

REDES NEURAIAS ARTIFICIAIS APLICADAS NA IDENTIFICAÇÃO AUTOMÁTICA DE ÁREAS CAFEIRAS OBTIDAS POR IMAGEM DE SATÉLITE

TATIANA GROSSI CHQUILOFF VIEIRA*, WILIAN SOARES LACERDA†, HELENA MARIA RAMOS ALVES*, MARGARETE MARIN LORDELO VOLPATO*, LÍVIA NAIARA DE ANDRADE*, RICARDO CÉSAR ARSILLO BRAGA*, VANESSA CRISTINA OLIVEIRA DE SOUZA*

**Laboratório de Geoprocessamento - GeoSolos
Empresa de Pesquisa em Agropecuária de Minas Gerais - EPAMIG
Caixa Postal 3037 - Lavras/MG - CEP 37200-000 - Brazil*

*†Depto. de Ciência da Computação - Universidade Federal de Lavras
Caixa Postal 3037 - Lavras/MG - CEP 37200-000 - Brazil*

Emails: tatiana@epamig.ufla.br, lacerda@ufla.br, helena@epamig.ufla.br,
margarete@epamig.ufla.br, livia@epamig.ufla.br, arsillo@agronomia.ufla.br,
vanessa@epamig.ufla.br

Abstract— Application of Artificial Neural Networks (ANNs) in the classification Remote Sensing data has shown a promising, especially in the discrimination of classes of higher complexity. In this paper, it is presented an application of ANNs in the identifying of coffee areas which has a standard spectrum very close to the forest, making difficult the classification of such classes of land use. It was used three spectral bands of HRV/SPOT5 satellite image of the region of Guaxupé (MG) with the software of image processing IDRISI. In order to validate the classification maps obtained, it was done the intersection of the visual classified map of use and occupation of land with the generated map by RNA. The Kappa index (k) between the classified map by RNA and reference map was 71.85%, which is considered a good index. The methodology of Artificial Neural Networks of type Multilayer Perceptron (MLP) presented a good result, however it is necessary to add other data entry to improve the classification.

Keywords— remote sensing, artificial neural network, automatic classification, land use mapping.

Resumo— A aplicação de Redes Neurais Artificiais (RNAs) na classificação de dados de Sensoriamento Remoto tem se mostrado uma abordagem promissora, principalmente na discriminação de classes de maior complexidade. No presente trabalho, é apresentado uma aplicação de RNAs na identificação de áreas cafeeiras que possui um padrão espectral muito próximo ao da mata, dificultando a classificação automática dessas classes de uso da terra. Foram utilizadas três bandas espectrais da imagem do satélite HRV/SPOT5 da região de Guaxupé (MG) com o software de processamento de imagens IDRISI. Para validação dos mapas obtidos pela classificação, realizou-se o cruzamento do mapa de uso e ocupação da terra por classificação visual com o gerado pela RNA. Em relação ao mapa de referência, o índice Kappa (k) do mapa classificado pela RNA ficou em 71,85%, o que é considerado um índice bom. A metodologia de Redes Neurais Artificiais do tipo multilayer perceptron (MLP) apresentou um bom resultado, porém é necessário que se acrescentem outros dados de entrada para melhorar a classificação.

Keywords— sensoriamento remoto, cafeicultura, classificação.

1 Introdução

Minas Gerais é o maior produtor brasileiro de café e a região Sul de Minas contribui com mais de 50% da produção mineira. Atualmente o café corresponde a 70% da renda das propriedades rurais do Sul de Minas. A média do Sul de Minas é de quatro mil cafeeiros por hectare, o que representa o sistema de cultivo semi-adensado (Break, 2008).

O município de Guaxupé tem sua economia baseada na atividade agrícola, possuindo mais de 200 propriedades rurais, sendo o café seu principal produto de cultivo, com produção de bebidas finas. Fato este que justifica a existência da Cooperativa de Cafeicultores (Cooxupé) na região, que é considerada a maior do mundo devido à estrutura que possui para atender o setor. Devido a importância que a cultura do café representa à região cafeeira de Guaxupé, utilizou-se a classificação automática por Redes Neurais Artificiais para o mapeamento

das áreas cafeeiras.

