

# Exploiting Feature Extraction Techniques for Remote Sensing Image Classification

M. G. Boell, H. M. R. Alves, M. M. L. Volpato, D. D. Ferreira and W. S. Lacerda

**Abstract**— Multispectral image classification derived from satellite sensors is a topic of great interest for the scientific community. The great interest is to automatically identify different areas including coffee production. The coffee stands out for being an important source of income and jobs, as well as being one of the most important products of the economy of Brazil. However, automatically map this culture has been a challenge so much for object-oriented analysis how much to methods based on “pixel to pixel” techniques. This work exploits different feature extraction techniques aiming at identifying the most discriminative features for remote image classification. The satellite image used in this study refers to the Três Pontas region, Minas Gerais, Brazil, which has a great agricultural production, especially coffee. It has been used the seven spectral image bands of Landsat 8 OLI (Operational Land Imager). It was considered 5 land use classes: Coffee, Wood, Water, Urban Area, Other Uses (Grassland, Soil, Weathered, Other Cultures, Eucalyptus). Various spectral and textural characteristics were extracted as features and combined for the classification. Higher-order statistics-based features were also extracted and combined with those commonly used in the literature for remote sensing image classification. Two feature selection methods for dimension reduction was used: the Fisher’s Discriminant Ratio (FDR) and the linear correlation. As classifier, a multilayer perceptron has been used. The best Kappa indices obtained was 73.13% for the model that considered all extracted features (a total of 43) as input.

**Keywords**— Artificial Neural Networks, Higher-order Statistics, Pattern Recognition, Remote Sensing.

## I. INTRODUÇÃO

A DETECÇÃO de mudanças na cobertura de terra em regiões do globo utilizando dados provenientes de satélites multiespectrais e hipertemporais tem sido um objetivo desejado da comunidade científica relacionada ao sensoriamento remoto [1]. Alterações na cobertura dos solos geralmente indicam mudanças no uso da terra com grandes impactos sócio-econômicos, enquanto a transformação da vegetação (desmatamento, expansão agrícola e urbanização) tem impactos significativos na hidrologia, clima e ecossistemas [2]. A detecção digital de alterações da cobertura do solo inclui processar vários dados de imagens temporais adquiridos por satélite artificial utilizando sensores multiespectrais [3].

M. G. Boell, Universidade Federal de Lavras, Lavras/MG, [milergrudtner@gmail.com](mailto:milergrudtner@gmail.com), H. M. R. Alves, EMBRAPA, Lavras/MG, [helena.alves@embrapa.br](mailto:helena.alves@embrapa.br), M. M. L. Volpato, EPAMIG, Lavras/MG, [margarete@epamig.ufla.br](mailto:margarete@epamig.ufla.br), D. D. Ferreira, Universidade Federal de Lavras, Lavras/MG, [danton@deg.ufla.br](mailto:danton@deg.ufla.br). Corresponding author.

W. S. Lacerda, Universidade Federal de Lavras, Lavras/MG, [lacerda@dcc.ufla.br](mailto:lacerda@dcc.ufla.br)

Devido à complexidade e a natureza não paramétrica da detecção e classificação da mudança de cobertura da terra, métodos de aprendizagem de máquina são amplamente considerados como a opção mais viável para a classificação e detecção de alterações [4]. Assim, muitos algoritmos de reconhecimento de padrões foram adotados na classificação de cobertura da terra através de sensoriamento remoto [5], [6], [7], [8], [9], [10], [11]. Entre esses métodos, a rede neural artificial (RNA), algoritmos genéticos, árvore de decisão, naive bayes, floresta randômica, máquinas de vetores de suporte, k-vizinhos-mais-próximos e algoritmo de máxima verossimilhança foram reconhecidos como os mais promissores algoritmos e os mais amplamente utilizados, incluindo o uso de métodos híbridos.

Vale ressaltar que a classificação manual de imagem de satélite é uma tarefa dispendiosa, pois exige que o perito tenha conhecimento suficiente da área. Então, o uso de técnicas automatizadas, baseadas em reconhecimento de padrões, são formas importantes para agilizar e facilitar o processo de classificação.

Vários procedimentos de classificação automática possuem limitações, principalmente devido à resolução espectral e radiométrica de imagens de satélite e as características intrínsecas da cultura [12]. Este trabalho propõe um método para classificação de imagens de satélite que é apropriado para a identificação e mapeamento do uso da terra e ocupação, com ênfase na cultura do café. As novidades do método proposto são: (i) o uso de diferentes características extraídas dos pixels que, combinados, geram vetores de parâmetros discriminativos; (ii) o uso de estatísticas de ordem superior como parâmetros discriminantes à classificação; o uso de métodos de seleção de características que auxiliam na escolha das características mais relevantes, reduzindo a complexidade do classificador além de aperfeiçoá-lo, podendo resultar em uma classificação mais confiável.

