



MILER GRUDTNER BOELL

**SISTEMA DE CLASSIFICAÇÃO DE
IMAGENS DE SENSORES REMOTOS**

LAVRAS – MG

2016

MILER GRUDTNER BOELL

**SISTEMA DE CLASSIFICAÇÃO DE IMAGENS DE SENSORES
REMOTOS**

Dissertação apresentada à
Universidade Federal de Lavras,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia de Sistemas e
Automação, área de concentração
em Engenharia de Sistemas e
Automação, para obtenção do título
de Mestre.

Orientador

Dr. Danton Diego Ferreira – UFLA

Coorientadora

Dra. Helena Maria Ramos Alves - EMBRAPA

LAVRAS – MG

2016

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Boell, Miler Grudtner.

Sistema de classificação de imagens de sensores remotos /
Miler Grudtner Boell. – Lavras : UFLA, 2016.
91 p. : il.

Dissertação (mestrado acadêmico)–Universidade Federal de
Lavras, 2016.

Orientador(a): Danton Diego Ferreira.
Bibliografia.

1. Sensoriamento Remoto. 2. Reconhecimento de Padrões. 3.
Estatísticas de Ordem Superior. 4. Redes Neurais Artificiais. 5.
Máquinas de Vetor de Suporte. I. Universidade Federal de Lavras.
II. Título.

MILER GRUDTNER BOELL

**SISTEMA DE CLASSIFICAÇÃO DE IMAGENS DE SENSORES
REMOTOS
SYSTEM OF CLASSIFICATION OF SENSORS REMOTE IMAGES**

Dissertação apresentada à
Universidade Federal de Lavras,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia de Sistemas e
Automação, área de concentração
em Engenharia de Sistemas e
Automação, para obtenção do título
de Mestre.

APROVADO em 16 de setembro de 2016.
Dr. Wilian Soares Lacerda UFLA
Dra. Margarete Marin Lordelo Volpato EPAMIG
Dra. Helena Maria Ramos Alves EMBRAPA
Dr. Giovani Bernardes Vitor UTC

Prof. Dr. Danton Diego Ferreira
Orientador

Dra. Helena Maria Ramos Alves
Coorientadora

**LAVRAS – MG
2016**

À Minha Mãe Maria por sua força e dedicação como exemplo de amor, ao meu pai Clarêncio pela paciência e pelas preciosas ajudas e ao meu irmão Victor pelos seus incentivos.

Dedico.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelo dom da vida e por me dar forças para concluir mais esta etapa. À minha família pelo apoio, amparo e carinho durante toda a minha vida e me incentivando a terminar mais este trabalho.

À Universidade Federal de Lavras, especialmente, ao Departamento de Engenharia de Sistemas e Automação, pela oportunidade.

Ao meu orientador Dr. Danton Diego Ferreira, principalmente, pelo apoio, incentivo e pelas correções deste trabalho, auxiliando-me durante a minha pesquisa. E aos professores do PPGESISA da UFLA por todo o conhecimento passado.

Agradeço às pesquisadoras Helena, Margarete e Tatiana pelo apoio financeiro e pelo conhecimento passado na área, durante meu período como bolsista na EPAMIG.

Agradeço à CAPES pela concessão da bolsa de estudos para a realização deste trabalho. E a todos que me ajudaram, direta ou indiretamente, o meu sincero muito obrigado!

RESUMO

A classificação de imagens multiespectrais, derivada de sensores de satélite, é um objetivo desejado pela comunidade científica para identificação de áreas em imagens multiespectrais. O grande interesse é na identificação de várias áreas, incluindo a produção de café. O café se destaca por ser uma importante fonte de renda e de emprego, bem como sendo um dos mais importantes produtos para a economia do Brasil. No entanto, mapear automaticamente essa cultura tem sido um desafio tanto em análise orientada a objeto quanto "pixel a pixel". O objetivo deste trabalho consiste no uso de diferentes métodos de seletores de parâmetros a fim de identificar os melhores parâmetros para a classificação. A imagem de satélite, utilizada neste estudo, refere-se à região de Três Pontas-Minas Gerais (MG), Brasil, que tem uma forte produção agrícola, sobretudo, do café. As imagens escolhidas foram usadas em todas as sete bandas espectrais do Landsat 8-OLI (Operacional Land Imager). Na metodologia proposta foram selecionadas 5 classes de uso: café, mata, água, área urbana, outros usos (pastagem, solo exposto, outras culturas, eucalipto). Várias características espectrais e texturas, para as classificações, foram combinadas. Também foi testado o desempenho de características, com base em estatísticas de ordem superior (EOS), combinadas com aqueles comumente utilizados na literatura para esta finalidade. Sete bandas espectrais do satélite Landsat 8 foram exploradas. Dois métodos de seleção de redução de dimensão: Discriminante Linear de Fisher (DLF) e a correlação linear. Os resultados mostraram que as performances, para ambos os classificadores, RNA e SVM, foram semelhantes. Os melhores índices de kappa obtidos foram 73.13% para RNA, alimentada por todas as características extraídas e 74,37% com o SVM por meio apenas dos pixels das 7 bandas como entrada. Os resultados foram comparados com os métodos atuais da literatura e com dois softwares comerciais.

Palavras-chave: Sensoriamento Remoto. Reconhecimento de Padrões. Estatísticas de Ordem Superior. Redes Neurais Artificiais. Máquinas de Vetor de Suporte.

ABSTRACT

The classification multispectral image derived from satellite sensors is an objective desired by the scientific community for identifying areas in multispectral images. The wide interest is in the identification of many areas, including coffee production. Coffee is highlighted as an important source of income and employment, as well as one of the most important products Brazilian economy. However, automatically mapping this culture has been a challenge both for object-oriented and for "pixel to pixel" analyses. The objective of this work consists in the use of different parameters selecting methods, in order to identify the best parameters for the classification. The satellite image used in this study concerns the region of Três Pontas-Minas Gerais (MG), Brazil, which presents a strong agricultural production, especially of coffee. The chosen images were used in all seven spectral bands of the Landsat 8-OLI (Operational Land Imager). In the proposed methodology, we selected 5 classes of use: coffee, forest, water, urban area, other uses (pasture, exposed soil, other cultures, eucalypt). Many spectral traits and textures were combined for the classification. Trait performance based on higher order statistics (HOS) were also tested in combination with those commonly used in the literature for this end. Seven spectral bands of Landsat 8 satellite were explored. Two selection methods of dimension reduction were used: Fisher Discriminant Ratio (FDR) and linear correlation. The results showed that performances for both classifiers, ANN and SVM, were similar. The best kappa indexes obtained were 73.13% for ANN, fed by all traits extracted, and of 74.37% for SVM, by the pixels of the seven bands as input. The results were compared with the methods currently found in literature and with the commercial software.

Keywords: Remote Sensing. Pattern Recognition. Higher Order Statistics. Artificial Neural Networks. Support Vector Machines.

LISTA DE FIGURAS

Figura 1 – Reflectância x Comprimento de onda.	23
Figura 2 – Faixa de espectro eletromagnético.	24
Figura 3 – Perceptron Multicamadas (2 camadas neurais).	27
Figura 4 – Early Stopping no treinamento da RNA para evitar overfitting. .	30
Figura 5 – Vista gráfica do SVM.	32
Figura 6 – Classificador SVM para um problema de classes $C > 2$	33
Figura 7 – Bandas de 1 a 7 usadas na região de Três Pontas.	40
Figura 8 – Imagem composta da área de estudo.	41
Figura 9 – Diagrama em blocos de concepção do método proposto.	42
Figura 10 – Aquisição de amostras no software ENVI.	43
Figura 11 – Esquema de classificação do SVM.	51
Figura 12 - Diagrama em blocos dos métodos pelos softwares comerciais. .	52
Figura 13 – Imagem segmentada no software eCognition.	53
Figura 14 – Parâmetros selecionados pelo Fisher.	55
Figura 15 – Médias e desvio padrão para as abordagens baseadas em RNA.	58
Figura 16 – Mapa classificado visualmente (por especialista).	60
Figura 17 – Mapa das classificações das abordagens: A, B, C, D e E por RNA.	61
Figura 18 – Mapas de erros das abordagens: A, B, C, D e E por RNA.	62
Figura 19 - Médias e desvio padrão para as abordagens baseadas em SVM.	67
Figura 20 - Mapa das classificações das abordagens: A, B, C, D e E por SVM.	68
Figura 21 - Mapas de erros das abordagens: A, B, C, D e E por SVM.	69
Figura 22 - Mapa classificado com o software eCognition via SVM.	75
Figura 23 - Mapa classificado com o software Idrisi via RNA.	76

LISTA DE TABELAS

Tabela 1 Resultados dos métodos para cafeicultura.....	21
Tabela 2 Comprimentos de onda do sensor OLI/TIRS Landsat 8	26
Tabela 3 Entradas para o treinamento dos classificadores	44
Tabela 4 Arquitetura geral.....	50
Tabela 5 Nível de precisão de classificação a partir do índice Kappa	54
Tabela 6 Desempenho da RNA, em %, para os dados de validação	57
Tabela 7 Matriz de confusão da abordagem A	63
Tabela 8 Matriz de confusão da abordagem B	63
Tabela 9 Matriz de confusão da abordagem C	64
Tabela 10 Matriz de confusão da abordagem D.....	64
Tabela 11 Matriz de confusão da abordagem E	64
Tabela 12 Desempenho do SVM, em %, para os dados de validação	66
Tabela 13 Matriz de confusão da abordagem A.....	70
Tabela 14 Matriz de confusão da abordagem B	70
Tabela 15 Matriz de confusão da abordagem C	71
Tabela 16 Matriz de confusão da abordagem D.....	71
Tabela 17 Matriz de confusão da abordagem E	71
Tabela 18 Índices Kappa obtidos pelo método proposto	72
Tabela 19 Matriz de confusão gerada pelo software eCognition (SVM).....	74
Tabela 20 Matriz de confusão gerada pelo software Idrisi (RNA)	74

LISTA DE SIGLAS

ANN	Artificial Neural Network
DT	Decision Tree
CONAB	Companhia Nacional de Abastecimento
EBP	Error Back-propagation
EGC	Escalar Gradiente Conjugado
EOS	Estatísticas de Ordem Superior
ES	Early Stopping
FDR	Fisher Discriminant Ratio
GP	Genetic Programming
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
KNN	K-Nearest Neighbor
LDA	Linear Discriminant Analysis
LM	Levenberg Marquardt
ML	Maximum-likelihood
MLP	Multilayer Perceptron
MSE	Mean Square Error
NASA	National Aeronautics and Space Administration
NB	Naive Bayes
NDVI	Normalized Difference Vegetation Index
OLI	Operacional Land Imager
RBF	Radial Basis Function
RF	Random Forest
RNA	Redes Neurais Artificiais
RP	Resilient back-propagation
SAVI	Soil Adjusted Vegetation Index
SCG	Scaled Conjugate Gradient
SVM	Support Vector Machine
TIRS	Thermal Infrared Sensor

USGS	United States Geological Survey
UTM	Universal Transverse de Mercator
WGS84	World Geodetic System 84

SUMÁRIO

1	INTRODUÇÃO.....	15
1.1	Objetivos.....	18
1.2	Organização do Trabalho.....	18
2	REVISÃO BIBLIOGRÁFICA	19
2.1	Motivação e Contextualização	19
2.2	Sensoriamento Remoto.....	23
2.3	Redes Neurais Artificiais	26
2.3.1	Algoritmos de Treinamento de RNA.....	28
2.4	Máquinas de Vetor de Suporte.....	31
2.5	Discriminante de Fisher	34
2.6	Correlação de Pearson.....	37
3	MATERIAIS E MÉTODOS.....	39
3.1	Banco de Dados	39
3.2	Método Proposto	42
3.3	Extração de Parâmetros	44
3.3.1	Cumulantes.....	45
3.3.2	Energia.....	46
3.3.3	Média e Desvio padrão	47
3.3.4	Índices de NDVI e SAVI	47
3.3.5	Brilho	48
3.4	Classificador com Redes Neurais Artificiais (RNA)	48
3.5	Classificador com Máquinas de Vetores de Suporte.....	50
3.6	Classificação com softwares comerciais.....	52
4	RESULTADOS	55
4.1	Resultados obtidos com RNA.....	55
4.2	Resultados obtidos com SVM	65
4.3	Resultados obtidos utilizando software comercial	73
5	CONCLUSÃO.....	79
	REFERÊNCIAS	81

1 INTRODUÇÃO

Com o surgimento da tecnologia de sensoriamento remoto, esta tem sido, amplamente, aplicada em diversas áreas como no monitoramento do uso e cobertura da terra, investigação de recursos florestais, monitoramento de desastres e planejamento urbano (MAULIK; CHAKRABORTY, 2010; ZHAO, 2003).

A identificação dos tipos de uso da terra, por meio da classificação de imagem, é uma área na qual a tecnologia de sensoriamento remoto desempenha um papel muito importante. As imagens obtidas do sensoriamento remoto refletem informações detalhadas da superfície da terra, de modo que é um desafio fazer uma classificação exata das imagens de sensoriamento remoto (YANG et al., 2014).

O uso das imagens do sensoriamento remoto, como fonte de informação em aplicações no agronegócio, é muito comum. Estas aplicações são fundamentais para saber como está o espaço de ocupação das culturas. No entanto o reconhecimento de algumas regiões como o tipo de cultura nas imagens do sensoriamento remoto tem sido um desafio. O local ou a idade das culturas, por exemplo, pode dificultar o processo de reconhecimento. Nestes casos, a resposta espectral e os padrões de textura, para o mesmo tipo de cultura, podem ser diferentes (SANTOS et al., 2010). O mapeamento do café é inserido, neste contexto, porque é plantado em relevo montanhoso e, geralmente, perto de áreas florestais (SANTOS et al., 2010).

Souza (2015) afirma que em virtude de problemas relativos à similaridade espectral, a ocorrência de plantações de café traz limitações, para a classificação de remanescentes de florestas, dificultando a diferenciação destas duas formações vegetais.

Portanto há várias tentativas recentes de sistemas de mapeamento de café que dependem de interpretação visual da imagem (TRABAQUINI et al., 2011) ou classificação melhorada pela interpretação visual (MOREIRA et al., 2010). No entanto a interpretação visual da imagem requer mão de

obra e tempo exigente, especialmente, quando se trata de sistemas de produção de café em pequena escala em áreas montanhosas. Por isso é necessário um método automatizado (MUKASHEMA; VELDKAMP; VRIELING, 2014).

Muitos métodos automatizados utilizam imagens de diversos sensores orbitais diferentes, incluindo Terra, Landsat, Spot, Quickbird e Rapideye, entre outros (SOUZA, 2015). As imagens da série Landsat são as mais utilizadas, em razão do seu longo período de imageamento espacial, para pesquisas de uso da terra e atividade agrícola. Este satélite é bastante utilizado por possuir resolução espacial, espectral e temporal adequada à identificação de alvos agrícolas monitorando as mudanças no uso da terra (SOUZA, 2015).

Além disso, as imagens Landsat apresentam boa qualidade espectral, resolução e facilidade de acesso (SARMIENTO et al., 2014).

No sensoriamento remoto, o mapeamento é realizado, por meio da classificação de imagens orbitais, que podem ser feitas pela análise visual ou automática, com o uso dos classificadores pixel a pixel ou baseado em objetos (SARMIENTO et al., 2014). Basicamente, a classificação pode ser supervisionada (em que o usuário seleciona os pixels de amostra e lhes atribui classes), ou não supervisionada. A classificação supervisionada é a mais utilizada no sensoriamento remoto (SARMIENTO et al., 2014).

