

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA CLASSIFICAÇÃO DE ÁREAS CAFEIRAS EM MACHADO-MG

Lívia Naiara de Andrade¹, Tatiana Grossi Chquiloff Vieira², Wilian Soares Lacerda³,
Margarete Marin Lordelo Volpato⁴, Clodoveu Augusto Davis Junior⁵

(Recebido: 21 de julho de 2011; aceito: 15 de outubro de 2012)

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. Apresenta-se, no presente estudo, uma aplicação de Redes Neurais Artificiais (RNA) para a classificação automática de dados de sensoriamento remoto, objetivando identificar áreas cafeeiras da região de Machado, MG. A metodologia para desenvolvimento da aplicação da RNA foi dividida em três etapas: pré-processamento dos dados; treinamento e uso da RNA; e análise dos resultados. Na primeira etapa foi realizada a divisão da área em estudo em duas partes (uma com relevo mais movimentado e outra com relevo menos movimentado), isso porque a região apresenta relevo suave ondulado a forte ondulado, o que acarreta maior dificuldade do mapeamento automático do uso da terra a partir de imagens de satélite. Foram também criadas máscaras na rede de drenagem e área urbana. Na segunda etapa, diversas RNAs foram treinadas a partir de várias amostras de imagens representativas das classes de interesse e foi feita a classificação do restante da imagem utilizando a melhor RNA obtida. A terceira etapa consistiu na análise e validação dos resultados, realizando um cruzamento entre o mapa classificado visualmente e o mapa classificado pela Rede Neural escolhida. Utilizou-se o índice Kappa para avaliar o desempenho da RNA, uma vez que o uso desse coeficiente é satisfatório na avaliação da precisão de uma classificação temática. O resultado obtido foi superior aos resultados encontrados na literatura, com um índice Kappa de 0,558 para o relevo mais movimentado e 0,602 para o relevo menos movimentado.

Termos para indexação: Redes Neurais Artificiais, classificação automática, cafeicultura.

APPLICATION OF ARTIFICIAL NEURAL NETWORK IN THE CLASSIFICATION OF COFFEE AREAS IN MACHADO, MINAS GERAIS STATE

ABSTRACT: The coffee is extremely important activity in southern of Minas Gerais and techniques for estimating acreage, seeking reliable crop forecasts are being intensely investigated. It is presented in this study, an application of Artificial Neural Networks (ANN) for the automatic classification of remote sensing data in order to identify areas of the coffee region Machado, Minas Gerais. The methodology for developing the application of RNA was divided into three stages: pre-processing of data, training and use of RNA, and analysis of results. The first step was performed dividing the study area into two parts (one embossed busiest and least busy one with relief), because this region has a strong emphasis smooth wavy, causing a greater difficulty of automatic mapping of use earth from satellite images. Masks were also created in the drainage network and the urban area. In the second step, various RNA's were trained from several samples representative of the classes of images of interest and was made to classify the rest of the image obtained using the best RNA. The third step consisted in analyzing and validating the results, performing a cross between the classified map and the map visually classified by neural network chosen. We used the Kappa index to evaluate the performance of the RNA, since the use of this coefficient is satisfactory to assess the accuracy of a thematic classification. The result was higher than the results reported in the literature, with a Kappa index of 0.558 to 0.602 relief busiest and least busy for relief.

Index Terms: Artificial Neural Networks, automatic classification, coffee.

¹ Universidade Federal de Lavras/UFLA - Departamento de Ciência da Computação/DCC - Cx. P. 3037 - 37.200-000 - Lavras - MG - livia.naiara.andrade@gmail.com

² Empresa de Pesquisa Agropecuária de Minas Gerais/EPAMIG - Laboratório de Geoprocessamento/ GEOSOLOs - Cx. P. 176 37.200-000 - Lavras - MG - tatiana@epamig.ufla.br

³ Universidade Federal de Lavras/UFLA - Departamento de Ciência da Computação/DCC - Cx. P. 3037 - 37.200-000 - Lavras - MG - lacerda@ufla.br

⁴ Empresa de Pesquisa Agropecuária de Minas Gerais/EPAMIG - Laboratório de Geoprocessamento/ GEOSOLOs - Cx. P. 176 37.200-000 - Lavras - MG - margarete@epamig.ufla.br

⁵ Universidade Federal de Minas Gerais/UFMG - Departamento de Ciência da Computação/DCC - Av. Antônio Carlos, 6627 Prédio do ICEX - Pampulha - 31270-010 - Belo Horizonte - MG - clodoveu@dcc.ufmg.br