Este trabalho contribui para a área oferecendo um estudo sobre diferentes características extraídas de imagens de satélite para classificações de cinco classes, café, mata, água, área urbana e outros usos. Além de introduzir novas características, como as estatísticas de ordem superior, explora características já usadas para este fim de forma a evidenciar quais são as mais relevantes. Aliado a isso, técnicas de inteligência computacional são empregadas para projetar o classificador final.

## II. BASE DE DADOS

A área de estudo usada para teste e avaliação de desempenho do método proposto é a região de café de Três Pontas, Minas Gerais, Brasil. Nesta região o café representa 70% do rendimento agrícola. A região está localizada geograficamente entre as coordenadas 21° 17' 07.10" e 21° 27' 57.41" Sul e 45° 30' 4.69" e 45° 45' 3.33" Oeste, com uma área total de 510 km<sup>2</sup>. Seu clima é tipo tropical de altitude, com temperatura média anual variando entre 18°C e 19°C, onde evidencia o predomínio de temperaturas moderadas durante grande parte do ano. A altitude média do município é de 905 metros, e o máximo atinge 1.234 metros na serra de Três Pontas.

As imagens multiespectrais utilizadas para classificação correspondem às imagens de satélite do sensor (OLI – *Operational Land Imager*) do Landsat 8, com a data de passagem no dia 23/09/2015. As bandas utilizadas foram: 1, 2, 3, 4, 5, 6 e 7 com pixels de 30 metros de resolução espacial. As imagens correspondentes foram adquiridas gratuitamente do site do Instituto Nacional de Pesquisas Espaciais (INPE). A Fig. 1 apresenta as bandas de imagem utilizadas em níveis de cinza.




Figura 1. Imagens das bandas de 1 a 7 obtidas da região de Três Pontas/MG.

Para implementar o método proposto, um conjunto de pixels foram selecionados para cada classe da imagem capturada. A Fig. 2 apresenta os pixels selecionados que foram destacados pelas cores vermelho, verde, azul, amarelo e branco, representando respectivamente: café, vegetação, água, área urbana e outros usos. Esses pixels foram selecionados manualmente usando o ambiente de software para visualização de imagens (ENVI).

A Tabela I apresenta o número de pixels coletados para cada classe e separados em projeto (treinamento e teste) e validação. Foram selecionadas mais amostras de treinamento (pixels) das classes café e outros usos, devido a grande variabilidade espectral destes alvos [12].

TABELA I  
AMOSTRAS UTILIZADAS PARA A AVALIAÇÃO DO DESEMPENHO

Classes	Treinamento e Teste	Validação
Café	20.300	5.075
Vegetação	5.672	1.418
Água	1.916	479
Área urbana	1.763	440

Outros usos	26.018	6.504
-------------	--------	-------




Figura 2. Aquisição das amostras. As regiões coloridas indicam café (vermelho), vegetação (verde), água (azul), área urbana (amarelo) e outros usos (branco).

### III. MÉTODO PROPOSTO

O diagrama de blocos mostrado na Fig. 3 ilustra as etapas do método proposto.




Figura 3. Diagrama em blocos do método proposto.

Após a aquisição das amostras conforme descrito na Seção II, uma etapa de extração de características foi executada. A finalidade da extração é revelar características importantes para construir vetores compactos de assinatura das classes a serem classificadas.

Após a extração de características, a próxima etapa consistiu no uso de dois métodos de seleção de características: o Discriminante Linear de Fisher, que é capaz de identificar as características mais relevantes [13] e a correlação linear que permite eliminar a redundância entre as características.

Por fim, foi implementada a RNA treinada para classificar as características selecionadas. As subseções a seguir explicam mais detalhadamente cada etapa.

#### A. Extração de Características

As seguintes características foram extraídas considerando-se os pixels das 7 bandas: média e desvio padrão; mínimos e máximos; brilho e máxima diferença [12]; índice de diferença normalizada (NDVI) [14]; índice de vegetação ajustado ao solo (SAVI); cumulantes [15]; energia [16]. Estas características são descritas a seguir.

##### A1. Média e desvio padrão

Os valores de média e desvio padrão foram obtidos através de (1) e (2), respectivamente.

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}[n] \quad (1)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (\mathbf{x}[n] - \bar{x})^2} \quad (2)$$

em que  $\mathbf{x}[n]$ , para  $n = 1, 2, 3, 4, 5, 6$  e  $7$ , representa o vetor contendo o valor dos pixels das sete bandas da imagem a ser processada (vide Figura 1) e  $\bar{x}$  é a sua média.