Existem diversos softwares no mercado, para classificação de imagens de sensoriamento remoto, que utilizam diversos classificadores, mas a maioria não está disponível de forma livre, exigindo, portanto a manutenção da licença para uso. Como exemplo, citam-se os softwares eCognition (TRIMBLE, 2015) e Idrisi (CLARK LABS, 2015).

O eCognition (TRIMBLE, 2015) utiliza diversos algoritmos de segmentação de imagens, baseados em amostra, conceitos de classificação orientada a objetos e os algoritmos de classificação incluem a classificação pixel a pixel por meio de máquinas de vetores de suporte.

O Idrisi (CLARK LABS, 2015) possui um conjunto de módulos,

para o processamento de imagens e de aplicações de sensoriamento remoto como os algoritmos de classificação de imagens por redes neurais artificiais e árvores de decisão.

Embora nenhum classificador seja descrito como, inerentemente, superior a qualquer outro, o seu desempenho depende muito do tipo e qualidade da entrada dos dados para a classificação e da saída desejada (TAPPEINER et al., 2009). Erener (2013) afirma que todos os algoritmos têm seus prós e contras e não há um algoritmo superior a todos os outros. A escolha de um determinado algoritmo de classificação depende da natureza dos dados de entrada e da saída desejada. Porém a combinação de diferentes variáveis de entrada pode ser eficiente para a classificação.

O presente trabalho propõe a investigação das variáveis mais relevantes à classificação e imagens de sensoriamento remoto, com foco em áreas cafeeiras. Para isso, variáveis (parâmetros) comumente utilizados na literatura, para a classificação e imagens de sensoriamento remoto, serão utilizados em conjunto com novos parâmetros baseados em Estatísticas de Ordem Superior (EOS) (MENDEL, 1991).

No início de 1990, especialmente, foi notado um grande aumento no interesse em EOS e em suas aplicações. Como destacado em Mendel (1991), foi verificada a aplicação de cumulantes, em uma variedade de aplicações, tais como sonar e radar, biomédica, processamento de dados sísmicos, reconstrução de imagem, estimativa harmônica, entre outros. Desta forma, pode-se afirmar que EOS permitem uma melhor forma de discriminação de padrões em algumas aplicações (BARBOSA et al., 2016; FERREIRA et al., 2011; GUEDES; DANTON; BARBOSA, 2016; GUEDES et al., 2015; MARQUES; FERREIRA; RIBEIRO, 2008; MOREIRA; FERREIRA; DUQUE, 2014; NAVES; BARBOSA; FERREIRA, 2016; VIANELLO et al., 2009).

Serão combinados dois classificadores não lineares, como as máquinas de vetores de suporte (SVM) e redes neurais artificiais (RNA). Além disso, serão extraídos dos pixels os parâmetros de EOS, Energia,

Média, Desvio Padrão, Mínimo e Máximo, (NDVI – *Normalized Difference Vegetation Index*), (SAVI – *Soil Adjusted Vegetation Index*), Brilho e Máxima diferença as quais serão investigados, a fim de encontrar a melhor metodologia. Estes classificadores foram escolhidos em decorrência de suas boas capacidades de generalização e da obtenção de bons resultados em diversos trabalhos envolvendo reconhecimento de padrões. Os resultados serão confrontados com os obtidos pelos softwares Idrisi e eCognition.

1.1 Objetivos

O presente trabalho tem como objetivo apresentar um sistema de classificação automática de imagens de satélite que seja eficiente, para a identificação e mapeamento do uso e ocupação da terra, com ênfase na cultura do café, por meio de um modelo de Redes Neurais Artificiais e de Máquinas de Vetores de Suporte.

1.2 Organização do Trabalho

Este trabalho está organizado da seguinte forma. A primeira parte do trabalho, Capítulo 1, apresentou uma breve Introdução do assunto abordado e descreveu o objetivo deste trabalho. O Capítulo 2 apresenta o Referencial Teórico, no qual é introduzida a relevância do problema a ser estudado e os conceitos utilizados. O Capítulo 3 apresenta a metodologia proposta. O Capítulo 4 mostra os resultados alcançados de forma qualitativa e quantitativa. O Capítulo 5 mostra a conclusão do trabalho. O Capítulo 6 apresenta as fontes literárias para elaboração do trabalho.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são apresentados os conceitos mais importantes para este estudo. Primeiro foi definida a principal motivação, para a elaboração deste trabalho, em seguida, foi feita uma revisão de literatura das principais teorias que envolvem o estudo sobre as imagens de sensoriamento remoto e diversas técnicas e métodos automatizados na classificação destas imagens.

2.1 Motivação e Contextualização

A detecção de mudanças na cobertura da terra em escalas regionais ou globais usando as imagens dos satélites multiespectral tem sido uma meta desejada da comunidade no sensoriamento remoto ambiental (HANSEN; DEFRIES, 2004; TOWNSHEND; JUSTICE, 1988).

O conhecimento da configuração espacial da superfície da Terra é a chave, para avaliar a distribuição de habitat, composição da paisagem ou na utilização de solos e é um requisito essencial, para modelar a paisagem e construção de cenários, particularmente, em tempos de mudança global (FOODY, 2009; LU; WENG, 2009).

Pode-se afirmar que a classificação de imagens de satélites é um método eficiente, para auxiliar na obtenção de informações detalhadas e precisas de cobertura da terra e estão entre as informações cruciais que são essenciais para investigação em grande escala do meio ambiente. A identificação das mudanças na cobertura da terra, muitas vezes, indica mudança no uso da terra como principal impacto socioeconômico, enquanto a transformação da cobertura da vegetação (e.g. desmatamento, expansão agrícola e urbanização) pode ter impactos sobre a hidrologia, clima e ecossistemas (DEFRIES; BOUNOURA; COLLATZ, 2002; FOLEY et al., 2005).

No caso da cafeicultura, o levantamento das informações oficiais, que são feitas no Brasil, é realizada pela Companhia Nacional de

Abastecimento (CONAB) e pelo Instituto Brasileiro de Geografia e Estatística (IBGE). O levantamento de informações é feita por meio de questionários padrões que são apresentadas aos produtores rurais e em cooperativas (SARMIENTO et al., 2014). Porém esta metodologia não oferece um detalhamento necessário para realizar um planejamento estratégico regional e municipal (MACHADO et al., 2010; RAMIREZ; ZULLO JÚNIOR, 2010). Por isso, o uso de métodos automatizados têm sido promissores para avaliar a dinâmica da cafeicultura (MOREIRA et al., 2010; MOURA et al., 2009; ORTEGA-HUERTA et al., 2012; SARMIENTO et al., 2014; SOUZA et al., 2012; VIEIRA et al., 2007).

Moreira, Adami e Rudorff (2004) demonstraram que os campos de café têm grande variabilidade pelas diferenças de idade, espaçamento entre plantas e cultivares. Além disso, os efeitos topográficos e confusão espectral entre café e outras culturas arbóreas podem levar à exatidão pobre de classificação (CORDERO-SANCHO; SADER, 2007; GOMEZ et al., 2010; ORTEGA-HUERTA et al., 2012).

Na literatura, existem diversas propostas de algoritmos que foram utilizados na classificação supervisionada de imagens de sensoriamento remoto no mapeamento da cafeicultura.

Dentre estes algoritmos, encontram-se: Redes neurais artificiais (ANN – *Artificial Neural Network*) (ANDRADE, 2011; PEREIRA, 2013), algoritmos genéticos (GP – *Genetic Programming*) (SANTOS et al., 2010), árvores de decisão (DT – *Decision Tree*) (SOUZA, 2015), classificador bayesiano (NB – *Naive Bayes*) (SOUZA, 2015), floresta randômica (RF – *Random Forest*) (BISPO; LAMPARELLI; ROCHA, 2014; GIROLAMO NETO et al., 2015; SOUZA, 2015), classificação orientada a objeto com o algoritmo de máquinas de vetores de suporte (SVM – *Support Vector Machine*) (FARIA et al., 2012; SARMIENTO et al., 2014; SOUZA, 2015), classificação orientada a objetos utilizando vizinhos mais próximos (KNN – *K-Nearest Neighbor*) (FARIA et al., 2012; MARUJO et al., 2013; SARMIENTO et al., 2014; SOUZA, 2015), classificação pixel a pixel com o

algoritmo máxima verossimilhança (ML – *Maximum-likelihood*) (MARUJO et al., 2013; SARMIENTO et al., 2014) dentre outros. A Tabela 1 apresenta um resumo dos desempenhos e de algumas características destes trabalhos.

Tabela 1 – Resultados dos métodos para cafeicultura.

Autores	Método	Satélites	Resolução (Pixels)	Índice (Kappa)
Andrade (2011)	RNA	Landsat 5	30m	67,61%
Pereira (2013)	RNA	Landsat 5	30m	67,11%
Santos et al. (2010)	GP	SPOT 5	10m	66,33%
Souza (2015)	SVM	RapidEye	5m	82,25%
Faria et al. (2012)	SVM	SPOT 5	10m	62,00%
Sarmiento et al. (2014)	SVM	RapidEye	5m	67,00%
Bispo, Lamparelli e Rocha (2014)	SVM	MODIS	250m	41,00%
Souza (2015)	DT	RapidEye	5m	79,00%
Souza (2015)	RF	RapidEye	5m	79,50%
Girolamo Neto et al. (2015)	RF	Landsat 8	30m	60,00%
Souza (2015)	KNN	RapidEye	5m	79,50%
Sarmiento et al. (2014)	KNN	RapidEye	5m	67,00%
Marujo et al. (2013)	KNN	RapidEye	5m	80,30%
Marujo et al. (2013)	ML	RapidEye	5m	61,96%
Sarmiento et al. (2014)	ML	RapidEye	5m	78,00%
Faria et al. (2012)	KNN	SPOT 5	10m	59,00%
Souza (2015)	NB	RapidEye	5m	76,50%

Fonte: Do autor (2016).

Andrade (2011) e Pereira (2013) utilizaram o classificador de redes

neurais com o uso de somente 3 das 7 bandas do satélite Landsat TM5, para classificação, que são: 3 (Vermelho visível), 4 (Infravermelho próximo) e 5 (Infravermelho médio). A motivação da escolha das redes neurais se deve ao fato de que, com o uso de poucos parâmetros, foi capaz de discriminar áreas cafeeiras alcançando um resultado satisfatório, de acordo com (CONGALTON; GREEN, 1999). Por esse motivo, pretende-se investigar o desempenho da rede neural com o uso de vários parâmetros de entrada.

Recentemente, particular atenção tem sido dedicada pela comunidade internacional às técnicas de SVM, para fins de reconhecimento de padrões em imagens de alta dimensionalidade em sensoriamento remoto (ANDREOLA; HAERTEL, 2009). Estudos desenvolvidos por alguns autores, como (FOODY; MATHUR, 2008; HUANG; DAVIS; TOWSHEND, 2002; MELGANI; BRUZZONE, 2004), mostram que SVM binários, aplicados em problemas multiclasse, têm, frequentemente, proporcionado uma acurácia na classificação melhor que outras técnicas de reconhecimento de padrões largamente utilizadas (ANDREOLA; HAERTEL, 2009).

Uma etapa importante que deve preceder ao processo de classificação refere-se à redução da dimensionalidade dos dados, que pode ser feita a partir de duas abordagens distintas: seleção e/ou extração de parâmetros (ANDREOLA; HAERTEL, 2009). De acordo com Landgrebe (2003), o emprego de todas as variáveis originais disponíveis pode ser prejudicial à eficiência de classificação.

Por isso, para a redução da dimensionalidade, pretende-se estudar as técnicas de seleção e extração de características como o Discriminante Linear de Fisher e o método da Correlação de Pearson.

Portanto as novidades deste estudo consiste na utilização das 7 bandas espectrais do satélite Landsat 8, pois pode-se afirmar que não foi encontrado na literatura o emprego de todas as bandas para o objetivo aqui proposto. Serão adotados novos parâmetros como as estatísticas de ordem superior e a combinação dos métodos de seleção e extração de características com os classificadores não lineares RNA e SVM.

Além disso, serão comparadas as potencialidades da classificação “pixel a pixel” por RNA e SVM aos mesmos métodos utilizados em softwares comerciais como o Idrisi e eCognition.


2.2 Sensoriamento Remoto

A interpretação e a análise de imagens de sensoriamento remoto envolvem a identificação e/ou medição de vários alvos numa imagem, a fim de extrair informações úteis sobre eles. Segundo Canada (1988, p. 5),

[...] o sensoriamento remoto é a ciência (e, em certa medida, a arte) de adquirir informações sobre a superfície da Terra sem realmente estar em contato com ela. Isso é feito através da detecção e gravação refletida ou emitida da energia, processando, analisando e aplicando essa informação.

Os alvos em imagens de sensoriamento remoto podem ser qualquer recurso ou objeto, que pode ser observado na imagem e são separados por meio de comprimentos de onda. Um exemplo disso pode ser observado na Figura 1, em que dois tipos de alvos específicos são similares em comprimentos de onda visíveis, porém são quase sempre separáveis no infravermelho com comprimento de onda de $0,8\mu\text{m}$ (CANADA, 1988).


Figura 1 – Reflectância x Comprimento de onda.



Fonte: Adaptado de Canada (1988).

A resposta espectral pode ser bastante variável até para o mesmo tipo de alvo e, também, pode variar com o tempo, por exemplo, ao nível de verde das folhas e localização. No sensoriamento remoto, a detecção dos alvos é dada pelos sensores de satélites que são sensíveis aos alvos e que possuem diversas bandas nas regiões visuais e pelas regiões do espectro do infravermelho (CANADA, 1988). A Figura 2 ilustra os comprimentos de onda do espectro eletromagnético das bandas espectrais.

Figura 2 – Faixa de espectro eletromagnético.



Fonte: Adaptado de Abadal, Alda e Agustí (2014).

Em mais de 40 anos, a série de satélites Landsat fornece o mais longo registro temporal de observações da superfície baseado no espaço. O Landsat 1 foi lançado, em 1972 e foi seguido por uma série consecutiva e temporalmente sobrepostas de observatórios Landsat (Landsat 2, 3, 4, 5 e 7) que forneceram cobertura quase global com comprimento de onda reflexivo e térmica de observações com o aumento da fidelidade espectral e espacial (LAUER; MORAIN; SOLOMONSON, 1997; LOVELAND; DWYER, 2012; WILLIAMS; GOWARD; ARVIDSON, 2006).

A função primária do Landsat é obter e transmitir imagens da Terra do espaço, para fins de monitoramento e das condições ambientais no

planeta (GONZALEZ; WOODS, 2008). Em 11 de fevereiro de 2013, houve o lançamento do satélite Landsat 8 pela Base da Força Aérea de Vandenburg, Califórnia. Este novo observatório Landsat foi desenvolvido por intermédio de uma parceria interinstitucional entre a (*National Aeronautics and Space Administration* - NASA) e o Departamento de Interior dos EUA, (*United States Geological Survey* - USGS) (IRONS; LOVELAND, 2013).

O satélite Landsat 8 transporta uma carga útil de dois sensores, o sensor da cobertura da terra (*Operational Land Imager* - OLI) e o sensor infravermelho térmico (*Thermal Infrared Sensor* - TIRS), que são descritos em detalhe em (IRONS; DWYER; BARSİ, 2012). O satélite Landsat 8 melhorou a alta capacidade de transmissão e gravação da superfície em comparação com os sistemas Landsat anteriores. Além disso, o OLI tem dois comprimentos de onda refletora ou 2 bandas suplementares com um novo comprimento de onda mais curto que são: a banda azul (0,43-0,45 μm) destinada a melhorar a sensibilidade à clorofila e outros materiais suspensos, em águas costeiras e para detectar propriedades de aerossóis atmosféricos (partículas suspensas no ar) e uma nova banda infravermelho de ondas curtas (1.36-1.39 μm) para a detecção de nuvens.

