

# ESTUDOS DE CASOS DE CLASSIFICAÇÃO DE ÁREAS CULTIVADAS COM CAFÉ POR MEIO DE DESCRITORES DE TEXTURA

Lucas Silva da Silveira<sup>1</sup>, Domingos Sárvio Magalhães Valente<sup>2</sup>,  
Francisco de Assis Carvalho Pinto<sup>3</sup>, Fábio Lúcio Santos<sup>4</sup>

(Recebido: 17 de fevereiro de 2016; aceito: 03 de junho de 2016)

**RESUMO:** O objetivo neste trabalho foi desenvolver um sistema para identificar áreas cultivadas com café utilizando Redes Neurais Artificiais (RNAs) tendo como variáveis de entrada os descritores de textura de Haralick. Utilizou-se o algoritmo de treinamento do tipo retro-propagação do erro (*backpropagation*) e o método de Levenberg-Marquardt. Foram realizados dois estudos de casos: no primeiro, as RNAs foram desenvolvidas para discriminar entre as classes café, mata, água, solo exposto, pastagem e área urbana; no segundo, as RNAs foram desenvolvidas para classificar as plantações de café de acordo com a idade e com a data de recepa. Para a avaliação do desempenho de classificação das RNAs empregou-se um mapa de referência de uso e ocupação do solo elaborado por meio do Sistema de Informações Geográficas. A concordância entre os mapas temáticos, classificados pela RNA, e o mapa de referência foi avaliada pelo coeficiente Kappa. Verificou-se que o coeficiente Kappa para discriminar a região cafeeira das outras classes temáticas foi de 0,652 no primeiro estudo de caso, desempenho considerado muito bom. Para classificar os plantios de café em função da idade e data de recepa o índice Kappa foi variável (0,675 a 0,4783), sendo considerado muito bom para a fazenda Itatiaia e razoável para a fazenda Pedra Redonda.

**Termos para indexação:** Redes neurais artificiais, sensoriamento remoto, classificação supervisionada.

## CASE STUDIES OF CLASSIFICATION OF CULTIVATED AREAS WITH COFFEE BY TEXTURE DESCRIPTORS

**ABSTRACT:** *The objective of this work is to develop a system to identify areas cultivated with coffee using ANNs having as input variables descriptors Haralick. We used the training algorithm Back-propagation and Levenberg -Marquardt method. There were two cases of study: in the first step, the ANN was trained with representative samples of each class of interest (coffee, forest, water, bare soil, and urban area), thus verifying the potential to discriminate output classes; in the second step the objective was to classify the coffee plantations accordingly with the age. For the evaluation of the classification performance of ANNs was employed a reference map and land use through the Geographic Information System. The concordance between the thematic maps, classified by ANN, and the reference map was evaluated by Kappa index. It was verified that Kappa index for discriminating the coffee region of the other class of interest was 0,652 in the first case study, performance as very good. To classify the coffee plantations accordingly with the age, Kappa index was variable (0.675 to 0.4783), very good for Itatiaia farm and reasonable to Pedra Redonda farm.*

**Index terms:** Artificial neural networks, remote sensing, supervised classification.

### 1 INTRODUÇÃO

Tendo em vista a relevância socioeconômica da atividade cafeeira no Brasil, obter dados referentes às áreas de plantio e a quantidade produzida é imprescindível para o manejo racional dessa cultura e para a definição de políticas públicas para o setor. Atualmente, os dados são obtidos por meio de questionários aplicados junto a produtores, cooperativas e órgãos públicos. Esse procedimento é caracterizado pelo alto custo e pela dificuldade de obtenção de dados em um curto período de tempo (IPPOLITI-RAMILO et al., 1999). Nesse contexto, várias pesquisas vêm sendo desenvolvidas com o objetivo de extrair informações a partir de imagens orbitais para as atividades agrícolas (GALVÃO et al., 2009;

RIZZI; RUDORFF, 2007; RUDORFF et al., 2010; SOARES; GALVÃO; FORMAGGIO, 2008).

O uso de imagens orbitais para o gerenciamento de atividades agrícolas é relativamente recente, mas suas potencialidades são amplamente reconhecidas (LAMPARELLI et al., 2012). Para extrair as informações das imagens orbitais, pode ser utilizada a técnica conhecida como classificação de imagens digitais. A classificação de imagens digitais é um procedimento pelo qual, a partir de uma imagem observada, obtém-se uma nova imagem, onde a cada posição é atribuído um rótulo, entre diversos rótulos possíveis. A classificação identifica regiões da imagem que tenham características similares em relação a um determinado tema de interesse.

<sup>1</sup>Secretaria de Agricultura/SEAGRO-Diretoria de Irrigação e Drenagem- Q. 110 Norte Alameda 21, 250- 77006-166- Palmas - TO lucaseng86@gmail.com

<sup>2,3,4</sup>Universidade Federal de Viçosa/UFV - Departamento de Engenharia Agrícola/DEA - Campus Universitário s/n - 36570-900 Viçosa - MG - valente@ufv.br, facpinto@ufv.br, ffabiolss@gmail.com

Dentre os classificadores destacam-se as Redes Neurais Artificiais (RNA) e Máxima Verossimilhança (MAXVER). As RNA possuem a vantagem de não assumir nenhuma distribuição para os dados, tendo a habilidade de aprender por meio de exemplos e generalizar o conhecimento diante de informações que ainda não foram apresentadas (HAYKIN, 2001). Já o MAXVER considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos (NERY et al., 2013).

