

Revista Brasileira de Cartografia (2013) N° 65/1: 53-61
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

ALGORITMOS DE CLASSIFICAÇÃO DE IMAGEM NO MAPEAMENTO DE PASTAGEM EM DIFERENTES ESTÁDIOS DE DEGRADAÇÃO

*Algorithms of Image Classification in Mapping Pasture in Different Stadiums of
Degradation*

**Edgley Pereira da Silva¹; Eliana de Souza²;
Rafael Mendes Pereira¹; Reinaldo Bertola Cantarutti²
& Elpídio Inácio Fernandes Filho²**

¹Universidade do Estado de Mato Grosso – UNEMAT
Campus Universitário de Alta Floresta
CEP 78580000, Alta Floresta, MT.
edyps2004@hotmail.com, rafael.agronomia@hotmail.com

²Universidade Federal de Viçosa – UFV
Departamento de Solos
CEP 36570000, Viçosa, MG
elianadsouza@yahoo.com.br, cantarutti@ufv.br, elpidio@ufv.br

Recebido em 25 de julho, 2011/ Aceito em 27 de outubro, 2011
Received on July 25, 2011/ Accepted on October 27, 2011

RESUMO

Os métodos de classificação automática comumente utilizados na análise de imagens de média resolução têm eficiência questionável quando empregados na classificação de imagens de alta resolução espacial. O classificador de Redes Neurais Artificiais (RNAs) é baseado em técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes adquirindo conhecimento pela experiência. O objetivo desse trabalho foi avaliar o desempenho de classificadores no mapeamento de pastagens com diferentes estádios de degradação, utilizando imagem do satélite Ikonos II. A área em estudo apresenta 1.305 ha e localiza-se no município de João Pinheiro, Noroeste do Estado de Minas Gerais. Os algoritmos de classificação avaliados foram Máxima Verossimilhança e RNAs. Os resultados mostraram-se eficientes na separação das quatro categorias de pastagens. Os mapas gerados pelo MaxVer e RNAs apresentaram um Kappa de 0,897 e 0,907, respectivamente.

Palavras chaves: Pastagem, Sensoriamento Remoto, Redes Neurais, IKONOS, Índice Kappa.

ABSTRACT

The automatic classification methods commonly used to analyze medium resolution images have questionable effectiveness when used with images of high spatial resolution. The Artificial Neural Networks (RNAs) classifier is based on computational techniques that present a model inspired on the neural structure of intelligent organisms and acquires knowledge by experience. This study aimed at evaluating the performance of automated classifiers in mapping pastures with different stages of degradation, using images of Ikonos II satellite. The study area has 1,305 ha and is

located in the municipality of João Pinheiro, Northwest of Minas Gerais state. The classification algorithms evaluated were Maximum Likelihood and RNAs. The classifiers were efficient in separating the four categories of pasture. The maps generated by MaxVer and RNAs showed a kappa of 0.897 and 0.907, respectively.

Keywords: Pasture, Remote Sensing, Neural Network, IKONOS, Kappa Index.

1. INTRODUÇÃO

Os sensores dos satélites são capazes de captar constantemente imagens da terra, abrangendo extensas áreas e fornecendo dados atualizados, que são processados por meio de técnicas de interpretação visual e ou classificação automática 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. O processo de classificação é baseado nos níveis de cinza ou cores, características de forma e textura dos objetos (NASCIMENTO et al., 2006).

Diversos classificadores são utilizados na extração de informação de imagens digitais, sendo o de Máxima verossimilhança (Maxver) tradicionalmente utilizado para classificação de classes da cobertura do solo, e, mais recentemente o classificador de redes neurais. Mas com o aparecimento de sensores de alta resolução espacial, a eficiência dos classificadores, comumente usados está sendo questionada, pois o alto nível de detalhe destas imagens torna mais evidente as variações espectrais entre os objetos. Em trabalho realizado por Chagas, et al. (2008) comparando imagens de diferentes satélites observaram que a resolução espectral apresentou maior influência sobre a exatidão da classificação do que a resolução espacial, para classificação de níveis de degradação em pastagens.

Os algoritmos tradicionalmente usados no processo de classificação consideram normalmente que as classes são estatisticamente separáveis e utilizam como unidade de medida os valores estatísticos do nível de cinza do pixel, sem contudo,

estabelecer relações entre pixels. Porém, com o aumento da resolução espacial e espectral das imagens produzidas pelos sensores, existe um aumento na variação interna das classes, e conseqüentemente uma sobreposição das classes no espaço característico, inviabilizando o uso dos classificadores comumente usados (KURY & VIEIRA, 2004).