O OLI, também, é capaz de produzir imagens digitais de 16 bits de níveis de cinza, em formato geotiff, georreferenciadas com o sistema de coordenada e projeção Universal Transversa de Mercator (*Universal Transverse Mercator* - UTM) e do sistema de projeção Geodésico Mundial (*World Geodetic System 84* - WGS84), herdado de Landsat anteriores (ROY et al., 2014).

O Landsat 8 (L8/OLI) possui 9 bandas espectrais com 8 canais de 30 m de resolução espacial e uma banda pancromática com 15 m de resolução espacial (VANHELLEMONT; RUDDICK, 2015). Neste trabalho, foram considerados somente as 7 primeiras bandas espectrais do satélite Landsat 8 do sensor OLI. Na Tabela 2 é mostrada a sensibilidade de cada banda espectral em detectar um respectivo tipo de alvo.

Tabela 2 – Comprimentos de onda do sensor OLI/TIRS Landsat 8.

Banda	Comprimento de onda	Útil para mapeamento
Banda 1 – Coastal aerosol	0,43 – 0,45	Águas costeiras e estudos de aerossóis (nuvens finas).
Banda 2 – Blue	0,45 – 0,51	Mapeamento batimétrico, solo distintiva da vegetação e decidual de vegetação coníferas.
Banda 3 – Green	0,53 – 0,59	Enfatiza vegetação de pico, que é útil para avaliar o vigor da planta.
Banda 4 – Red	0,64 – 0,67	Discrimina encostas de vegetação.
Banda 5 - Near Infrared (NIR)	0,85 – 0,88	Enfatiza teor de biomassa e linhas costeiras.
Banda 6 - Short-wave Infrared (SWIR) 1	1,57 – 1,65	Discrimina conteúdo de umidade do solo e da vegetação; penetra nuvens finas.
Banda 7 - Short-wave Infrared (SWIR) 2	2,11 – 2,29	Melhora o conteúdo do solo e da vegetação e penetração de nuvem fina.

Fonte: Do autor (2016).

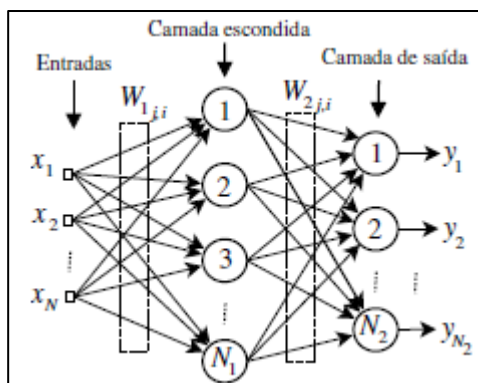
2.3 Redes Neurais Artificiais

As redes neurais artificiais (RNA) (HAYKIN, 2008) apresentam uma grande versatilidade na resolução de diversos tipos de problemas, como em sistemas de reconhecimento de padrões e compressão de voz e imagem, pilotos automáticos de aviões, sistemas de predição de taxa de câmbio, desenvolvimento de produtos, controle de processos e vários outros problemas em diferentes áreas (FERREIRA, 2010). Das diversas arquiteturas (estruturas) de redes, a mais utilizada, em aplicações de reconhecimento de padrões, é a rede alimentada diretamente com múltiplas

camadas. Conforme definido em (2008), esta rede consiste de um conjunto de unidades sensoriais, que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída.

O sinal de entrada se propaga para frente por meio da rede, camada por camada. Tais redes são, normalmente, chamadas de perceptrons de múltiplas camadas (*Multilayer Perceptron* - MLP) (ROSENBLATT, 1962). A Figura 3 ilustra um Perceptron com a camada de entrada que possui N componentes e 2 camadas, representadas por N_1 que representa a camada oculta ou intermediária e N_2 que representa a camada de saída.

Figura 3 – Perceptron Multicamadas (2 camadas neurais).



Fonte: Adaptado de Carvalho (2013).

Um perceptron multicamadas (MLP) é um modelo de rede comumente utilizado em aprendizagem supervisionada. No treinamento da MLP um vetor de características x é apresentado à camada de entrada e a camada de saída representa um discriminante entre uma determinada classe e demais classes (BELLO, 1992).

No treinamento, a RNA extrai informações relevantes dos padrões que lhes forem apresentadas, criando, assim, uma representação própria. Esta etapa é conhecida por aprendizagem ou treinamento e consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos de conexões

entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente que está operando (FERREIRA, 2010).

Assim, seus dados são transmitidos, para a camada seguinte, que define a saída desejada, realizando, assim, uma aprendizagem supervisionada (HAYKIN, 1999).

A função, a seguir, mostra a função *tansig*, tangente hiperbólica usada:

$$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (1)$$

Enquanto os valores de saída não forem os desejados, então, os valores das saídas devem ser corrigidos, para uma nova amostragem. Essa correção pode ser feita por diversas técnicas, porém é utilizada a de aproximação dos mínimos quadrados (*Mean Square Error* - MSE) (HAYKIN, 1999).

A rede é dada como treinada, quando toda a série amostrada apresenta uma saída uniforme de valor, a qual pertence à faixa de tolerância de erro de saída do valor ideal.

2.3.1 Algoritmos de Treinamento de RNA

O algoritmo de retropropagação (EBP – *Error Back-propagation*) apresenta baixa taxa de convergência e, em redes, neurais foi uma das principais preocupações, com esforços sendo feitos para acelerar o algoritmo (RUMELHART; HINTON; WILLIAMS, 1986; WERBOS, 1988).

Muitas melhorias têm sido feitas para o algoritmo EBP (ANDERSEN; WILAMOWSKI, 1995; WILAMOWSKI, 1996; WILAMOWSKI; CHEN; MALINOWSKI, 1999; WILAMOWSKI; TORVIK, 1993), mas estas melhorias são relativamente menores (HAO;

WILAMOWSKI, 2016; WILAMOWSKI, 2002; WILAMOWSKI, 2009; WILAMOWSKI; HUNTER; MALINOWSKI, 2003; YU; WILAMOWSKI, 2009). O algoritmo EBP, ainda, é amplamente utilizado hoje em dia. No entanto é, igualmente conhecido, como um algoritmo ineficiente (HAO; WILAMOWSKI, 2010).

Diversos estudos indicam que o algoritmo de treinamento, (LM – *Levenberg Marquadt*), é o mais eficiente e pode ser visto, em (KISI; UNCUOGLU, 2005), comparando-o com o gradiente conjugado (SCG – *Scaled Conjugate Gradient*). No algoritmo de retropropagação (RP - *Resilient back-propagation*) constatou-se que o LM é considerado mais rápido e com melhor desempenho que os outros algoritmos de treinamento.

Mohamad et al. (2010) apresentou uma comparação entre os algoritmos Levenberg Marquardt (LM) e o Escalar Gradiente Conjugado (EGC) para diagnóstico de câncer de mama. O estudo concluiu que ambos os algoritmos foram comparáveis em termos de precisão e velocidade. O algoritmo LM apresentou melhor vantagem em termos de precisão e velocidade.

Batra (2014) comparou o algoritmo SCG com o LM, para compactação de imagem, o LM mostrou-se melhor em termos de precisão (como encontrado na precisão média de treinamento e no erro médio quadrático).

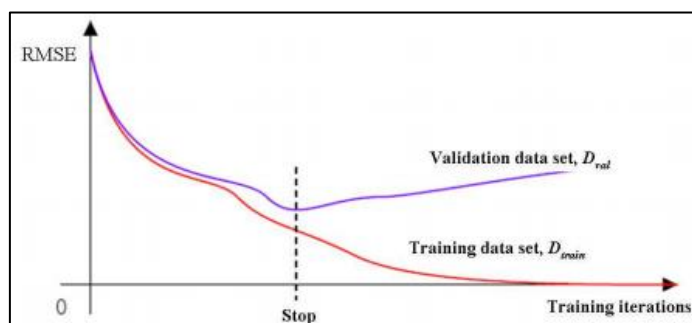
A generalização da rede é dependente do caráter das amostras de treinamento (como o tamanho e a qualidade do conjunto de treino), da estrutura da rede (camadas escondidas e camadas ocultas) e da complexidade do problema. Se há poucas amostras de treino, a aprendizagem não pode capturar informações suficientes, para refletir a essência do problema e a confiabilidade da rede é afetada, muito menos a generalização. Por outro lado, se há muitas amostras, a rede produz facilmente o *over-fitting* (sobreajuste), que pode ser causado por um conjunto muito grande de dados ou com muitas iterações. Na prática, existem dois métodos principais para melhorar a generalização da rede (NIU et al., 2012). O método padrão, para

melhorar a generalização, é chamado de interrupção precoce (ES – *Early Stopping*). Parar a aprendizagem, em um momento adequado, é, também, um método importante para melhorar a capacidade de generalização (MINH; HUSSEIN; ROBERT, 2005; YANG; GREGORY; STEPHEN, 2011). Uma vez que o erro atinge o mínimo (ponto de parada ideal), pode ser encerrado o processo de aprendizagem (NIU et al., 2012).

Nesta técnica, os dados disponíveis são divididos em três subconjuntos. O primeiro subconjunto é o conjunto de treinamento, que é usado para calcular o gradiente e atualizar os pesos da rede e o bias. O segundo subconjunto é o conjunto de validação. O erro no conjunto de validação é monitorado durante o processo de formação (HAYKIN, 2008).

O erro de validação, normalmente, diminui durante a fase inicial de treinamento, assim como o erro de conjunto de treinamento. No entanto, quando ocorre o sobreajuste da rede, o erro de validação definido, tipicamente, começa a subir. Quando há aumentos de erro de validação, para um determinado número de iterações, o treinamento é interrompido (HAYKIN, 2008). A Figura 4 ilustra o gráfico do processo de parada, por interrupção precoce, pelos dados de treinamento e validação.

Figura 4 – Early Stopping no treinamento da RNA para evitar overfitting.



Fonte: Adaptado de Pedroni, Zio e Apostolakis (2010).

O conjunto de teste não é utilizado, durante o treinamento, mas é usado para comparar modelos diferentes. Também é útil, para traçar o erro

do conjunto de teste, durante o processo de formação. Se o erro no conjunto de teste atinge um mínimo a um número de iteração, significativamente, diferente do que o erro do conjunto de validação, isto poderá indicar uma má divisão do conjunto de dados (HAYKIN, 2008). Yang, Gregory e Stephen (2011) utilizaram o ES como critério de parada, para a rede neural, para classificação da cobertura da terra, obtendo excelentes resultados, parando o treinamento da rede, quando a redução da MSE entre as iterações de formação tornou-se mínima.

2.4 Máquinas de Vetor de Suporte

O (SVM – *Support Vector Machine*) é uma técnica de aprendizagem supervisionada que pode ser aplicada à classificação e regressão. Geralmente é utilizado, para o reconhecimento de padrões, em que implementa um mapeamento não linear dos vetores de entrada, para um espaço de alta dimensão, em que uma superfície de decisão linear é construída (HAYKIN, 1999). O SVM é uma técnica, baseada em uma teoria de aprendizagem estatística, apresentado por (VAPNIK, 1998).

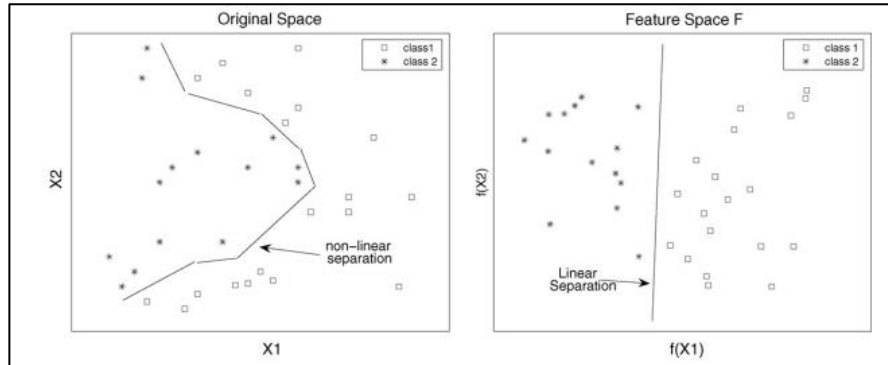
O mapeamento não linear dos vetores de entrada altera o problema original não linear, para se obter uma separação linear sobre o novo espaço, chamado espaço de características F da Figura 5.

No espaço de características, o problema de separação das duas classes é reduzido a encontrar o hiperplano ideal que separa, linearmente, as duas classes, resultando em um problema de otimização quadrática (CERQUEIRA et al., 2008).

Após a otimização, a solução é escrita como uma soma ponderada dos valores de uma função de *kernel* avaliados nos vetores de suporte (VAPNIK, 1998). Por conseguinte, os vetores de suporte são os eventos de ambas as classes mais próximas ao hiperplano ideal. As principais vantagens do SVM são a utilização de *kernel*, a ausência de mínimos locais (problema quadrático), a escassez da solução e a capacidade de generalização obtida

por otimizar à margem (CERQUEIRA et al., 2008).

Figura 5 – Vista gráfica do SVM.



Legenda: Mapeamento não linear dos vetores de entrada. A separação não linear de duas classes, no espaço original, pode ser visto no lado esquerdo e, no lado direito, uma função não linear $f(\bullet)$ é aplicada aos dados e uma separação linear é alcançada no espaço de características.

Fonte: Adaptado de Cerqueira et al. (2008).

Os principais inconvenientes do SVM são a escolha da função de kernel e seus parâmetros e tamanho dos dados, tanto para o treinamento quanto para o teste. O desempenho depende, diretamente, da escolha da função de *kernel* e os seus parâmetros, depende do conjunto de treinamento e da complexidade do problema (CERQUEIRA et al., 2008).

Considerando a amostra de treinamento $\{x_i, y_i\}_{i=1}^N$, em que x_i é a padrão de entrada, para a amostra, em que y_i é o alvo correspondente de saída, o hiperplano de separação linear é definido no espaço de características como:

$$f(\mathbf{x}) = \mathbf{w}\varphi(\mathbf{x}) + b, \quad (2)$$

em que \mathbf{W} é um vetor n-dimensional de peso ajustável, b a polarização e $\varphi(\cdot)$ é a função não linear que mapeia os vetores de entrada para o espaço de características. Considerando-se um problema de duas classes, podem-se definir as saídas $y_i = +1$ para uma classe e $y_i = -1$ para a outra classe, por conseguinte, separando o hiperplano $f(x) > 0$, se x pertence à classe

positiva e $f(x) < 0$, se x pertence à classe negativa, resulta em:

$$y_i(\mathbf{w}\varphi(\mathbf{x}_i) + b) \geq 0, \quad i = 1, \dots, N. \quad (3)$$

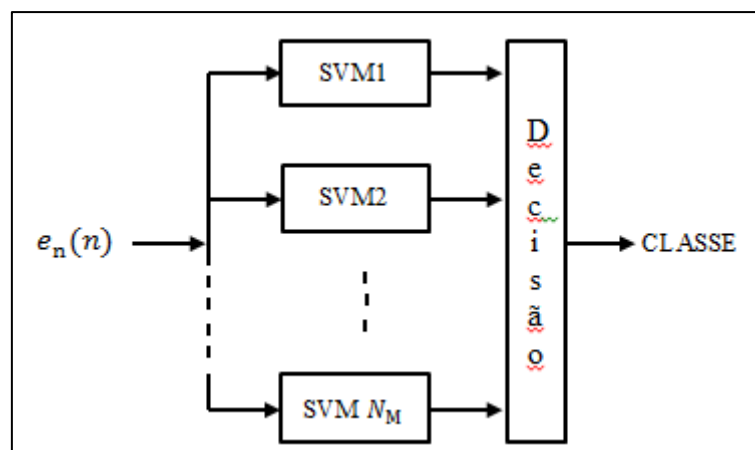
Reescrevendo Equação (3), o problema de otimização pode ser indicado como segue: encontrar os parâmetros \mathbf{w}_0 e b_0 para o hiperplano ótimo, dado o conjunto de treinamento $\{x_i, y_i\}_{i=1}^N$, que satisfaça a restrição:

$$y_i(\mathbf{w}_0\varphi(\mathbf{x}_i) + b_0) \geq 1. \quad (4)$$

Recentemente, o SVM foi encontrado como eficiente método de reconhecimento de padrões para classificação de imagens de satélites (ANDREOLA; HAERTEL, 2009; FOODY; MATHUR, 2008; MITRA; SHANKAR; PAL, 2004; SOUZA, 2015).