Moreira et al. (2010) relatam que as lavouras cafeeiras apresentam uma significativa variação na resposta espectral, principalmente, devido a grande diversidade de práticas de manejo, lavouras de diferentes idades, espaçamentos variados e diferentes variedades. A resposta espectral do café e da vegetação natural é muito semelhante (LOPEZ-GOMEZ; WILLIAMS-LINERA; MANSON, 2008), o que dificulta a sua discriminação (MARTÍNEZ-VERDUZCO; GALEANA-PIZAÑA; CRUZ-BELLO, 2012). Por isso, é esperada uma confusão entre essas duas classes. Por outro lado, o que mais diferencia visualmente uma área de mata, de uma área ocupada por café é a textura das imagens (GOMEZ et al., 2010).

Os descritores de textura são definidos como variações tonais repetitivas e organizadas em uma pequena região da imagem (HARALICK; SHANMUGAN; ITSHAK, 1973). Shiguemori, Martins e Monteiro (2007) desenvolveram um sistema de classificação de imagens em tempo real com a utilização de descritores de textura retirados de um banco de dados gerado a partir de uma imagem orbital. O sistema de reconhecimento consistiu no treinamento de uma rede neural baseado nesses descritores de textura para classificação em tempo real de imagens aéreas que foram tomadas a partir de uma câmera acoplada a um helicóptero.

O uso de redes neurais, classificação supervisionada e análise de textura, são técnicas comuns no estudo do mapeamento e classificação de áreas cultivadas com café (GOMEZ et al., 2010; MARTÍNEZ-VERDUZCO; GALEANA-PIZAÑA; CRUZ-BELLO, 2012; TRABAGUINI et al., 2011). Mas a combinação dessas três técnicas para análise e classificação de plantios de café em região de montanha é limitada. Nesse contexto, objetivou-se com esse trabalho desenvolver classificadores neurais para fazer a discriminação de lavouras de café tendo como variável de entrada os descritores de textura de Haralick.

## 2 MATERIAL E MÉTODOS

A área de estudo foi o município de Araponga, na região da Zona da Mata Mineira, com coordenadas 20° 40' de latitude Sul e 42° 31' de longitude Oeste. Esse município possui altitudes que variam de 600 a 2.000m, solos argilosos, e o clima da região apresenta verões brandos e invernos fortes. Segundo a classificação climática de Köppen e Geiger (1928), destaca-se o subtipo tropical de altitude (Cwa), com chuvas durante o verão e temperatura média anual em torno de 19 °C, com variações médias entre 12 e 26°C.

Para realizar a classificação automatizada utilizando redes neurais artificiais (RNA), foi adquirida uma imagem de alta resolução do satélite GeoEye-1 com data de passagem no dia 11/07/2012. Essa imagem tem resolução espacial de 1,64 m no modo multiespectral, resolução radiométrica de 11 bits e quatro bandas espectrais: azul (450-520 nm), verde (520-600 nm), vermelho (625-695 nm) e infravermelho próximo (760-900 nm). A área abrangida pela imagem foi de 10 km por 10 km, o que garante a cobertura de várias lavouras de café com diferentes idades no entorno da cidade de Araponga, MG.

Foram desenvolvidos classificadores utilizando-se RNA para dois estudos de caso. No primeiro estudo de caso, foi desenvolvido um classificador para discriminar as plantações de café de outras classes temáticas. Nesta etapa foram definidas cinco classes de interesse: café, mata, área urbana, solo exposto e pastagem e água.

No segundo estudo de caso, foi desenvolvido um classificador para discriminar o estágio de desenvolvimento das plantações de café de acordo com a idade de plantio e data de recepa da planta. Foram feitas visitas de campo para a coleta dos parâmetros da cultura. Os parâmetros idade e data de recepa foram agrupados em classes, de acordo com as suas características, e pela similaridade espectral. Três classes de interesse foram definidas: cafeeiro novo (0-2 anos de idade ou 0-2 anos após a recepa), cafeeiro em desenvolvimento (2-4 anos de idade ou 2-4 anos após a recepa) e cafeeiro em produção (> 4 anos de idade ou > 4 anos após a recepa).

Dessas três classes, foram tomadas aleatoriamente, amostras representativas de cada uma dessas classes de interesse. E com essas amostras foram calculados os descritores de textura de haralick. Esses descritores de textura foram utilizados para treinar a RNA.

Nos dois estudos de casos, as RNAs tiveram como parâmetros de entrada os descritores de textura. Os descritores de textura foram calculados com amostras de blocos recortadas de cada classe de interesse na imagem original.

Os classificadores foram desenvolvidos com base nos seguintes passos: cálculo dos descritores de textura, treinamento das RNAs, verificação do desempenho das RNAs, classificação da imagem pela RNA e qualidade da classificação da imagem.

Para obtenção dos descritores de textura, foram recortadas três dimensões diferentes de blocos de imagens: 5x5, 7x7 e 9x9 pixels.

Os descritores de textura foram calculados de acordo com as Equações 1 a 6 (Tabela 1).

Para a classificação das imagens com os descritores de textura, foram desenvolvidas diversas RNAs no sistema computacional Matlab® (The Mathworks Inc., Massachusetts, USA). Utilizou-se o algoritmo de treinamento do tipo retropropagação do erro (*backpropagation*) com o método de otimização de Levenberg-Marquardt (HAYKIN, 2001).