As Redes Neurais Artificiais (RNAs) têm sido aplicadas com sucesso nas áreas de processamento de imagens e reconhecimento de padrões. Os trabalhos de (Hepner, 1990) e (Benediktsson et al., 1990) fizeram uso de RNA na classificação de imagens de sensoriamento remoto. Para resolver o problema de classificação, utilizaram uma rede de perceptrons multicamadas (MLP), que 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.

A utilização de modelos de RNAs em classificação possibilita a incorporação não apenas de dados multiespectrais, mas de dados adquiridos por outras fontes, mesmo que não apresentem natureza espectral. Nessas situações, as RNAs parecem desempenhar a tarefa de classificação de imagens tão bem, ou melhor, que as técnicas estatísticas, uma

vez que não requerem que a natureza paramétrica dos dados as serem classificadas seja explicitada (Galo et al., 2002).

Este trabalho tem como objetivo definir um procedimento de classificação automática utilizando Redes Neurais Artificiais para identificação de áreas cafeeiras em imagens do satélite SPOT 5 com sensor HRV.

2 Material e Métodos

A área de estudo encontra-se na Região Sul do estado de Minas Gerais, localizada no Planalto de Poços de Caldas, no município de Guaxupé. Posiciona-se geograficamente entre as coordenadas 21° 5' 42.46" a 21° 17' 10.85" de latitude sul e 46° 36' 59.12" a 46° 51' 30.28" de longitude oeste.

Neste trabalho foram utilizadas imagens multi-espectrais para classificação automática com RNA, que se referem às bandas 1, 2 e 3 do satélite SPOT 5 (sensor HRV) com resolução espacial de 10m, com datas de passagem de 28/05/2005. O mapa de uso da terra foi classificado visualmente com imagens com resolução espacial de 2,5m. Foram utilizados os sistemas de informações geográficas SPRING (Câmara et al., 1996), versão 4.3.3 e o IDRISI (Clark Labs - Clark University, 2006).

As etapas do processo utilizado para obtenção dos dados, treinamento da Rede Neural Artificial e validação dos resultados está resumida no diagrama da Figura 1 e é descrita a seguir.

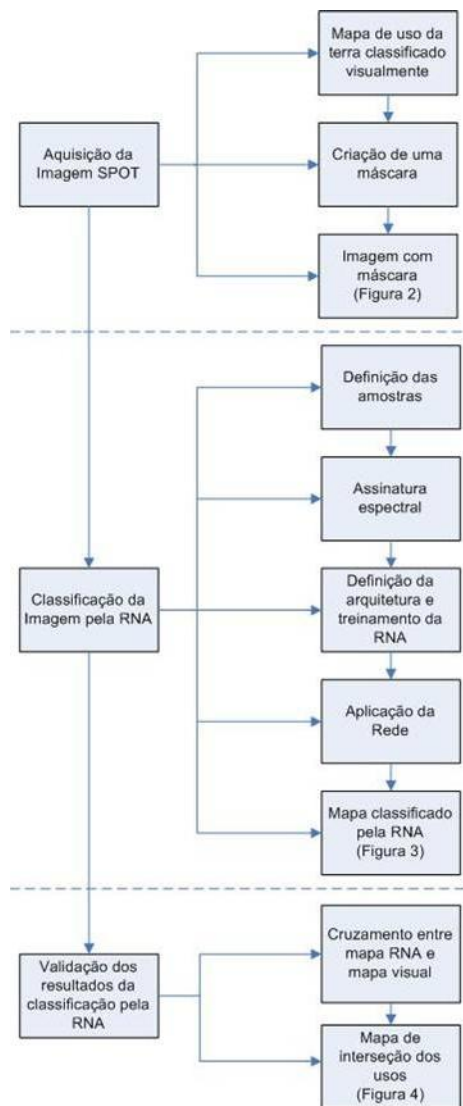


Figura 1: Diagrama da metodologia adotada para processamento dos dados.