Cerqueira et al. (2008) apresentam dois métodos utilizados, para reconhecimento de padrões, obtendo bons resultados de classificação. A primeira abordagem compara classe por classe com inúmeras máquinas e combina a saída com alguma regra de decisão, de acordo com a Figura 6.

Figura 6 – Classificador SVM para um problema de classes $C > 2$.



Fonte: Adaptado de Cerqueira et al. (2008).

O número de máquinas (N_M) necessário à C classes, para problemas de separação, é expresso por:

$$N_M = \frac{C!}{2(C-2)!} \quad (5)$$

Nesta abordagem, cada classe é associada contra outra (SVM binário). A vantagem de tal processo é que as informações, acerca de cada classe de separação, são, geralmente, utilizadas para resolver o problema de eventos simultâneos. Uma regra de decisão simples é usada: a classe vencedora é a em que todas as saídas relativas à classe de interesse forem maiores do que zero.

A segunda abordagem, para resolver o problema de separação de classe múltipla ($C > 2$), usando SVMs, é comparar uma classe contra todos os outros, por conseguinte, o número de máquinas (N_M) necessário é o mesmo número de classes C .

A regra de decisão aplicada às saídas C é o vencedor leva tudo (*winner takes all*). Neste caso, a regra de decisão é simplificada, porque cada saída está relacionada a uma classe. Uma vantagem desta solução é o esperado custo computacional ser inferior em comparação com a primeira abordagem em que são necessárias menos máquinas.

2.5 Discriminante de Fisher

Para a redução da dimensão, o discriminante linear de Fisher (FDR) foi empregado em razão de sua simplicidade e de resultados satisfatórios. A função será descrita na seção 2.4.

O *Linear Discriminant Analysis* (LDA), (FISHER, 1938) é uma das ferramentas mais populares de estatística multivariada, para estudar a relação entre um conjunto de preditores e uma resposta categórica. Ele, também, tem

a característica de proporcionar uma ferramenta de redução de dimensão que pode ser utilizada para efeitos de classificação (SHIN, 2008).

O LDA (DUDA; HART; STORK, 2001; MARTINEZ; KAK, 2001) é um método de aprendizagem supervisionada, amplamente, adotado e usado para, reduzir a alta dimensionalidade por combinar características lineares, que opera por meio da projeção de dados de alta dimensão ao espaço de baixa dimensão. Ele utiliza a informação de categoria associada com cada amostra. O LDA procura uma projeção que melhor separe os dados no sentido dos mínimos quadrados (MESHGINI; ALGHAGOLZADEH; SEYEDARABI, 2012).

O LDA tem como objetivo minimizar a dispersão dos dados dentro da matriz \mathbf{S}_W e maximizar a dispersão entre a matriz \mathbf{S}_B , que são definidos como se segue (MESHGINI; ALGHAGOLZADEH; SEYEDARABI, 2012):

$$\mathbf{S}_W = \sum_{j=1}^c \sum_{i=1}^{N_j} (x_i^j - \mu_j)(x_i^j - \mu_j)^T \quad (15)$$

A matriz \mathbf{S}_W é conhecida por matriz *scatter* intraclases e é proporcional à matriz de covariância dos dados.

$$\mathbf{S}_B = \sum_{j=1}^c (\mu_j - \mu)(\mu_j - \mu)^T \quad (16)$$

A matriz \mathbf{S}_B é, também, simétrica e positiva, é chamada de matriz *scatter* entreclasses. A variável x_i^j é a amostra i^{th} da classe j e μ_j representa a média da classe j . O μ representa a média de todas as classes da imagem e C é o número de classes com N_j que representa o número de amostras da classe j .

Em termos de \mathbf{S}_W e \mathbf{S}_B , a função custo, para o critério LDA como discriminante, é escrita como:

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w \mathbf{w}} \quad (17)$$

O vetor \mathbf{w} que maximiza $J(\cdot)$ será:

$$\mathbf{w} = S_w^{-1}(\mu_1 - \mu_2) \quad (18)$$

Assim, o vetor \mathbf{w} obtido representa a máxima razão entre a matriz *scatter* entreclasses e a intraclasses. Dessa forma, o processo de classificação é convertido de um espaço de N dimensões para um espaço de 1 dimensão. Neste novo espaço, pode-se obter um limiar que fará a separação entre os dados projetados em w das classes 1 e 2.

Diferentemente do critério para classificação, a função custo do critério FDR como ferramenta de seleção de parâmetros é:

$$J_C = (\mu_1 - \mu_2)^2 \odot \frac{1}{\sigma_1^2 - \sigma_2^2} \quad (19)$$

Em que $J_C = [J_1 \cdots J_{L_l}]^T$, L_l é o número total de parâmetros, μ_1 e μ_2 , e σ_1^2 e σ_2^2 são, respectivamente, os vetores de média e variância dos dados da classe 1 e da classe 2. O símbolo \odot (ponto a ponto) refere-se ao produto de Hadamard $\mathbf{r} \odot \mathbf{s} = [r_0 s_0 \dots r_{L_l-1} s_{L_l-1}]^T$. Pode-se entender que os i -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de J_C , representam os parâmetros que apresentam melhor separabilidade entre classes.

A generalização da Equação (19) para o FDR para M classes é dada por:

$$J_C = \sum_i^M \sum_{j \neq i}^M (\mu_i - \mu_j)^2 \odot \frac{1}{\sigma_i^2 + \sigma_j^2}. \quad (20)$$

2.6 Correlação de Pearson

De acordo com Correa (2003), o coeficiente de correlação linear pode ser apresentado como uma medida de correlação, pois tem como objetivo indicar o nível de intensidade que ocorre na correlação entre variáveis. O coeficiente de correlação linear pode ser positivo ou negativo. O sinal positivo do coeficiente indica que o sentido da correlação corresponde a uma reta de inclinação descendente, e o sinal negativo corresponde a uma reta de inclinação ascendente. Uma das formas de medir o coeficiente de correlação linear foi desenvolvida por Pearson e recebe o nome de coeficiente de correlação de Pearson. O coeficiente de correlação de Pearson mede o grau de ajustamento dos valores em torno de uma reta.

Coeficiente de Correlação de Pearson (r) e dada pelo cálculo:

$$r = \frac{n \sum(x_i y_i) - (\sum x_i) \cdot (\sum y_i)}{\sqrt{n \sum x_i^2 - (\sum x_i)^2} \cdot \sqrt{n \sum y_i^2 - (\sum y_i)^2}} \quad (21)$$

Temos que:

r = o coeficiente de Pearson

n = o número de observações

x_i = variável independente

y_i = variável dependente

O valor do coeficiente de correlação r tem a variação entre +1 e -1, ou seja, está limitado entre os valores do intervalo [-1,+1].

- a. $r = +1$ (correlação positiva entre as variáveis);
- b. $r = -1$ (correlação perfeita negativa entre as variáveis);
- c. $r = 0$ (não há correlação entre as variáveis ou, ainda, a correlação não é linear, caso exista).

Em resumo, quanto mais próximo o valor de r estiver do valor 1 mais forte é a correlação linear. Quanto mais próximo o valor de r estiver do valor 0 mais fraca é a correlação linear.

As técnicas de seleção de características com o Fisher e a correlação de Pearson são úteis para selecionar variáveis e, conseqüentemente, reduzir dimensão, o que pode auxiliar no processo de classificação de imagens proporcionando um menor custo computacional.

3 MATERIAIS E MÉTODOS

Neste capítulo, são apresentados os materiais e métodos utilizados para o desenvolvimento do sistema de classificação de imagens. Foi escolhido um banco de dados das imagens de sensoriamento remoto de uma das regiões que possuem maior representação no cultivo do café. Em seguida, são descritas as ferramentas necessárias, utilizadas para este estudo, depois são discutidos os parâmetros mais utilizados, para a classificação destas imagens, além de uma breve explicação da metodologia empregada. E, por último, serão apresentados os classificadores do método proposto juntamente com os classificadores dos softwares comerciais.

3.1 Banco de Dados

No método proposto, foram utilizados dois softwares, o Matlab® na versão 2011, para a análise dos dados e, para a aquisição das amostras, foi utilizado o software ENVI® na versão 4.7. O Hardware utilizado é um computador com processador da tecnologia Intel Core™ i7-4790 (3,6 GHz) de 64 bits, com 4GB de RAM e com um Sistema Operacional Windows 10.


A área de estudo usada, para desenvolver e testar o método proposto, é a região do café de Três Pontas, Minas Gerais, Brasil. Em tal região, o café representa 70% da renda agrícola (ANDRADE, 2011).

O retângulo envolvente está localizado, 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 km². Seu clima é tropical de altitude, com uma temperatura média anual que varia entre 18°C e 19°C, o que evidencia a predominância de temperaturas amenas durante grande parte do ano. A altitude média do município é de 905 metros e a máxima atinge 1.234 metros na Serra de Três Pontas (ANDRADE, 2011).

A imagem multiespectral, utilizada para a classificação, é oriunda do sensor OLI do satélite Landsat 8, com a data de passagem do dia 23/09/2015. A imagem foi composta pelas 7 bandas as quais foram: 1, 2, 3,

4, 5, 6 e 7, com resolução espacial de 30 metros da área de Três Pontas. As imagens correspondentes foram disponibilizadas, gratuitamente, no site do Instituto Nacional de Pesquisas Espaciais. A Figura 7 mostra as imagens das bandas utilizadas.

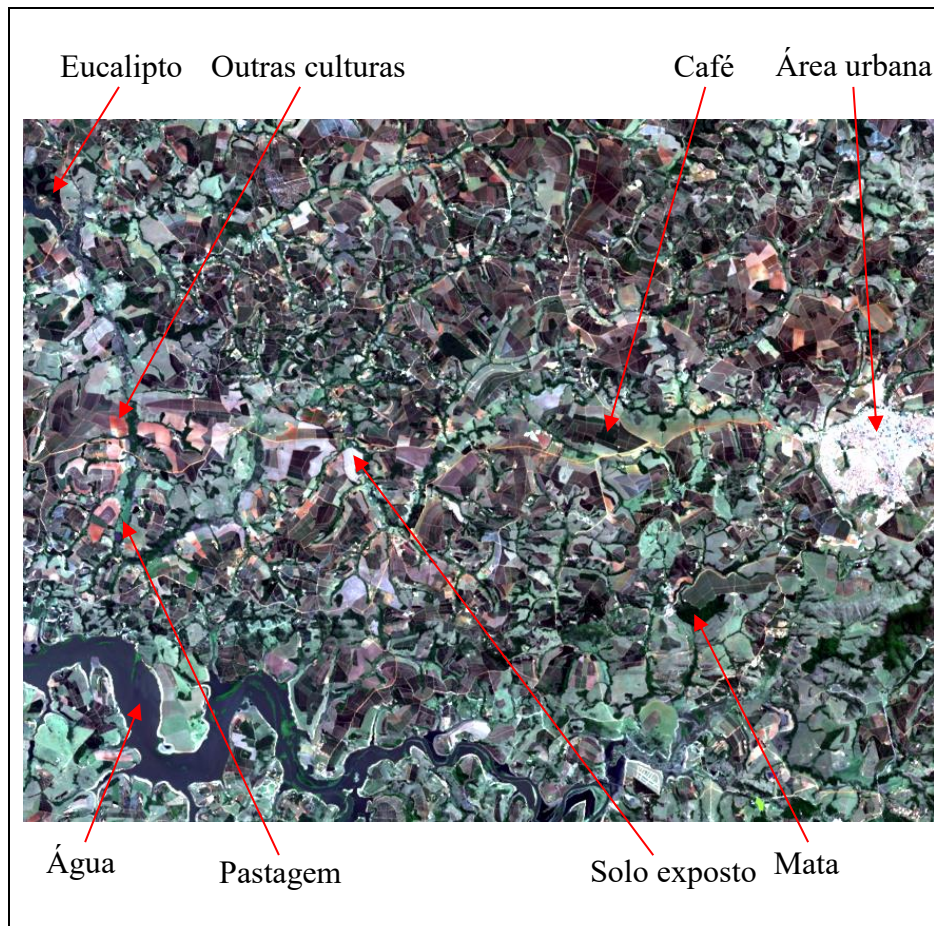
Figura 7 – Bandas de 1 a 7 usadas na região de Três Pontas.



Fonte: Do autor (2016).

Além da classe Café, a Figura 8 evidencia as principais classes predominantes que foram consideradas para este estudo.

Figura 8 – Imagem composta da área de estudo.




Fonte: Do autor (2016).

Foi observado que as classes Água, Outras culturas e Pastagem são completamente distintas entre si e das demais classes, enquanto as classes Café, Eucalipto e Mata evidenciam uma forte similaridade espectral, visto isto, também, nas classes Área urbana e Solo exposto, o que justifica a dificuldade em classificar tais áreas. Em vários trabalhos foram relatadas essas dificuldades (ADAMI; MOREIRA; BARROS, 2009; ANDRADE, 2011; ANDRADE et al., 2013; MACHADO et al., 2001; MARTINEZ-VERDUZCO; GALEANA-PIZAÑA; CRUZ-BELLO, 2012; MOREIRA; ADAMI; RUDORFF, 2004; MOREIRA et al., 2010; SARMIENTO et al., 2014; SOUZA, 2015; VIEIRA et al., 2006).

3.2 Método Proposto

O diagrama de blocos, mostrado na Figura 9, ilustra as fases do desenvolvimento do método proposto.


Figura 9 – Diagrama em blocos de concepção do método proposto.



Fonte: Do autor (2016).

Para projetar o método proposto, foi selecionado um conjunto de pixels para cada classe da imagem capturada. A Figura 10 mostra os pixels selecionados, destacadas as cores em vermelho, verde, azul, amarelo e branco, que representam o café, vegetação, água, área urbana e outros usos, respectivamente. Esses pixels foram selecionados, manualmente, usando o ambiente de software para visualização de imagens (*Environment for Visualizing Images* – ENVI).

Figura 10 – Aquisição de amostras no software ENVI.



Fonte: Do autor (2016).

A Tabela 3 mostra a quantidade de pixels coletada de cada classe para o treino e teste (projeto do método) e para a validação. A escolha de poucas amostras, para as classes Água e Área urbana, foi em razão da baixa variabilidade entre estes dois alvos. Nas demais classes, por apresentarem grande variabilidade espectral, foram coletadas mais amostras de treinamento.

Tabela 3 – Entradas para o treinamento dos classificadores.

Classes	Entradas (teste e treino)	Entradas (validação)
Café	20300	5075
Mata	5672	1418
Água	1916	479
Área urbana	1763	440
Outros usos	26018	6504

Fonte: Do autor (2016).