Coffee Science, Lavras, v. 8, n. 1, p. 78-90, jan./mar. 2013

1 INTRODUÇÃO

O mapeamento e a dinâmica do uso e ocupação da terra, em termos de usos e coberturas, têm impactos importantes nos sistemas socioeconômicos 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 essas estão inseridas num contexto ambiental, havendo, portanto, interferências múltiplas, tanto dos objetos adjacentes, quanto das variações de suas próprias características. Dessa forma o solo, por exemplo, influencia a reflectância de superfícies compostas de vegetação e solos. Outro fator a se considerar é a exposição dessa 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 isso o fato de que cafezais com mais de três anos de plantio, apresentam uma resposta espectral semelhante à mata (EPIPHANIO; LEONARDI; FORMAGGIO, 1994; VIEIRA et al., 2006).

Devido a estes fatores, no mapeamento de áreas cafeeiras os métodos de classificação baseados em conceitos estatísticos não têm 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) utilizadas para classificação de culturas agrícolas têm apresentado resultados superiores em relação aos métodos convencionais de classificação automática (CHAGAS et al., 2009; VIEIRA; LACERDA; BOTELHO, 2009).

As redes neurais têm sido aplicadas com sucesso nas áreas de processamento de imagens e reconhecimento de padrões (GONÇALVES et al., 2008). 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 humano (BRAGA; CARVALHO; LUDERMIR, 2007; GONZALES; WOODS, 2008). No caso particular de aplicações em classificação de imagens de sensoriamento remoto, diversos trabalhos (CHAGAS et al., 2010; LIU; XIAO, 1991; RUHOFF; FANTIN-CRUZ; COLLISCHONN, 2010) fizeram uso de RNA, aplicando uma rede de Perceptrons multicamadas (MLP - *Multi Layer Perceptron*) para resolver o problema de classificação. Esse 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.

2 MATERIAIS E MÉTODOS

A área de estudo encontra-se no Sul de Minas Gerais, localizada na região de Machado, delimitada pelas coordenadas 21°42'05" e 21°31'10" Sul e 46°02'38" e 45°47'30" Oeste. 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 nessa cultura.

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 (Figura 1), disponibilizadas pelo Instituto Nacional de Pesquisas Espaciais – INPE, e o mapa de uso da terra Machado-MG (EMPRESA DE PESQUISA AGROPECUÁRIA DE MINAS




FIGURA 1 – Imagens TM/Landsat 5, bandas 3, 4 e 5.

GERAIS - EPAMIG, 2009) (Figura 2), classificado visualmente a partir da mesma imagem. Foram utilizados os sistemas de informações geográficas SPRING⁶ versão 4.3.3 e o software IDRISI⁷.

O diagrama da Figura 3 apresenta todas as etapas de desenvolvimento do trabalho.

Pré-processamentos

Foi realizado um processo de restauração nas imagens para melhorar a qualidade espacial dos dados (PAPA et al., 2008). O processo de restauração transformou os *pixels* que possuíam resolução espacial de 30m para 10m. Boggione e Fonseca (2003) explicam que as técnicas de restauração de imagens são orientadas para a modelagem da degradação e recuperação do sinal original que foi degradado durante o processo de formação de imagens.

Durante o processo de geração de imagens, a resolução espacial é degradada devido à difração óptica, ao tamanho do detector, às limitações do filtro eletrônico, canal de transmissão, etc. Essa degradação faz com que as imagens apresentem um aspecto borrado, que caracteriza a perda de detalhes. Com técnicas de restauração, é possível melhorar a resolução efetiva da imagem até certo nível (BOGGIONE; FONSECA, 2003).

Em seguida, foi criada uma máscara ao longo da rede de drenagem (Figura 4), utilizando a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do SPRING, em cada uma das três bandas. Foram utilizadas as linhas de drenagem digitais 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 nessas 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

⁶ <http://www.dpi.inpe.br/spring/>

⁷ CLARK LABS. IDRISI Andes. Version 15.00. Worcester: Clark University, 2006.

