



APLICAÇÃO DE REDES NEURAS ARTIFICIAIS (RNA) NA ANÁLISE E CLASSIFICAÇÃO DE ÁREAS CAFEEIRAS DA REGIÃO DE MACHADO-MG

LÍVIA N. ANDRADE¹, TATIANA G. C. VIEIRA², HELENA M. R. ALVES³,
MARGARETE M. L. VOLPATO⁴, VANESSA C. O. SOUZA⁵

¹ Tecnóloga em Análise e Desenvolvimento de Sistemas, Bolsista Embrapa Café CBP&D/Café, livia.naiara.andrade@gmail.com

² M. Sc. em Solos e Nutrição de Plantas, Pesquisadora EPAMIG/URES, Bolsista FAPEMIG, tatiana@epamig.ufla.br

³ D. Sc. em Soil Science And Land Evaluation, Pesquisadora EMBRAPA CAFÉ, helena@epamig.ufla.br

⁴ D. Sc. em Engenharia Agrícola, Pesquisadora EPAMIG/URES, Bolsista FAPEMIG, margarete@epamig.ufla.br

⁵ M. Sc. em Sensoriamento Remoto, Bolsista EPAMIG CBP&D/Café, vanessa@epamig.ufla.br

Apresentado no

IX Congresso Latinoamericano y del Caribe de Ingeniería Agrícola - CLIA 2010

XXXIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2010

25 a 29 de julho de 2010 - Vitória - ES, Brasil

RESUMO: A cafeicultura é atividade de fundamental importância na região sul de Minas Gerais e técnicas de estimativa da área plantada, visando previsões de safra confiáveis, estão sendo intensamente pesquisadas. Neste sentido, o presente estudo apresenta uma aplicação de Redes Neurais Artificiais (RNA) para a classificação automática de dados de sensoriamento remoto, com o objetivo de identificar áreas cafeeiras da região de Machado, MG. A região apresenta relevo ondulado a forte ondulado, o que acarreta maior dificuldade do mapeamento automático do uso da terra a partir de imagens de satélite. Outro complicador é a alta similaridade do padrão espectral do café e áreas de mata nativa. A área foi dividida entre os relevos plano e acidentado, e foram criadas máscaras na drenagem e na área urbana. O resultado da classificação feita pela RNA foi superior aos resultados encontrados na literatura, que utilizam classificadores automáticos clássicos, como o Battacharya e o Maxver. O Kappa do mapa classificado pela RNA foi de 55.84% para o relevo mais movimentado e 60.29% para o relevo menos movimentado.

PALAVRAS-CHAVE: Cafeicultura, Redes Neurais Artificiais, Sensoriamento Remoto.

APPLICATION OF ARTIFICIAL NEURAL NETWORKS (ANN) IN THE ANALYSIS AND CLASSIFICATION OF COFFEE AREAS IN THE REGION OF MACHADO-MG

ABSTRACT: The coffee is an activity of fundamental importance in the southern region of Minas Gerais and techniques for estimating the area planted, in order to yield reliable estimates, are being intensely investigated. In this sense, this study presents an application of Artificial Neural Networks (ANN) for the automatic classification of remote sensing data, in order to identify areas of the region's coffee Machado, MG. The regional relief is predominantly undulating to hilly, which leads to greater difficulty of automatic mapping of land use from satellite images. Another complicating factor is the high similarity of the spectral pattern of coffee and areas of native forest. The area was divided between flat and hilly reliefs and masks were created in the drainage and urban areas. The result of classification made by the ANN was superior to the results found in literature, using known automatic classifiers such as Battacharya and Maxver. The Kappa index of the map classified

by ANN was 55.84% for the more undulated part of the experimental area and 60.29% for smoother areas.

KEYWORDS: Coffee Production, Artificial Neural Networks, Remote Sensing.

INTRODUÇÃO

O mapeamento e a dinâmica do uso e ocupação da terra, em termos de usos e coberturas, têm impactos importantes nos sistemas sócio-econômicos e ambientais, apresentando medidas estratégicas significativas para a cadeia produtiva do café.

Quando se tem como alvo lavouras de café, é preciso ter em conta que estas estão inseridas num contexto ambiental, havendo, portanto, interferências múltiplas, tanto dos objetos adjacentes, quanto das variações de suas próprias características. Desta forma o solo, por exemplo, influencia a reflectância de superfícies compostas de vegetação e solos. Outro fator a se considerar é a exposição desta superfície à luz incidente, em função da orientação da vertente causando diferentes efeitos resultantes de sombreamento (relevo muito movimentado propicia regiões sombreadas) e aumento ou redução da componente de radiação difusa. Além disso, estudos têm mostrado que o café apresenta uma resposta espectral complexa e variada que está relacionada aos parâmetros da cultura. Soma-se a isto o fato de que cafezais com mais de três anos de plantio, apresentam uma resposta espectral semelhante à mata (EPIPHANIO *et al.*, 1994 e VIEIRA *et al.*, 2006).