Imagem multiespectral Ikonos II apresenta alta resolução espacial, portanto mostra uma diversidade das feições, que por um lado, facilita visualmente a detecção das feições por meio de parâmetros fotointerpretativos, e por outro lado, a classificação automática passa a exigir um maior cuidado do usuário, pois além da informação espectral os objetos da imagem possuem outros atributos que podem ser utilizados na classificação tal como forma e textura (ANTUNES, 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 utilizadas, com frequência, para classificação de imagens de sensoriamento remoto e que consistem em um método de solucionar problemas com inteligência artificial, que simulem o cérebro humano (NISHIDA & BASTOS, 1998, LIPPMANN, 1987) inclusive seu comportamento, ou seja, aprendendo, errando e até mesmo fazendo descobertas, sendo ainda capaz de adquirir conhecimento com a experiência (MENDONÇA, et al., 2002).

Conforme Dyminski (2000), as RNAs são constituídas 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 e camada de saída: onde o resultado final é concluído e apresentado.

As RNAs passam por um processo de treinamento a partir dos casos reais conhecidos. Sendo assim, as RNAs são capazes 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.

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. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior (GALO, 2000).

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).

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 produtividade.

2. MATERIAL E MÉTODOS

2.1 Área de estudo

A área de estudo localiza-se na Fazenda São Geraldo no município de João Pinheiro, ocupa uma área de 1.305 ha, na região noroeste do estado de Minas Gerais, entre as coordenadas geográficas: 17° 12' 39,6" Sul e 46° 20' 24" Oeste; 17° 39' Sul e 46° 10' 33,6" Oeste (Fig. 1). Possui altitude média de 532 metros, 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 a classificação

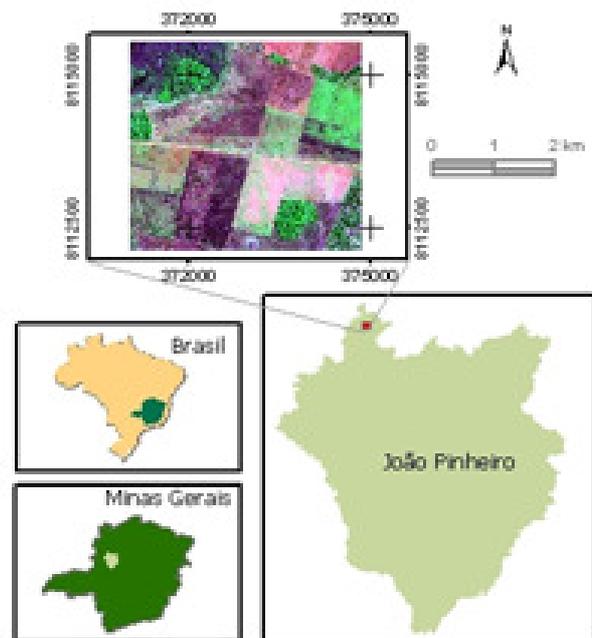


Fig 1 – Localização da área em estudo no município de João Pinheiro, MG

de Köppen), com meses mais seco durante o inverno. As principais classes de solos encontradas são Latossolos, Neossolos Quartzarênicos, Neossolos Flúvicos e Gleissolos.

2.2 Imagem utilizada na classificação

Na realização deste trabalho, foi utilizada uma imagem do satélite Ikonos II, com resolução espacial de 4 m no modo multiespectral (bandas, azul, verde, vermelho e infra vermelho próximo) e 1 m no pancromático, com 11 bits (2.048 níveis de cinza) capturada no dia 14 de abril de 2005. As bandas multiespectrais foram fusionadas com a banda Pancromática, obtendo imagens com 1 m de resolução.

Dessa imagem foi gerado o Índice de Vegetação por Diferença Normalizada (NDVI) em que os dados de reflectância dos alvos podem ser transformados em índices de vegetação, os quais foram criados com o intuito de ressaltar o comportamento espectral da vegetação em relação ao solo e a outros alvos da superfície terrestre (MOREIRA, 2005).

2.3 Caracterização das pastagens

A área foi percorrida em três visitas, sendo a primeira em maio de 2004, para o reconhecimento geral da área em estudado; a segunda em maio de 2005, para quantificação da forragem disponível nas pastagens e classificação dos estádios de

degradação, bem como para a coleta dos pontos de controles com sistema GPS e a terceira em agosto de 2005 para correlacionar e coletar pontos para gerar os índices Kappa.