A partir das amostras coletadas, foi realizada a etapa de extração das características. O objetivo da extração de características é revelar características importantes, para construir assinaturas compactas, para as classes a serem classificadas. As características extraídas incluem as Estatísticas de 2ª, 3ª e 4ª ordens, Energia, Média, Desvio padrão, Mínimo e Máximo, NDVI, SAVI, Brilho e Máxima diferença, as quais foram descritas em detalhes na seção 2.4.

Após a etapa de extração de características (parâmetros), utilizou-se o FDR, descrito na seção 2.5, para a seleção das características mais relevantes e, também, o cálculo da correlação entre as características, descrito na seção 2.6, a fim de identificar redundância entre elas. A seguir, foram utilizados os classificadores de Redes Neurais Artificiais e de Máquinas de Vetores de Suporte, por apresentarem uma boa capacidade de generalização.

3.3 Extração de Parâmetros

Neste trabalho foram utilizados parâmetros para melhorar o desempenho do treinamento e a classificação de imagens. A seguir são descritos todos os parâmetros os quais foram extraídos dos pixels (ANDRADE, 2011), como os Cumulantes (MENDEL, 1991), Energia (SILVA et al., 2013), Média (SOUZA, 2015), Desvio padrão (MARUJO et

al., 2013), os valores mínimos e máximos dos Pixels, NDVI (CORDERO-SANCHO; SADER, 2007), SAVI (SOUZA, 2015), Brilho (MARUJO et al., 2013) e Máxima diferença (SOUZA, 2015). Essas características são brevemente descritas a seguir.

3.3.1 Cumulantes

Os cumulantes são Estatísticas de Ordem Superior (EOS) e foram utilizadas com sucesso em métodos de classificação (FERREIRA et al., 2011; GUEDES et al., 2015; MARQUES; FERREIRA; RIBEIRO, 2008; MOREIRA; FERREIRA; DUQUE, 2014; VIANELLO et al., 2009).

Neste trabalho foram explorados os Cumulantes de segunda, terceira e quarta ordem, que são definidos pelas aproximações apresentadas em (6)-(8) que levam a uma boa simplificação para problemas em que é empregado um vetor de comprimento finito (FERREIRA et al., 2006):

$$\hat{C}_{2,x}[i] := \frac{2}{N} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}[\text{mod}[n+i, N]], \quad (6)$$

$$\hat{C}_{3,x}[i] := \frac{2}{N} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}^2[\text{mod}[n+i, N]], \quad (7)$$

$$\begin{aligned} \hat{C}_{4,x}[i] := & \frac{2}{N} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}^3[\text{mod}[n+i, N]] \\ & - \frac{2}{N^2} \sum_{n=0}^{N-1} \mathbf{x}[n] \mathbf{x}[\text{mod}[n+i, N]] \sum_{n=0}^N \mathbf{x}^2[n], \end{aligned} \quad (8)$$

A partir das Equações (6)-(8), pode-se definir que $\text{mod}[n+i, N]$ é o resto inteiro da divisão de $n+i$ por N .

A variável i refere-se a lags (atrasos), nos vetores de amostras, a variável N representa o sinal de entrada e \mathbf{x} é o vetor de comprimento finito.

A extração dos cumulantes do método proposto é descrita da seguinte forma:

N = total de amostras de cada classe, representado o sinal de entrada e $x[n]$ representa o cálculo de cada pixel ou sinal menos a média do sinal de entrada.

No cálculo dos cumulantes de $\hat{C}_{2,x}[i]$, $\hat{C}_{3,x}[i]$ e $\hat{C}_{4,x}[i]$ ordem, foram utilizadas as amostras de cada classe variando entre 1 a 7 sinais distintos de entrada (amostras de pixels). Todavia a extração dos cumulantes foi baseada, nas dimensões das amostras, que, neste caso, foram 7 dimensões. Assim, a partir das 7 dimensões das amostras foram obtidos 7 sinais (*lags*), para cada cumulante de cada ordem correspondente, totalizando 21 parâmetros.

Pode-se observar que para um sinal com N amostras, tem-se N cumulantes para cada ordem de EOS. Para efeitos de classificação e detecção, a combinação de poucos destes cumulantes é suficiente, para a obtenção de um bom desempenho, conforme mostrado em (RIBEIRO et al., 2007) e (FERREIRA et al., 2011).

3.3.2 Energia

O termo “Energia”, no processamento de sinal, é, também, uma medida da força do sinal. Esta definição pode ser aplicada a qualquer sinal (ou de um vetor), independentemente, se ela possui energia real (uma propriedade básica quantitativa, tal como descrito pela física) ou não. O conteúdo da Energia de um sinal é, muitas vezes, calculado no processamento de sinais em aplicações de comunicação (VISWANATHAN, 2013). Para qualquer sinal a Energia é calculada pela equação:

$$Energia = \sum_{n=0}^{N-1} x^2[n] \quad (9)$$

Em que $0 < n < N - 1$ significa o intervalo finito, ou seja, o comprimento do vetor de amostras e x representa a média quadrática do sinal. Neste

trabalho, foi utilizada a Equação (9), para a extração da característica de Energia dos pixels, em cada classe.

3.3.3 Média e Desvio padrão

Os valores de Média e Desvio padrão foram obtidos pelas Equações (10)-(11) em que $n = 1, \dots, N$, referem-se ao tamanho das amostras de entrada. A variável x_i representa cada valor do conjunto de dados (amostras) e, no cálculo do desvio padrão, a variável \bar{x} é a média aritmética dos dados. As Equações (10)-(11) são definidas, respectivamente, como:

$$Média = \frac{1}{N} \sum_{i=1}^N x_i \quad (10)$$

$$Desvio\ padrão = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (11)$$

3.3.4 Índices de NDVI e SAVI

O índice de NDVI é um dos indicadores mais importantes para detectar a cobertura vegetal por diferentes períodos e em áreas específicas por meio do sensoriamento remoto. O NDVI é calculado combinando as bandas do vermelho visível (RED) e infravermelho próximo (NIR) de um sistema sensor (ABURAS et al., 2015).

O índice SAVI é semelhante ao NDVI, foi sugerido por Houete (1989), que introduziu um parâmetro de ajustamento, denotado por L , que caracteriza o solo e sua taxa de cobertura pela vegetação. O parâmetro L assume o valor 0,25, para uma densidade forte e 1, para uma densidade muito baixa da vegetação. Para densidades intermediárias, é igual a 0,5 (FATIHA et al., 2013). Na metodologia proposta foi utilizado o valor $L =$

0,5. Os índices de NDVI e SAVI foram expressos pelas equações (12) e (13), respectivamente.

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (12)$$

$$SAVI = \frac{(NIR-RED)}{(NIR+RED+L)} \cdot (1 + L) \quad (13)$$

3.3.5 Brilho

Para a extração do brilho, foi utilizada a função do Matlab *brighten* que permite um aumento ou diminuição da intensidade do brilho dos pixels. Os pixels são mais brilhantes, quando $0 < \beta < 1$ e, mais escuros, se $-1 < \beta < 0$, com os pixels mais claros ou mais escuros das mesmas cores. A equação é descrita como:

$$Brilho = \begin{cases} 1 - \beta, & \beta > 0 \\ \frac{1}{1+\beta}, & \beta \leq 0 \end{cases} \quad (14)$$

Na metodologia proposta foi utilizado um valor de $\beta = 0.5$ como padrão.

3.4 Classificador com Redes Neurais Artificiais (RNA)

A rede neural foi implementada no Matlab do tipo perceptron multicamadas com duas camadas intermediárias e 5 neurônios na camada de saída, em que cada neurônio de saída representa uma classe. Os dados foram divididos conforme mostrado na Tabela 3. O algoritmo utilizado para o treinamento foi o *Levenberg-Marquardt* (HAGAN; MENHAJ, 1994). Para a função de performance da rede neural foi utilizado o (MSE – *Mean Squares Error*). Como critério de parada de treinamento foi utilizado o método de interrupção precoce (*ES-early stopping*) (PRECHELT, 1998). A Equação (21) descreve o alvo utilizado para o treinamento da rede neural. A função de

ativação utilizada foi a tangente hiperbólica.

$$saída = \begin{bmatrix} +\mathbf{1} & -1 & -1 & -1 & -1 & -1 \\ -1 & +\mathbf{1} & -1 & -1 & -1 & -1 \\ -1 & -1 & +\mathbf{1} & -1 & -1 & -1 \\ -1 & -1 & -1 & +\mathbf{1} & -1 & -1 \\ -1 & -1 & -1 & -1 & +\mathbf{1} & -1 \end{bmatrix} \quad (21)$$

A fim de comparar diferentes abordagens, considerando o uso e o não uso de extração e seleção de características, cinco abordagens foram implementadas:

a) Os pixels das 7 bandas foram utilizados como entradas do classificador, totalizando 7 entradas.

b) Usando os parâmetros de pixels, EOS, Energia, Média, Desvio padrão, Mínimo e Máximo, NDVI, SAVI, Brilho e Máxima diferença totalizando 43 entradas.

c) Os cumulantes de 2^a, 3^a e 4^a ordens e seus respectivos *lags* (de 1 a 7) foram utilizados como entradas, totalizando 21 entradas.

d) Usando o discriminante linear de Fisher para selecionar 21 entradas.

e) Usando a correlação linear entre as variáveis de forma a selecionar 11 entradas.

Nas camadas intermediárias, foram testadas diferentes arquiteturas a fim de se obter uma arquitetura com o melhor desempenho. A variação de neurônios, na camada intermediária, ocorreu de acordo com a Tabela 4 que ilustra a arquitetura geral definida pelo método proposto.

Tabela 4 – Arquitetura geral.

Abordagens	RNA
A (Pixels das 7 bandas)	7x8x5x5
B (Todos os parâmetros)	43x45x5x5
C (Estatística de Ordem Superior)	21x23x5x5
D (Discriminante de Fisher)	21x22x5x5
E (Correlação de Pearson)	11x11x5x5

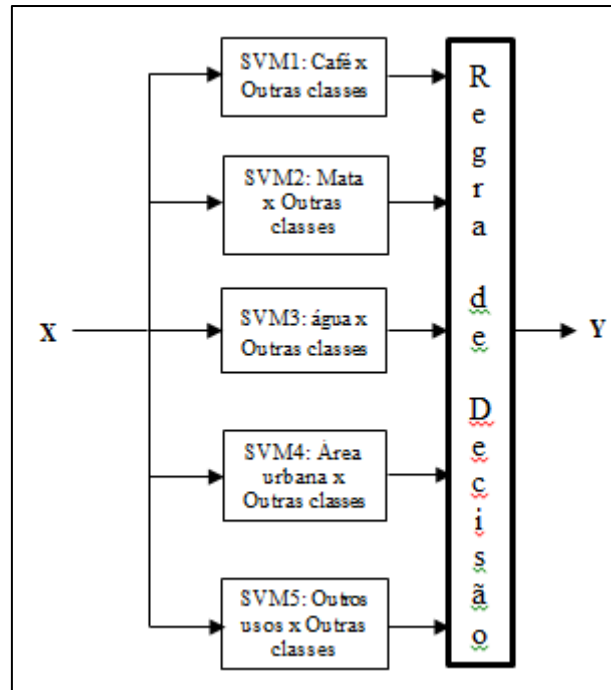
Fonte: Do autor (2016).

3.5 Classificador com Máquinas de Vetores de Suporte

A implementação do SVM como classificador foi realizada, de acordo com Cerqueira et al. (2008), para classificar mais de 2 classes, em que 5 máquinas de vetores de suportes foram implementadas, fazendo uma classe contra todas as outras. Os parâmetros de entradas das 5 máquinas foram semelhantes às abordagens A, B, C, D e E que foram utilizadas pelo classificador de RNA. Diferentes funções de *Kernel* foram testadas, porém o melhor desempenho foi por meio do *Kernel* Função de Base Radial Gaussiana (RBF – *Radial Basis Function*).

O diagrama da Figura 11 ilustra o esquema de classificação final, baseado em SVM, em que \mathbf{X} é o vetor de parâmetros de entrada.

Figura 11 – Esquema de classificação do SVM.



Legenda: Abordagem uma classe contra todas as outras.
 Fonte: Do autor (2016).

A regra de decisão correspondente de cada máquina é representada pela Equação (22), em que a saída positiva indica classe de interesse e a negativa indica demais classes.

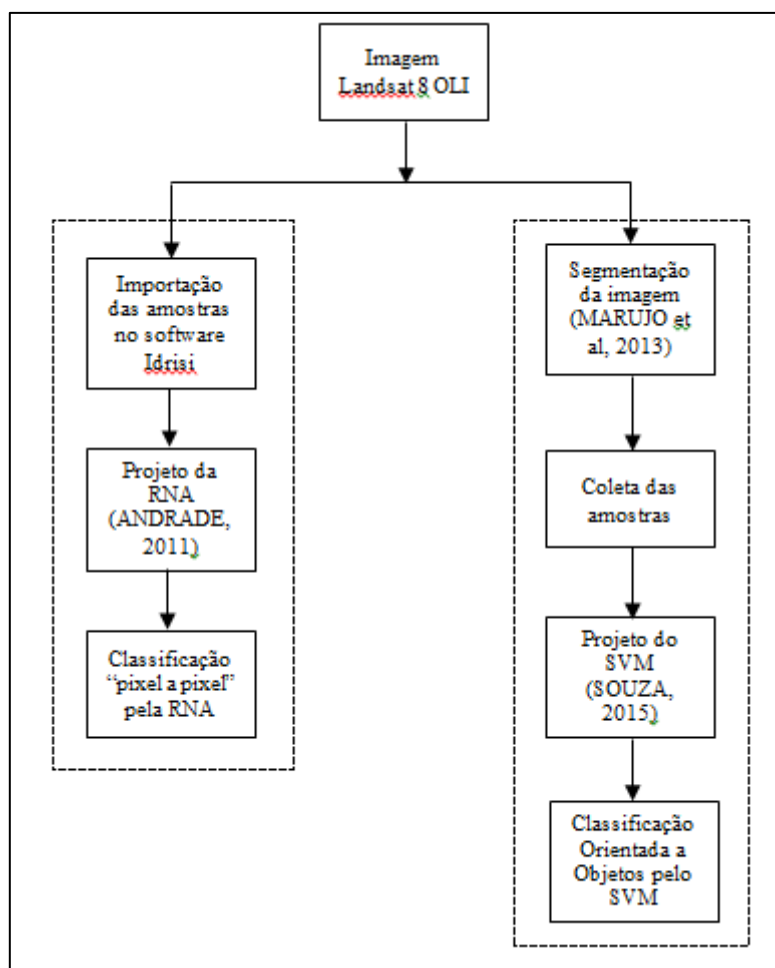
$$saída = \begin{bmatrix} +1 \\ -1 \end{bmatrix} \quad (22)$$

A regra de decisão binária aponta o evento como pertencente à classe que apresentar a saída com maior valor em comparação às outras classes. Caso mais de uma máquina apresente um valor de saída positiva, outras submáquinas de Vetores de Suporte são ativadas, para o critério de desempate, de modo que o esquema de classificação se torne semelhante à regra da primeira abordagem (CERQUEIRA et al., 2008).

3.6 Classificação com softwares comerciais

Na metodologia dos softwares comerciais, foram utilizados os software eCognition (SVM) e Idrisi (RNA), para ambos foi utilizada a abordagem A. O fluxograma da Figura 12 ilustra os passos necessários, para a classificação de cada um dos softwares, pois possuem características de funcionamento diferentes.

Figura 12 – Diagrama em blocos dos métodos pelos softwares comerciais.




Legenda: Idrisi à esquerda e eCognition à direita.

Fonte: Do autor (2016).