##### A2. Mínimo e máximo

Os valores de máximo e mínimo do vetor de pixels  $\mathbf{x}[n]$  foram também extraídos, conforme (3) e (4).

$$x_{min} = \min(\mathbf{x}[n]) \quad (3)$$

$$x_{max} = \max(\mathbf{x}[n]) \quad (4)$$

##### A3. Brilho e máxima diferença

Para a extração de brilho é usada a Equação (5) onde  $\beta$  é o nível de intensidade de iluminação do pixel.

$$\text{Brilho} = \begin{cases} 1 - \beta, & \beta > 0 \\ \frac{1}{1 + \beta}, & \beta \leq 0 \end{cases} \quad (5)$$

##### A4. Índice de diferença normalizada (NDVI)

O índice NDVI é um dos indicadores mais importantes para detectar a cobertura vegetal de diferentes períodos de tempo e em áreas específicas através de sensoriamento remoto. O NDVI é calculado através da combinação das bandas do vermelho visível (vermelho) e infravermelho próximo (NIR) de um sistema de sensor [17]. O índice NDVI é expresso por (6).

$$\text{NDVI} = \frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED})} \quad (6)$$

##### A5. Índice de vegetação ajustado ao solo (SAVI)

O índice SAVI é semelhante ao NDVI, mas foi sugerido por [18], que introduziu um parâmetro de ajuste, denotado por  $L$ , que caracteriza o solo e a sua taxa de cobertura pela vegetação. O parâmetro  $L$  assume o valor de 0,25 para uma densidade muito baixa e 1 para alta densidade de vegetação. Para densidades intermediárias é igual a 0,5 [19]. No método proposto foi usado  $L = 0,5$ . O índice SAVI é expresso por (7).

$$\text{SAVI} = \frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED} + L)} \cdot (1 + L) \quad (7)$$

##### A6. Cumulantes

Os cumulantes são estatísticas de ordem superior (EOS) e foram usados com sucesso como características em métodos de classificação [20], [21], [22]. Neste trabalho, os cumulantes de segunda, terceira e quarta ordens foram utilizados, e são definidos pelas aproximações apresentadas em (8)-(10), que levam a uma boa simplificação para problemas onde um vetor  $\mathbf{x}[n]$  de comprimento finito ( $N$ ) é usado [21]:

$$\hat{C}_{2,x}[i] := \frac{2}{N} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}[\text{mod}[n+i, N]], \quad (8)$$

$$\hat{C}_{3,x}[i] := \frac{2}{N} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}^2[\text{mod}[n+i, N]] \quad (9)$$

e

$$\hat{C}_{4,x}[i] := \frac{2}{N} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}^3[\text{mod}[n+i, N]] - \frac{2}{N^2} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}[\text{mod}[n+i, N]] \sum_{n=0}^N \mathbf{x}^2[n], \quad (10)$$

em que  $n = 1, 2, \dots, N$  é o índice da amostra,  $\text{mod}[n+i, N]$  é o restante inteiro da divisão de  $n+i$  por  $N$  e  $i$  é o  $i$ -ésimo atraso (*lag*).

Neste trabalho, o vetor  $\mathbf{x}[n]$  compreende os valores de pixel para as 7 bandas da imagem (ver Fig. 1). Então, para cada 2ª, 3ª e 4ª ordem de cumulante, um total de 7 valores foram calculados, referentes aos atrasos de 1 a 7. Portanto, o vetor de características baseado em cumulante é composto por um total de 21 características. Para efeitos de classificação e detecção, a combinação de alguns cumulantes é suficiente para obter um bom desempenho, conforme mostrado em [20] e [21].

##### A7. Energia

A energia mede o “tamanho” de um sinal e pode ser estendida a um vetor de variáveis. A energia é calculada de acordo com (11).

$$\text{Energia} = \sum_{n=0}^{N-1} \mathbf{x}^2[n] \quad (11)$$

#### B. Seleção de Características

Para a redução da dimensão, a Razão de Discriminação de Fisher (FDR - *Fisher's Discriminant Ratio*) foi empregada devido a sua simplicidade e resultados satisfatórios [23]. A função de custo do critério FDR para o problema multiclasse é:

$$J_c = \sum_i^M \sum_{j \neq i}^M (\mu_i - \mu_j)^2 \odot \frac{1}{\sigma_i^2 + \sigma_j^2} \quad (12)$$

em que  $J_c = [J_1 \dots J_{L_l}]^T$ ,  $L_l$  é o número total de características  $\mu_i$  e  $\mu_j$ , e  $\sigma_i^2$  e  $\sigma_j^2$  são, respectivamente, vetores de média e variância dos dados da classe  $i$  e classe  $j$ . O símbolo  $\odot$  refere-se ao produto de Hadamard, em que  $\mathbf{r} \odot \mathbf{s} = [r_0 s_0 \dots r_{L_r-1} s_{L_r-1}]^T$ .

Pode-se entender que o  $i$ -ésimo elemento do vetor de características, referente ao valor mais alto de  $J_c$  é selecionado para ser usado pelo classificador. Em outras palavras, valores mais altos de  $J_c$  indicam características mais discriminativas.