Devido a estes fatores, no mapeamento de áreas cafeeiras os métodos de classificação baseados em conceitos estatísticos não tem alcançado os objetivos desejados, visto que, se torna necessária ainda a interação humana, ou seja, a interpretação visual tem desempenhado um papel expressivo. Tendo em vista as dificuldades observadas no processo de reconhecimento de padrões em imagens, aplicações na classificação de imagens de sensoriamento remoto têm sido registradas na literatura, mostrando que as Redes Neurais Artificiais (RNAs) em meios agrícolas têm apresentado resultados superiores em relação aos métodos convencionais de classificação automática (VIEIRA *et al.*, 2009 e ANDRADE *et al.*, 2009).

As RNAs têm sido aplicadas com sucesso nas áreas de processamento de imagens e reconhecimento de padrões. As RNAs usam elementos de computação não-linear (chamados neurônios) organizados como redes, de maneira análoga à que se acredita que os neurônios estejam interconectados no cérebro (GONZALES *et al.*, 2000). No caso particular de aplicações em classificação de imagens de sensoriamento remoto, diversos trabalhos (HEPNER, 1990; BENEDIKTSSON *et al.*, 1990; LIU *et al.*, 1991) fizeram uso de RNA, aplicando uma rede de perceptrons multicamadas (MLP) para resolver o problema de classificação. Este tipo de rede caracteriza-se por assumir regiões de decisão semelhantes àquelas formadas por um classificador estatístico, porém com entradas não correlacionadas e distribuições diferentes para os dados (LIPPMANN, 1987).

Sendo assim, objetivou-se neste trabalho definir um procedimento de classificação automática utilizando Redes Neurais Artificiais para identificação de áreas cafeeiras em imagens de satélite da região de Machado-MG, que se encontra entre as mais importantes regiões cafeeiras do Sul de Minas.

METODOLOGIA

Área de Estudo

A área de estudo encontra-se no Sul de Minas Gerais, localizada na região de Machado, delimitada pelas coordenadas s 21°42'05" e s 21°31'10" e entre o 46°02'38" e o 45°47'30". O ambiente é caracterizado por áreas elevadas, com altitudes de 780 a 1260 metros, clima ameno, sujeito a geadas, moderada deficiência hídrica, relevo suave ondulado a forte ondulado, com grande possibilidade de produção de bebidas finas, sistemas de produção

de médio a alto nível tecnológico. O café produzido nas montanhas de Machado tem destaque internacional. Recentemente a cidade recebeu o título de capital mundial do café orgânico devido a seu pioneirismo nesta cultura. Possui uma moderna Torrefação de cafés especiais, junto ao IFET - Campus Machado e abriga o Centro de Excelência do Café.

Material

Neste trabalho foram utilizadas imagens multiespectrais para classificação automática com RNA, que se referem às bandas 3, 4 e 5 do satélite Landsat 5, sensor TM, com data de passagem de 16/08/2007 e o Mapa de uso da terra Machado–MG (EPAMIG, 2009), classificado visualmente. Foram utilizados os sistemas de informações geográficas SPRING (CÂMARA *et al.*, 1996) versão 4.3.3 e o software IDRISI (CLARK, 2006).

O diagrama da Figura 1 mostra todas as etapas de desenvolvimento do trabalho.

Métodos

O diagrama da Figura 1 mostra as etapas de desenvolvimento do trabalho.