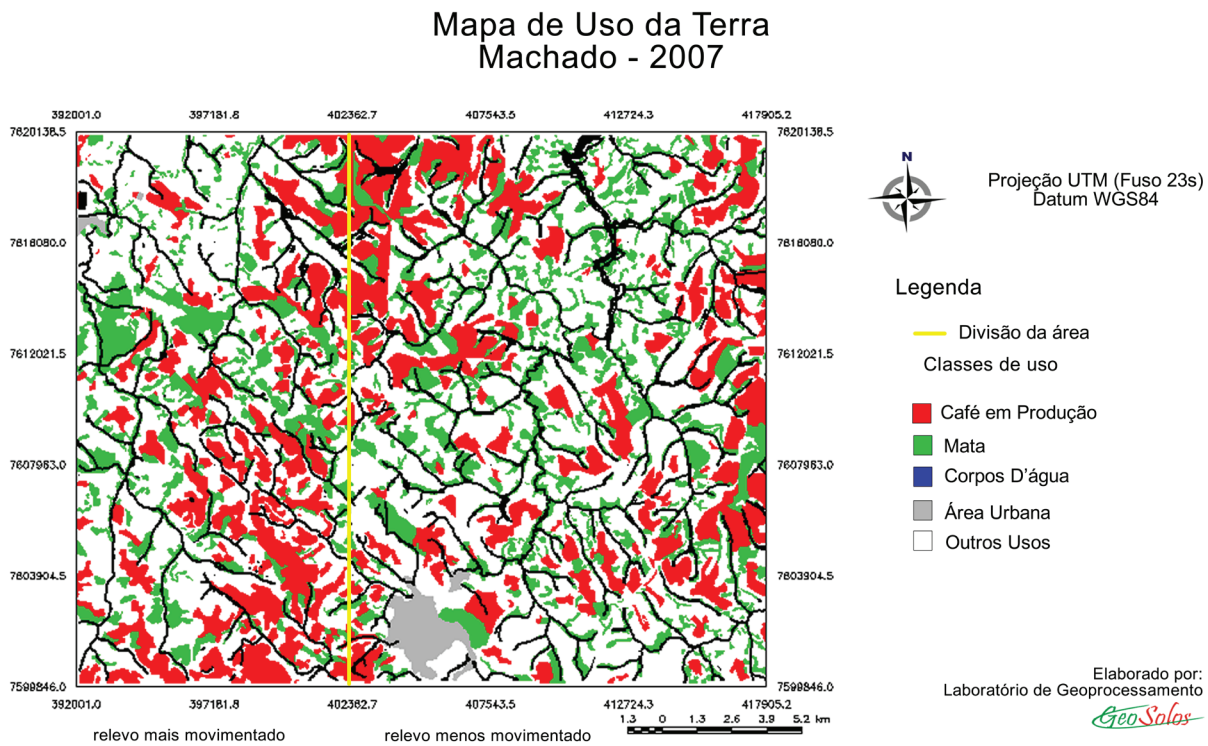


FIGURA 2 – Mapa de uso da terra classificado visualmente com a máscara de drenagem.

urbana de Machado e atribuído o valor dos pixels em 255.

Após a criação da máscara, a imagem foi dividida em duas partes, uma com relevo mais movimentado e outra com relevo menos movimentado. Utilizou-se o software SPRING para realizar a divisão da imagem, sendo que a separação dos ambientes ocorreu em linha reta (por questão de simplificação), como pode ser visto na imagem RGB apresentada na Figura 4. De acordo com Lacerda et al. (2001), na região de Machado existem dois ambientes geomórficos: Ambiente Geomórfico N-NE-E, em relevo predominantemente plano a ondulado, ocorrendo na região norte, nordeste e leste em relação ao núcleo urbano; e Ambiente Geomórfico WNW, ocorrendo relevo predominantemente ondulado a montanhoso na região oeste e noroeste em relação ao núcleo urbano. O ambiente mais movimentado da imagem apresenta sombreamento em algumas áreas, o que dificulta a classificação da imagem pela rede neural, enquanto que o ambiente menos

movimentado está menos propício à ocorrência de sombras. A separação dos ambientes permite à rede neural identificar melhor as classes, pois, se aplicada sobre toda a imagem poderia não apresentar bons resultados, porque o mau desempenho de um ambiente prejudicaria o resultado do outro.

Treinamento da RNA

A obtenção de áreas para treinamento 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, classificado 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 na rede 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. A classe “outros usos” agregou diversas áreas para que essas áreas não interferissem na classificação da RNA, uma vez que o objetivo principal do trabalho era identificar as áreas cafeeiras existentes na imagem.