Alternativamente, a correlação linear entre características foi usada para eliminar a redundância e, conseqüentemente, reduzir a dimensão dos dados. Por isso, um limiar de 0,9 foi definido para que a característica seja eliminada se sua correlação com outra característica for superior a este limiar.

Após a fase de seleção de características, o vetor de característica final é apresentado a um classificador.

C. Classificação com redes neurais artificiais (RNA)

A rede neural utilizada foi um perceptron multicamada com uma camada escondida e 5 neurônios na camada de saída, onde cada neurônio de saída representa uma classe. O algoritmo usado para treinamento foi o Levenberg-Marquardt [24]. Como critério de parada do treinamento foi usado o método *Early-Stopping* (ES) [25]. A equação (13) descreve os alvos usados para treinar a rede neural. A função de ativação utilizada foi a tangente hiperbólica.

$$Alvo = \begin{bmatrix} +1 & -1 & -1 & -1 & -1 \\ -1 & +1 & -1 & -1 & -1 \\ -1 & -1 & +1 & -1 & -1 \\ -1 & -1 & -1 & +1 & -1 \\ -1 & -1 & -1 & -1 & +1 \end{bmatrix} \quad (13)$$

Cinco diferentes abordagens que levaram a diferentes entradas para a rede neural foram testadas comparativamente:

- A) Utilizando os pixels de todas as bandas da imagem, totalizando 7 entradas;
- B) Utilizando o vetor de características completo, com 43 características de entrada;
- C) Utilizando apenas os cumulantes de segunda, terceira e quarta ordens (atrasos de 1 a 7), totalizando 21 entradas;
- D) Pré-processamento com o FDR e escolhendo as 21 características com maior  $J_c$  como entrada;
- E) Utilizando a correlação linear entre as variáveis para eliminar variáveis redundantes, levando a um total de apenas 11 características como entradas.

D. Avaliação de Desempenho

Para avaliação de desempenho, foram utilizados os índices Kappa [26] e a acurácia. Estes índices foram calculados conforme Equações (14) e (15) respectivamente.

$$Kappa = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (14)$$

em que  $n$  é o número total de observações,  $n_{ii}$  é o número de observações na linha e coluna  $i$ ,  $n_{i+}$  é a soma da linha  $i$ ,  $n_{+i}$  é a soma da coluna  $i$  da matriz de confusão e  $k$  é o número total de classes.

$$Acurácia = \frac{VP+VN}{VP+VN+FP+FN} \quad (15)$$

em que  $VP$  é o verdadeiro positivo,  $VN$  é o verdadeiro negativo,  $FP$  é o falso positivo e  $FN$  é o falso negativo.

O nível de precisão do índice Kappa é geralmente classificado de acordo com [27], conforme Tabela II.

TABELA II  
NÍVEL DE PRECISÃO DE CLASSIFICAÇÃO DO ÍNDICE KAPPA

Índice Kappa (K)	Qualidade
$K > 0.80$	Concordância muito forte
$0.60 < K < 0.80$	Concordância substancial
$0.40 < K < 0.59$	Concordância moderada
$0.20 < K < 0.39$	Concordância leve
$0.00 < K < 0.19$	Concordância fraca
$K < 0.00$	Sem concordância

IV. RESULTADOS

A Fig. 4 ilustra os resultados alcançados na etapa de seleção de características. Observa-se que a característica de brilho das bandas 5, 6 e 7 são as características mais relevantes para a classificação de acordo com o critério FDR. Os índices NDVI e SAVI também se mostraram relevantes, seguidos pelos pixels das bandas 5, 6 e 7. Os cumulantes, em geral, apresentaram o menor potencial de discriminação dentre as variáveis analisadas.




Figura. 4. Características selecionadas pelo Fisher.

Para a abordagem D foram selecionadas as características com valores  $J$  superiores a 150, totalizando 21 características. Embora esta análise seja capaz de realizar a seleção das características que melhor discriminam entre classes, a mesma

não é capaz de eliminar dados redundantes. Assim, a correlação linear foi aplicada de modo que para cada correlação entre um par de características, com valor acima de 0,9, uma das características é descartada. As características que foram selecionadas pela correlação foram o cumulante de segunda ordem (atraso 6), o cumulante de terceira ordem (atraso 6), o cumulante de quarta ordem (atrasos 1, 2, 3 e 6), valor máximo de pixels, SAVI, brilho das bandas 5 e 7, e máxima diferença.

No projeto da RNA, o número de neurônios na camada intermediária foi variado a fim de se alcançar a melhor arquitetura de rede. A Tabela III ilustra a arquitetura de RNA final alcançada para cada abordagem.