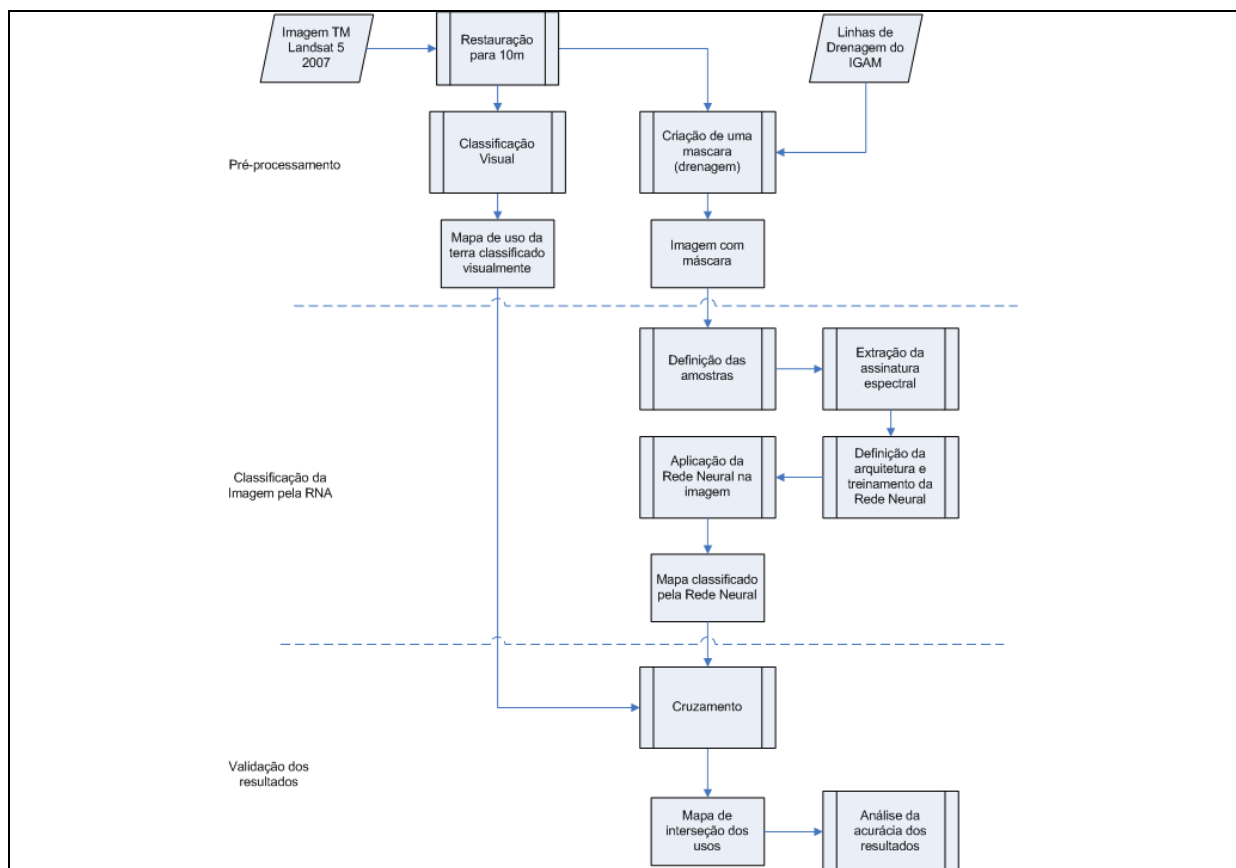



FIGURA 1. Metodologia do trabalho

Pré-processamentos

As imagens foram restauradas de 30m para 10m para melhorar a qualidade espacial dos dados (FONSECA, 1987). Foi criada uma máscara ao longo da rede de drenagem (Figura 2), utilizando a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do SPRING, em cada uma das três bandas. Foram utilizadas as linhas de drenagem do Instituto Mineiro de Gestão das Águas (IGAM), e sobre elas, criado um buffer de 50m e atribuído o valor dez aos pixels que se encontravam nestas áreas. Esse procedimento foi realizado para tentar eliminar o erro causado pela classificação da RNA, uma vez que ao longo da drenagem existem pequenas áreas de mata que se confundem com café ou qualquer outra classe de uso. Foi criada, também, uma máscara na área urbana de Machado e atribuído o valor de pixels de 255.

Após a criação da máscara, a imagem foi dividida em duas partes, uma com relevo mais movimentado e outra com relevo menos movimentado. LACERDA (2001) desenvolveu um trabalho na região de Machado e mostrou que existem dois ambientes geomorficos: Ambiente Geomorfico N-NE-E, em relevo predominantemente plano a ondulado, ocorrendo na região norte, nordeste e leste em relação ao núcleo urbano; e Ambiente Geomorfico W-NW, ocorrendo relevo predominantemente ondulado a montanhoso na região oeste e noroeste em relação ao núcleo urbano.



Classificação da imagem pela RNA

Foram realizados diversos testes para definição da arquitetura ideal para a classificação, sendo adotado um modelo de rede neural com estrutura de múltiplas camadas, da abordagem supervisionada. A RNA foi treinada com algoritmo *backpropagation*, realizando as seguintes alterações na arquitetura da RNA: número do conjunto de *pixels* para o conjunto de treinamento e teste; número de camadas; número de neurônios nas camadas; fator de *momentum* e taxa de aprendizado.

A obtenção de áreas de treinamento e validação da RNA foi realizada por meio da extração de áreas em formato de polígonos da imagem para cada classe a ser classificada. Para auxílio na definição das amostras de treinamento foi utilizado um mapa temático de uso da terra da região selecionada classificada visualmente. Foram selecionados entre 45 e 50 polígonos de tamanhos variados e espaçados ao acaso para cada classe, compostas da seguinte forma: **café em produção**: lavouras com idade superior a três anos; **mata**: formações florestais densas e florestas de galeria às margens dos córregos; **área urbana**: área com grande concentração de construções; **água**: lagoas, represas e a máscara de drenagem; e **outros usos**: áreas com café em formação (menor que três anos), áreas com culturas anuais em diversos estágios de desenvolvimento, pastagens e outros tipos de vegetação.

Após a obtenção das áreas de treinamento, foi utilizado o módulo *Makesig* do IDRISI para realizar a extração da assinatura espectral do conjunto de amostras. Para a definição da arquitetura da RNA para classificação da imagem, foi executado o módulo de classificação por redes neurais do tipo *multi-layer perceptron*, do *software* IDRISI. O número de elementos

da camada de saída foi definido com base no número de classes a serem classificadas na imagem, sendo cinco nós com valores identificados na criação das amostras.

