESSORIA, em 2004.

Após a extração das informações contidas no Capítulo I referente ao reconhecimento da área e geração de mapas temáticos, foi selecionado uma

área (Figura 19) que contemplasse as pastagens com diferentes estágios de degradação para aplicação dos métodos de classificação automáticos.



Figura 19. Imagem do satélite Ikonos II, de parte da Fazenda São Geraldo localizada no município de João Pinheiro, MG, obtida em 14 de abril/2005.

### 2.3. Trabalho de Campo

As informações de campo obtidas no reconhecimento geral da área, feito por meio de um roteiro pré-estabelecido, foram correlacionadas com as informações da imagem com o objetivo de conhecer os padrões fotointerpretativos de tonalidades de cores e de textura na imagem Ikonos II.

### 2.4. Classificação da imagem

Obedeceu-se todas as etapas que envolvem o processo de classificação de imagens, partindo, desde o trabalho de campo, até o resultado da classificação.

Utilizou-se os seguintes softwares ARC/INFO versão 8.2 (Environmental Systems Research Institute), ArcView GIS versão 3.2a (Environmental Systems Research Institute), JavaNNS - Java Neural Network Simulator - Version 1.1 (University of Tübingen); SNNS - Stuttgart Neural Network Simulator, Version 4.2. (University of Stuttgart e University of Tübingen) e ERDAS IMAGINE versão 8.5 – ERDAS Systems, Funcpow e Microsoft Excel 2000 (Microsoft Corporation).

O arquivo de treinamento e validação é composto pelas amostras coletadas por pixel. As classes informacionais definidas foram:

- 1) mata;
- 2) solo exposto;
- 3) área inundável;
- 4) pastagem com nula degradação;
- 5) pastagem com baixa degradação,
- 6) pastagem com média degradação e
- 7) pastagem com intensa degradação.

Foram utilizados três métodos de classificação: a) ISODATA, b) MaxVer e c) RNA.

Na classificação pelo ISODATA foi usado um método híbrido, utilizando os métodos supervisionados e não-supervisionados. O índice Kappa foi calculado a partir de 50 pontos observados a campo e correlacionados na imagem, utilizando as mesmas classes informacionais da RNA e MaxVer.

Foram testadas todas as bandas do satélite Ikonos e ainda uma composição no NDVI e o MDE.

## **2.5. Coleta das amostras de treinamento e validação para processamento da rede neural**

A primeira etapa na classificação pela Rede Neural Artificial foi à obtenção das amostras de treinamento e validação. Para isso, foi feita uma composição de todas as bandas numa mesma imagem, pela opção “Layer Stack” no software ERDAS IMAGINE 8.5. Previamente todos os atributos foram re-escalados para ficarem com seus valores associados às células na faixa de

0 a 1 para cada atributo e gerou-se um arquivo de treinamento e outro de validação no formato requerido (planilha excel).

As amostras para treinamento e validação constaram da definição e extração de pequenos segmentos de imagem a partir do ponto georreferenciado no campo presente em cada classe informacional. As amostras de treinamento e de validação de cada classe informacional foram constituídas de 400 pixels, totalizando 2.800 pixels para cada uma das etapas. Os dados de treinamento e validação foram combinados a fim de constituírem um único arquivo de padrões no formato aceito pelo simulador (formato requerido pelo JavaNNS). Foram realizados os treinamentos com várias arquiteturas de RNA's, buscando-se aquela que apresente o menor erro caracterizado pelo índice Kappa.

Para estabelecer o número de camadas, uma série de simulações foi realizada, nas quais o número e a configuração da camada intermediária foram sistematicamente modificados. Desta forma a arquitetura considerada ideal foi constituída de 4 neurônios na camada de entrada, 23 neurônios na camada oculta e 7 neurônios na camada de saída (Figura 20). Procurando verificar o desempenho da classificação pela RNA e MaxVer, as amostras de treino e validação foram escolhidas de forma bastante criteriosa, evitando-se padrões que pudessem estar fora das respectivas classes informacionais.

O arquivo de validação foi apresentado à arquitetura de RNA e ao classificador MaxVer, gerando para a RNA e para o MaxVer uma matriz de confusão com o seu respectivo índice Kappa e outros valores estatísticos. Os arquivos de saída da rede foram convertidos em uma imagem, para cada uma das arquiteturas de rede contendo a área de interesse.