2.1 Pré-processamento dos dados de treinamento

Considerando as características dos sensores remotos orbitais, quanto à sua resolução espacial e espectral e os mecanismos de interação da radiação eletromagnética com a cultura do café, percebe-se uma variabilidade espectral bem tênue com áreas de mata, de modo que os estudos envolvendo o mapeamento de áreas cafeeiras por meio de Sensoriamento Remoto têm sido desenvolvidos (Vieira et al., 2006). Devido ao fato de ocorrer esta ambigüidade espectral entre áreas de mata e café foi criada uma máscara sobre as três bandas da imagem SPOT, na qual a máscara deixava visível para a RNA apenas as classes café, mata e outros usos (classes agregadas). Para o desenvolvimento desta máscara, foi utilizada a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL), do SPRING.

2.2 Definição da arquitetura e treinamento da RNA

A obtenção de dados 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 (Gonzales and Woods, 2000). Para auxílio na definição das amostras de treinamento foi utilizado o mapa de uso da terra classificado visualmente. Foram selecionados entre 5 e 8 polígonos de tamanhos variados e espaçados ao acaso para cada classe, compostas da seguinte forma:

1. Café em produção: lavouras com idade superior a três anos;
2. Mata: formações florestais naturais densas e florestas de galeria às margens dos córregos;

3. Outros usos: água, 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 assinatura espectral do conjunto de amostras. Em seguida foram indicadas as três bandas da imagem utilizadas na classificação. 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. O número de elementos da camada de saída foi definido com base no número de classes a serem classificadas na imagem, sendo três nós com valores identificados na criação das amostras.

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 de camadas; número de neurônios nas camadas; número do conjunto de pixels para o conjunto de treinamento e teste; fator de *momentum* e taxa de aprendizado.

2.3 Processamentos pós-classificação

Para validação da classificação realizada pela RNA, foi realizado um cruzamento entre o mapa classificado visualmente com o classificado pela Rede Neural Artificial utilizando a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL). A análise do desempenho da RNA foi avaliada em três classes, sendo elas:

- Áreas classificadas corretamente: pixels de áreas de café classificadas igualmente 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

Foram realizadas modificações nos parâmetros de aprendizado da RNA, fator de *momentum* e o número de iterações, na tentativa de obter um índice melhor para esta arquitetura. No entanto,

não foi observado melhoria no resultado, pelo contrário, foi observada uma queda nos resultados dos testes (vide Tabela 1). A arquitetura da RNA que apresentou melhor resultado de treinamento foi uma rede neural com 14 neurônios em uma única camada escondida e 3 neurônios na saída. Outros parâmetros definidos foram: um conjunto de 55 pixels por categoria para o conjunto de teste e treinamento, taxa de aprendizado da RNA de 0,02; fator de momentum de 0,50 para agilizar na convergência da rede; e constante de sigmóide de 1. Como critério de parada do treinamento da RNA foi estabelecido 10.000 iterações ou erro médio quadrático (EQM) de 0,0001. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo backpropagation, resultando em um valor de EQM de 0,006641 para os dados de treinamento, e 0,00779 para os dados de teste. As configurações utilizadas para teste na tentativa de obter a rede que melhor classificasse a imagem está demonstrada na Tabela 1.

Tabela 1: Configurações utilizadas no treinamento.

Rede	Pixel ¹	Neurônios ²	Mom.	Erro trein.	Erro teste
1	60	10+1	0,53	0,007076	0,008265
2	55	14+1	0,50	0,006641	0,00779
3	65	8+1	0,53	0,006891	0,007366
4	55	16+1	0,50	0,006284	0,008308
5	60	10+8+1	0,53	0,008646	0,007089

Obs.:

Taxa de aprendizado = 0,02

Iterações = 10.000

¹Número de pixels selecionados por amostra

²Número de neurônios por camada

A Figura 2 mostra o mapa de uso da terra obtido por classificação visual e pré-processado, criando o mapa de uso da terra classificado visualmente com máscara. Esse mapa foi utilizado como referência para avaliar a classificação feita pela RNA. O mapa classificado pela Rede Neural treinada é apresentada na Figura 3.

Em relação ao mapa de referência, o índice de acurácia Kappa do mapa classificado pela RNA foi de 71,85%, que segundo Galparsoro e Fernández (Galparsoro and Fernández, 2001) é considerado um índice bom. O erro na classificação realizada pela rede neural é influenciado pela ambigüidade existente entre o padrão espectral da cultura do café com as matas. A matriz de confusão entre os mapas é apresentada na Tabela 2, onde da área total de café em produção classificado pela RNA, 78,72% foram classificados corretamente. Em relação ao total da área de mata do mapa de referência, a classificação correta pela rede foi de 55,65%. O total da área classificado como outros usos pela RNA apresentou uma porcentagem de acerto de 97,01%.