A arquitetura da RNA utilizada foi do tipo 6-n<sub>1</sub>-n<sub>2</sub>-n<sub>3</sub>: um vetor de entrada com seis descritores de textura, uma primeira camada intermediária com n<sub>1</sub> neurônios artificiais uma segunda camada intermediária com n<sub>2</sub> neurônios artificiais e a camada de saída com n<sub>3</sub> neurônios representando cada classe, cinco neurônios para o primeiro estudo de caso e três para o segundo.

**TABELA 1** - Equações utilizadas para cálculo dos descritores de textura, segundo Haralick, Shanmugan e Itshak (1973).

| Descritor               | Equação   |
|-------------------------|---|
| Contraste               | $\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} (i-j)^2 P(i, j) \quad (1)$                                   |
| Correlação              | $\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} \frac{ijP(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2)$ |
| Entropia                | $-\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} P(i, j) \ln P(i, j) \quad (3)$                              |
| Homogeneidade           | $\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} \frac{P(i, j)}{1 + (i-j)^2} \quad (4)$                       |
| Segundo momento angular | $\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} [P(i, j)]^2 \quad (5)$                                       |
| Variância               | $\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} (i-m)^2 P(i, j) \quad (6)$                                   |

Ng: quantidade de níveis de cinza na imagem, P(i,j): pixel na posição (i,j) na matriz de co-ocorrência,  $\mu_x$ : média na direção x,  $\mu_y$ : média na direção y,  $\sigma_x$ : desvio padrão da média na direção x,  $\sigma_y$ : desvio padrão da média na direção p y.

O número de neurônios nas camadas intermediárias variou de 1 a 20. Dessa maneira, para cada tipo de classificador, foram testadas 400 arquiteturas diferentes. Nas duas camadas intermediárias usou-se a função de ativação tangente hiperbólica, e na camada de saída a função linear (HAYKIN, 2001).

Os vetores de entrada foram compostos pelos descritores de textura, os quais foram obtidos a partir da combinação de diferentes parâmetros: tamanho de bloco recortado (9x9, 7x7 e 5x5 pixels), a banda espectral (azul, verde, vermelho e infravermelho), a resolução radiométrica (8, 5 e 2 bits) e o ângulo de orientação do pixel vizinho (0°, 45°, 90° e 135°).

Os dados foram subdivididos aleatoriamente em três subconjuntos: 60% dos dados utilizados no conjunto de treinamento, 20% dos dados utilizados no conjunto de validação e os 20% restantes no conjunto de teste da rede.

Tendo em vista que, no início do treinamento, os parâmetros livres são gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final do treinamento, cada arquitetura de RNA foi treinada 10 vezes. Dentro dessas 10 RNAs treinadas, armazenou-se a que apresentou o menor erro quadrático médio relativo a amostra de teste.

Para a verificação do desempenho das RNAs treinadas, foram selecionadas 40 novas amostras na imagem de cada classe temática. A classificação foi avaliada comparando os resultados obtidos pela RNA com os valores da classificação visual por meio de uma matriz de confusão (CONGALTON, 1991). A matriz de confusão permitiu identificar o erro global da classificação para cada categoria, mostrando também como se deram as confusões entre as categorias (BRITES; SOARES; RIBEIRO, 1996). O coeficiente Kappa, que leva em consideração os erros de omissão e comissão na classificação, foi utilizado para avaliar cada RNA treinada. O coeficiente indicou o quanto o acerto do classificador foi melhor que o acerto ao acaso (COHEN, 1960).

Com base na melhor combinação entre tamanho de bloco, ângulo de direção do pixel vizinho e resolução radiométrica, foi desenvolvida uma rotina no Matlab® que fez a classificação da imagem. Para o primeiro estudo de caso, utilizou-se um recorte de 1,00 km x 1,00 km em torno da cidade de Araponga (Figura 1). Para o segundo estudo de caso, utilizou-se um recorte na imagem de satélite focalizando o entorno das fazendas: Itatiaia e Pedra Redonda (Figura 2).