Na área foram delimitadas e georreferenciadas parcelas de aproximadamente um hectare, sendo as mais representativas das condições de cada pastagem. Nestas parcelas estimou-se: a forragem disponível, 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 a degradação segundo critério adaptados por Spain e Gualdrón (1988) (Tabela 1).

A partir do reconhecimento da área e classificação das pastagens as classes informacionais definidas para a classificação automática foram: mata, solo exposto, área inundável, pastagem com nula degradação (pastagem produtiva), pastagem com baixa degradação, pastagem com média degradação e pastagem com intensa degradação.

2.4 Classificação da imagem

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).

Foram utilizados dois algoritmos de classificação, quais sejam: MaxVer e RNs.

Os arquivos de treinamento e validação foram compostos pelas amostras coletadas pixel a pixel selecionadas a partir das amostras de pontos georreferenciados, obtidos em campo durante o reconhecimento dos padrões da imagem e identificação das classes de pastagens.

Tabela 1 - Caracterização do estado de degradação de pastagens (adaptado de Spain e Gualdrón, 1988).

Indicadores de degradação	Estádio de degradação
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

Foram testadas combinações com as 4 bandas do satélite Ikonos, o NDVI e o dados de altitude do modelo digital de elevação (MDE) gerado com mapas de curvas de nível com 5 metros de equidistância.

A primeira etapa na classificação pelas Redes Neurais foi a 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 de treinamento apresentaram boa separabilidade, o que contribuiu para o desempenho satisfatório dos classificadores utilizados (Sousa et al., 2010).

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, treinamento e validação. Os dados de treinamento e validação foram organizados em planilhas no formato aceito pelo simulador *JavaNNS*. O mesmo conjunto de amostras foi utilizado na classificação pelo MaxVer e pelas RNAs. 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, foram realizadas várias simulações, 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. 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 das RNAs e ao classificador MaxVer, gerando para as RNAs e para o MaxVer uma matriz de confusão com o seu respectivo índice Kappa e outros valores estatísticos da exatidão da classificação.

O índice Kappa é um método estatístico utilizado na avaliação da concordância entre pontos

de referencia da área mapeada e os resultados encontrados no mapa temático obtido a partir da interpretação da imagem de satélite (CONGALTON & GREEN, 1998).

Com base nos valores obtidos após a análise da classificação por meio do índice Kappa, estabeleceu-se o critério de exatidão, conforme os intervalos propostos por Landis: Ruim ($K \leq 0,2$), Razoável ($0,2 < K \leq 0,4$), Boa ($0,4 < K \leq 0,6$), Muito Boa e ($0,6 < K \leq 0,8$) Excelente ($0,8 < K \leq 1$) (MOREIRA, 2005).

3. RESULTADOS E DISCUSSÕES

Os resultados da classificação pelos classificadores RNAs e MaxVer foram comparados entre si utilizando os mesmos parâmetros quantitativos e qualitativos. A comparação quantitativa foi baseada na avaliação estatística do coeficiente Kappa obtido para cada resultado de classificação (CONGALTON e GREN, 1989). Na comparação qualitativa avaliou-se visualmente o resultado da classificação, comparando-o com a imagem original e fotointerpretada.

No treinamento das redes foram utilizadas as bandas da faixa do visível 1, 2 e 3 (Fig. 2) e banda faixa infra-vermelho da imagem do satélite Ikonos II, formando quatro bandas na camada de entrada da arquitetura. Outra arquitetura foi avaliada utilizando além das bandas mencionadas, o NDVI e o MDE que não apresentaram resultado satisfatório na separação das classes de cobertura vegetal, ficando, portanto, fora do processo final de treinamento. Percentuais de acerto e índices Kappa das classificações totais foram calculados durante a fase de teste utilizando amostras de treinamento.

As imagens geradas pelos algoritmos MaxVer e RNAs foram analisadas de forma quantitativa utilizando o índice de exatidão Kappa obtido nas matrizes de confusão geradas com dados de treinamento e validação da classificação. De acordo com os índices Kappa (Tabela 1), ambos os classificadores MaxVer (Tabela 2) e RNAs (Tabela 3) foram excelentes ($0,8 < K \leq 1,0$).