Validação dos resultados

Para validação das classificações realizadas pela RNA, foram realizados cruzamentos entre o mapa classificado visualmente com os classificados pela Rede Neural Artificial utilizando a linguagem LEGAL. A Figura 3 mostra o mapa de uso da terra classificado visualmente com as máscaras de drenagem e área urbana. Esse mapa foi utilizado como referência para avaliar a classificação feita pela RNA

Para avaliar o desempenho da RNA, utilizou-se o índice Kappa que é baseado na construção de matrizes de erro ou de contingência. O uso desse coeficiente é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação (BERNARDES, 2006).

A análise do desempenho da RNA foi avaliada em três classes, sendo elas: **Áreas classificadas corretamente:** *pixels* de áreas de café classificadas pela RNA e pelo método visual; **Áreas classificadas incorretamente:** *pixels* que a RNA classificou como café, porém não eram áreas cafeeiras e **Áreas não classificadas:** *pixels* que a RNA deixou de classificar como café, classificando como outra classe.

RESULTADOS E DISCUSSÃO

As configurações de teste e treinamento da rede neural utilizadas foram as mesmas tanto para o relevo mais movimentado, quanto para o relevo menos movimentado. A Tabela 1 exhibe as configurações utilizadas, e em destaque as que apresentaram melhores resultados.

TABELA 1. Configurações utilizadas no treinamento.

Config.	Pixel ¹	Nº de cam.	Neurônios		Taxa de aprend.	Momentum	Iterações	EMQ (relevo menos movimentado)		EMQ (relevo mais movimentado)	
			1ª Cam.	2ª Cam.				Trein.	Teste	Trein.	Teste
1	60	1	16	-	0.01	0.5	10000	0.0056	0.0058	0.0050	0.0057
2	60	2	20	14	0.01	0.5	10000	0.0049	0.0059	-	-
3	65	1	14	-	0.01	0.5	10000	-	-	0.0054	0.0054
4	65	1	18	-	0.01	0.5	10000	-	-	0.0052	0.0055
5	65	1	18	-	0.01	0.5	10000	0.0048	0.0054	0.0052	0.0055
6	65	2	24	18	0.01	0.53	10000	0.0051	0.0051	-	-
7	70	1	16	-	0.01	0.5	10000	0.0050	0.0052	0.0043	0.0053
8	70	2	16	10	0.01	0.5	10000	0.0049	0.0051	-	-
9	70	1	18	-	0.01	0.5	10000	0.0047	0.0053	0.0051	0.0051
10	70	1	18	-	0.02	0.53	10000	0.0047	0.0049	0.0046	0.0050

¹ Número de pixels selecionados para o conjunto de treinamento e teste.

A rede que apresentou melhor resultado para o relevo menos movimentado possuía 18 neurônios em uma única camada escondida e 5 neurônios na saída, um conjunto de 70 pixels por categoria para o conjunto de teste e treinamento, taxa de aprendizado de 0.02; fator de momentum de 0.53 para agilizar na convergência da rede; e constante de sigmóide de 1. Para o relevo mais movimentado, a RNA que obteve melhor resultado também possuía apenas uma camada escondida, porém com 14 neurônios, um conjunto de teste e treinamento com 65 pixels, taxa de aprendizado de 0.01 e fator de momentum 0.5. Como critério de parada do treinamento da rede foi estabelecido, para ambas as partes, erro médio quadrático (EMQ) de 0,0001 ou 10.000 iterações. A parada do treinamento da RNA aconteceu pelo número de

iterações do algoritmo *backpropagation*, resultando em um valor de EQM para os dados de treinamento e de teste.

De acordo com a Tabela 1, pode-se relatar que a rede neural teve melhor desempenho com uma camada escondida, variando a quantidade de neurônios na camada e o conjunto de pixels. Observando os resultados obtidos no relevo menos movimentado, percebeu-se que aumentando o número de pixels do conjunto de treinamento e teste, a rede produziu melhores resultados, com um número de neurônios da primeira camada variando entre 16 e 18, o que não acontece no relevo mais movimentado, que obteve melhores resultados em uma única camada e uma quantidade menor de neurônios.