## Araponga-MG

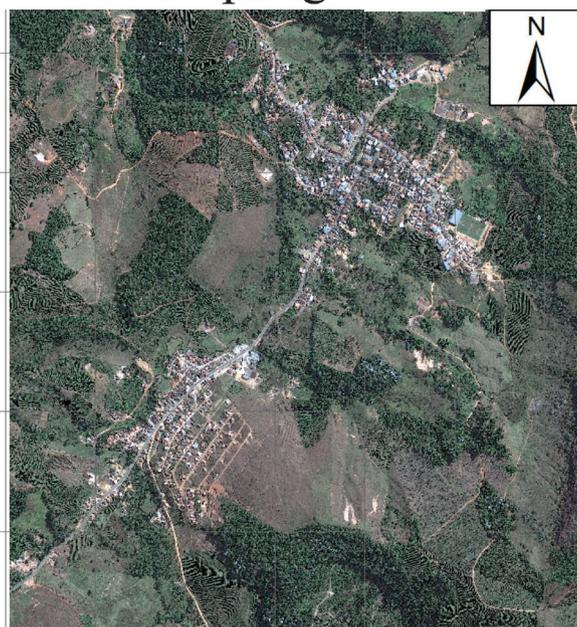
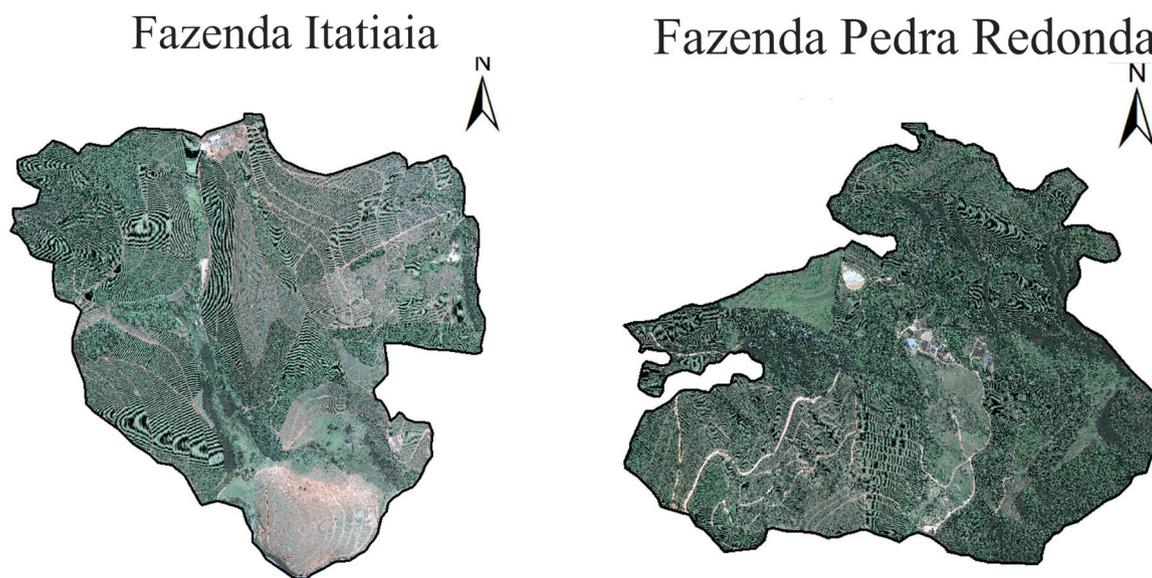


FIGURA 1 - Recorte da imagem GeoEye focalizando o entorno da cidade de Araponga para o primeiro estudo de caso.



**FIGURA 2** - Recorte da imagem GeoEye focalizando as fazendas Itatiaia e Pedra Redonda para o segundo estudo de caso.

Foi utilizado o Sistema de Informações Geográficas (SIG) ArcGIS (ESRI Inc., Redlands, CA, USA) para criar um mapa de referência de uso e ocupação do solo, com o propósito de confrontá-lo com o mapa feito com a RNA treinada. O mapa de referência foi obtido por fotointerpretação, suportado por visitas de campo. A concordância entre os mapas temáticos, classificados pela RNA, e o mapa de referência, classificado por fotointerpretação, foi avaliada pela estimativa o coeficiente Kappa (CONGALTON; MEAD, 1983) resultante da sobreposição destes mapas.

### 3 RESULTADOS E DISCUSSÃO

#### Primeiro estudo de caso

A partir do treinamento das RNA para classificação de café com vetor de saída como, mata, água, solo exposto e pastagem e área urbana, as melhores configurações foram obtidas na resolução radiométrica de 8 bits, bloco com dimensão 9x9 pixel, orientação do pixel de 90°, banda do vermelho. O número de neurônios da primeira e segunda camada foi de 10 e 17, respectivamente. Dessa forma, a arquitetura da RNA utilizada foi do tipo 6-10-17-1. Com um vetor de entrada com seis descritores de textura obtidos por meio dos seguintes parâmetros: banda

espectral do vermelho, ângulo de orientação do pixel vizinho de 90°, tamanho de bloco de 9x9 e resolução radiométrica de 8 bits.

Na Figura 3 é apresentado o mapa de referência, obtido por fotointerpretação suportada por visitas de campo, e o mapa de uso e ocupação do solo classificado pela RNA.

O coeficiente Kappa do mapa classificado pela RNA foi de 0,652 que, segundo Landis e Koch (1977), foi uma classificação Muito Boa. Vieira, Lacerda e Botelho (2009) fizeram um trabalho com o objetivo de identificar áreas cafeeiras usando uma RNA; o coeficiente Kappa determinado foi de 0,4676. As duas classes que mais se confundiram foram Café e Mata (Tabela 2).

A similaridade espectral da mata nativa e plantas do café dificultam a diferenciação entre estas classes (VIEIRA; LACERDA; BOTELHO, 2009). Quando se trabalha com descritores de textura, ocorre a minimização do problema relativo à similaridade espectral entre diferentes classes tendo em vista que o padrão espacial tem um papel mais importante que a informação espectral. No entanto, a informação espectral também apresentou um papel relevante tendo em vista os melhores resultados nas resoluções radiométricas maiores (Tabela 2).