A quantidade de neurônios tanto na camada de entrada como na camada oculta foram testadas várias vezes de modo a encontrar um treinamento que atingisse a maior exatidão, observado pelo índice Kappa. Na camada oculta o melhor desempenho do classificador foi obtido com 23 neurônios, sendo

Tabela 2 – Matriz de confusão gerada na classificação pelo maxver e proporção de acerto para cada 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
Total	400	400	400	400	400	400	400	2.800
Acerto	100.0	86.5	90.8	98.8	69.2	100.0	92.8	

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

Tabela 3 - Matriz de confusão gerada na classificação pelas redes neurais artificiais 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
Total	400	400	400	400	400	400	400	2.800
Acerto	96.5	96.0	91.3	94.5	87.0	96.5	82.3	

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

esse número três vezes maior do que o número de classes na camada de saída.

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 (Tabela 4).

No método MaxVer ($kappa = 0,897$) observou-se maiores confusões na classe de solo exposto, o que resultou em uma grande quantidade de informação confundidas nestas classes. Os

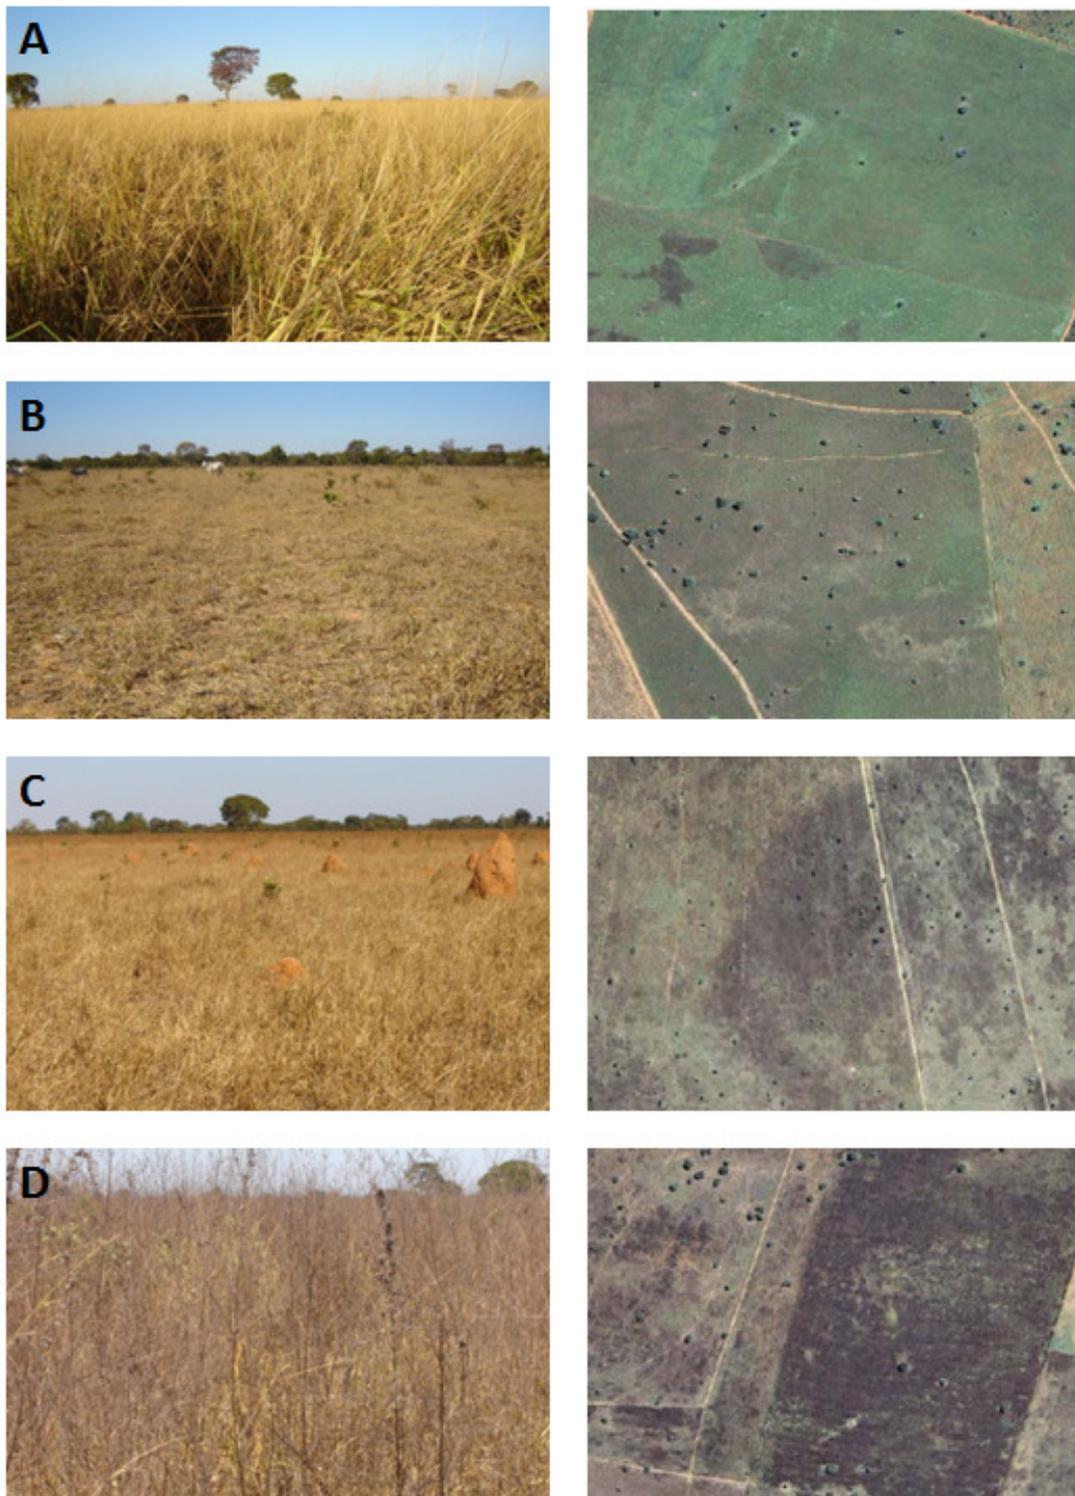


Fig 2 - Fotos e imagens de pastagem com estádios de degradação, pastagem produtiva (a), pastagem com baixa degradação (b), pastagem com média degradação (c) e pastagem degradadas (d).

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.

A RNA mostrou-se como o melhor classificador não havendo confusões significativas, classificando corretamente grande parte da imagem. Resultados condizem com trabalho realizado por Sartori, et al., (2009) em que a classificação pela RNA foi adequada para definir classes genéricas

associadas aos graus de infestação por plantas daninhas em um cafezal. No entanto, foi observado uma pequena confusão entre uma parte da área inundável com pastagem intensa de degradação pelo mesmo motivo que fez o método MaxVer confundir estas classes.