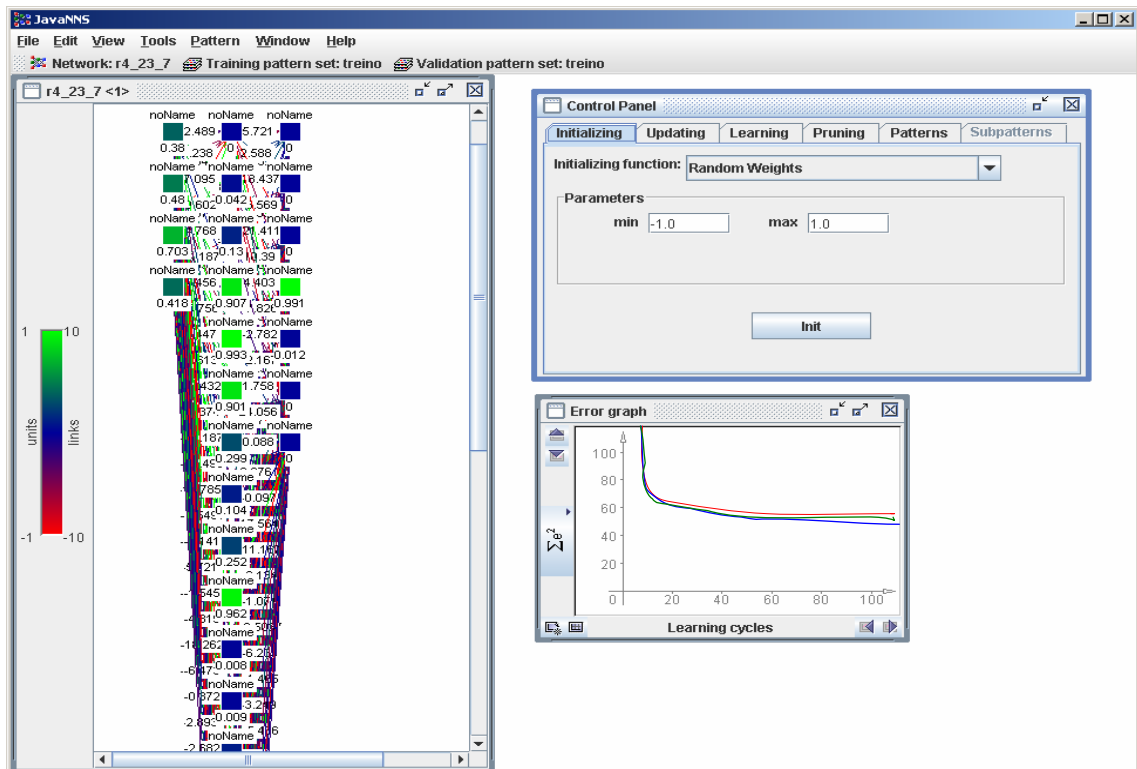



Figura 20. Representação gráfica da Rede Neural Artificial utilizada com 4 neurônios na camada de entrada, 23 neurônios na camada oculta e 7 neurônios na camada de saída e suas conexões, como se apresenta no software JavaNNS.

### 2.5.1. Separação de classes de solo exposto usando RNA

Com a finalidade de obter a classificação por RNA foi gerado um recorte de 12.5 ha dentro das categorias de degradação de pastagem, a fim de obter duas classes informacionais: solo exposto e cobertura vegetal procederam às mesmas etapas realizadas na classificação anterior (Figura 21).

Procurando verificar o desempenho da classificação da RNA foram coletados 200 pixels para cada informacional, totalizando 800 pixels, para procedimentos de treinamento e validação, respectivamente.

Aplicou-se um filtro de mediana 3 x 3 com a finalidade de melhorar a apresentação visual da imagem temática gerada, diminuindo a mistura de frequência (ruído).



- |   |   |
|---|---|
|  Pastagem com nula degradação  |  Pastagem com média degradação   |
|  Pastagem com baixa degradação |  Pastagem com intensa degradação |

Figura 21. Recortes extraídos das áreas de pastagem com diferentes intensidades de degradação para serem classificadas pela

O mecanismo de interpretação e classificação automática da imagem pode ser resumido em:

1) classificação supervisionada, combinando as respostas espectrais e as diferentes categorias da vegetação e uso do solo identificado durante o trabalho de campo;

2) teste dos diferentes algoritmos de segmentação e classificação supervisionada existentes;

3) identificação das classes de vegetação diferentes que apresentam parâmetros espectrais semelhantes, realizando, em seguida, um refinamento da coleta de assinaturas;

4) filtragem com o propósito de agrupar pixels isolados à classe predominante de maior fronteira e

5) cálculo das áreas mapeadas.

### 3. RESULTADOS E DISCUSSÃO

Os resultados da classificação utilizando os métodos RNA, ISODATA e MaxVer foram comparados entre si e entre os diferentes parâmetros utilizados dentro de um mesmo método. Esta comparação se deu de forma quantitativa e qualitativa. A comparação quantitativa foi baseada na avaliação estatística realizada, obtendo-se o cálculo do coeficiente Kappa para cada resultado de classificação. Na comparação qualitativa avaliou-se visualmente o resultado da classificação, comparando-o com a imagem original e fotointerpretada.