TABELA III  
ARQUITETURA GERAL

Abordagem	Arquitetura da RNA
A	7x8x5
B	43x45x5
C	21x23x5
D	21x22x5
E	11x11x5

Para a avaliação de desempenho, o procedimento de validação cruzada foi aplicado a cada abordagem proposta (A, B, C, D e E), efetuando-se 10 execuções para cada abordagem. A Fig. 5 apresenta os resultados obtidos para o conjunto de dados de validação em termos de média  $\pm$  desvio padrão ( $\mu \pm \sigma$ ). Pode ser visto que todas as abordagens propostas usando RNA obtiveram resultados médios acima de 91%, indicando a boa capacidade de generalização do método proposto. Ainda de acordo com a Fig. 5, a abordagem C, usando os cumulantes como características de entrada, mostrou o desempenho mais baixo em comparação com as outras abordagens.




Figura 5. Média e desvio padrão para abordagens baseadas em RNA (A, B, C, D e E), para classes 1 (Cafê), 2 (Vegetação), 3 (Água), 4 (área urbana) e 5 (outros usos).

O uso do FDR (abordagem D) mostrou um melhor resultado para as classes de café e outros usos. Para classes de

vegetação, água e área urbana, as abordagens A, B e E apresentaram resultados similares.

Os resultados mostrados na Fig. 5 estão relacionados à validação da RNA com as amostras selecionadas conforme mostrado na Fig. 2 e detalhado na Tabela I. Para verificar de fato o desempenho das abordagens propostas, a imagem inteira foi submetida à classificação e os resultados foram comparados a uma imagem classificada visualmente por um especialista.

A imagem com a classificação do especialista é mostrada na Fig. 6, onde se podem observar a predominância de café. A Fig. 7 mostra a classificação de cada uma das abordagens propostas comparadas com o alcançado pela imagem X, em que X refere-se a classificação do especialista. Por inspeção visual, pode-se notar que a classificação realizada pelas abordagens propostas foi similar à realizada por especialista.




Figura 6. Imagem classificada visualmente.




Figura 7. Mapa das classificações de abordagens: A, B, C, D e E por RNA, conforme indicativos no canto inferior direito das imagens. A letra X refere-se à imagem classificada por especialista.

A Fig. 8 ilustra um mapa de erros de classificação realizada pelas abordagens propostas. As áreas brancas dos mapas representam os acertos de classificação, enquanto que as áreas escuras representam os erros de classificação. Pode-se observar que a abordagem C atingiu maior quantidade de erros de classificação. Além da análise visual, é importante quantificar os sucessos das diferentes abordagens, dada a complexidade da imagem. Para isso, foi utilizado o método de validação por matriz de confusão e pelo índice Kappa.

As Tabelas IV-VIII mostram as matrizes de confusão geradas após a comparação com a imagem visualmente classificada (Fig. 6) para cada abordagem em conjunto com

seus respectivos índices kappa e acurácia. Pode ser visto que a abordagem C tem o menor desempenho dentre todas as abordagens utilizadas. Entretanto, a classe de vegetação foi a melhor classificada pela abordagem C. A classe de água foi mais bem classificada pelas abordagens A e D. A classe de área urbana foi mais bem classificada com as abordagens A, B e D.




Figura. 8. Abordagens de mapas de erro A, B, C, D e E por RNA.

TABELA IV  
MATRIZ DE CONFUSÃO DE APROXIMAÇÃO A COM RNA (%)

Classe	Café	Vegetação	Água	Área urbana	Outros usos
Café	86,17	10,66	0,01	0,24	8,88
Vegetação	2,55	66,55	6,12	0,05	5,33
Água	0,00	0,02	91,36	0,00	0,19
Área urbana	0,12	0,02	1,16	90,41	1,43
Outros usos	11,16	22,74	1,36	9,30	84,18
Índice Kappa: 72,83%					
Acurácia: 83,73%					

TABELA V  
MATRIZ DE CONFUSÃO DE APROXIMAÇÃO B COM RNA (%)

Classe	Café	Vegetação	Água	Área urbana	Outros usos
Café	86,20	12,04	2,75	0,26	8,41
Vegetação	2,78	68,09	5,54	0,08	5,26
Água	0,00	0,02	87,62	0,01	0,35
Área urbana	0,17	0,06	0,12	93,21	1,83
Outros usos	10,85	19,79	3,97	6,44	84,15
Índice Kappa: 73,13%					
Acurácia: 83,85%					

TABELA VI  
MATRIZ DE CONFUSÃO DE APROXIMAÇÃO C COM RNA (%)

Classe	Café	Vegetação	Água	Área urbana	Outros usos
Café	78,15	13,40	1,17	1,94	8,72
Vegetação	9,51	71,41	0,05	0,10	7,29

Água	0,16	0,10	79,91	1,17	0,67
Área urbana	0,26	0,14	7,54	84,77	2,71
Outros usos	11,92	14,95	11,33	12,02	80,61
Índice Kappa: 66,96%					
Acurácia: 78,97%					

TABELA VII  
MATRIZ DE CONFUSÃO DE APROXIMAÇÃO D COM RNA (%)