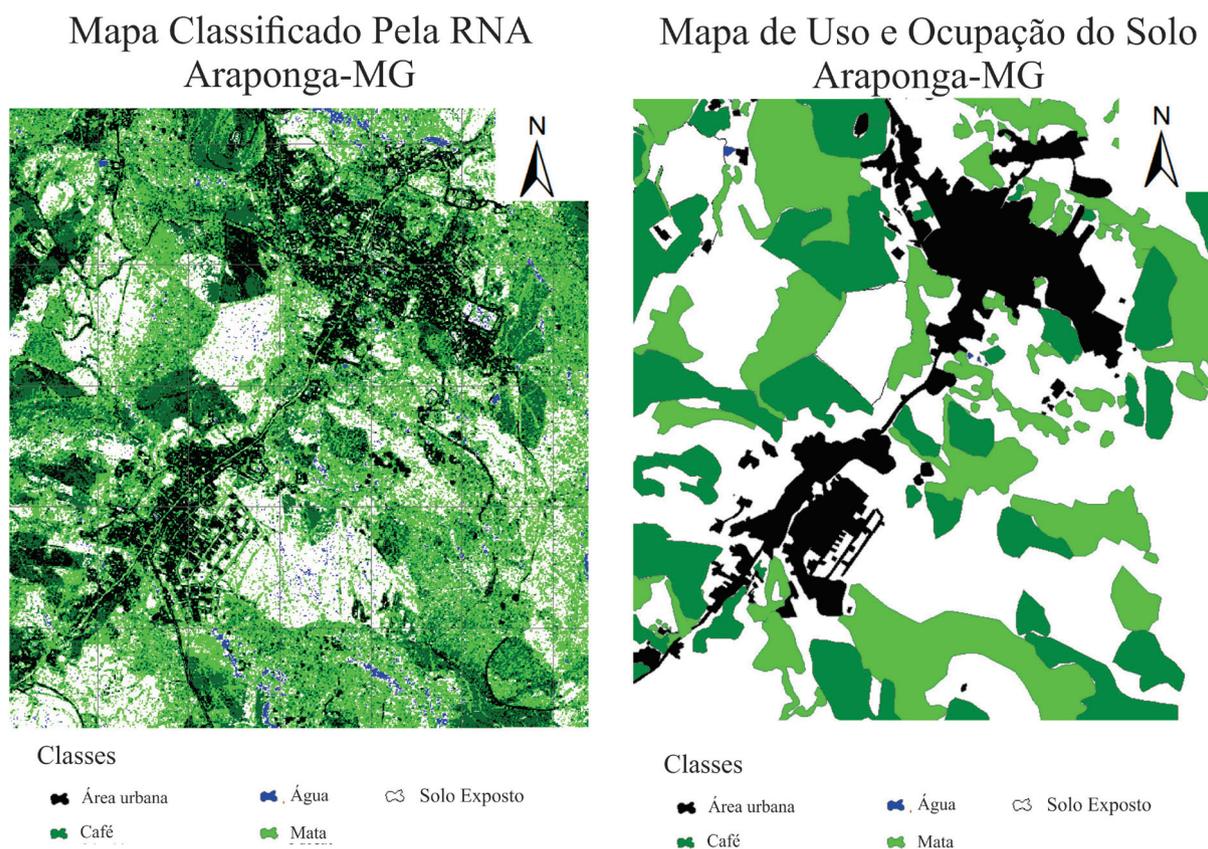


FIGURA 3 - (a) Mapa de referência e (b) mapa classificado pela rede neural artificial para o primeiro estudo de caso.

TABELA 2 - Matriz de confusão entre o mapa de referência e o mapa classificado pela RNA para o primeiro estudo de caso, valores em percentagem.

|              | Área urbana | Café  | Água  | Mata  | Solo exposto |
|--------------|-------------|-------|-------|-------|--------------|
| Área urbana  | 60,18       | 7,65  | 0     | 5,00  | 0            |
| Café         | 4,88        | 55,22 | 2,48  | 18,07 | 0            |
| Água         | 0           | 0     | 92,59 | 2,5   | 2,23         |
| Mata         | 22,44       | 29,67 | 0     | 71,93 | 16,89        |
| Solo exposto | 12,5        | 7,46  | 4,93  | 2,5   | 80,88        |

A existência de plantas, comerciais ou invasoras, nas linhas de café e o sombreamento devido ao relevo montanhoso da região também podem ter influenciado a diminuição do desempenho da classificação. Esta dificuldade em diferenciar a plantação de café da vegetação natural por técnicas de sensoriamento remoto em região de montanha também foi relatado por Martínez-Verduzco, Galeana-Pizaña e Cruz-Bello (2012).

### Segundo estudo de caso

A partir do treinamento das RNAs para classificação de café com vetor de saída como, cafeeiro novo, cafeeiro em desenvolvimento e cafeeiro em produção, as melhores configurações foram obtidas na resolução radiométrica de 5 bits, bloco com dimensão 7x7 pixel, orientação do pixel de 45°, banda do vermelho. O número de neurônios da primeira e segunda camada foi de 12 e 10, respectivamente. Dessa forma, a arquitetura da RNA utilizada foi do tipo 6-12-10-1. Com um vetor de entrada com seis descritores de textura obtidos por meio dos seguintes parâmetros: banda espectral do vermelho, ângulo de orientação do pixel vizinho de 45°, tamanho de bloco de 7x7 (Tabela 3).

Na Figura 4 é apresentado o mapa de referência, classificado por fotointerpretação e por visitas de campo, e o mapa classificado pela RNA para a fazenda Itatiaia.

A classificação da fazenda Itatiaia apresentou uma exatidão global de 0,783 e coeficiente Kappa do mapa classificado pela RNA foi de 0,675,

desempenho considerado Muito Bom (LANDIS; KOCH, 1977). Moreira, Barros e Rudorff (2008), em um trabalho de caracterização da cafeicultura no Estado de Minas Gerais, obtiveram desempenho de classificação com o índice Kappa variando de 0,654 a 0,849. Segundo estes autores, o que mais influenciou na classificação foi a heterogeneidade do comportamento espectral das lavouras que são relacionadas aos os parâmetros agrônômicos de manejo. Na fazenda Itatiaia, o manejo diferenciado entre os talhões, principalmente a poda e os espaçamentos diferenciados, provocou uma variabilidade nos padrões espectral e espacial dos talhões da mesma classe, diminuindo o desempenho da classificação, principalmente na classe Cafeeiro em Produção (Tabela 4).