No Idrisi foram utilizadas as mesmas amostras de treinamento, o método proposto e a arquitetura definida do classificador de RNA foi semelhante ao apresentado por (ANDRADE, 2011). Foram consideradas entre 1 e 2, camadas intermediárias, entre 14 e 22 neurônios, na 1ª camada e, na 2ª camada, entre 12 a 18 neurônios; a taxa de aprendizagem com valor 0,01 e um fator de momentum de 0,5 e o número de iterações de 10000.

No eCognition foi realizada a segmentação da imagem com o algoritmo *multiresolution segmentation* conforme os parâmetros apresentados por (MARUJO et al., 2013). A Figura 13 ilustra a imagem segmentada após o uso do algoritmo:

Figura 13 – Imagem segmentada no software eCognition.



Fonte: Do autor (2016).

O projeto de classificador do SVM foi elaborado, de acordo com Souza (2015), que utilizou 1 como valor da margem de decisão dos vetores de suporte e o *Kernel* Função de Base Radial Gaussiana (RBF) que foi

utilizado no treinamento e na classificação.

Para avaliação de desempenho, foi utilizado o Índice Kappa, que é expresso por (CONGALTON; GREEN, 1999):

$$Kappa = \frac{n \cdot \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (23)$$

em que k é o número de linhas na matriz de confusão, n é o número total de observações (amostras), n_{ii} é o número de observações na linha e coluna i , n_{i+} é o total de linha i e n_{+i} é o total de coluna i .

O nível de precisão do índice Kappa foi classificado, de acordo com a Tabela 4, que foi estabelecida por (LANDIS; KOCH, 1977).

Tabela 5 – Nível de precisão de classificação a partir do índice Kappa.

Índice Kappa (K)	Qualidade
$K > 0.80$	Forte concordância
$0.60 < K < 0.80$	Concordância substancial
$0.40 < K < 0.59$	Concordância moderada
$0.20 < K < 0.39$	Leve concordância
$0.00 < K < 0.19$	Fraca concordância
$K < 0.00$	Sem concordância

Fonte: Do autor (2016).

4 RESULTADOS

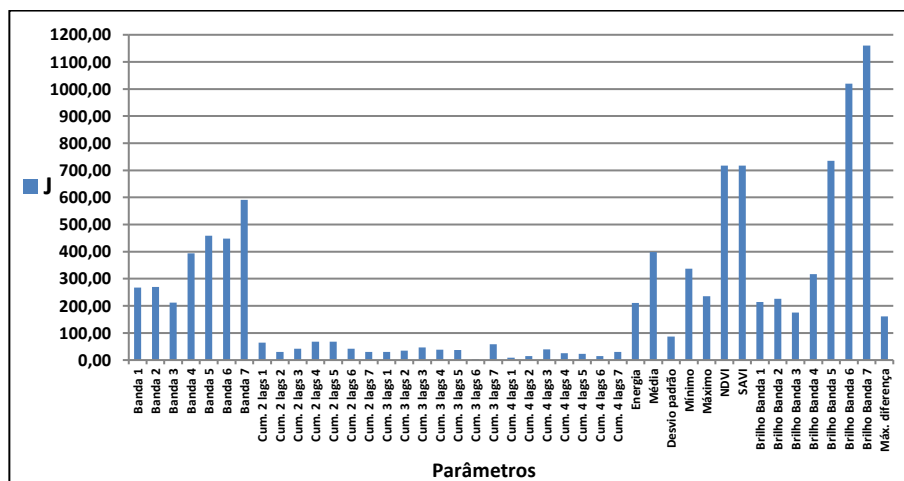
Este capítulo apresenta os principais resultados obtidos, em que são mostrados os parâmetros mais relevantes selecionados pelas técnicas de seleção de características e, por último, é mostrado o desempenho dos classificadores pela metodologia proposta.

4.1 Resultados obtidos com RNA

Para cada abordagem, foi definida uma arquitetura de RNA específica, contendo o número de entradas e de camadas intermediárias descritas na seção 3.4.

A Figura 14 ilustra os resultados obtidos pelo critério FDR. Pode ser claramente observado que a característica de brilho das faixas 6 e 7 são mais relevantes. Por outro lado, os cumulantes mostraram-se menos discriminativos.

Figura 14 – Parâmetros selecionados pelo Fisher.



Fonte: Do autor (2016).

Para a abordagem D, foram selecionados os parâmetros com valores superiores a 100, (valores indicados pelo vetor J como mais relevantes),

definidos pelo critério do FDR, com isso, foram descartados os cumulantes e o desvio padrão.

Embora a análise de Fisher consiga realizar a seleção de características que mais discriminam as classes, esta verificação não é capaz de detectar dados redundantes. Para isso, foi utilizado um outro método de seleção que é denominado por correlação de Pearson. Na correlação foram consideradas todas as variáveis com redundância inferior a 90%. Para cada par de variáveis com correlação linear maior ou igual a 0,9 entre si, uma das variáveis era eliminada. A correlação linear foi calculada conforme descrito na Seção 2.6. Como resultado, os parâmetros que apresentaram baixa redundância e que foram submetidos à abordagem E são:

- a. Cumulantes de 2^a ordem *lag* 6.
- b. Cumulantes de 3^a ordem *lag* 6.
- c. Cumulantes de 4^a ordem *lags* 1, 2, 3 e 6.
- d. Máximo valor dos pixels.
- e. SAVI.
- f. Brilho da banda 5 e 7.
- g. Máxima diferença.

Os resultados apresentados pelas abordagens A, B, C, D e E referem-se ao banco de dados de validação. Foram realizadas 10 execuções, para cada abordagem e os resultados de validação, obtidos com as amostras de validação, conforme divisão mostrada na Tabela 3. Foram listadas, na forma de Tabela 6, sendo μ a média e σ desvio padrão.

Tabela 6 – Desempenho da RNA, em %, para os dados de validação.

Abordagem	Média das 10 execuções	Café	Mata	Água	Área urbana	Outros usos
A	μ	96,96	97,39	100,00	98,12	94,13
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,28	0,52	0,00	0,52	0,57
B	μ	97,49	97,48	99,96	98,19	95,77
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,50	0,44	0,10	0,76	0,26
C	μ	91,29	94,33	99,05	96,71	93,34
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,74	0,56	0,67	1,12	0,68
D	μ	98,30	96,41	99,96	97,67	96,98
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,15	0,56	0,07	0,74	0,21
E	μ	96,07	97,60	99,97	98,28	93,89
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,41	0,58	0,07	0,80	0,41


Fonte: Do autor (2016).

Pode-se observar que todas as abordagens propostas com o uso de RNA obtiveram desempenhos médios acima de 91%, evidenciando a boa capacidade do método para a aplicação proposta.

A abordagem que utiliza os cumulantes como parâmetros de entrada apresentou o menor desempenho. Para facilitar as comparações, a média das 10 execuções, para cada abordagem seguida do erro padrão, foram mostradas, na forma de barra de erros (95% de confiança), na Figura 15.

A partir da Figura 15, fica claro que os cumulantes (abordagem C) apresentaram o menor resultado. O uso do FDR (abordagem D) apresentou o melhor resultado para as classes Café e Outros usos. Para as classes Mata, Água e Área urbana, as abordagens A, B e E apresentaram resultados equivalentes, ou seja, com diferenças entre as médias não significantes.

Figura 15 – Médias e desvio padrão para as abordagens baseadas em RNA.




Legenda: Abordagens A (Pixels das 7 bandas), B (Todos os parâmetros), C (Cumulantes), D (Discriminante de Fisher) e E (Correlação de Pearson), para as classes 1 (Café), 2 (Mata), 3 (Água), 4 (Área urbana) e 5 (Outros usos).
Fonte: Do autor (2016).

Para validar a precisão dos resultados qualitativos, foi necessário realizar a classificação automática da imagem de Três Pontas e compará-la a uma imagem classificada visualmente (Figura 16). A Figura 17 mostra uma comparação da classificação visual com as abordagens propostas. A Figura 18 ilustra os mapas de erros das classificações, de acordo com as abordagens propostas, com o classificador de RNA. Pode-se observar que as áreas brancas dos mapas representam a concordância das classificações, enquanto, na área escura, representam os erros de discordância entre as classes. As abordagens propostas, em geral, apresentam grande semelhança com a classificação visual, apresentando poucos erros.

No entanto, além da análise visual, é importante quantificar os acertos das diferentes abordagens, dada a complexidade da imagem. Um


método de validação bastante utilizado para este fim é o uso do índice Kappa. Para a geração do índice Kappa, é realizado um cruzamento do mapa classificado visualmente com uma imagem classificada automaticamente. No final, uma matriz de confusão é gerada, a partir da qual o índice é obtido, indicando o nível de precisão do método.

Figura 16 – Mapa classificado visualmente (por especialista).




Fonte: Do autor (2016).

Figura 17 – Mapa das classificações das abordagens: A, B, C, D e E por RNA.



Fonte: Do autor (2016).

Figura 18 – Mapas de erros das abordagens: A, B, C, D e E por RNA.



Fonte: Do autor (2016).

As Tabelas 7 a 11 apresentam as matrizes de confusão geradas, após a comparação com a imagem classificada visualmente (Figura 14) com a classificação por RNA de cada abordagem.

Tabela 7 – Matriz de confusão da abordagem A.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	86,17%	10,66%	0,01%	0,24%	8,88%
Mata	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%
Total	Média: 83,73%			Desvio padrão: 10,05	

Fonte: Do autor (2016).

Tabela 8 – Matriz de confusão da abordagem B.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	86,20%	12,04%	2,75%	0,26%	8,41%
Mata	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%
Total	Média: 83,85%			Desvio padrão: 9,43	

Fonte: Do autor (2016).

Tabela 9 – Matriz de confusão da abordagem C.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	78,15%	13,40%	1,17%	1,94%	8,72%
Mata	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%
Total	Média: 78,97%			Desvio padrão: 4,87	

Fonte: Do autor (2016).

Tabela 10 – Matriz de confusão da abordagem D.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	85,45%	15,08%	1,20%	1,12%	8,93%
Mata	1,91%	63,19%	0,81%	0,02%	3,19%
Água	0,00%	0,02%	93,72%	0,00%	0,31%
Área urbana	0,11%	0,05%	0,22%	91,26%	1,49%
Outros usos	12,53%	21,66%	4,05%	7,60%	86,08%
Total	Média: 83,94%			Desvio padrão: 12,11	

Fonte: Do autor (2016).

Tabela 11 – Matriz de confusão da abordagem E.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	84,49%	12,54%	2,08%	1,63%	8,89%
Mata	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%
Total	Média: 82,30%			Desvio padrão: 7,44	

Fonte: Do autor (2016).

No geral, pode-se observar que a abordagem C obteve um baixo

desempenho, dentre todas as abordagens utilizadas. Porém a classe Mata foi mais bem classificada pela abordagem C, apesar de apresentar uma alta confusão espectral entre as classes Café e Outros usos. A classe Água obteve excelente desempenho com as abordagens A e D. A classe Área urbana foi mais bem classificada com as abordagens A, B e D. Estas dificuldades, também, foram relatadas nos trabalhos de Souza (2015), pois, apesar de empregar diversas variáveis espectrais, texturais, geométricas e com o uso de diferentes classificadores, as classes Mata e Café, ainda, foram confundidas no processo de classificação.

A classe Café obteve um bom desempenho de classificação, principalmente, pelas abordagens A e B, porém apresentou uma alta confusão com a classe Outros usos. Da mesma forma, a classe Outros usos apresentou grande confusão com a classe Café visto que o melhor resultado de classificação para Outros usos foi com a abordagem D.

4.2 Resultados obtidos com SVM

Para a validação dos resultados pelo método do SVM, o classificador foi submetido às mesmas abordagens, descritas na seção 3.2. A Tabela 12 descreve os resultados dessas abordagens, seguidos pelas imagens classificadas e pelo índice Kappa.

Tabela 12 – Desempenho do SVM, em %, para os dados de validação.


Abordagem	Média das 10 execuções	Café	Mata	Água	Área urbana	Outros usos
A	μ	95,55	95,05	100,00	95,90	93,91
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,08	0,71	0,00	0,92	0,13
B	μ	96,75	96,38	99,86	95,52	95,77
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,12	0,43	0,15	0,81	0,14
C	μ	89,65	85,10	96,55	85,48	92,30
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,74	1,18	0,49	1,35	0,57
D	μ	96,45	95,00	99,95	96,78	95,40
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,13	0,65	0,08	0,76	0,16
E	μ	95,70	95,93	99,95	91,72	94,22
	\pm	\pm	\pm	\pm	\pm	\pm
	σ	0,25	0,58	0,09	0,63	0,15

Fonte: Do autor (2016).

Pode-se observar que todas as abordagens propostas com o uso de SVM obtiveram desempenhos médios acima de 85%, evidenciando uma boa capacidade do método para a aplicação proposta.

Para o entendimento do resultado de validação pelo método do SVM, a média das 10 execuções é expressa pela Figura 18, acompanhada pelo erro padrão (95% de confiança). Os cumulantes (abordagem C) obtiveram o pior desempenho em todas as classes. O uso de todos os parâmetros (Abordagem B) foi indicado como melhor para as classes Café, Mata, Água e Outros usos. O FDR (abordagem D) foi melhor para discriminar as classes Café, Água, Área urbana e Outros usos. Da mesma forma, a correlação (abordagem E) é melhor em discriminar as classes Mata e Água. Já a classe Água é equivalentemente classificada pelas abordagens A, B, D e E.


Figura 19 – Médias e desvio padrão para as abordagens baseadas em SVM.



Legenda: Abordagens A (Pixels das 7 bandas), B (Todos os parâmetros), C (Cumulantes), D (Discriminante de Fisher) e E (Correlação de Pearson), para as classes 1 (Café), 2 (Mata), 3 (Água), 4 (Área urbana) e 5 (Outros usos).
 Fonte: Do autor (2016).


A Figura 20 mostra uma comparação da classificação completa das diferentes abordagens em comparação à classificação visual. Na Figura 21, são mostradas, exatamente, as principais áreas em que, de fato, ocorreram essas discordâncias. De forma semelhante ao classificador de RNA, a classificação obtida pelas abordagens propostas, em geral, apresentaram poucos erros em relação ao mapa classificado visualmente, apresentando grande semelhança com a classificação visual e evidenciando o potencial da metodologia proposta.

Figura 20 – Mapa das classificações das abordagens: A, B, C, D e E por SVM.



Fonte: Do autor (2016).

Figura 21 – Mapas de erros das abordagens: A, B, C, D e E por SVM.



Fonte: Do autor (2016).

A seguir são apresentadas pelas Tabelas 13 a 17 as matrizes de confusão geradas após a comparação da imagem classificada visualmente (Figura 16) com a classificação via SVM de cada abordagem.

Tabela 13 – Matriz de confusão da abordagem A.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	86,10%	12,16%	2,09%	1,41%	8,35%
Mata	2,95%	69,28%	0,19%	0,02%	4,41%
Água	0,00%	0,00%	91,69%	0,00%	0,20%
Área urbana	0,13%	0,02%	0,02%	91,66%	1,55%
Outros usos	10,80%	18,51%	5,99%	6,88%	85,47%
Total	Média: 84,84%			Desvio padrão: 9,18	

Fonte: Do autor (2016).

Tabela 14 – Matriz de confusão da abordagem B.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	86,41%	14,40%	19,61%	4,85%	11,46%
Mata	2,47%	66,64%	0,04%	0,02%	3,83%
Água	0,00%	0,00%	79,16%	0,00%	0,06%
Área urbana	0,05%	0,01%	0,02%	88,00%	1,42%
Outros usos	11,05%	18,93%	1,14%	7,11%	83,20%
Total	Média: 80,68%			Desvio padrão: 8,54	

Fonte: Do autor (2016).