Classe	Café	Vegetação	Água	Área urbana	Outros usos
Café	85,45	15,08	1,20	1,12	8,41
Vegetação	1,91	63,19	0,81	0,02	5,26
Água	0,00	0,02	93,72	0,00	0,35
Área urbana	0,11	0,05	0,22	91,26	1,83
Outros usos	12,53	21,66	4,05	7,60	84,15
Índice Kappa: 73,01%					
Acurácia: 83,55%					

TABELA VIII  
MATRIZ DE CONFUSÃO DE APROXIMAÇÃO E COM RNA (%)

Classe	Café	Vegetação	Água	Área urbana	Outros usos
Café	84,49	12,54	2,08	1,63	8,89
Vegetação	2,97	69,35	6,50	0,12	5,53
Água	0,00	0,00	85,62	0,05	0,15
Área urbana	0,09	0,03	0,91	88,31	1,72
Outros usos	12,45	18,08	4,89	9,89	83,71
Índice Kappa: 71,95%					
Acurácia: 82,30%					

Apesar do emprego de diversas técnicas de seleção e do uso de diversas características, a classificação ainda apresentou muita confusão entre algumas classes. Isso é notado entre as classes de vegetação, café e outros usos.

Os erros de classificação ocorridos entre as classes vegetação e outros usos podem ser explicados pelo fato de que a cultura de eucalipto, que está presente na classe outros usos, possui uma grande similaridade espectral com a vegetação e com o café, comprometendo significativamente o resultado final. Entre as classes de café, vegetação e outros usos houve muita confusão. Estas dificuldades em classificar o café e as demais classes também têm sido relatadas em [14].

Em geral, a classe café alcançou uma maior taxa de acerto, principalmente pelas abordagens A e B, mas apresentou uma alta taxa de confusão com a classe outros usos e vegetação. Com relação ao índice kappa as melhores abordagens foram B e D, sendo que a abordagem D é a mais indicada por apresentar menor complexidade devido ao uso de poucas características em comparação com B. As abordagens A e B apresentaram maior acurácia, sendo neste caso a abordagem A a mais indicada por apresentar menor complexidade computacional.

## V. CONCLUSÃO

Para obter um maior desempenho de classificação foi proposto neste trabalho combinar as características mais relevantes na literatura em conjunto com as EOS e utilizar dois métodos de seleção de características como o Discriminante de Fisher e a correlação linear. Desta forma foram testadas cinco abordagens a fim de se obter aquela com maior precisão.

Com os resultados alcançados pela combinação do classificador de RNA e o uso de diferentes abordagens pode-se concluir que o uso dos cumulantes não foi capaz de classificar corretamente a classe de Café, porém, dentre todas as abordagens, foi a melhor em classificar a vegetação. Os cumulantes como parâmetros únicos não são bons discriminantes para as classes abordadas. Todas as abordagens levaram a modelos de concordância substancial de acordo com a classificação dada por [27]. Apesar da abordagem B ter alcançado o maior resultado de classificação, é mais indicado usar a abordagem D, que é menos complexa, por ter menos entradas e cuja arquitetura é descrita na Tabela III.

Este trabalho contribuiu para a área oferecendo um estudo sobre diferentes características extraídas de imagens de satélite para classificações de áreas terrestres. Além de introduzir novas características, como as estatísticas de ordem superior, o trabalho explorou características já usadas para este fim de forma a evidenciar quais são as mais relevantes e automatizou o processo de classificação utilizando métodos de reconhecimento de padrões e técnicas de inteligência computacional.

Para trabalhos futuros, os autores pretendem introduzir a transformada de Fourier das estatísticas de ordem superior, bem como propor métodos de segmentação de imagens baseado em rede SOM (*Self Organizing Maps*) e Curvas Principais.

## AGRADECIMENTOS

Os autores agradecem a FAPEMIG, CAPES, CNPq e o Consórcio Pesquisa Café pela concessão de bolsas de estudos para a realização deste trabalho.

## REFERÊNCIAS

- [1] M. C. Hansen and R. S. Defries. "Long-term global Vegetation change using continuous fields of tree-cover maps from 8-km Advanced Very High Resolution Radiometer (AVHRR) data for the years 1982-99," *Journal of Ecosystems*. vol. 7, no. 7, pp. 695-716, Nov. 2004.
- [2] J. A. Foley, R. S. Defries, G. P. Asner, C. Barford, S. R. Carpenter, F. S. Chapin, M. T. Coe, G. C. Daily, H. K. Gibbs, J. H. Helkowski, T. Holloway, E. A. Howard, C. J. Kucharik, C. Monfreda, J. A. Patz, I. C. Prentice, N. Ramankutty and P. K. Snyder. "Global consequences of land use," *Journal of Science*. vol. 309, no. 5734, pp. 570-574, Jul. 2005.
- [3] R. S. Lunetta., J. F. Knight, J. Ediriwickrema, J. G. Lyon and D. Worthy. "Land-cover change detection using multi-temporal MODIS NDVI data," *Journal Remote Sensing of Environment*. vol. 105, no. 2, pp. 142-154, Nov. 2006.