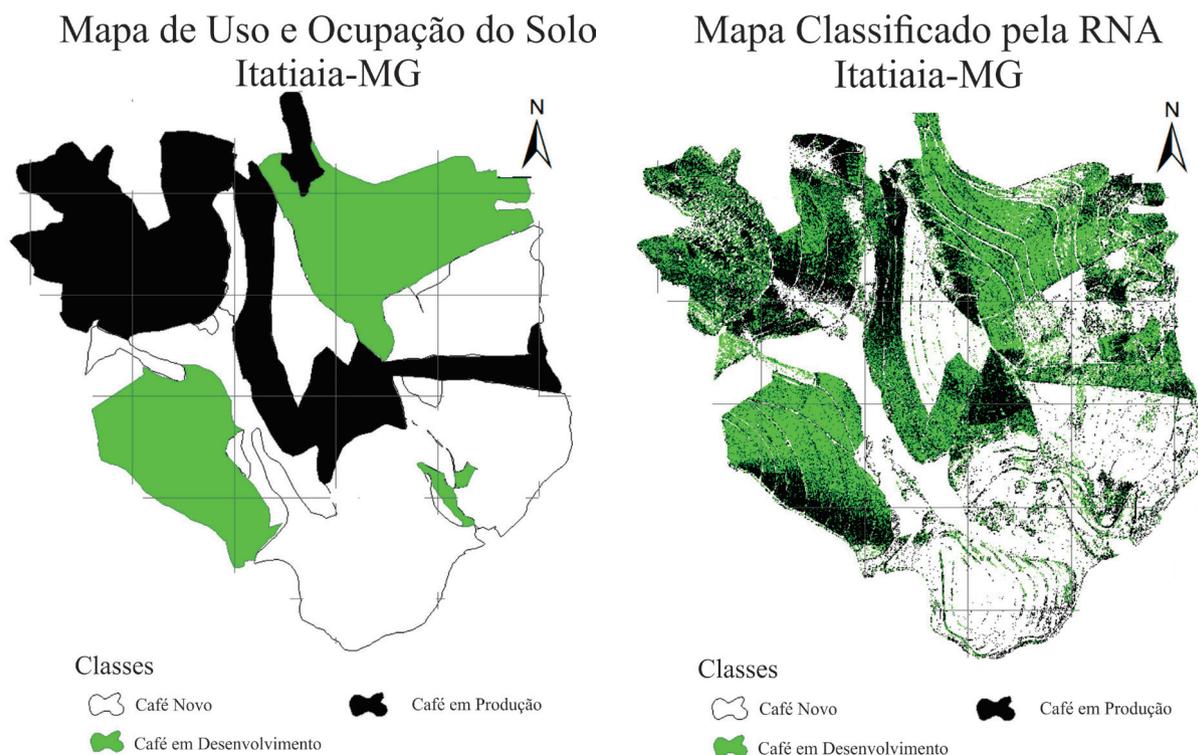
Somente 60% da área de cafeeiro em produção no mapa de referência foi classificada corretamente pela RNA, sendo que a confusão com o cafeeiro em desenvolvimento foi de 30%. O desempenho do classificador melhorou nas áreas de plantas mais novas, com acerto de 85 e 90% para cafeeiros em desenvolvimento e novos, respectivamente. O padrão espectral e o padrão espacial apresentaram-se mais uniformes à medida que mais solo era exposto. Quando aumentou a influência do dossel dos cafeeiros na área, a confusão na classificação aumentou, provavelmente, devido ao manejo diferenciado, influenciado pela variabilidade edafoclimática mais evidente em áreas montanhosas.

Na Figura 5 é apresentado o mapa de referência e o mapa classificado pela RNA para a fazenda Pedra Redonda.

**TABELA 3** - Redes neurais artificiais que apresentam os maiores coeficientes Kappas com amostras representativas de cada classe de interesse (cafeeiro novo, cafeeiro em desenvolvimento, cafeeiro em produção).

| RNA <sup>1</sup> | Resolução Radiométrica | Banda Espectral | Ângulo | N. de Neurônios |           | EG <sup>2</sup> | Kappa |
|------------------|------------------------|-----------------|--------|-----------------|-----------|-----------------|-------|
|                  |                        |                 |        | 1ª Camada       | 2ª Camada |                 |       |
| 1                | 8                      | Azul            | 45     | 12              | 10        | 0,850           | 0,775 |
| 2                | 8                      | Verde           | 45     | 10              | 13        | 0,842           | 0,762 |
| 3                | 8                      | Vermelho        | 45     | 16              | 12        | 0,825           | 0,737 |
| 4                | 5                      | Vermelho        | 45     | 16              | 16        | 0,808           | 0,712 |
| 5                | 5                      | Azul            | 135    | 13              | 11        | 0,791           | 0,687 |
| 6                | 5                      | Verde           | 135    | 16              | 17        | 0,792           | 0,687 |
| 7                | 8                      | Verde           | 90     | 16              | 14        | 0,783           | 0,675 |
| 8                | 5                      | Vermelho        | 90     | 17              | 15        | 0,767           | 0,650 |

<sup>1</sup>RNA: Rede Neural Artificial; <sup>2</sup>EG: exatidão global



**FIGURA 4** - (a) Mapa de referência e (b) mapa classificado pela Rede Neural Artificial para a fazenda Itatiaia no segundo estudo de caso.