#### 3.1. Análise quantitativa

No treinamento da rede foi utilizada imagem do satélite Ikonos II, nas bandas 1B2G3R e 1B2G4R, formando quatro bandas na camada de entrada da arquitetura. Foi testada, também, com as variáveis NDVI e MDE que não apresentou um resultado significativo no detalhamento da cobertura vegetal, ficando, portanto, fora da rede de treinamento. Percentuais de acerto e índices Kappa das classificações totais foram calculados durante a fase de testes.

A imagem Ikonos classificada pelos métodos ISODATA, MaxVer e RNA possibilitou uma análise quantitativa utilizando os índices Kappa (Quadro 11) e as matrizes de confusão. Como suporte a essa análise, são abordados alguns aspectos relacionados com os dados de treinamento e validação utilizados no processo. De acordo com os índices Kappa, o método ISODATA foi razoável ( $0,4 < K \leq 0,8$ ) e os métodos MaxVer e RNA foram excelentes ( $0,8 < K \leq 1,0$ ).

A quantidade de neurônios tanto de entrada como na camada oculta foram testadas várias vezes de modo a encontrar um treinamento que atingisse um índice Kappa satisfatório. Observou que o número ideal de neurônios na camada oculta foi de 23, portanto, encontrado um número de neurônio da camada oculta três vezes maiores que o número de classes na camada de saída.

Quadro 11. Índices Kappa, suas variâncias e valores de Z, para cada método de classificação testado

<b>Método</b>	<b>Kappa</b>	<b>Exatidão global</b>	<b>Variância Kappa</b>	<b>Z</b>
Isodata	0.485	56,0	0.000034	148.587*
RNA	0.907	92,0	0.000036	151.684*
MaxVer	0.897	91,1	0.000039	143.583*

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

O número de ciclos satisfatório foi entre 2500 a 3000 ciclos atingindo um erro médio de 62. Foi percebido que com essa quantidade de ciclos o erro quadrado estabilizou-se e não alterou o índice Kappa.

No método MaxVer ( $K = 0,897$ ) observou-se maiores confusões na classe de solo exposto (Quadro 12), o que resultou em uma grande quantidade de informação confundidas nestas classes. Os maiores acertos na classificação foram para a mata e para as pastagens com nula degradação e com média degradação.

Avaliando a RNA ( $K = 0,907$ ), os maiores erros ocorreram nas classes pastagem com baixa degradação e com intensa degradação, devido à similaridade da resposta espectral destas classes. As áreas de solo inundável apresentavam uma cobertura de gramíneas secas as quais foram confundidas com as pastagens degradadas que apresentaram grande quantidade de plantas invasoras, também, secas. Os maiores acertos na classificação (Quadro 13) foram nas classes de mata, solo exposto, pastagem com nula degradação e com média degradação.

Quadro 12. Matriz de confusão gerada pelo algoritmo método MaxVer e proporção de acerto para cada classe

Classe	Classe							Total
	1	2	3	4	5	6	7	
1	400	0	1	2	0	0	0	403
2	0	346	0	0	0	0	0	346
3	0	0	363	0	0	0	0	363
4	0	0	0	395	123	0	0	518
5	0	0	0	3	277	0	0	280
6	0	54	36	0	0	400	29	519
7	0	0	0	0	0	0	371	371
<b>Total</b>	400	400	400	400	400	400	400	2.800
<b>acerto</b>	100.0	86.5	90.8	98.8	69.2	100.0	92.8	

1-Mata; 2-Solo exposto; 3-Área inundável; 4-Pastagem com nula degradação; 5-Pastagem com baixa degradação; 6-Pastagem com média degradação e 7-Pastagem com intensa degradação.

Quadro 13. Matriz de confusão gerada pela rede neural artificial e proporção de acerto para cada classe

Classe	Classe							Total
	1	2	3	4	5	6	7	
1	386	2	8	3	0	0	16	415
2	0	384	1	0	0	2	0	387
3	0	0	365	2	6	7	16	396
4	3	0	0	378	44	0	0	425
5	2	0	1	17	348	3	1	374
6	5	2	20	0	2	386	38	463
7	4	12	5	0	0	2	329	340
<b>Total</b>	400	400	400	400	400	400	400	2.800
<b>acerto</b>	96.5	96.0	91.3	94.5	87.0	96.5	82.3	

1-Mata; 2-Solo exposto; 3-Área inundável; 4-Pastagem com nula degradação; 5-Pastagem com baixa degradação; 6-Pastagem com média degradação e 7-Pastagem com intensa degradação.