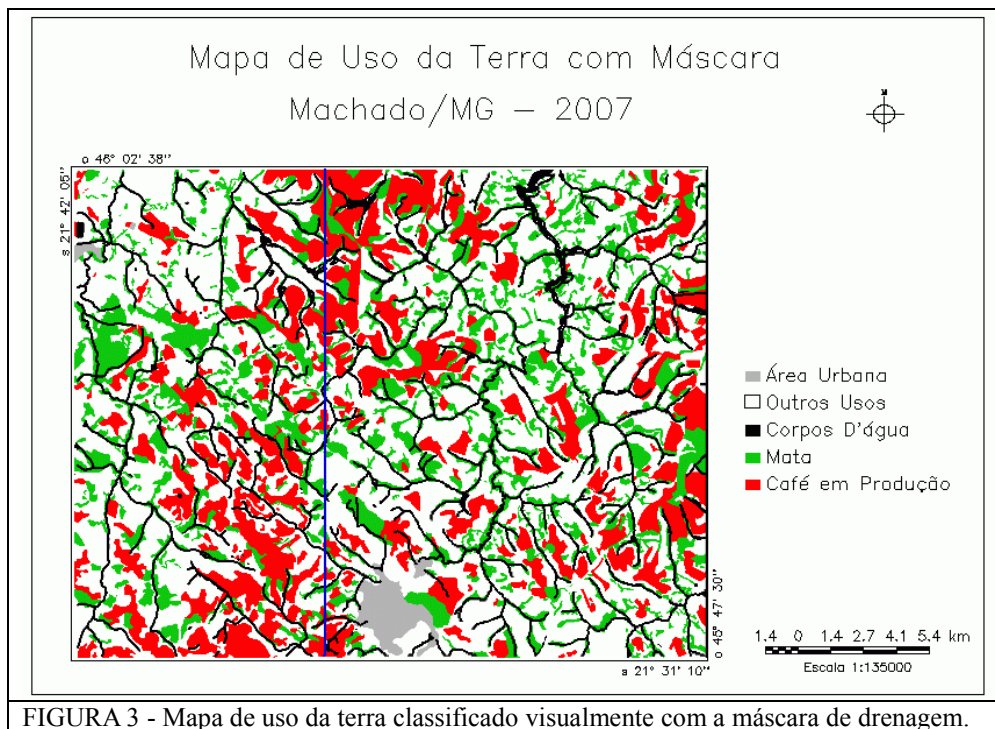


FIGURA 3 - Mapa de uso da terra classificado visualmente com a máscara de drenagem.

O desempenho da rede neural foi testado gerando-se o índice Kappa entre os mapas de classificado pela RNA (Figura 4) e o de uso da terra classificado visualmente (mapa de referência). O índice de acurácia Kappa do mapa classificado pela RNA foi de 55.84% para o relevo mais movimentado e 60.29% para o relevo menos movimentado, que segundo GALPARSORO & FERNÁNDEZ (2001) são índices moderados. Os índices de acurácia Kappa obtidos na classificação por RNA podem ter sido prejudicados pelos fatores ambientais que interferem no padrão espectral da imagem, tais como, variações do estágio fenológico, vigor vegetativo, do espaçamento das plantas nas lavouras e dos tratos culturais utilizados, existência de culturas intercalares, maior sombreamento devido ao relevo acidentado e baixa resolução espacial das imagens Landsat utilizada. Contudo, se comparados aos resultados obtidos por SANTOS (2007) e MARQUES (2003), que utilizaram os algoritmos de classificação automática Battacharya e Maxver na mesma região cafeeira para mapeamento de uso da terra, a RNA apresentou melhor resultado.

MARQUES (2003), aplicou os classificadores automáticos Battacharya (classificador por região) e Maxver (classificador pixel a pixel) em imagens Landsat 7 ETM+ do ano 2000 e apesar dos baixos índices de acurácia Kappa, Maxver com 39% e Battacharya com 42%, o autor concluiu que os classificadores tiveram um desempenho moderado, pois a área possui um relevo que dificulta a classificação. Já SANTOS (2007), utilizou os mesmos classificadores automáticos em imagens Landsat 5 TM do ano de 2005, da mesma área e obteve baixos índices de acurácia kappa, sendo 20.2% para o classificador Battacharya e

25.09% para o Maxver. Ele conclui que o baixo desempenho das classificações pode ser explicado por essa região possuir um relevo muito movimentado, proporcionando regiões sombreadas e lavouras cafeeiras contíguas a fragmentos de vegetação nativa, os quais apresentam resposta espectral semelhante ao café.