**TABELA 4** - Matriz de confusão, com valores em porcentagem, entre o mapa de referência e o mapa classificado pela RNA para a fazenda Itatiaia.

|                             | Cafeeiro em Produção | Cafeeiro em desenvolvimento | Cafeeiro Novo |
|-----------------------------|----------------------|-----------------------------|---------------|
| Cafeeiro em Produção        | 60                   | 12,5                        | 5             |
| Cafeeiro em desenvolvimento | 30                   | 85                          | 5             |
| Cafeeiro Novo               | 10                   | 2,5                         | 90            |

A fazenda Pedra Redonda apresentou uma exatidão global de 0,652 e o coeficiente Kappa do mapa classificado pela RNA foi de 0,4783, desempenho considerado Bom (LANDIS; KOCH, 1977). A piora do desempenho do classificador em relação à Fazenda Itatiaia, pode ser atribuída à presença de árvores no meio das lavouras de café e o relevo desta fazenda ser mais acidentado, causando confusão no classificador.

Somente 52,3 % da área de cafeeiro em produção no mapa de referência foram classificadas corretamente pela RNA, sendo que a confusão com o cafeeiro em desenvolvimento foi de 36,5% (Tabela 5). O desempenho do classificador melhorou nas áreas de plantas mais novas, com acerto de 64,87 e 78,49% para cafeeiros

em desenvolvimento e novos, respectivamente. O padrão espectral e o padrão espacial apresentaram-se mais uniformes nas plantas mais jovens.

De modo geral, observou-se que os resultados da classificação variam, sendo considerado Muito Bom para a fazenda Itatiaia e Bom para a fazenda Pedra Redonda. Esses resultados assemelharam-se ao trabalho realizado por Moreira, Adami e Rudorff (2004), que enfatizaram que a heterogeneidade da diversidade espectral da cultura do café associado aos parâmetros de manejo da cultura influenciam na classificação. Sendo assim, em trabalhos futuros seria interessante entrar com outros parâmetros (altura, espaçamento e índice de área foliar) além da idade e data de recepa.

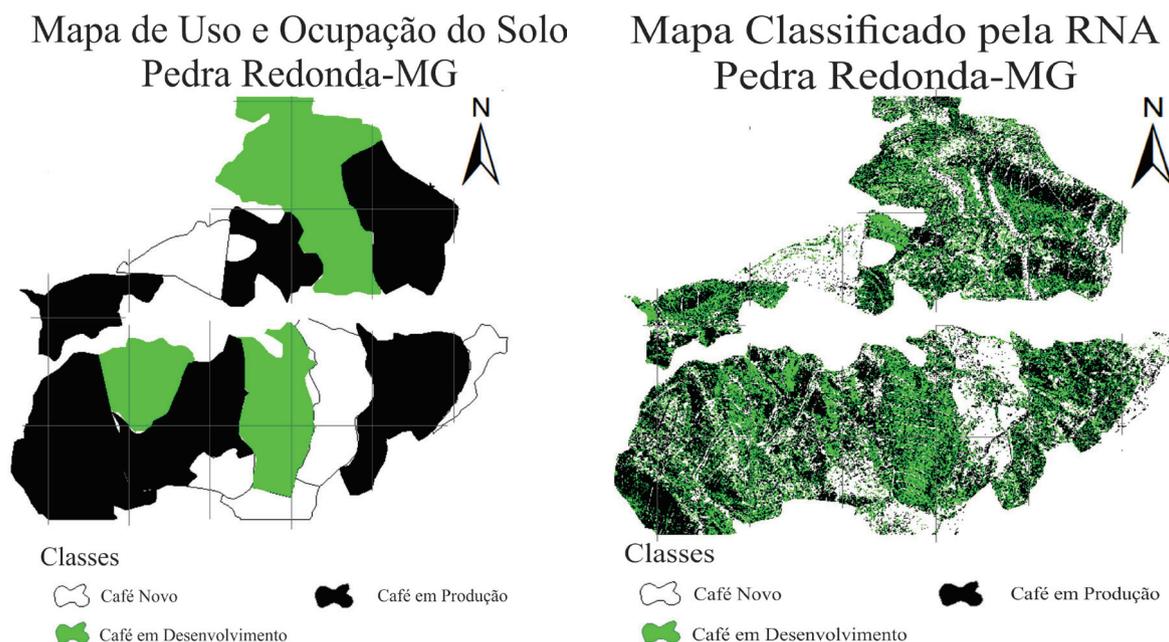


FIGURA 5 - (a) Mapa de referência e (b) mapa classificado pela rede neural artificial para a fazenda Pedra Redonda no segundo estudo de caso.

TABELA 5 - Matriz de confusão, com valores em porcentagem, entre o mapa de referência e o mapa classificado pela RNA para a fazenda Pedra Redonda.

|                             | Cafeeiro em Produção | Cafeeiro em desenvolvimento | Cafeeiro Novo |
|-----------------------------|----------------------|-----------------------------|---------------|
| Cafeeiro em Produção        | 52,3                 | 14,66                       | 5,25          |
| Cafeeiro em desenvolvimento | 36,5                 | 64,87                       | 16,26         |
| Cafeeiro Novo               | 11,2                 | 20,47                       | 78,49         |

#### 4 CONCLUSÃO

O uso de redes neurais utilizando as características de textura mostrou-se uma alternativa viável para identificação de lavouras de café em imagens orbitais.