Com o método ISODATA ( $K = 0,485$ ) as confusões (Quadro 14) foram altas impossibilitando a discriminação das pastagens quanto às classes de produtividade, sendo que as pastagens com baixa e média degradação não foram diferenciadas.

Quadro 14. Matriz de confusão gerada pelo método ISODATA

Classe	Classe							Total
	1	2	3	4	5	6	7	
1	2	0	0	1	0	0	1	4
2	0	5	0	0	0	0	0	5
3	0	0	5	0	2	0	0	7
4	1	1	0	2	1	0	0	5
5	0	0	1	2	5	1	2	11
6	0	2	0	0	1	3	0	6
7	3	0	1	0	0	0	6	10
<b>Total</b>	6	9	7	6	9	4	9	50
<b>acerto</b>	33,33	55,56	71,43	33,33	55,56	75,00	66,67	

1-Pastagem com intensa degradação; 2-Mata; 3-Solo exposto; 4-Área inundável; 5-Pastagem com baixa degradação; 6-Pastagem com nula degradação e 7-Pastagem com média degradação.

### 3.2. Análise qualitativa

A avaliação das imagens mostra que as diferenças geradas pelos classificadores MaxVer e RNA são pouco perceptíveis sendo que ambos apresentaram boa resposta visual (Figura 22 e 23). A imagem temática gerada pelo método ISODATA apresentou qualidade visual inferior (Figura 24), com grande quantidade de ruído gerando confusão entre as classes.

A imagem temática classificada pelo método MaxVer apresentou maior área de pastagem com média degradação que no método RNA e ISODATA. Observou-se que área de solo exposto com restos de cultura de sorgo, localizado no canto superior direito da imagem (Figura 22) o classificador MaxVer a reconheceu como pastagem com média degradação, confirmado pela distribuição relativa das áreas (Quadro 15). O método MaxVer também fez confusão, incluindo a classe de área inundável como pastagem com intensa degradação, devido as semelhanças espectrais destas classes. No campo essa classe está coberta por uma vegetação rasteira seca que possui um padrão semelhante à pastagem com intensa degradação.



#### LEGENDA

	Mata
	Solo exposto
	Área inundável
	Pastagem com nula degradação
	Pastagem com baixa degradação
	Pastagem com média degradação
	Pastagem com intensa degradação

Figura 22. Imagem temática resultante da classificação pelo método de Máxima Verossimilhança – MaxVer, filtrada.



#### LEGENDA

	Mata
	Solo exposto
	Área inundável
	Pastagem com nula degradação
	Pastagem com baixa degradação
	Pastagem com média degradação
	Pastagem com intensa degradação

Figura 23. Imagem temática resultante da classificação pelo método Rede Neural Artificial- RNA, filtrada.



#### LEGENDA

	Mata
	Solo exposto
	Área inundável
	Pastagem com nula degradação
	Pastagem com baixa degradação
	Pastagem com média degradação
	Pastagem com intensa degradação

Figura 24. Imagem temática resultante da classificação pelo método ISODATA, filtrada.

Quadro 15. Distribuição em percentagem das classes de uso, obtida pela aplicação dos métodos de classificação

Classe	Métodos de Classificação		
	RNA	MaxVer	ISODATA
	----- % -----		
Mata	10,1	10,9	8,6
Solo exposto	9,2	5,5	15,2
Área inundável	10,6	6,9	11,3
Past. nula degradação	8,7	9,8	10,1
Past. baixa degradação	27,4	22,8	28,7
Past. média degradação	31,1	40,9	21,5
Past. Intensa degradação	2,4	3,2	4,6
Total	100,0	100,0	100,0

A RNA mostrou-se como o melhor classificador não havendo confusões significativas, classificando corretamente grande parte da imagem. No entanto, foi observado uma pequena confusão entre uma parte da área inundável com pastagem intensa degradação pelo mesmo motivo que fez o método MaxVer confundir estas classes.

A imagem gerada pelo método ISODATA diferentemente dos métodos MaxVer e RNA não apresentou boa resposta visual, pois houve grande equívoco entre as classes área inundável, pastagem média degradação e intensa degradação. A grande quantidade de ruído mesmo depois de aplicada o filtro 3 x 3 (mediana) deve-se a quantidade de pixels confundidos. As classes de maior acerto nesse método foi vegetação natural (mata) e solo exposto, isto deve-se ao padrão de resposta espectral ser facilmente identificados, sendo a mata com maior absorvância de energia e solo exposto com maior reflectância.

A pesquisa constatou uma boa correlação entre a condição das pastagens, feita pela classificação automática RNA. Portanto, existe efetivamente um alto potencial de uso de imagem de alta resolução espacial classificada automaticamente para o diagnóstico das pastagens. O uso de imagens de satélite tomadas em épocas diferentes, com a finalidade de conhecer o comportamento espectral das pastagens pode contribuir ainda mais para este diagnóstico.