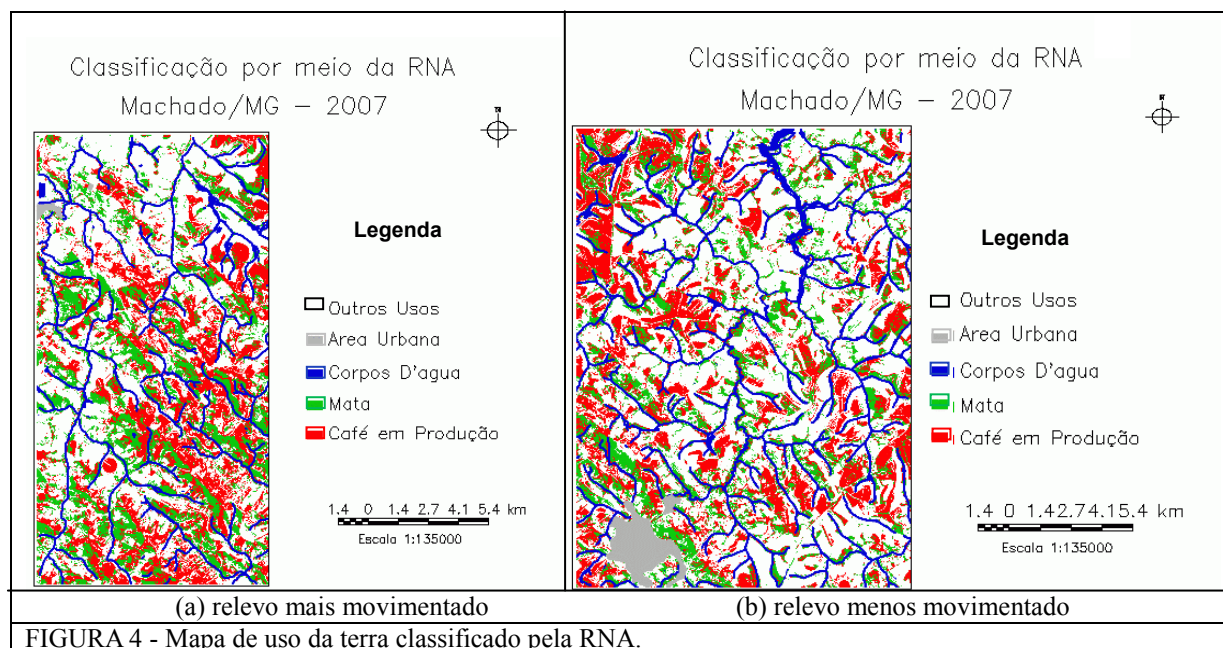


FIGURA 4 - Mapa de uso da terra classificado pela RNA.

Na Tabela 2 é apresentada a matriz de confusão entre os mapas de referência e o classificado pela RNA. A matriz contém as taxas de erro e acerto da classificação para cada classe. Os valores marcados de cinza são das áreas com relevo menos movimentado.

TABELA 2. Matriz de confusão entre os mapas de referência e o classificado pela RNA (em %)*

Mapa Classificado Visualmente	Mapa Classificado pela RNA					
	Café em Produção	Mata	Água	Área Urbana	Outros Usos	TOTAL
Café em Produção	63.60%	14.09%	0.32%	0.02%	21.98%	100%
	59.06%	20.60%	0.00%	0.01%	20.33%	
Mata	28.22%	42.35%	2.31%	0.03%	27.10%	100%
	27.89%	50.34%	0.01%	0.00%	21.75%	
Água	1.30%	2.30%	91.52%	0.61%	4.27%	100%
	0.00%	0.00%	99.99%	0.00%	0.01%	
Área Urbana	0.35%	0.50%	0.11%	97.76%	1.29%	100%
	0.00%	0.00%	0.00%	99.98%	0.02%	
Outros Usos	8.53%	7.72%	1.04%	0.11%	82.60%	100%
	11.98%	12.15%	0.01%	0.01%	75.84%	

*Cada célula da tabela contém dois valores, referentes às duas áreas classificadas pela rede neural (Relevo menos Movimentado, Relevo mais Movimentado).

Analisando a matriz de confusão, pôde-se observar que no relevo menos movimentado a rede classificou melhor áreas cafeeiras, com uma porcentagem de acerto de 63.60%, enquanto que no relevo mais movimentado a rede conseguiu um acerto um pouco menor, de 59.06%. Como era de se esperar, na área de relevo menos movimentado o índice apresentou melhor devido a menor interferência da sombra na reflectância do dossel do cafeeiro. Outro fator importante foi a criação de máscaras na rede drenagem, eliminando o erro de classificação entre as classes temáticas mata e café ao longo dos drenos, e, assim, melhorando o resultado da classificação da RNA.

A classe outros usos que engloba café em formação, culturas anuais em diversos estágios de desenvolvimento, pastagens e outros tipos de vegetação, também pode ser considerada como uma boa classificação, variando entre 75 e 82%, apresentando pequena confusão com áreas de café e mata. Por englobar diversos tipos de vegetação, a RNA pode ter confundido com áreas cafeeiras, fato este que justifica as taxas de 21.98 e 20.33% de áreas classificadas incorretamente como café pela rede neural.

Outra dificuldade de classificação apresentada pela RNA pode ser observada na classe mata, que obteve como acerto 42.35 e 50.34% para o relevo menos movimentado e para o relevo mais movimentado, respectivamente. A classificação da mata teve grande confusão com áreas de café, devido ao padrão espectral muito próximo (VIEIRA, 2006), e apresentou também grande confusão com áreas de outros usos, devido a fatores já discutidos anteriormente.

A classe água apresentou taxa de acerto superior a 90%, porque durante a criação da máscara foi atribuído o valor dez aos pixels que se encontravam nas áreas cobertas pelo buffer e nas áreas de água. A classe área urbana teve uma boa classificação, com índices superiores a 95%, pois também foi criada uma máscara com pixels no valor de 255.