- [4] D. LU and Q. Weng. "A survey of image classification methods and techniques for improving classification performance," *International Journal Remote Sensing of Environment*. vol. 28, no. 5. pp. 823-870, Mar. 2007.
- [5] S. Gopal., E. C Woodcock and A. H. Strahler. "Fuzzy neural network classification of global land cover from a 1 degree AVHRR data set," *Journal Remote Sensing Environment*. vol. 67, no. 2, pp. 230-243, Feb. 1999.
- [6] S. Bandyopadhyay and S. K. Pal. "Pixel classification using variable string genetic algorithms with chromosome differentiation," *IEEE Trans. Geosci. Remote Sens*. vol. 39, no. 2, pp. 303-308, Feb. 2001.
- [7] F. Al-Obeidat, T. A. Al-Taani, N. A. Belacel and A. N. Banerjee. "A Fuzzy Decision Tree for Processing Satellite Images and Landsat Data," The 2nd International Workshop on Machine Learning and Data Mining for Sensor Networks. *Procedia Computer Science*. vol. 52, pp. 1192-1197, Jun. 2015.
- [8] Z. Liu, A. Liu, C. Wang and Z. Niu. "Evolving neural network using real coded genetic algorithm (GA) for multispectral image classification," LARSIS, Chinese Academy of Sciences, The Institute of Remote Sensing Applications, Beijing 100101, China. *Future Generation Computer Systems*. vol. 20, no. 7, pp. 1119-1129, Oct. 2004.
- [9] C. S. Chagas, E. I. F. Filho, C. A. O. Vieira, C. E. G. R. Schaefer, W. C. Júnior. "Atributos topográficos e dados do Landsat 7 no mapeamento digital de solos com uso de redes neurais," *Pesquisa Agropecuaria Brasileira*. vol. 45, no. 5, pp. 497-507. May. 2010.
- [10] T. G. C. Vieira, W. S. Lacerda and T. G. Botelho. "Mapeamento de áreas cafezeiras utilizando redes neurais artificiais: estudo de caso na região de Três Pontas, Minas Gerais," in *Anais (SBSR), 2009 XIV Simpósio Brasileiro de Sensoriamento Remoto on, Foz do Iguaçu*. pp. 7947-7954, Apr. 2009.
- [11] L. N. Andrade., W. S. Lacerda., M. M. L. Volpato., C. A. Davis Jr. "Aplicação de Redes Neurais Artificiais na Classificação de Áreas Cafezeiras em Machado-MG," *Coffee Science*, vol. 8, n. 1, pp. 78-90, Mar. 2013.
- [12] C. G. Souza. "Uso de Series Temporais para o Mapeamento da Cafeicultura", 2015. 162 p. thesis, Dept. Florestal Engineering, UFPA, Lavras, 2015.
- [13] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed. San Diego, CA: Academic Press, 2008.
- [14] S. Cordero-Sancho and S. Sader. "Spectral analysis and classification accuracy of coffee crops using Landsat and a topographic-environmental model," *International Journal of Remote Sensing*. vol 28, no. 7 pp. 1577-1593, Apr. 2007.
- [15] M. J. Mendel. "Tutorial on higher-order statistics (Spectra) in signal processing and system theory: theoretical results and some applications," *Proceedings of the IEEE*. vol. 79, no. 3. pp. 278-305, Mar. 1991.
- [16] A. C. de Oliveira. Silva., W. S. Lacerda., L. N. Andrade., T. G. C. Vieira. "Discriminação de áreas cafezeiras em imagens multispectrais da região de Três Pontas – MG através de redes neurais artificiais e extratores de textura," in *Anais (SBSR) Simpósio Brasileiro de Sensoriamento Remoto on, Foz do Iguaçu*, pp. 7947-7954, Apr. 2013.
- [17] M. M. Aburas, H. S. Abdullah, M. F. Ramli and H. Z. Ash'aari. "Measuring land cover change in Seremban, Malaysia using NDVI index," *Procedia Environmental Sciences (iENFORCE2015)*, 2015 International Conference on Environmental Forensics on, Malaysia, 2015, pp. 238-243.
- [18] R. A. Houete Soil influences in remotely sensed vegetation canopy spectra. Theory and application of optical remote sensing, G. Asrar Ed. Wiley New York (1989), pp. 107-141.
- [19] B. Fatiha, A. Abdellaoui, H. Latifa and E. Mohamed. "Spatio temporal

analysis of vegetation by vegetation indice from multi-dates satellite images: Application to a semi arid area in ALGERIA," in Energy Procedia, TerraGreen 13 International Conference 2013 - Advancements in Renewable Energy and Clean Environment, 2013, pp. 667-675.