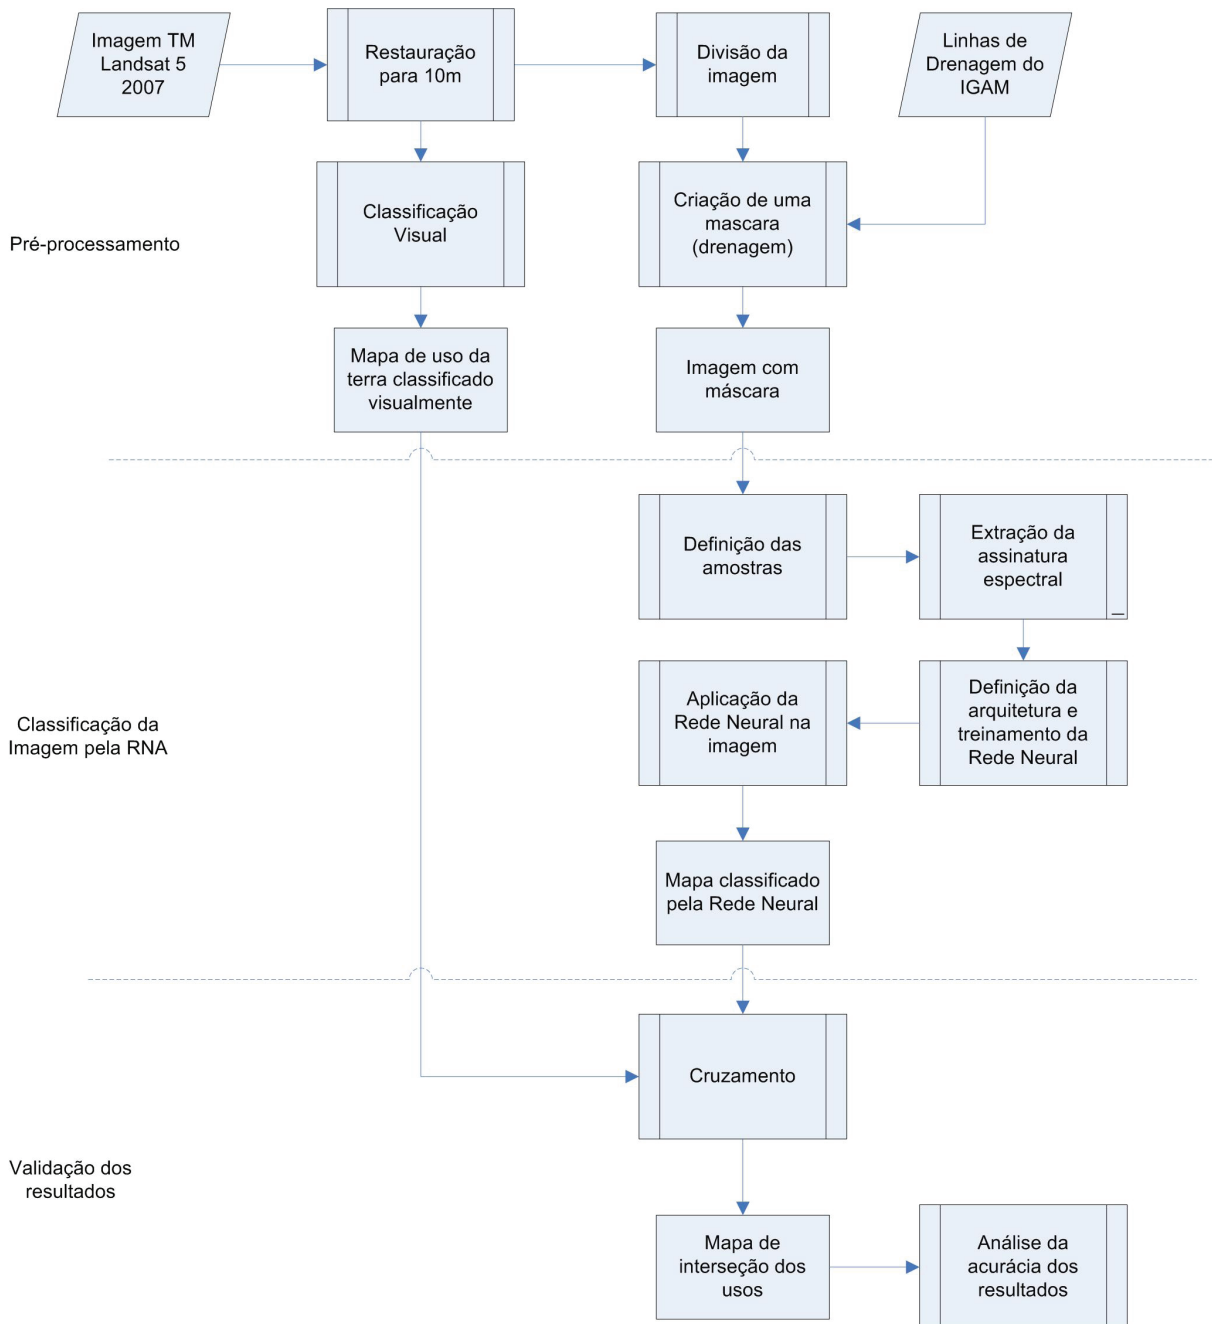


FIGURA 3 – Metodologia do trabalho.