O mapa de referência e o gerado pela classificação da RNA foram cruzados no SPRING, utilizando a linguagem LEGAL. Deste cruzamento obteve-se o mapa temático apresentado na Figura 5, que demonstra, espacialmente, o desempenho da RNA, e apresenta as seguintes classes temáticas: áreas corretamente classificadas, áreas classificadas incorretamente, e áreas não classificadas.

A área total do mapa é de 520 km², sendo 110,13 km² de áreas cafeeiras. Os mapas apresentam o desempenho da RNA sobre a classe café, onde o café classificado corretamente equivale a 67,95 km², o classificado incorretamente a 50,58 km² e as áreas de café não classificadas a 42,18 km². Analisando as áreas separadamente, o relevo menos movimentado possui 69,34 km² de áreas cafeeiras, sendo classificadas corretamente pela RNA 40,80 km², e 28,54 km² áreas classificadas incorretamente. Já o relevo mais movimentado possui 49,20 km² de áreas cafeeiras, sendo 27,15 km² classificadas corretamente e 22,04 km² classificadas incorretamente.

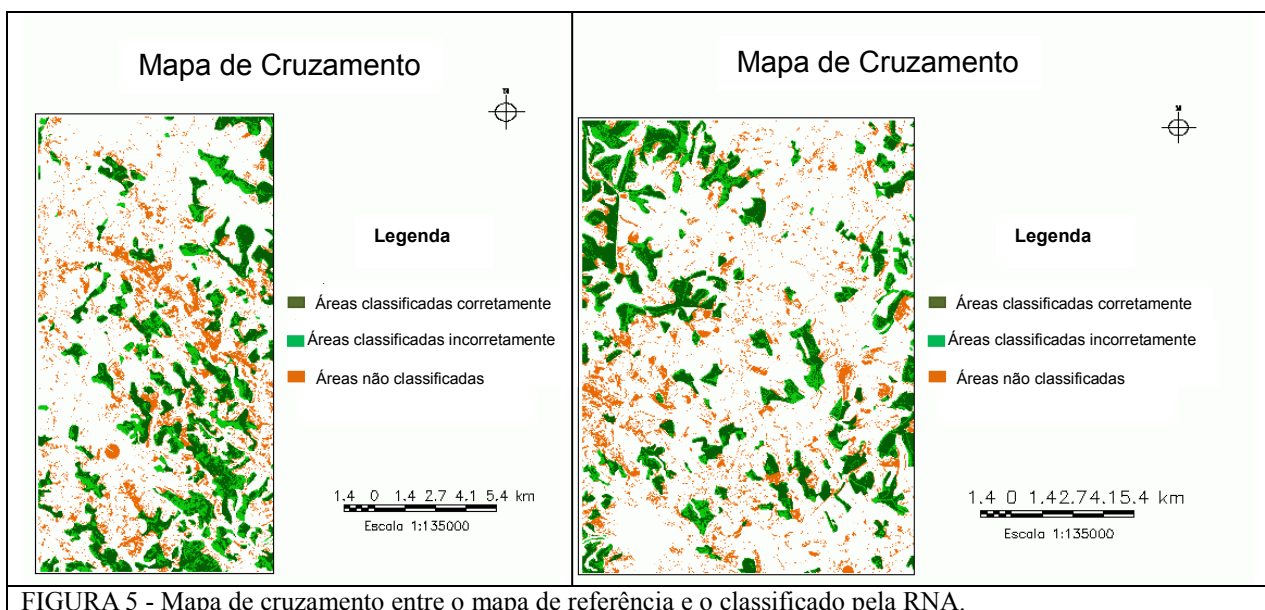


FIGURA 5 - Mapa de cruzamento entre o mapa de referência e o classificado pela RNA.

CONCLUSÕES

A maioria dos classificadores automáticos de imagens espectrais avalia apenas a resposta espectral dos alvos. Quando o alvo estudado, como a cultura cafeeira, apresenta tamanha complexidade, onde fatores ambientais, fenológicas e de manejo interferem na resposta espectral, tais classificadores não apresentam resultados satisfatórios.

Assim, redes neurais artificiais podem ser consideradas como uma alternativa aos classificadores atualmente utilizados para a classificação de imagens espectrais, por permitirem a utilização de outros parâmetros, além do espectral.

Este estudo exploratório superou os resultados encontrados na literatura até então. Apesar de ainda não ter sido incorporado à rede, nenhum outro parâmetro, a não ser o espectral, a metodologia proposta separou os ambientes geomórficos, a fim de permitir uma melhor coleta de amostras; e incluiu máscaras na rede de drenagem e na área urbana, diminuindo assim a quantidade e a variabilidade dos alvos observados nas imagens.

Trabalhos futuros visam incorporar à estrutura da RNA, atributos como forma e textura dos alvos, visto que estes são os atributos utilizados pela interpretação visual, em momentos onde a resposta espectral apenas não é suficiente.