Tabela 15 – Matriz de confusão da abordagem C.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	78,57%	13,59%	2,10%	3,27%	8,36%
Mata	9,81%	72,08%	0,05%	0,11%	6,89%
Água	0,08%	0,03%	69,17%	0,65%	0,31%
Área urbana	0,20%	0,08%	11,62%	83,39%	3,24%
Outros usos	11,31%	14,20%	17,04%	12,55%	81,17%
Total	Média: 76,87%			Desvio padrão: 6,04	

Fonte: Do autor (2016).

Tabela 16 – Matriz de confusão da abordagem D.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	85,80%	12,79%	7,72%	1,91%	8,23%
Mata	2,63%	67,13%	0,08%	0,02%	3,64%
Água	0,00%	0,00%	80,14%	0,00%	0,06%
Área urbana	0,05%	0,01%	0,02%	89,98%	1,42%
Outros usos	11,49%	20,04%	12,01%	8,08%	86,63%
Total	Média: 81,93%			Desvio padrão: 9,00	

Fonte: Do autor (2016).

Tabela 17 – Matriz de confusão da abordagem E.

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	84,13%	12,79%	11,39%	0,71%	8,00%
Mata	2,74%	69,26%	0,28%	0,06%	4,44%
Água	0,00%	0,00%	84,37%	0,00%	0,11%
Área urbana	0,12%	0,03%	0,05%	90,44%	1,91%
Outros usos	12,99%	18,78%	3,89%	8,77%	85,52%
Total	Média: 82,74%			Desvio padrão: 7,95	

Fonte: Do autor (2016).

Com o resultado apresentado nas tabelas 13 a 17, a abordagem A foi a melhor de acordo com a média global de 84,84%. Em geral, a abordagem

A obteve um alto desempenho em discriminar as classes Água e Área urbana. A classe Café foi mais bem classificada pelas abordagens A e B, apresentando uma alta confusão com a classe Outros usos.

De forma semelhante à RNA, o SVM apresentou as mesmas dificuldades em discriminar a classe Mata corretamente, porém a abordagem C, de fato, apresentou o melhor resultado para esta classe. A classe Outros usos obteve melhor resultado com a abordagem D e apresentando muita confusão com a classe Café.

A Tabela 18 ilustra os índices Kappa obtidos de cada abordagem e em cada classificador utilizado. Assim, observou-se que pela metodologia apresentada, os índices Kappa maiores foram de 74,37% com o uso dos pixels (abordagem A) alcançado pelo SVM e 73,13% com todos os parâmetros (abordagem B) obtido pela RNA.

Tabela 18 – Índices Kappa obtidos pelo método proposto.

Abordagens	Kappa (RNA)	Kappa (SVM)
A (Pixels das 7 bandas)	72,82%	74,37%
B (Todos os parâmetros)	73,13%	71,56%
C (Estatística de Ordem Superior)	66,96%	67,19%
D (Discriminante de Fisher)	73,01%	73,85%
E (Correlação de Pearson)	71,95%	72,94%

Fonte: Do autor (2016).

Observou-se que a maior parcela de erros, alcançada pelas abordagens propostas, foi pela confusão entre as classes Mata e Outros usos. Isso pode ser explicado pelo fato da cultura de Eucalipto ser pertencente à classe de Outros usos, apresentando uma alta confusão espectral com Mata, comprometendo o resultado final.

Apesar da confusão apresentada entre as classes Café e Outros usos, as abordagens propostas apresentaram um bom resultado de classificação em

comparação com os métodos listados na Tabela 1. Os trabalhos de Andrade (2011) e Pereira (2013) alcançaram índices de acerto de 51,99% e 76,25%, para a classe Café, respectivamente, enquanto as abordagens propostas alcançaram desempenhos de 86,20% com o método de RNA e 86,41% de acerto com o SVM para esta mesma classe. Ambos os trabalhos de Andrade (2011) e Pereira (2013) utilizaram as mesmas imagens da região de estudo, porém, em períodos diferentes do satélite Landsat 5 TM.

Em relação aos trabalhos, utilizando imagens de alta resolução do satélite RapidEye (5m de resolução espacial), os resultados dos autores foram superiores ao método proposto. No trabalho de Marujo et al. (2013), apesar de utilizar a mesma imagem da região de estudo, a classe Café do método proposto alcançou um resultado semelhante.

O método proposto por Sarmiento et al. (2014) alcançou uma elevada acurácia, de 94,91% de acerto com o classificador “pixel a pixel” do algoritmo de Máxima Verossimilhança, porém a autora utilizou apenas 2 classes que foram Café e Outros usos e imagens de resolução espacial de 5m.

Em Souza (2015) foram utilizadas imagens de alta resolução das regiões de Araguari, Carmo de Minas e Três Pontas. Constatou-se que os resultados de acerto da classe Café foram acima de 87,69%, em Araguari, 82,86%, em Carmo de Minas, enquanto em Três Pontas foi acima de 89,00% de acerto. Em comparação aos classificadores de RNA e SVM do método proposto, pode-se afirmar que foram semelhantes aos resultados dos classificadores DT e SVM utilizados em Carmo de Minas.

4.3 Resultados obtidos utilizando software comercial

Essa seção apresenta os resultados de classificação da mesma imagem, alcançados pelos softwares eCognition, configurado para classificar utilizando SVM, e o Idrisi, por meio do classificador de RNA. Por limitações dos softwares, foi implementada apenas a abordagem A. As matrizes de

confusão 19 e 20 revelam o desempenho alcançado por cada um dos softwares comerciais.

Tabela 19 – Matriz de confusão gerada pelo software eCognition (SVM).

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	84,68%	18,14%	0,01%	0,12%	8,98%
Mata	1,64%	55,45%	1,06%	0,01%	2,63%
Água	0,00%	0,02%	94,57%	0,00%	0,37%
Área urbana	0,10%	0,02%	0,03%	89,41%	1,00%
Outros usos	13,53%	26,37%	4,34%	10,46%	87,02%
Total	Média: 82,22%			Desvio padrão: 15,41	

Fonte: Do autor (2016).


Tabela 20 – Matriz de confusão gerada pelo software Idrisi (RNA).

Classes	Café	Mata	Água	Área urbana	Outros usos
Café	88,99%	23,37%	0,00%	0,38%	12,04%
Mata	1,55%	59,39%	0,01%	0,03%	3,20%
Água	0,00%	0,06%	96,71%	0,00%	0,80%
Área urbana	0,07%	0,02%	0,85%	92,09%	1,24%
Outros usos	9,39%	17,16%	1,92%	7,50%	82,72%
Total	Média: 83,98%			Desvio padrão: 14,65	

Fonte: Do autor (2016).


Os resultados foram compatíveis com os obtidos pelo método proposto. As Figuras 22 e 23 ilustram as imagens geradas por ambos os softwares.

Figura 22 – Mapa classificado com o software eCognition via SVM.



Fonte: Do autor (2016).

Figura 23 – Mapa classificado com o software Idrisi via RNA.



Fonte: Do autor (2016).

Os resultados mostram que os softwares eCognition e Idrisi conseguiram alcançar um bom resultado de classificação, atingindo um índice Kappa de 71,31% e 71,92% de acurácia, respectivamente. Importante observar que ambos conseguiram discriminar corretamente pouco mais de 50% da classe Mata. Este fato comprova a dificuldade em classificar a classe Mata em detrimento das demais e mostra, também, que as abordagens propostas apresentaram vantagens, com acertos superiores aos alcançados pelos softwares comerciais, entre 63% e 72%.

De acordo com a tabela 18 o software eCognition atingiu um índice Kappa superior apenas à abordagem baseada em cumulantes (abordagem C), enquanto o Idrisi foi superior à abordagem C e B via SVM.

5 CONCLUSÃO

Com os resultados alcançados pelos classificadores de RNA e SVM, pode-se concluir que:

- a. 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 classe Mata.
- b. Os cumulantes como parâmetros únicos não são bons discriminantes para as classes abordadas.
- c. Todas as abordagens por RNA e SVM levaram a modelos com concordâncias substanciais de acordo com a classificação dada por Andrade (2011).
- d. Apesar da abordagem B ter sido boa com RNA, é mais indicado usar a abordagem D via RNA, que é menos complexa, por ter menos entradas, cuja arquitetura é descrita na Tabela 4.
- e. Quando se utiliza o classificador SVM, é mais indicado utilizar a abordagem A, por ser menos complexa.

Portanto os resultados apresentados pelo método proposto com imagens Landsat 8 foram aproximados dos diversos autores que utilizaram imagens de alta resolução, uma vez que foi utilizada uma imagem considerada, pela comunidade científica da área, de média resolução como as imagens Landsat. Esta nova metodologia foi eficaz, para a classificação de áreas cafeeiras em imagem Landsat 8, apresentando um bom desempenho.

REFERÊNCIAS

- ABADAL, G.; ALDA, J.; AGUSTÍ, J. Electromagnetic radiation energy harvesting – The rectenna based approach. In: FAGAS, G. et al. (Ed.). **ICT - Energy - Concepts Towards Zero - Power Information and Communication Technology**. Rijeka: Intech, 2014. chap. 5. Disponível em: <<http://www.intechopen.com/books/ict-energy-concepts-towards-zero-power-information-and-communication-technology/electromagnetic-radiation-energy-harvesting-the-rectenna-based-approach>>. Acesso em: 16 ago. 2016.
- ABURAS, M. M. et al. Measuring land cover change in Seremban, Malaysia using NDVI index. **Procedia Environmental Sciences**, Seri Kembangan, v. 30, p. 238-245, 2015.
- ADAMI, M.; MOREIRA, M. A.; BARROS, M. A. Avaliação da exatidão do mapeamento da cultura do café no estado de Minas Gerais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 1-8.
- ANDERSEN, T. J.; WILAMOWSKI, B. M. A modified regression algorithm for fast one-layer neural network training. In: WORLD CONGRESS OF NEURAL NETWORKS, 1995, Washington. **Proceedings...** New York: IEEE, 1995. p. 687-690.
- ANDRADE, L. N. et al. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em Machado-MG. **Coffee Science**, Lavras, v. 8, n. 1, p. 78-90, jan./mar. 2013.
- ANDRADE, L. N. **Redes neurais artificiais aplicadas na identificação automática de áreas cafeeiras em imagens de satélite**. 2011. 90 f. Tese (Mestrado em Ciência da Computação) - Universidade Federal de Minas Gerais, Belo Horizonte, 2011.
- ANDREOLA, R.; HAERTEL, V. Support vector machines na classificação de imagens hiperespectrais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 6757-6764.
- BARBOSA, T. S. et al. Fault detection and classification in cantilever beams through vibration signal analysis and higher-order statistics. **Journal of**

Control, Automation and Electrical Systems, New York, v. 27, n. 5, p. 535-541, June 2016.

BATRA, D. Comparison between levenberg-marquardt and scaled conjugate gradient training algorithms for image compression using MLP.

International Journal of Image Processing, Kuala Lumpur, v. 8, n. 6, p. 412-422, Nov./Dec. 2014.

BELLO, M. G. Enhanced training algorithms, and integrated training/architecture selection for multilayer perceptron networks. **IEEE Transactions on Neural Networks**, New York, v. 3, n. 6, p. 864-875, 1992.

BISPO, R. C.; LAMPARELLI, R. A. C.; ROCHA, J. V. Using fraction images derived from modis data for coffee crop mapping. **Engenharia Agrícola**, Jaboticabal, v. 34, n. 1, p.102-111, jan./fev. 2014.

CANADA. Natural Resources Canada. Center for Remote Sensing. **Fundamentals of Remote Sensing**. Ottawa, 1988. 258 p. Disponível em: <http://www.ldeo.columbia.edu/res/fac/rsvlab/fundamentals_e.pdf>. Acesso em: 16 ago. 2016.

CARVALHO, J. R. **Estatísticas de ordem superior e redes neurais artificiais aplicadas à proteção digital de linhas de transmissão**. 2013. 261 p. Tese (Doutorado em Sistemas Elétricos de Potência) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

CERQUEIRA, S. A. et al. Power quality events recognition using a SVM-based method. **Electric Power Systems Research**, Lausanne, v. 78, n. 9, p. 1546-1552, Sept. 2008.

CLARK LABS. **Geospatial software for monitoring and modeling the earth system**. Disponível em: <<http://www.clarcklabs.org/productsidrisi-taiga.cfm>>. Acesso em: 20 maio 2015.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remote sensed data: principle and practices**. New York: Lewis, 1999. 123 p.

CORDERO-SANCHO, S.; SADER, S. A. Spectral analysis and classification accuracy of coffee crops using Landsat and a topographic-environmental model. **International Journal of Remote Sensing**, Basingstoke, v. 28, n. 7/8, p. 1577-1593, Apr. 2007.

CORREA, S. M. B. B. **Probabilidade e estatística**. 2. ed. Belo Horizonte: PUC Minas Virtual, 2003. 116 p.

DEFRIES, R. S.; BOUNOURA, L.; COLLATZ, G. J. Human modification of the landscape and surface climate in the next fifty years. **Global Change Biology**, Oxford, v. 8, n. 5, p. 438-458, May 2002.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. New York: Wiley, 2001. 680 p.

ERENER, A. Classification method, spectral diversity, band combination and accuracy assessment evaluation for urban feature detection. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 21, n. 1, p. 397-408, Apr. 2013.

FARIA, A. F. et al. Automatic fusion of region-based classifiers for coffee crop recognition. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2012, Munich. **Proceedings...** New York: IEEE, 2012. p. 2221-2224.

FATIHA, B. et al. Spatio temporal analysis of vegetation by vegetation indice from multi-dates satellite images: application to a semi arid area in ALGERIA. **Energy Procedia**, Amsterdam, v. 36, p. 667-675, 2013.

FERREIRA, D. D. **Analise de distúrbios elétricos em sistemas de potência**. 2010. 210 p. Tese (Doutorado em Engenharia Elétrica) - Instituto Alberto Luiz de Coimbra, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

FERREIRA, D. D. et al. Exploiting higher-order statistics information for power quality monitoring. In: EBERHARD, A. (Org.). **Power quality**. New York: Intech, 2011. chap. 17, p. 345-362.

FERREIRA, D. D. et al. HOS-Based method for power quality event classification. In: EUROPEAN SIGNAL PROCESSING CONFERENCE, 14., 2006, Florence. **Proceedings...** New York: IEEE, 2006. p. 1-5.

Disponível em:

<https://www.researchgate.net/publication/228738061_HOS-based_method_for_power_quality_event_classification>. Acesso em: 15 ago. 2016.

FISHER, R. A. The statistical utilization of multiple measurements. **Annals of Human Genetics**, London, v. 8, n. 4, p. 376-386, Aug.1938.

FOLEY, J. A. et al. Global consequences of land use. **Science**, New York, v. 309, n. 5734, p. 570-574, July 2005.

FOODY, G. M.; MATHUR, A. Multiclass and binary SVM classification: implications for training and classification users. **IEEE Geoscience and Remote Sensing Letters**, New York, v. 5, n. 2, p. 241-245, Apr. 2008.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, New York, v. 80, n. 1, p. 185-201, Apr. 2009.

GIROLAMO NETO, C. D. et al. Classificação automática de áreas cafeeiras utilizando imagens de sensoriamento remoto e técnicas de mineração de dados. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 1609-1616. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM495M>>. Acesso em: 24 jul. 2016.

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 York, v. 114, n. 11, p. 2731-2744, Nov. 2010.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3rd ed. New Jersey: Pearson Prentice Hall, 2008. 954 p.