A utilização do ambiente SIG com RNA e MaxVer permitiram rapidez na obtenção de dados quantitativos e qualitativos das classificações das pastagens.

As imagens temáticas geradas podem ser utilizadas como fontes de dados quantitativos, já que a radiância detectada é convertida em valores numéricos, em uma escala definida pela resolução do sensor com base no conhecimento da resposta espectral da vegetação. Esta resposta, bem como a distribuição dos valores numéricos da imagem, tornam possíveis estudos quantitativos que visam inferir sobre uma determinada cobertura vegetal, com relação à sua produtividade.

### 3.3. Quantificação do solo exposto e cobertura vegetal das pastagens

Utilizando as categorias: pastagem com nula degradação, pastagem com baixa degradação, pastagem com média degradação e pastagem com intensa degradação em áreas de 12,5 hectares, foi aplicado o método RNA para classificação da cobertura vegetal e solo exposto. A rede foi amostrada com 200 pixels para treino e 200 pixels para validação, que é considerado o número ideal encontrado neste trabalho para montagem de uma rede com duas classes informacionais.

A rede neural treinada com 4 neurônios na camada de entrada, 8 neurônios na camada oculta e 2 na camada de saída foi capaz de separar com alta capacidade o solo exposto e a cobertura vegetal, obtendo um índice Kappa considerado excelente (Quadro 16).

Quadro 16. Índices Kappa, suas variâncias e valores de Z, aplicado a diferentes produtividade de pastagem na classificação de solo exposto e cobertura vegetal pelo método RNA

Pastagem	Kappa (%)	Exatidão global	Variância Kappa	Z
Pastagem nula degradação	0.98	98.0	0.000198	69.660*
Pastagem baixa degradação	0.97	98.5	0.000295	56.431*
Pastagem média degradação	0.97	98.5	0.000295	56.431*
Pastagem intensa degradação	0.97	98.5	0.000198	56.453*

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

Pelas matrizes de confusão (Quadro 17) avalia-se que não houve conflitos significativos na classificação realizada pela RNA. A RNA mostra-se como uma ferramenta capaz de separar com precisão pixel de solo exposto

não perceptíveis pela interpretação visual, dessa forma a interpretação de imagem passam a ser mais precisa e numericamente calculada.

Quadro 17. Matriz de confusão gerada pela RNA para as classes solo exposto e cobertura vegetal nas diferentes categorias de pastagens

<b>Classes</b>	<b>Solo exposto</b>	<b>Cobertura vegetal</b>	<b>Total</b>
Pastagem com nula degradação			
Solo exposto	100	2	102
Cobertura vegetal	0	98	98
Total	100	100	200
acerto	100.0	98.0	
Pastagem com baixa degradação			
Solo exposto	98	1	99
Cobertura vegetal	2	99	101
Total	100	100	200
acerto	100.0	99.0	
Pastagem com média degradação			
Solo exposto	98	1	99
Cobertura vegetal	2	99	101
Total	100	100	200
acerto	100.0	98.0	
Pastagem com intensa degradação			
Solo exposto	100	3	103
Cobertura vegetal	0	97	97
Total	100	100	200
acerto	100.0	98.0	

Pelas imagens temáticas geradas na classificação RNA pode-se calcular a percentagem de cobertura vegetal e solo exposto para as quatro categorias de pastagens na área estudada (Quadro 18). A pastagem com intensa degradação possui maior percentagem de cobertura vegetal (77,94), isso pode ser explicado pela intensa presença de plantas invasoras, dominando o espaço antes ocupado pela forrageira.

Na classe de pastagem nula degradação também com 70,03 % de cobertura vegetal apresentava, ao contrário da pastagem degradada, melhor população da forrageira. O solo exposto nessa classe (29,07%) ocorre de

forma fragmentada e, muitas das vezes mascarada pelo padrão dos pixels de vegetação, sendo quantificada pela RNA apenas em contagem pixel por pixel.

Quadro 18. Cobertura vegetal e proporção de solo exposto em pastagens com diferentes categorias de degradação estimada a partir da classificação realizada pelo algoritmo RNA

Pastagem	Classe	
	Cobertura vegetal	Solo exposto
	----- % -----	
Pastagem com nula degradação	70,6	29,0
Pastagem com baixa degradação	31,4	68,5
Pastagem com média degradação	50,1	49,8
Pastagem com intensa degradação	77,9	22,7
Total	100,0	100,0

A pastagem com média degradação pela maior população da forrageira e menor incidência de plantas invasora, apresentou uma maior percentagem de solo exposto. A pastagem com baixa degradação mesmo possuindo pouca cobertura vegetal esta é predominantemente pelas forrageiras. Observa-se que as pastagens com média degradação e com intensa degradação, apresentam boa cobertura, isto pode ser explicado pela maior quantidade de biomassa presente nestas pastagens. Ao passo que a pastagem com nula degradação possui uma cobertura natural com resposta espectral mais homogênea.