O tamanho dos blocos influenciou no processo de classificação da imagem, sendo que o maior tamanho identificou melhor o padrão espacial das áreas produtoras de café.

O coeficiente Kappa obtido para discriminação das lavouras cafeeiras das classes mata, área urbana, água e solo exposto foi de 0,652, que é índice considerado Bom.

O coeficiente Kappa para discriminar as lavouras cafeeiras em função da sua idade e data foi Muito Bom para a fazenda Itatiaia e Bom para a fazenda Pedra Redonda, com valores de 0,657 e 0,478, respectivamente.

#### 5 REFERÊNCIAS

- BRITES, R. S.; SOARES, V. P.; RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais. In: SIMPÓSIO BRASILEIRO DE SENSOREAMENTO REMOTO, 8., 1996, Salvador. **Anais...** Salvador: Instituto Nacional de Pesquisas Espaciais, 1996. 1 CD-ROM.
- COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, Durham, v. 20, p. 37-46, 1960.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, New York, v. 55, n. 37, p. 35-46, 1991.

- CONGALTON, R. G.; MEAD, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering & Remote Sensing**, Falls Chrch, v. 49, n. 1, p. 69-74, 1983.
- GALVÃO, L. S. et al. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data. **Remote Sensing of Environment**, New York, v. 113, n. 4, p. 846-856, 2009.
- GOMEZ, C. et al. Use of high-resolution satellite imagery in an integrated model to predict the distribution of shade coffee tree hybrid zones. **Remote Sensing of Environment**, New Caledonia, v. 114, n. 11, p. 2731-2744, 2010.
- HARALICK, R. M.; SHANMUGAN, K.; ITSHAK, D. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, Lawrence, v. 3, n. 6, p. 610-621, 1973.
- HAYKIN, S. **Redes neurais: princípio e prática**. Porto Alegre: Bookman, 2001.
- IPPOLITI-RAMILO, G. A. et al. Sensoriamento remoto orbital como meio auxiliar na previsão de safras. **Agricultura em São Paulo**, São Paulo, v. 46, n. 1, p. 89-101, 1999.
- KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes, 1928. wall-map 150 cm x 200 cm.
- LAMPARELLI, R. A. C. et al. Use of data mining and spectral profiles to differentiate condition after harvest of coffee plants. **Engenharia Agrícola**, Jaboticabal, Jaboticabal, v. 32, n. 1, p. 184-196, jan./fev. 2012.
- LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, Washington, v. 33, n. 3, p. 159-179, 1977.
- LOPEZ-GOMEZ, A. A.; WILLIAMS-LINERA, G.; MANSON, R. H. Tree species diversity and vegetation structure in shade coffee farms in Veracruz, Mexico. **Agriculture, Ecosystems and Environment**, Veracruz, v. 124, n. 3/4, p. 160-172, 2008.
- MARTÍNEZ-VERDUZCO, G. C.; GALEANA-PIZAÑA, J. M.; CRUZ-BELLO, G. M. Coupling community mapping and supervised classification to discriminate Shade coffee from natural vegetation. **Applied Geography**, Indiana, v. 34, p. 1-9, 2012.
- MOREIRA, M. A. Geotecnologias para mapear lavouras de café nos Estados de Minas Gerais e São Paulo. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 6, p. 1123-1135, 2010.
- MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Análise espectral e temporal da cultura do café em imagens Landsat-5. **Pesquisa Agropecuária Brasileira**, Brasília, v. 39, n. 3, p. 223-231, mar. 2004.
- MOREIRA, M. A.; BARROS, M. A.; RUDORFF, B. F. T. Geotecnologias no mapeamento da cultura do café em escala municipal. **Saúde e Natureza**, Uberlândia, v. 20, n. 1, p. 101-110, 2008.
- NERY, C. V. M. et al. Avaliação das técnicas de classificação MAXVER, MAXVER: ICM e Distância Mínima Euclidiana de acordo com Índice Kappa. **Revista Brasileira de Geografia Física**, Recife, v. 6, n. 2, p. 320-328, 2013.
- RIZZI, R.; RUDORFF, B. F. T. Imagens do sensor MODIS associadas a um modelo para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v. 42, p. 73-80, 2007.
- RUDORFF, B. F. T. et al. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo state (Brazil) using Landsat data. **Remote Sensing**, Basel, v. 2, n. 4, p. 1057-1076, 2010.
- SHIGUEMORI, E. H.; MARTINS, M. P.; MONTEIRO, M. V. T. Landmarks recognition for autonomous aerial navigation by neural networks and gabor transform. **Image Processing**, Sacramento, v. 6497, n. 1, p. 1-8, 2007.
- SOARES, D. M.; GALVÃO, L. S.; FORMAGGIO, A. R. Crop area estimate from original and simulated spatial resolution data and landscape metrics. **Scientia Agrícola**, Piracicaba, v. 65, n. 5, p. 459-467, 2008.
- TRABAQUINI, K. et al. Caracterização de lavouras cafeeiras, utilizando técnicas de geoprocessamento e sensoriamento remoto, no município de Umarama, PR. **Ciência e Agrotecnologia**, Lavras, v. 35, n. 1, p. 35-44, jan./fev. 2011.
- VIEIRA, T. G. C. V.; 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...** Natal, 2009. p. 7947-7954.