AGRADECIMENTOS

Os autores agradecem ao apoio da Fundação de Amparo à Pesquisa de Minas Gerais - FAPEMIG e ao Consórcio Brasileiro de Pesquisa e Desenvolvimento do Café - CBPD/Café pelos recursos financeiros para o desenvolvimento do projeto e bolsas.

REFERÊNCIAS

ANDRADE, L. N.; VIEIRA, T. G. C.; LACERDA, W. S.; ALVES, H. M. R.; VOLPATO, M. M. L.; BRAGA, R. C. A.; SOUZA, V. C. O. **Redes neurais artificiais na classificação de áreas cafeeiras da região de Guaxupé**. 2009. In. Simpósio de Pesquisa dos Cafés do Brasil, v. 6, Vitória-ES. Brasília: Embrapa Café. CDROM .

BENEDIKTSSON, J. A., SWAIN, P. H., ERSOY, O. K. Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 4, p. 540-552, 1990.

BERNARDES, T. **Caracterização do ambiente agrícola do Complexo Serra Negra por meio de Sensoriamento Remoto e Sistemas de Informação Geográfica**. 2006. 119 p. Dissertação (Mestrado em Ciência do Solo) -Universidade Federal de Lavras, Lavras.2006.

CÂMARA, G., R. C. M. SOUZA, U. M. FREITAS e J. GARRIDO. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v.20, n.3, May/June 1996, p.395-403. 1996.

CLARK LABS, IDRISI Andes, v.15.00, Clark University, Worcester, 2006.

EPAMIG. Centro Tecnológico do Sul de Minas. Laboratório de Geoprocessamento. **Geosolos**. Lavras, 2009. Disponível em: <www.epamig.br/geosolos/>. Acesso em: 18 fev 2010.

EPIPHANIO, J. C. N.; LEONARDI, L.; FORMAGGIO, A. R. **Relações entre parâmetros culturais e resposta espectral de cafezais**. Pesquisa Agropecuária Brasileira. v. 29, n. 3, p. 439-447, mar. 1994.

FONSECA, L.M.G.; MASCARENHAS, N.D.A.; BANON, G.J.F. **"Técnicas de Restauração para Reamostragem de Imagens do Satélite Landsat-5"**, 1987. In. Simpósio Brasileiro de

Telecomunicações, v. 5, p.204-208, Campinas-SP, 8-10 Setembro 1987. (INPE-4189-PRE/1076)

GALPARSORO, L. U. FERNÁNDEZ, S. P. **Medidas de concordância: el índice Kappa**. 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em: 10 mar. 2010.

GONZALES, R.C.; WOODS, R.E. **Processamento de Imagens Digitais**. São Paulo: Edgard Blücher Ltda, 2000.527p.

HEPNER, G. F. Artificial Neural Networks Classification using a Minimal Training Set: Comparison to Conventional Supervised Classification. **Photogrammetric Engineering and Remote Sensing**, v. 56, n. 4, p. 469-473, 1990.

LACERDA, M. P. C.; ALVES, H. M.R.; VIEIRA, T. G. C.; RESENDE, R. J. T. P.; ANDRADE, H.; MACHADO, M. L.; CEREDA, G. J. **Caracterização de agroecossistemas cafeeiros de Minas Gerais por meio do SPRING. Parte II – Agroecossistema de Machado**. 2001. In: Simpósio de Pesquisas dos Cafés do Brasil, v. 2, 2001, Poços de Caldas. Brasília: Embrapa Café. CD-ROM.

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

LIU, Z. K., XIAO, J. Y. Classification of remotely-sensed image data using artificial neural networks. **International Journal of Remote Sensing**, v. 12, n. 11, p. 2433-2438, 1991.

MARQUES, H. S. **Uso de geotecnologias no estudo das relações entre solos, orientação de vertentes e o comportamento espectral de áreas cafeeiras em Machado, Minas Gerais**. 2003. 82 p. Dissertação (Mestrado em Agronomia-Solos e Nutrição de Plantas) - Universidade Federal de Lavras, Lavras.2003.

SANTOS, W. J. R.; Vieira, T. G. C.; BERNARDES, T.; ALVES, H. M. R.; SILVEIRA, S. P. S. **Exatidão de classificações automáticas de uma imagem Landsat 5 TM para a região cafeeira de Machado, MG**. 2007. In: Simpósio de Pesquisa dos Cafés do Brasil, v. 5, 2007, Águas de Lindóia. Brasília: Embrapa Café. CDROM.

VIEIRA, T. G. C.; ALVES, H. M. R.; LACERDA, M. P. C.; VEIGA, R. D.; EPIPHANIO, J. C. N. Crop parameters and spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, v.1, n.2, p.111-118, 2006.

VIEIRA, T. G. C.; LACERDA, W. S.; BOTELHO, T. G. **Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de Três Pontas, Minas Gerais**. 2009. In: Simpósio Brasileiro de Sensoriamento Remoto. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.13.12.57/doc/7947-7954.pdf>> Acesso em: 05 mar 2010.