- [20] S. D. J. Guedes, D. D. Ferreira and B. G. H. Barbosa, A. C. Duque and S. A. Cerqueira. "Non-Intrusive Appliance Load Identification Based on Higher-Order Statistics," *IEEE Transactions on America Latina*. vol. 13, no. 10, pp. 3343-3349, Oct. 2015.
- [21] D. D. Ferreira, S. A. Cerqueira, M. V. Ribeiro and C. A. Duque. "HOS-Based Method for Classification of Power Quality Disturbances," *Electronics Letters*. vol. 45, no. 3, pp. 183-185, Jan. 2009.
- [22] D. D. Ferreira, G. A. C. Marques, A. S. Cerqueira, J. M. Seixas, A. C. Duque and V. M. Ribeiro. "Exploiting Higher-Order Statistics Information for Power Quality Monitoring", *Power Quality: Intech Open Access Publisher*, Andreas Eberhard, 2011, pp. 345-362.
- [23] O. R. Duda, E. P. Hart and G. D. Stork. "Pattern Classification," New York, 2001.
- [24] M. T. Hagan and M. B. Menhaj. "Training feedforward networks with the Marquardt algorithm," *IEEE Transactions on Neural Networks*. vol. 5, no. 6, pp. 989-993, Nov. 1994.
- [25] L. Prechelt. "Automatic early stopping using cross validation: Quantifying the criteria. *Neural Networks*. vol. 11, no. 4, pp. 761-767, Nov. 1994.
- [26] G. C. Congalton., K. Green. *Assessing the Accuracy of Remote Sensed Data: Principle and Pratices*. Lewis Publishers, New York , 1999.
- [27] R. J. Landis and G. G. Koch. "The Measurement of Observer Agreement for Categorical Data," *International Biometric Society*. pp. 159-174, Mar. 1977.



**Miler Grudtner Boell** holds a Technologist degree in Systems Technology for Internet from Institute Federal of Minas Gerais (2012). Has experience in the area of computer science with na emphasis in database. He worked as a scholar/researcher in Scientific Development and Innovation level 2 (Inn-2) of Embrapa, working in Coffee research company of Minas Gerais EPAMIG. He is recently acquired M.S. degree in Systems Engineering at the Federal University of Lavras with emphasis in GIS, remote sensing and pattern recognition.



**Helena Maria Ramos Alves** holds a B.S. degree in Agronomy from the School of Agriculture of Lavras (1979), M.S. degree in Agronomy (SoiL and Plant Nutrition) from Federal University of Lavras (1981) and Ph.D. degree in Soil Science And Land Evaluation by the University of Reading, UK (1993) He is currently a researcher at Brazilian agricultural research Company - EMBRAPA and researcher collaborator of the Agricultural research company of Minas Gerais - EPAMIG and the Federal University of Lavras - UFLA. Has experience in the field of Earth Sciences, with emphasis on soil science and currently works in the areas

of GIS, remote sensing, land use, environmental characterization and coffee production.



**Margarete Marin Lordelo Volpato** holds a B.S. degree in Forest Engineering from the Federal University of Lavras (1990), M.S. degree in Forest Science from the Federal University of Vic,osa (1993) and Ph.D. degree in agricultural engineering from University State of Campinas (2002). She is currently a researcher at the Agricultural research company of Minas Gerais - EPAMIG, working mainly in the following areas of knowledge: Geographic information System, Remote sensing and Agrometeorology.



**Danton Diego Ferreira** is B.S. in Electrical Engineering (2005) from the Federal University of São Joao del-Rei, received the M.S. degree in Electrical Engineering (2007) from the Federal University of Juiz de Fora and Doctorate degree in Electrical Engineering (2010) from the Federal University of Rio de Janeiro/COPPE. He concluded his Ph.D. at the Federal University of Juiz de Fora in 2014. He has been with the Federal University of Lavras since 2009 as teacher at the Engineering Department. He works in Electrical Engineering with emphasis on computational intelligence, signal processing and electrical power quality.



**Wilian Soares Lacerda** got title in Electronic Technician by the Federal Center for Technological Education of Minas Gerais - CEFET/MG (1986), he hold a B.S. degree in Electrical Engineering from the Federal University of Minas Gerais (1991), M.S. degree in Electrical Engineering (Automatic area) from the Federal University of Minas Gerais (1994) and Ph.D. in Electrical Engineering (computing engineering area) from the Federal University of Minas Gerais (2006). He is currently an associate professor at the University Federal of Lavras acting in the Computing Science Department where he teaches the following undergraduate and graduate disciplines: Basic Electronic, Digital Systems, Embedded Systems and Microcontrollers, Artificial Neural Networks. He develops research in the area of Computational Intelligence, working mainly on the following subjects: Artificial Neural Networks, Fuzzy Systems and Evolutionary Computation. Develops prototypes of embedded systems for specific applications using: microcontrollers, reconfigurable hardware (FPGA), various types of sensors and actuators.