GUEDES, J. D. S.; DANTON, D. F.; BARBOSA, B. H. G. A non-intrusive approach to classify electrical appliances based on higher-order statistics and genetic algorithm: a smart grid perspective. **Electric Power Systems Research**, Lausanne, v. 140, p. 65-69, Nov. 2016.

GUEDES, J. D. S. et al. Non-intrusive appliance load identification based on higher-order statistics. **IEEE Latin America Transactions**, Buenos Aires, 13, n. 10, p. 3343-3349, Oct. 2015.

HAGAN, M. T.; MENHAJ, M. B. Training feed-forward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, New York, v. 5, n. 6, p. 989-993, Nov. 1994.

HANSEN, M. C.; DEFRIES, R. S. Detecting long-term global forest change using continuous fields of tree-cover maps from 8-km Advanced Very High Resolution Radiometer (AVHRR) data for the years 1982-99. **Ecosystems**, New York, v. 7, n. 7, p. 695-716, Nov. 2004.

HAO, Y.; WILAMOWSKI, B. M. **Levenberg-Marquadt training.**

Disponível em:

<<https://pdfs.semanticscholar.org/708a/e4da2eabd4b6a19471cfa7fd072537d499a8.pdf>>. Acesso em: 16 ago. 2016.

HAYKIN, S. **Neural networks: a comprehensive foundation.** 2nd ed. New Jersey: Prentice Hall, 1999. 842 p.

HAYKIN, S. **Neural networks and learning machines.** 3rd ed. New Jersey: Prentice Hall, 2008. 936 p.

HOUETE, A. R. Soil influences in remotely sensed vegetation canopy spectra. In: ASRAR, G. (Ed.). **Theory and application of optical remote sensing.** New York: J. Wiley, 1989. p. 107-141.

HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, Basingstoke, v. 23, n. 4, p. 725-749, Nov. 2002.

IRONS, J. R.; DWYER, J. L.; BARSİ, J. A. The next Landsat satellite: the Landsat data continuity mission. **Remote Sensing of Environment**, New York, v. 122, p. 11-21, July 2012.

IRONS, J. R.; LOVELAND, T. R. Eighth Landsat satellite becomes operational. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 79, n. 5, p. 398-401, May 2013.

KISI, O.; UNCUOGLU, E. Comparison of three back-propagation training algorithms for two case studies. **Indian Journal of Engineering & Materials Sciences**, New Delhi, v. 12, n. 5, p. 434-442, Oct. 2005.

LANDGREBE, D. A. **Signal theory methods in multispectral remote sensing.** New York: J. Wiley, 2003. 528 p.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, Washington, v. 33, n. 3, p. 159-174, Mar. 1977.

LAUER, D. T.; MORAIN, S. A.; SALOMONSON, V. V. The Landsat program: its origins, evolution, and impacts. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 63, n. 7, p. 831-838, July 1997.

LOVELAND, T. R.; DWYER, J. L. Landsat: building a strong future. **Remote Sensing of Environment**, New York, v. 122, p. 22-29, July 2012.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, Basingstoke, v. 28, n. 5, p. 823-870, Jan. 2009.

MACHADO, M. L. et al. Caracterização do meio físico de agroecossistemas cafeeiros da zona da mata de Minas Gerais usando técnicas de sensoriamento remoto e sistemas de informação geográficas. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 2., 2001, Vitória. **Anais...** Vitória: Embrapa Café, 2001. p. 2399-2409.

MACHADO, M. L. et al. Mapeamento de áreas cafeeiras (*Coffea arabica* L.) da zona da mata mineira usando sensoriamento remoto. **Coffee Science**, Lavras, v. 5, n. 2, p. 113-122, maio/ago. 2010.

MARQUES, C. A. G.; FERREIRA, D. D.; RIBEIRO, M. V. Wavelet e EOS para detecção de distúrbios em aplicações de qualidade de energia: análise comparativa. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 17., 2008, Juiz de Fora. **Anais...** Juiz de Fora, 2008. 1 CD-ROM.

MARTINEZ, A. M.; KAK, A. C. PCA versus LDA. **IEEE Transactions Pattern Analysis and Machine Intelligence**, New York, v. 23, n. 2, p. 228-233, Feb. 2001.

MARTINEZ-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**, Oxford, v. 34, p. 1-9, May 2012.

MARUJO, R. F. B. et al. Classificação orientada a objetos aplicada à cultivos cafeeiros em Três Pontas - MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 1338-1345.

MAULIK, U.; CHAKRABORTY, D. A. Robust multiple classifier system for pixel classification of remote sensing images. **Journal Fundamenta Informaticae**, Amsterdam, v. 101, n. 4, p. 287-304, Dec. 2010.

MELGANI, F.; BRUZZONE, L. Classification of hyperspectral remote sensing images with support vector machines. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 42, n. 8, p. 1778-1790, Aug. 2004.

MENDEL, J. M. Tutorial on higher-order statistics (Spectra) in signal processing and system theory: theoretical results and some applications. **Proceedings of the IEEE**, New York, v. 79, n. 3, p. 278-305, Mar. 1991.

MESHGINI, S.; ALGHAGOLZADEH, A.; SEYEDARABI, H. Face recognition using Gabor filter bank, kernel principle component analysis and

support vector machine. **International Journal of Computer Theory & Engineering**, Ottawa, v. 4, n. 5, p. 767-771, Oct. 2012.

MINH, H. N.; HUSSEIN A. A.; ROBERT, I. M. Stopping criteria for ensemble of evolutionary artificial neural networks. **Journal Applied Soft Computing**, Amsterdam, v. 6, n. 1, p. 100-107, Nov. 2005.

MITRA, P.; SHANKAR, B. U.; PAL, S. K. Segmentation of multispectral remote sensing images using active support vector machines. **Pattern Recognition Letters**, Amsterdam, v. 25, n. 9, p. 1067-1074, July 2004.

MOHAMAD, N. et al. Comparison between Levenberg-Marquardt and scaled conjugate gradient training algorithms for breast cancer diagnosis using MLP. In: INTERNATIONAL COLLOQUIUM ON SIGNAL PROCESSING AND ITS APPLICATIONS, 6., 2010, Malacca. **Proceedings...** New York: IEEE, 2010. p. 1-7.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Análise espectral e temporal da cultura do café em imagens Landsat. **Pesquisa Agropecuária Brasileira**, Brasília, v. 39, n. 3, p. 223-231, mar. 2004.

MOREIRA, M. A. et al. Geotecnologias para mapear lavouras de café nos estados de Minas Gerais e São Paulo. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 6, p.1123-1135, nov./dez. 2010.

MOREIRA, M. G.; FERREIRA, D. D.; DUQUE, C. A. Sub-harmonics detection and identification using higher order statistics. In: INTERNATIONAL CONFERENCE ON HARMONICS AND QUALITY OF POWER, 16., 2014, Bucharest. **Proceedings...** New York: IEEE, 2014. p. 283-287.

MOURA, L. C. et al. Levantamento e mapeamento espaço: temporal dos cafezais no município mineiro de Machado. **Caminhos de Geografia**, Uberlândia, v. 10, n. 31, p. 124-134, set. 2009.

MUKASHEMA, A.; VELDKAMP, A.; VRIELING, A. Automated high resolution mapping coffee on Rwanda using an expert Bayesian network. **International Journal of Applied Earth Observation and Geoinformation**, Enchede, v. 33, p. 331-340, Dec. 2014.

NAVES, R.; BARBOSA, B. H. G.; FERREIRA D. D. Classification of lung sounds using higher-order statistics: a divide-and-conquer approach. **Computer Methods and Programs in Biomedicine**, Amsterdam, v. 129, p. 12-20, Mar. 2016.

NIU, D. et al. Multi-variable echo state network optimized by Bayesian regulation for daily peak load forecasting. **Journal of Networks**, Miami, v. 7, n. 11, p. 1790-1795, Nov. 2012.

ORTEGA-HUERTA, M. A. et al. Mapping coffee plantations with Landsat Imagery: an example from El Salvador. **International Journal of Remote Sensing**, Basingstoke, v. 33, n. 1, p. 220-242, Jan. 2012.

PEDRONI, N.; ZIO, E.; APOSTOLAKIS, G. E. Comparison of bootstrapped artificial neural networks and quadratic response surfaces for the estimation of the functional failure probability of a thermal-hydraulic passive system. **Reliability Engineering and System Safety**, Barking, v. 95, n. 4, p. 386-395, Apr. 2010.

PEREIRA, A. L. dos A. **Classificação automática de áreas cafeeiras em imagens de satélite, utilizando redes neurais artificiais**. 2013. 83 p. Monografia (Graduação em Ciência da Computação) - Universidade Federal de Lavras, 2013.

PRECHELT, L. Automatic early stopping using cross validation: quantifying the criteria. **Neural Networks**, New York, v. 11, n. 4, p. 761-767, Apr. 1998.

RAMIREZ, G. M.; ZULLO JÚNIOR, J. Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial. **Revista Engenharia Agrícola**, Jaboticabal, v. 30, n. 3, p. 468-479, jun. 2010.

RIBEIRO, M. V. et al. Detection of disturbances in voltage signals for power quality using HOS. **EURASIP Journal on Applied Signal Processing**, New York, v. 2007, n. 1, p. 177-178, Jan. 2007.

ROSENBLATT, F. **Principles of neurodynamics**: perceptrons and the theory of brain mechanisms. New York: Spartan Books, 1962. 616 p.

ROY, D. P. et al. Landsat-8: science and product vision for terrestrial global change research. **Remote Sensing of Environment**, New York, v. 145, p. 154-172, Apr. 2014.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing**: explorations in the microstructure of cognition: foundations. Cambridge: MIT, 1986. v. 1, chap. 8, p. 318-362.

SANTOS, J. A. et al. Genetic programming approach for coffee crop recognition. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2010, Honolulu. **Proceedings...** New York: IEEE, 2010. p. 3418-3421.

SARMIENTO, C. M. et al. Comparação dos classificadores supervisionados na discriminação de áreas cafeeiras em Campos Gerais. **Coffee Science**, Lavras, v. 9, n. 4, p. 546-557, out./dez. 2014.

SHIN, H. An extension of fisher's discriminant analysis for stochastic processes. **Journal of Multivariate Analysis**, New York, v. 99, n. 6, p. 1191-1216, July 2008.

SILVA, C. A. de O. et al. Classificação de áreas cafeeiras em imagens multiespectrais através de redes neurais artificiais e extratores de textura. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 3795-3802.

SOUZA, G. C. **Uso de séries temporais para o mapeamento da cafeicultura**. 2015. 162 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2015.

SOUZA, V. C. O. et al. Espacialização e dinâmica da cafeicultura mineira entre 1990 e 2008, utilizando técnicas de geoprocessamento. **Coffee Science**, Lavras, v. 7, n. 2, p. 122-134, maio/ago. 2012.

TAPPEINER, U. et al. Classifiers vs. input variables - The drivers in image classification for land cover mapping. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 11, n. 6, p. 423-430, Dec. 2009.

TOWNSHEND, J. R. G.; JUSTICE, C. O. Selecting the spatial resolution of satellite sensors required for global monitoring of land transformations. **International Journal of Remote Sensing**, Basingstoke, v. 9, n. 2, p. 187-236, Feb. 1988.

TRABAQUINI, K. et al. Caracterização de lavouras cafeeiras, utilizando técnicas de geoprocessamento e sensoriamento remoto no município de Umuarama – PR. **Ciência e Agrotecnologia**, v. 35, n. 1, p. 35-44, jan./fev. 2011.

TRIMBLE. **Trimble Geospatial Imaging**. Disponível em: <<http://www.ecognition.com/essentials>>. Acesso em: 10 maio 2015.

VANHELLEMONT, Q.; RUDDICK, K. Advantages of high quality SWIR bands for ocean color processing: examples from Landsat-8. **Remote Sensing of Environment**, New York, v. 161, p. 89-106, May 2015.

VAPNIK, V. N. **Statistical learning theory**. New York: J. Wiley, 1998. 768 p.

VIANELLO, R. et al. Classificação de múltiplos distúrbios de qualidade de energia baseado em transformada Wavelet, EOS e redes neurais. In:

CONFERÊNCIA BRASILEIRA SOBRE QUALIDADE DE ENERGIA ELÉTRICA, 8., 2009, Blumenau. **Anais...** Blumenau, 2009. v. 1, p. 212-219.

VIEIRA, T. G. C. et al. Crop parameters and spectral response of coffee (coffea arábica. 1) areas within the state of Minas Gerais, Brazil. **Coffee Science**, Lavras, v. 1, n. 2, p. 111-118, jul./dez. 2006.

VIEIRA, T. G. C. et al. Geotechnologies in the assessment of land use changes. **Coffee Science**, Lavras, v. 2, n. 2, p. 142-149, jul./dez. 2007.

VISWANATHAN, M. **Power and energy of a signal**. [S.l.], 2013. Disponível em: < <http://www.gaussianwaves.com/2013/12/power-and-energy-of-a-signal/>>. Acesso em: 16 set. 2016.

WERBOS, P. J. Back-propagation: past and future. In: INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1988, San Diego. **Proceedings...** New York: IEEE, 1988. v. 1, p. 343-354.

WILAMOWSKI, B. M.; CHEN, Y.; MALONIWSKI, A. Efficient algorithm for training neural networks with one hidden layer. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 1999, Washington. **Proceedings...** New York: IEEE, 1999. v. 3, p. 1725-1728.

WILAMOWSKI, B. M. Neural networks and fuzzy systems. In: BISHOP, R. R. (Ed.). **Mechatronics handbook**. Boca Raton: CRC, 2002. chap. 12, p. 33-45.

WILAMOWSKI, B. M. Neural networks and fuzzy systems. In: WHITAKER, J. C. (Ed.). **The electronic handbook**. Boca Raton: CRC, 1996. chap. 24, p. 1893-1914.

WILAMOWSKI, B. M. Neural network architectures and learning algorithms. **IEEE Industrial Electronics Magazine**, New York, v. 3, n. 4, p. 56-63, Dec. 2009.

WILAMOWSKI, B. M.; HUNTER, D.; MALINOWSKI, A. Solving parity-n problems with feedforward neural network. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 3., 2003, Portland. **Proceedings....** New York: IEEE, 2003. p. 2546-2551.

WILAMOWSKI, B. M.; TORVIK, L. Modification of gradient computation in the back-propagation algorithm. In: ARTIFICIAL NEURAL NETWORKS IN ENGINEERING CONFERENCE, St. Louis, 1993. **Proceedings...** New York: ASME, 1993. Disponível em: <http://www.eng.auburn.edu/~wilambm/pap/1993/ANNIE'93_Modification_of_gradient_computation.pdf>. Acesso em: 16 set. 2016.

WILLIAMS, D. L.; GOWARD, S.; ARVIDSON, T. Landsat: yesterday, today, and tomorrow. **Photogrammetric Engineering & Remote Sensing**, Falls Church, v. 72, n. 10, p. 1171-1178, Oct. 2006.

YANG, B. et al. Automatic classification of remote sensing images using multiple classifier systems. **Mathematical Problems in Engineering**, Cairo, v. 2015, p. 1-10, 2014.

YANG, S.; GREGORY, N. T.; STEPHEN, J.W. Comparison of early stopping criteria for neural-network-based subpixel classification. **IEEE Geoscience and Remote Sensing Letters**, New York, v. 8, n. 1, p. 113-118, Feb. 2011.

YU, H.; WILAMOWSKI, B. M. C++ implementation of neural networks trainer. In: INTERNATIONAL CONFERENCE ON INTELLIGENT ENGINEERING SYSTEMS, 13., Barbados, 2009. **Proceedings...** New York: IEEE, 2009. p. 257-262.

ZHAO, Y. S. **The principle and method of analysis of remote sensing application**. Beijing: Science, 2003.