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 classificações relativas se adequam exatamente às situações onde existe a necessidade de trabalhar com esses tipos de classes temáticas, além de permitirem uma análise mais acurada da confusão entre as classes, a partir das imagens de

maiores acertos na classificação foram para a mata e para as pastagens com nula degradação e com média degradação.

Avaliando a classificação pelas RNAs ($kappa = 0,907$), 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 foram nas classes de mata, solo exposto, pastagem com nula degradação e com média degradação.

A avaliação das imagens mostra que as diferenças geradas pelos classificadores MaxVer e RNAs são pouco perceptíveis sendo que ambos apresentaram boa resposta visual (Fig. 3). A classificação orientada a objeto obteve resultados diferenciados sobre as imagens consideradas. Os resultados alcançados neste estudo comprovam, mais uma vez, a eficiência da utilização de redes neurais artificiais para classificação do uso e cobertura do solo, podendo este classificador ser considerado uma alternativa viável para a classificação de níveis de degradação de pastagens (Chagas et al, 2008).

A imagem temática classificada pelo método MaxVer apresentou maior área de pastagem com média degradação que no método RNA. Observou-se que área de solo exposto com restos de cultura de sorgo, localizado no canto superior direito da imagem o classificador MaxVer a reconheceu como pastagem com média degradação, confirmado pela distribuição relativa das áreas. O método MaxVer

Tabela 4 - Matriz de significância para os métodos de classificação testado.

Método	RNAs	MaxVer
Kappa	0,907	0,897
Variância	0,000036	0,000039
RNAs	151,167	
MaxVer	1,155	143,635

* significativo a 95% de probabilidade ($Z e''1,96$).