FIGURA 4 – Imagem composição RGB com máscara de drenagem: (a) relevo mais movimentado (b) relevo menos movimentado.

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

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. Em seguida, a melhor rede treinada foi aplicada sobre a área de estudo, identificando automaticamente as classes definidas durante a coleta das amostras, resultando em um mapa temático.

Validação dos resultados

Um mapeamento temático baseado em imagens de satélite necessita ser validado para que as informações geradas possam ser

confiáveis. Utilizando-se a linguagem LEGAL do software SPRING, foram realizados cruzamentos entre o mapa classificado visualmente com os classificados automaticamente pela melhor rede neural treinada. O resultado desse cruzamento é uma matriz de confusão, a partir da qual é possível obter os coeficientes de concordância para validar a exatidão da classificação.

A matriz de confusão é uma matriz quadrada de números que expressam a quantidade de unidades amostrais, associada a uma dada categoria durante o processo de classificação efetuado, e à categoria real a que pertencem essas unidades (CONGALTON, 1991; SOUSA et al., 2010).

Utilizou-se o índice Kappa (GÓES; MELLO FILHO; CARVALHO, 2006) para avaliar o desempenho da RNA. 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 (FRANCA; SANO, 2011).

O índice Kappa é uma medida da concordância real (indicado pelos elementos diagonais da matriz de confusão) menos a concordância por chance (indicado pelo produto total da linha e coluna) (MOREIRA, 2005), conforme segue:

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

sendo: K = índice Kappa; N = quantidade total de pontos amostrais; r = número de linhas da matriz de erro; x_{ii} = valor na linha i e coluna i; x_{i+} = soma da linha i; x_{+i} = soma da coluna i. Os níveis utilizados para avaliar a qualidade da classificação, baseados no valor Kappa obtido, são os propostos por Nanni et al. (2010).

A análise do desempenho da RNA também foi avaliada através de um mapa, constituído de 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.

3 RESULTADOS E DISCUSSÃO

Para definir o número de camadas escondidas e o número de neurônios de cada camada foram realizadas diversas implementações com diferentes arquiteturas de rede e verificado o desempenho de cada rede treinada. O número de camadas escondidas e o número de elementos nessas camadas foram definidos experimentalmente, tendo sido avaliadas arquiteturas com uma e duas camadas escondidas. Alguns dos resultados obtidos constam da Tabela 1.

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.

A rede que apresentou melhor resultado para o relevo menos movimentado possuía 18 neurônios em uma única camada escondida e 5 neurônios na saída, sendo cada amostra com 70 pixels de imagem, 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, 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 (o que ocorrer primeiro). A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*, resultando em um valor final de EQM para os dados de treinamento e de teste.

De acordo com a Tabela 1, a rede neural obteve melhor desempenho com uma camada escondida. As camadas intermediárias trabalham com estimativas de erro para ajustes dos pesos de entrada dos neurônios, as quais, em maior quantidade, levam a problemas de convergência

TABELA 1 – Configurações utilizadas no treinamento.

Conf.	Pixel ^{1*}	Nº de camadas internas	Neurônios		Taxa de aprend.	Mom.	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	0,005661	0,005841	0,00501	0,005715
2	60	2	20	14	0,01	0,5	10000	0,004914	0,005907	-	-
3	65	1	14	-	0,01	0,5	10000	-	-	0,005491	0,005474
4	65	1	18	-	0,01	0,5	10000	-	-	0,005231	0,005599
5	65	1	18	-	0,01	0,5	10000	0,004861	0,005471	0,005231	0,005599
6	65	2	24	18	0,01	0,53	10000	0,005129	0,005137	-	-
7	70	1	16	-	0,01	0,5	10000	0,005062	0,005216	0,004369	0,005332
8	70	2	16	10	0,01	0,5	10000	0,00497	0,005185	-	-
9	70	1	18	-	0,01	0,5	10000	0,004771	0,005381	0,005116	0,00514
10	70	1	18	-	0,02	0,53	10000	0,00472	0,004984	0,00465	0,005073

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

da rede (sobreajuste). Observando os resultados obtidos no relevo menos movimentado, percebeu-se que aumentando o número de pixels das amostras dos conjuntos de treinamento e teste, a rede produziu melhores resultados com um número de neurônios da primeira camada variando entre 16 e 18. No relevo mais movimentado, a rede que obteve melhores resultados também possuía um número pequeno de neurônios na camada intermediária. O bom desempenho na utilização de apenas uma camada oculta pode ser visto também no trabalho dos pesquisadores Boschi e Galo (2007) que aplicaram uma rede do tipo MLP na classificação da cobertura do solo urbano de Presidente Prudente e obtiveram resultados satisfatórios na discriminação das variações na cobertura do solo urbano.