O mapa de referência classificado visualmente com a máscara e o gerado pela classificação da RNA foram cruzados no SPRING, utilizando a Linguagem Espacial para Geoprocessamento Algébrico (LEGAL). Deste cruzamento obteve-se o

Tabela 2: Matriz de confusão entre os mapas de referência e o classificado pela RNA (em %)

Class. visual	Class. pela RNA		
	Café em prod.	Mata	Outros usos
Café em prod.	78,72	16,46	4,82
Mata	33,48	55,65	10,87
Outros usos	1,94	1,05	97,01

mapa apresentado na Figura 4. O mapa apresenta o desempenho da RNA na área de café classificada corretamente pela RNA, que totaliza 80,9%, o que equivale a 88,27 km². A área que a RNA classificou erroneamente como café totalizou 44,09 km².

4 Considerações Finais

A classificação de imagens espectrais por RNA pode ser considerada como uma excelente alternativa aos classificadores atualmente utilizados, mas deve ser melhor investigada. A utilização de parâmetros incorporados na estrutura da rede, que levem em conta o aspecto da distribuição espacial dos padrões e parâmetros de relevo deve ser analisada. No caso do mapeamento de áreas cafeeiras onde existe similaridade espectral entre café/mata, sugere-se criar uma máscara ao longo da rede de drenagem, onde existem pequenas áreas de matas ciliares. Outra possível alternativa para a melhoria da classificação pela RNA seria a inserção de parâmetros de entrada para o treinamento da RNA, como dados de relevo (altitude, orientação de vertente e declive). No Sul de Minas Gerais, onde o café é cultivado em áreas de altitudes mais elevadas, acima de 700m, a altitude pode ser um parâmetro discriminador a ser incorporado à rede, eliminando a possibilidade da RNA se confundir.

Um processamento que poderá ser utilizado para melhorar o acerto da classificação pela RNA, também é descrito por Souza (Souza, 2009). Este trabalho fez uso do classificador textural do software Texture utilizando as medidas cluster shade e variância do vetor soma, com quantização de 256 níveis de cinza e janela de 3x3 pixels, para realização de testes sobre imagens do satélite Landsat 5, sensor TM, bandas 3 e 4. Este procedimento resultou em um índice Kappa de 86%, evidenciando que medidas de textura podem ser usadas satisfatoriamente para o mapeamento automático de áreas cafeeiras.

Agradecimentos

Os autores agradecem o 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,

e à Cooxupé (Cooperativa Regional de Cafeicultores de Guaxupé Ltda.) pelas imagens de satélite sedidas.

Referências

- Benediktsson, J. A., Swain, P. H. and Ersoy, O. K. (1990). Neural network approaches versus statistical methods in classification of multisource remote sensing data, *IEEE Transactions on Geoscience and Remote Sensing* **28**(4): 540–552.
- Break, C. (2008). Sul de minas: café representa 70% da renda agrícola, Disponível em <<http://www.coffeefbreak.com.br/ocafezal.asp?SE=6&ID=38>>. Acesso em 02/09/2008.
- Clark Labs - Clark University (2006). IDRISI Andes, Disponível em <www.clarklabs.org>. Acesso em 18/03/2009.
- Câmara, G., Souza, R. C. M., Freitas, U. M. and Garrido, J. (1996). SPRING: Integrating remote sensing and gis by object-oriented data modelling, *Computers & Graphics* **20**(3): 395–403.
- Galo, M. L. B. T., Velini, E. D., Trindade, M. L. B. and Santos, S. C. A. (2002). Uso do sensoriamento remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do complexo Tietê, *Plantas Daninhas* **20**: 7–20. Edição Especial.
- Galparsoro, L. U. and Fernández, S. P. (2001). Medidas de concordância: el índice kappa, Disponível em:<<http://www.fisterra.com/mbe/investigacion/kappa/kappa.htm>>. Acesso em 10/03/2009.
- Gonzales, R. C. and Woods, R. E. (2000). *Processamento de Imagens Digitais*, Edgard Blücher Ltda. 527p.
- Hepner, G. F. (1990). Artificial neural networks classification using a minimal training set: Comparison to conventional supervised classification, *Photogrammetric Engineering and Remote Sensing* **56**(4): 469–473.
- Souza, V. C. O. (2009). Análise e classificação textural de áreas de mata e café na região de Machado - MG. Disponível em: <<http://www.dsr.inpe.br/sbsr2009/aceitos/>>. Acesso em 12/03/2009.
- Vieira, T. G. C., Alves, H. M. R., C., M. P., Veiga, R. D. and Epiphanyo, J. C. N. (2006). Crop parameters and spectral response of coffee (*Coffea Arabica* L.) areas within the state of Minas Gerais, *Coffee Science* **1**(2): 111–118.