A proporção de solo exposto para as quatro classes de pastagem mostrou-se elevada, caracterizando que pode contribuir para a degradação do solo (Figura 25).

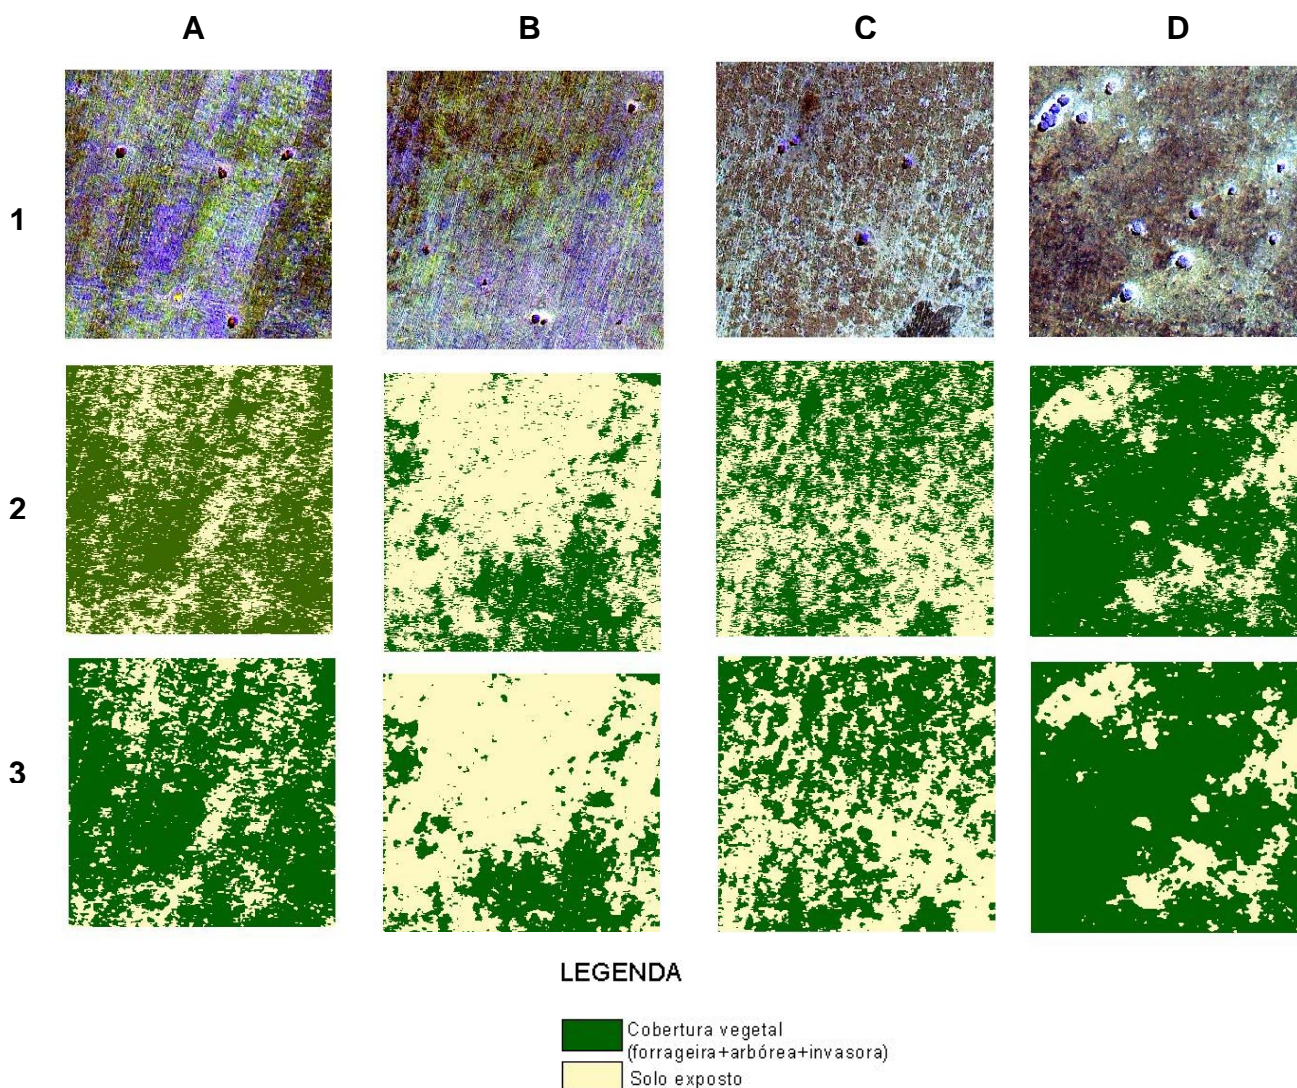


Figura 25. Imagem temática da cobertura do solo em pastagem – com nula degradação (A); com baixa degradação (B); com média degradação (C) e intensa degradação (D), resultante da aplicação da RNA. Recorte da imagem Ikonos (1), imagem temática (2) e imagem temática filtrada (3).

## 4. CONCLUSÕES

De acordo com os resultados obtidos neste trabalho, concluiu-se que:

- A utilização dos métodos RNA e MaxVer de classificação imagens Ikonos II, mostram-se eficientes na discriminação das quatro categorias de degradação das pastagens, discriminando estatisticamente bem, com Kappa de 0,897 e 0,907, respectivamente;
- Os métodos MaxVer e RNA apresentam alto potencial para classificação de imagem de alta resolução espacial;
- Os mapas temáticos gerados pelo MaxVer e RNA mostram excelente qualidade visual;
- O método ISODATA foi estatisticamente inferior para imagem de alta resolução espacial, devido a grande quantidade de confusões geradas;
- As RNAs com 23 neurônios na camada oculta apresenta um índice Kappa excelente tanto com amostras de treinamento como com amostras teste.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

AGRO-AMBIENTAL ASSESSORIA. **Relatório de impacto ambiental da Fazenda São Geraldo município de João Pinheiro**. 2004, 256p.

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em Imagens de alta resolução espacial**. Tese de doutoramento – Curso de Pós-Graduação em Ciências Geodésicas – Universidade Federal do Paraná, Curitiba-PR. 2003.

BELUCO, A. Classificação de imagens de sensoriamento remoto baseada em textura por redes neurais. (**Dissertação de mestrado**) UFRGS - CEPSRM, 2002, 127p.

BRONDINO, N.C.M. **Estudo da Influencia da Acessibilidade no Valor de Lotes Urbanos Através do Uso de Redes Neurais**. São Carlos, SP, 1999.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas, UNICAMP/IG, 1996. 170p.