O desempenho da melhor rede neural obtida foi testado gerando-se o índice Kappa entre o mapa classificado pela RNA e o de uso da terra classificado visualmente. A Figura 5 apresenta a classificação realizada pela RNA nos dois ambientes.

O índice de exatidão global do mapa classificado pela RNA foi de 73.33% para o relevo menos movimentado e 70.42% para o relevo mais movimentado. O índice de acurácia Kappa foi de 0,558 para o relevo mais movimentado e 0,602 para o relevo menos movimentado, que segundo Nanni et al. (2010) são índices bom e muito bom. Os índices 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 utilizadas. Contudo, se comparados aos resultados obtidos por Marques (2003) e Santos et al. (2007), 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.

Classificação por meio da RNA Machado - 2007

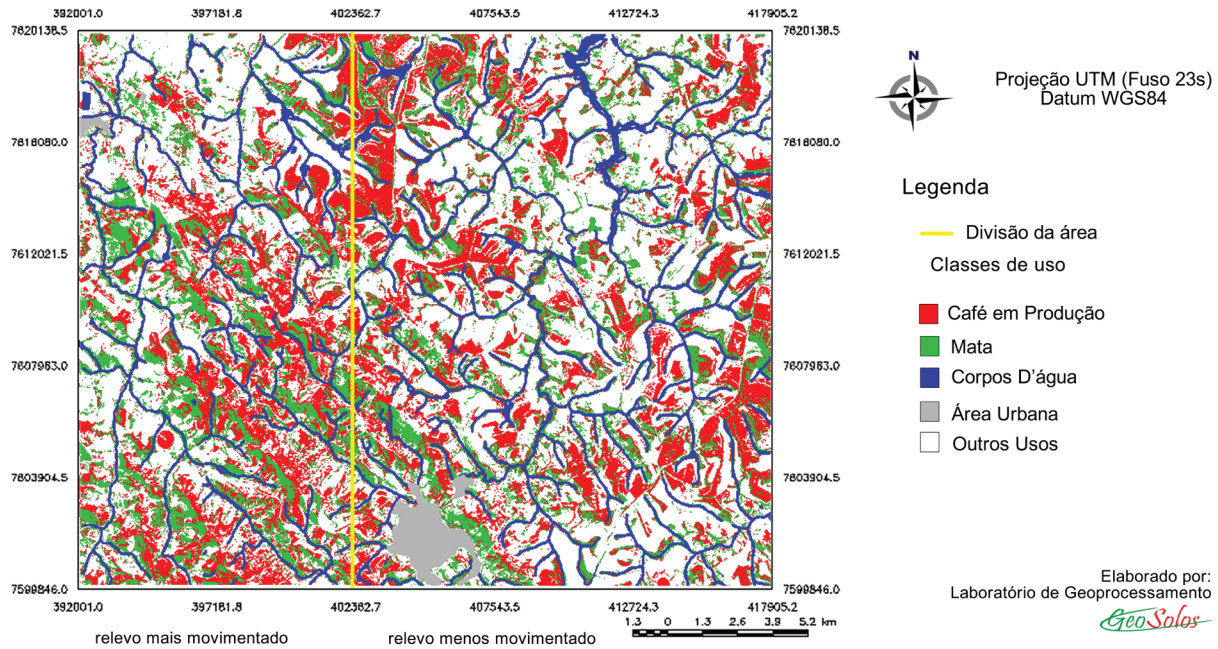


FIGURA 5 – Mapa de uso da terra classificado pela RNA.

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 0,39 e Battacharya com 0,42, o autor concluiu que os classificadores tiveram um desempenho moderado, pois a área possui um relevo que dificulta a classificação. Já Santos et al. (2007) utilizaram os mesmos classificadores automáticos em imagens Landsat 5 TM do ano de 2005, na mesma área e obteve baixos índices de acurácia Kappa, sendo 0,202 para o classificador Battacharya e 0,25 para o Maxver. Os autores concluíram 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 à da lavoura de café.

Na Tabela 2 é apresentada a matriz de confusão entre os mapas de referência e o

classificado pela RNA. A matriz contém os erros de omissão e comissão, exatidão do consumidor e produtor para cada classe. Os valores destacados em cinza são das áreas com relevo menos movimentado.