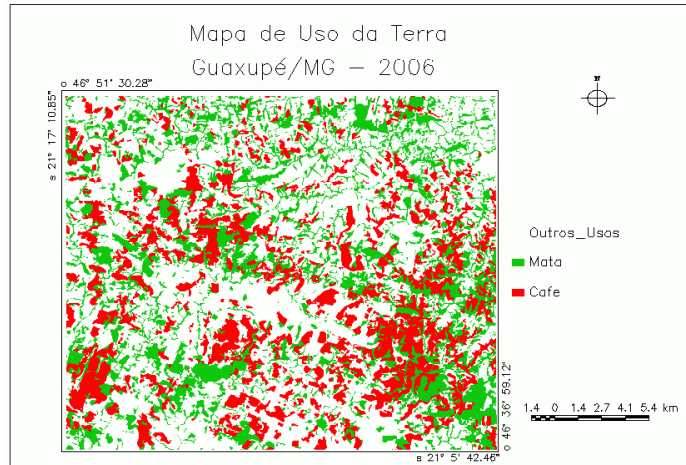


Figura 2: Mapa de uso da terra classificado visualmente com a máscara.

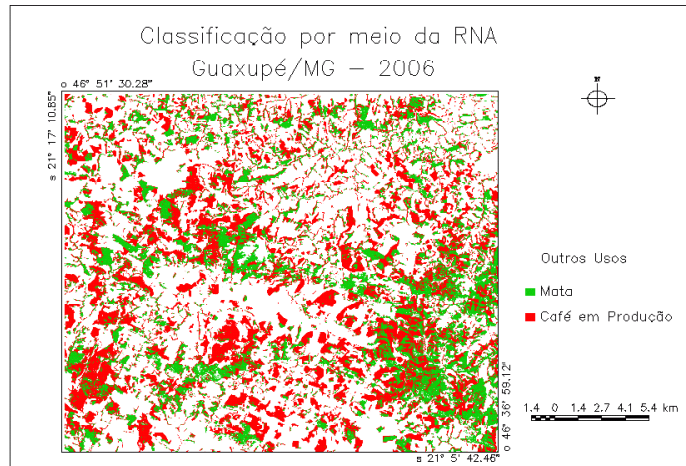


Figura 3: Mapa de uso da terra classificado pela RNA.

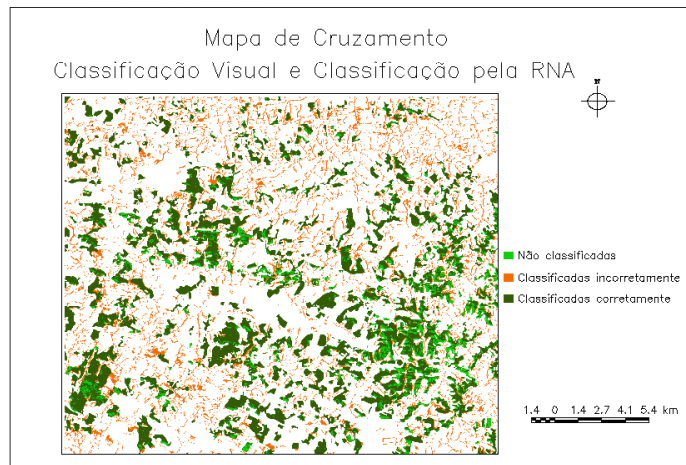


Figura 4: Mapa de cruzamento entre o mapa de referência e o classificado pela RNA.