DYMINSKI, A S. *Análise de Problemas Geotécnicos Através de Redes Neurais*. Rio de Janeiro. Universidade Federal do Rio de Janeiro, 2000.

GALO, M. L. B. T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo**. São Carlos, 2000. 205f. Tese (Doutorado), Escola de Engenharia de São Carlos. Universidade de São Paulo.

GONZALEZ, R. C.; WOODS, R. E.. **Processamento Digital de Imagens**. Edgard Blücher, 2000, 717p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Anuário Estatístico do Brasil. Rio de Janeiro: IBGE, 2002. v. 55.

IWAI, O. K. **Mapeamento do uso do solo urbano do município de São Bernardo do Campo, através de imagem de satélite**. Ed. Ver. São Paulo, 2003. 127 p.

JENSEN, J. R. **Introductory digital image processing. A remote sensing perspective**, Prentice Hall, New Jersey; Estados Unidos, 2000.

KURY, E. B. & VIEIRA, C. A O. **Classificação automática de imagens de alta resolução.** In NUGEO 2002 – workshop sobre geoprocessamento da UFV. 2002. Viçosa. **Anais...** Viçosa 2002. 4p Disponível em: <http://www.ufv.br/nugeo>. Acesso em: 27 de novembro 2004.

LIPPMANN, R. P.. An introduction to computing with neural nets. **IEEE ASSP Magazine**, v.4, 4-22p, 1987.

LILLESAND, T. M. & KIEFER, R. W. Remote sensing and image interpretation. 3<sup>rd</sup>. John Wiley e Sons. New York, 1994, 748p.

MACHADO, B. P. Aplicação de redes neurais para o tratamento de grandes massas de dados. IME. Rio de Janeiro, RJ, 1992.

NASCIMENTO, J. P. R; MADEIRA, H. M.F. E PEDRINI, H. Classificação de Imagens utilizando descritores estatísticos de textura. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., 2003, Belo Horizonte. **Anais...** São José dos Campos:INPE, 2003. p. 109-116. CD ROM.

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

NISHIDA, W. & BASTOS, L. C. **Classificação de Imagens de Sensoriamento Remoto Utilizando uma Rede Neural Artificial com Função de Base Radial.** Anais IX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brasil, 11-18 setembro 1998, INPE, p. 991-1001.