Analisando a matriz de confusão, pode-se observar que no relevo menos movimentado a rede classificou melhor as áreas cafeeiras, com uma porcentagem de acerto de 63,60% (exatidão do produtor), que corresponde a aproximadamente 55% da área real de café, representados pela exatidão do consumidor. Aproximadamente 44% da área mapeada como café não correspondia espacialmente ao real, o que equivale aos erros de comissão para essa classe. No relevo mais movimentado, a rede conseguiu um acerto um pouco menor, de 59,06%. Como era de se esperar, o relevo menos movimentado apresentou melhor resultado devido a menor interferência da sombra na reflectância do dossel do cafeeiro. Outro fator importante foi a criação de máscaras na rede de 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.

Outra dificuldade de classificação apresentada pela RNA pode ser observada na classe mata, que obteve como acerto 42% e 50% 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 et al., 2006), e apresentou

também grande confusão com áreas de outros usos, devido a fatores já discutidos anteriormente.

A classe água apresentou exatidão superior a 90%, porque durante a criação da máscara foi atribuído o valor 10 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. Desse cruzamento obteve-se o mapa temático apresentado na Figura 6, em que consta, especialmente, o desempenho da RNA, e apresenta as seguintes classes temáticas: áreas corretamente classificadas, áreas classificadas incorretamente e áreas não classificadas.

TABELA 2 – Matriz de confusão com os erros de omissão e comissão, exatidão do consumidor e produtor, índice de exatidão global e kappa, obtidos entre os mapas de referência e o classificado pela RNA.

		Mapa Classificado pela RNA (km ²)					TOTAL	Erro de omissão	Exatidão do produtor
		Café em Produção	Mata	Água	Área Urbana	Outros Usos			
Mapa Classificado Visualmente (km ²)	Café em Produção	40.801	9.0397	0.205	0.01	14.0987	64.1544	36%	63.60%
		27.1553	9.4697	0.0001	0.0054	9.3493	45.9798	40.94%	59.06%
	Mata	14.875	22.3209	1.2182	0.0134	14.2844	52.7119	58%	42.35%
		9.5603	17.254	0.0051	0.0006	7.4564	34.2764	49.66%	50.34%
	Água	0.4812	0.8532	33.9702	0.2273	1.5846	37.1165	8%	91.52%
		0.0001	0.0002	21.3333	0	0.0015	21.3351	0.01%	99.99%
	Área Urbana	0.0215	0.0313	0.0069	6.0838	0.08	6.2235	2%	97.76%
		0	0	0	0.516	0.0001	0.5161	0	99.98%
	Outros Usos	13.1591	11.913	1.6071	0.1669	127.4844	154.3305	17%	82.60%
		12.4853	12.6592	0.014	0.011	79.0199	104.1894	24.16%	75.84%
TOTAL	69.3378	44.1581	37.0074	6.5014	157.5321	314.5368			
	49.201	39.3831	21.3525	0.533	95.8272	206.2968			
Erro de omissão	44.48%	41.43%	8.18%	6.71%	19.47%				
	47.95%	64.56%	0.09%	3.29%	16.13%				
Exatidão do produtor	55.52%	58.57%	91.82%	93.29%	80.53%				
	52.05%	35.44%	99.91%	96.71%	83.87%				
Índice de exatidão global		73.33%				0.602			
		70.42%		Kappa		0.558			

* Cada célula da tabela contém dois valores, referentes as duas áreas classificadas pela rede neural (relevo menos movimentado, relevo mais movimentado).




FIGURA 6 – Mapa de cruzamento das áreas de café entre o mapa de referência e o classificado pela RNA.

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, em que 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 em 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.

4 CONCLUSÕES

Este trabalho demonstrou o potencial das redes neurais artificiais na classificação automática de imagens de satélite para identificação de áreas cafeeiras, obtendo-se na acurácia da classificação índices superiores aos encontrados na literatura.

A separação dos ambientes geomórficos e a inclusão das máscaras na rede de drenagem e na área urbana no pré-processamento possibilitaram a diminuição da variabilidade dos alvos observados nas imagens.

Trabalhos futuros propondo a divisão dos diferentes ambientes geomórficos por meio de um mapa de declividade, derivado de um Modelo Digital de Elevação, poderão ser realizados separando com mais precisão as áreas com diferentes relevos. Também como propostas futuras, incorporar à estrutura da RNA atributos como forma e textura dos alvos, visto que esses são os atributos utilizados pela interpretação visual, em momentos em que apenas a resposta espectral não é suficiente.