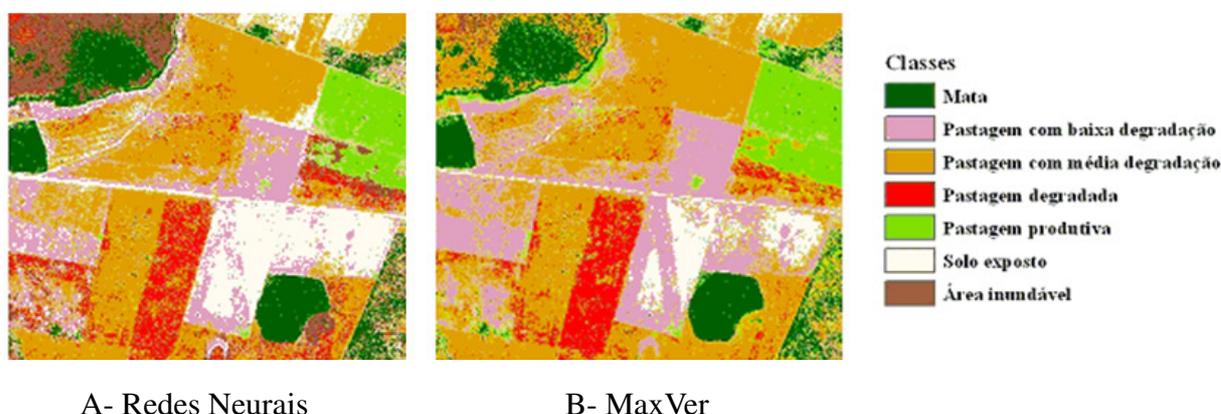


Fig 3 - Imagens temáticas resultante da classificação automática pelos algoritmos: A) Redes Neurais e B) MaxVer.

incerteza associadas a cada classe (Prado et al, 2009).

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, torna possíveis estudos quantitativos que visam inferir sobre uma determinada cobertura vegetal, com relação à sua produtividade.

4. CONCLUSÕES

1. De acordo com os resultados obtidos neste trabalho, concluiu-se que a utilização dos algoritmos RNA e MaxVer para a classificação de 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.

2. A exatidão obtida com as RNAs foi superior à obtida pelo Maxver, porém estatisticamente a diferença não foi significativa.

3. Os mapas temáticos gerados pelo MaxVer e RNA mostram excelente qualidade visual.

REFERÊNCIAS BIBLIOGRÁFICAS

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.

CHAGAS, C. S.; VIERIRA, C. A. O.; FILHO, E. I. F.; JÚNIOR, W. C. Comparação entre imagens ASTER e LANDSAT7 na classificação de pastagens utilizando redes neurais artificiais. **Revista Brasileira de Cartografia**. No 60/03, outubro 2008. 613 – 627p.

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

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**. Tese (Doutorado) Curso de Pós-Graduação em Engenharia Civil – Pontifca Universidade Católica do Rio de Janeiro, Rio de Janeiro, Rio de Janeiro-RJ, 2000. Páginas?

FERNANDA DE ALMEIDA PRADO, MARIA DE LOURDES BUENO TRINDADE GALO. Classificação de imagens multiespectrais baseada em abordagem *fuzzy*. **Revista Brasileira de Cartografia**, No 61/03, 2009. 233,244, 2009p.

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.

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.

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.

MENDONÇA, M.; NÉIA, J. .M; BRINHOLE, E. .R. **Redes neurais aplicadas em simulação de circuitos eletrônicos**. UNOPAR Cient..., Ciênc. Exatas Tecnol., Londrina, v. 1, n. 1, p. 29-32, Nov. 2002.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto: metodologias de aplicação**. 3 ed. Viçosa: UFV. 2005. 320p.

NASCIMENTO, M C. et al. Uso de imagens do sensor ASTER na identificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.10, n.1, p.196–202, 2006.

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.

SARTORI, L. B.; GALO, M. L. B. T.; IMAI, N. N. Mapeamento de plantas daninhas em cultura de café a partir de imagens multiespectrais de escalas grandes usando redes neurais artificiais. **Revista Brasileira de Cartografia** No 61/02, 2009. 165 – 175 p.

SOUSA, B. F. S; TEIXEIRA, A. S; SILVA, F A. T. F. ANDRADE, E. M; BRAGA. A. P. S. Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma caatinga. **Revista Brasileira de Cartografia**, No 62 EDIÇÃO ESPECIAL 2, 2010. 385, 349p.

SOUTO, R. P. **Segmentação de imagem multiespectral utilizando-se o atributo matiz / R. P. Souto**. Dissertação (Mestrado) Curso da Pós-Graduação em Sensoriamento Remoto, São José dos Campos: INPE, 2003. 171p.

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 Connectionnist Approach. *International Journal of Neural Systems*, 1990; Vol.1, nº.3, pp.193-209.