SOUTO, R. P. Segmentação de imagem multiespectral utilizando-se o atributo matiz / R. P. Souto. – São José dos Campos: INPE, 2000. 171p.

TATIBANA & KAETSU. **Uma Introdução a Redes Neurais.** Disponível em: [www.din.uem.br/ia/neuruais](http://www.din.uem.br/ia/neuruais). 2006.

VENTURIERI, A.; SANTOS, J. R. Técnicas de Classificação de Imagens para Análise de Cobertura Vegetal. In: ASSAD, E. D.; SANO, E. E., eds. **Sistema de Informação Geográfica: Aplicações na Agricultura.** Brasília: DF. Embrapa – SPI/Embrapa-CPAC, 1998. p 351-371.

WEIGEND, A. S. & HUBERMAN, B. A. Predicting the Future : A Connectionist Approach. International Journal of Neural Systems, 1990; Vol.1, n<sup>o</sup>.3, pp.193-209.

ZELL, A. SNNS: Stuttgart Neural Network Simulator. User Manual, Version 4.1. Stuttgart: University of Stuttgart, 1995.

## CONCLUSÕES GERAIS

Os métodos aplicados atingiram o objetivo proposto que foi: a) diagnosticar e caracterizar os sistemas de uso do solo e estádios de degradação de pastagens e b) avaliar a utilização da Rede Neural Artificial na classificação automática de pastagens com diferentes categorias de degradação utilizando imagem de alta resolução espacial.

Neste sentido, os resultados da classificação supervisionada mostraram que as classes informacionais foram bem representativas, possíveis de serem identificadas na imagem de alta resolução espacial.

A resolução espacial da imagem Ikonos facilitou a discriminação de diferentes graus de degradação de pastagem, presença de diferentes gramíneas forrageiras, assim como os diversos usos e cobertura do solo de forma rápida e precisa.

A retirada de amostras por pixel e o prévio conhecimento do ambiente contribuíram para que a amostragem fosse bem caracterizada, diminuindo assim o erro na classificação automática da imagem.

A utilização de imagens Ikonos como ferramenta mostrou-se bastante eficaz.

## APÊNDICE

Quadro 1A. Matriz de confusão do mapa degradação das pastagens

1-Solo exposto

<b>Classes</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>Total</b>
<b>1</b>	<b>19</b>	0	0	0	0	0	19
<b>2</b>	0	<b>20</b>	0	0	0	0	20
<b>3</b>	0	0	<b>15</b>	4	0	0	19
<b>4</b>	0	0	3	<b>12</b>	1	0	16
<b>5</b>	1	0	2	3	<b>16</b>	1	23
<b>6</b>	0	0	0	1	3	<b>19</b>	23
<b>Total</b>	20	20	20	20	20	20	<b>120</b>
<b>Produto</b>	95.0	100.0	75.0	60.0	80.0	95.0	

2-Vegetação nativa

3-Pastagem produtiva

4-Pastagem com baixa degradação

5-Pastagem com média degradação

6-Pastagem degradada

Quadro 2B. Matriz de confusão do mapa de uso e cobertura

<b>Classes</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>	<b>9</b>	<b>10</b>	<b>11</b>	<b>Total</b>
<b>1</b>	5	0	0	0	0	0	0	0	0	0	0	5
<b>2</b>	0	3	0	0	1	0	0	0	0	0	0	4
<b>3</b>	0	0	4	0	0	0	0	0	0	0	0	4
<b>4</b>	0	0	1	4	0	0	0	0	1	0	0	6
<b>5</b>	0	2	0	1	4	0	0	0	0	0	0	6
<b>6</b>	0	0	0	0	0	5	0	0	0	0	0	5
<b>7</b>	0	0	0	0	0	0	5	0	0	0	0	5
<b>8</b>	0	0	0	0	0	0	0	5	0	0	0	5
<b>9</b>	0	0	0	0	0	0	0	0	4	0	0	4
<b>10</b>	0	0	0	0	0	0	0	0	0	5	0	5
<b>11</b>	0	0	0	0	0	0	0	0	0	0	5	5
<b>Total</b>	5	5	5	5	5	5	5	5	5	5	5	<b>55</b>
<b>Produto</b>	100	60	80	80	80	100	100	100	80	100	100	

- 1-Cerradão
- 2-Cerrado típico
- 3-Campo limpo
- 4-Cerrado ralo
- 5-Campo sujo
- 6-Mata ciliar
- 7-Mata densa
- 8-Pastagem plantada
- 9-Pastagem natural
- 10-Solo exposto
- 11-Área inundável



*Sede em meu favor, Virgem soberana, livrai me do inimigo com vosso valor. Glória seja ao Pai, ao Filho e ao Amor também, em pessoas três, agora e sempre e sem fim . Amém.*