5 AGRADECIMENTOS

À Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) e ao CBP&D/Café, pelos recursos financeiros disponibilizados para o desenvolvimento do projeto e bolsas.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- BOGGIONE, G. A.; FONSECA, L. M. G. Restoration of Landsat-7 images. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT: INFORMATION FOR RISK MANAGEMENT AND SUSTAINABLE DEVELOPMENT, 30., 2003, Honolulu. **Proceedings...** Honolulu: ISRSE, 2003. 1 CD-ROM.
- BOSCHI, L. S.; GALO, M. L. B. T. Análise da incerteza na representação de classes de cobertura do solo urbano resultantes da aplicação de uma rede neural artificial. **Revista Boletim de Ciências Geodésicas**, Curitiba, v. 13, n. 1, p. 22-41, jan./jun. 2007.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007. 226 p.
- CHAGAS, C. S. et al. Atributos topográficos e dados do Landsat 7 no mapeamento digital de solos com uso de redes neurais. **Pesquisa Agropecuária Brasileira**, Brasília, v. 45, n. 5, p. 497-507, maio 2010.
- _____. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 13, n. 3, p. 319-327, 2009.
- CONGALTON, R. G. A review of assessing the accuracy classifications of remotely sensed data. **Remote Sensing of Environment**, New York, v. 49, n. 12, p. 1671-1678, Dec. 1991.
- EMPRESA DE PESQUISA AGROPECUÁRIA DE MINAS GERAIS. Centro Tecnológico do Sul de Minas. Laboratório de Geoprocessamento. **Geosolos**. Lavras, 2009. Disponível em: <<http://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**, Brasília, v. 29, n. 3, p. 439-447, mar. 1994.
- FRANCA, A. M. S.; SANO, E. E. Mapeamento de áreas de Campo Limpo Úmido no Distrito Federal a partir de fusão de imagens multiespectrais. **Sociedade & Natureza**, Uberlândia, v. 23, n. 2, p. 197-209, 2011.
- GÓES, C. A.; MELLO FILHO, W. L.; CARVALHO, M. Avaliação do desempenho de diferentes classificadores (Isoseg, Bhattacharyya, Maxwer e Maxwer-ICM), utilizando imagens CCD/CBERS-1 e ETM+/Landsat-7 fusionadas. **Revista Ambi-Água**, Taubaté, v. 1, n. 2, p. 80-89, 2006.
- GONÇALVES, M. L. et al. Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamento hierárquicos. **Revista Brasileira de Cartografia**, Campina Grande, v. 60, n. 1, p. 17-29, 2008.
- GONZALES, R. C.; WOODS, R. E. **Digital image processing**. 3rd ed. New York: Prentice Hall, 2008.
- LACERDA, M. P. C. et al. Caracterização de agroecossistemas cafeeiros de Minas Gerais por meio do SPRING: parte II, agroecossistema de Machado. In: SIMPÓSIO DE PESQUISAS DOS CAFÉS DO BRASIL, 2., 2001, Poços de Caldas. **Anais...** Brasília: EMBRAPA Café, 2001. 1 CD-ROM.
- LIPPMANN, R. P. An introduction to computing with neural nets. **IEEE ASSP Magazine**, Ottawa, 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**, Basingstoke, v. 12, n. 11, p. 2433-2438, Nov. 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 Solos e Nutrição de Plantas) - Universidade Federal de Lavras, Lavras, 2003.
- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3. ed. Viçosa, MG: UFV, 2005. 320 p.

Coffee Science, Lavras, v. 8, n. 1, p. 78-90, jan./mar. 2013

- NANNI, M. R. et al. Discriminação de unidades de paisagem para fins de levantamentos pedológicos por meio da resposta espectral orbital. **Acta Scientiarum. Agronomy**, Maringá, v. 32, n. 3, p. 555-561, 2010.
- PAPA, J. P. et al. Convex restriction sets for CBERS-2 satellite image restoration. **International Journal of Remote Sensing**, Basingstoke, v. 29, p. 443-458, 2008.
- RUHOFF, A.; FANTIN-CRUZ, I.; COLLISCHONN, W. Modelos de simulação dinâmica do desmatamento na Amazônia. **Caminhos de Geografia**, Uberlândia, v. 11, n. 36, p. 258-268, dez. 2010.
- SANTOS, W. J. R. et al. Exatidão de classificações automáticas de uma imagem Landsat 5 TM para a região cafeeira de Machado, MG. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 5., 2007, Águas de Lindóia. **Anais...** Brasília: EMBRAPA Café, 2007. 1 CD-ROM.
- SOUSA, B. F. S. et al. Avaliação de classificadores baseados em aprendizado de máquina para classificação do uso e cobertura da terra no bioma Caatinga. **Revista Brasileira de Cartografia**, Campina Grande, v. 62, n. 2, p. 385-399, 2010. Edição especial.
- VIEIRA, T. G. C. et al. Crop parameters and spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, Lavras, 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. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. 1 CD-ROM.