

COMPARAÇÃO DE CLASSIFICADORES SUPERVISIONADOS NA DISCRIMINAÇÃO DE ÁREAS CAFEEIRAS EM CAMPOS GERAIS - MINAS GERAIS

Christiany Mattioli Sarmiento¹, Gláucia Miranda Ramirez², Priscila Pereira Coltri³, Luis Felipe Lima e Silva⁴, Otávio Augusto Carvalho Nassur⁵, Jefferson Francisco Soares⁶

(Recebido: 12 de fevereiro de 2014; aceito: 3 de abril de 2014)

RESUMO: O uso de técnicas de sensoriamento remoto orbital representa um significativo avanço para os levantamentos de dados da cafeicultura, principalmente visando a complementação das técnicas utilizadas atualmente. Objetivou-se, neste trabalho, mapear áreas cafeeiras em imagens de alta resolução, a partir de métodos de classificação por análise de imagens orientada a objeto, com os algoritmos k nearest neighbor (KNN), support vector machine (SVM) e pixel-a-pixel, com o algoritmo maximum likelihood (Maxver). A área de estudo foi mapeada, em duas classes: 'café' e 'outros usos'. Realizou-se a análise da exatidão dos mapeamentos a partir da comparação com o mapa de referência da área e foi constatado que a classificação pixel a pixel, pelo método maximum likelihood, obteve os melhores resultados, com 0,78 de índice kappa e 94,61% de exatidão. Conclui-se, a partir deste estudo que o método pixel a pixel do algoritmo Maxver mostra-se mais eficiente para discriminar café, quando se considera somente dois tipos de uso da terra, café e não café, em imagens de alta resolução.

Termos para indexação: Sensoriamento remoto, cafeicultura, análise de imagem orientada a objetos, exatidão.

COMPARISON OF SUPERVISED CLASSIFIERS IN DISCRIMINATION COFFEE AREAS FIELDS IN CAMPOS GERAIS - MINAS GERAIS

ABSTRACT: The use of remote sensing techniques represents a significant advance for the coffee crop data, mainly to complement the currently techniques that have been used. In this context, this study aimed to map coffee areas in high resolution images using object-oriented images analyses methods, with k nearest neighbor (KNN) and support vector machine (SVM) algorithm, and pixel-by-pixel methods, using maximum likelihood (Maxver) algorithm. The study area was mapped using two classes: 'coffee' and 'other uses'. We performed the mappings accuracy analysis using reference map and it was found that the pixel by pixel classification with maximum likelihood algorithm has the best results, with kappa value of 0.78 and 94.61% of accuracy. In this study, we concluded that the pixel by pixel method of Maxver algorithm seems more efficient to discriminate coffee areas when considering only two types of land use, coffee and no coffee, in high resolution images.

Index terms: Remote sensing, coffee farming, object-oriented image analyses, accuracy.

1 INTRODUÇÃO

A cafeicultura é uma atividade de grande importância mundial (SOUZA et al., 2012), sendo desenvolvida no Brasil desde 1727 (SILVA; ALVES, 2013; ZULLO JÚNIOR et al., 2011). Atualmente, o Brasil é responsável por aproximadamente 35% da produção mundial de café e 25,3% das exportações de grãos verdes (BRASIL, 2013). O estado de Minas Gerais é o maior produtor de café, responsável por 53% da produção nacional, sendo a região Sul do Estado, a maior produtora (Companhia Nacional de Abastecimento - CONAB, 2013).

No Brasil, a obtenção de informações oficiais referentes à cafeicultura, tais como área

plantada, quantidade produzida e área colhida, é realizada pela CONAB - Companhia Nacional de Abastecimento - e pelo IBGE - Instituto Brasileiro de Geografia e Estatística - que utilizam informações municipais obtidas através da aplicação de questionários padrões a produtores, cooperativas e representantes de órgãos públicos e privados. No entanto, essa metodologia não fornece o detalhamento necessário para planejamentos estratégicos regionais e municipais (MACHADO et al., 2010; RAMIREZ; ZULLO JÚNIOR, 2010), deixando o setor carente de informações (MOREIRA et al., 2007). Para suprir essa lacuna, as geotecnologias têm sido promissoras para avaliar a dinâmica da cafeicultura (MOREIRA et al., 2010; MOURA et al., 2009; ORTEGA-HUERTA et al.,

^{1,2,5,6}Universidade Federal de Lavras/UFLA - Departamento de Engenharia/DEG - Cx. P. 3037 - 37200-000 - Lavras - MG
chrislavras@yahoo.com.br, glaucia_ramirez@yahoo.com.br, otavionassur@yahoo.com.br, jefferson@ahefunil.com.br

³Universidade Estadual de Campinas/UNICAMP - Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura/ CEPAGRI
Cidade Universitária Zeferino Vaz - Barão Geraldo - 13083-970 - Campinas - SP - priscilapereira.coltri@gmail.com

⁴Universidade Federal de Lavras/UFLA - Departamento de Agricultura/DAG - Cx. P. 3037 - 37200-000 - Lavras - MG - luisufila@hotmail.com

2012; SOUZA et al., 2012; VIEIRA et al., 2007), incluindo variáveis como extensão, distribuição e localização do ambiente em que o café é cultivado. Essas ações de mapeamento e quantificação das relações da cultura cafeeira com o meio físico favorecem ações estratégicas de planejamento (MOREIRA et al., 2010; SOUZA et al., 2012) e tomadas de decisões (BERNARDES et al., 2012).

Em sensoriamento remoto, o mapeamento é realizado por meio da classificação de imagens orbitais, que podem ser feitas através de análise visual (manual) ou automática, utilizando classificadores pixel a pixel ou baseado em objetos. Basicamente, a classificação pode ser supervisionada (em que o usuário seleciona pixels de amostra e atribui classes a eles), uma das mais utilizadas em sensoriamento remoto, ou não supervisionada (em que o próprio algoritmo atribui as classes aos pixels). Na classificação de áreas cafeeiras, o algoritmo Maxver, que é uma técnica supervisionada pixel a pixel, tem sido aplicado com frequência em imagens de média resolução espacial, como as do satélite Landsat (MOREIRA et al., 2010; ORTEGA-HUERTA et al., 2012; SOUZA et al., 2012; TARDIN; ASSUNÇÃO; SOARES, 1992; TRABAQUINI et al., 2011).

A larga utilização do satélite Landsat ocorre devido à sua qualidade espectral, resolução e, principalmente, facilidade de acesso. No entanto, a nova geração de satélites de alta resolução (como Quickbird, Ikonos, RapidEye, Geoeye-1) tem se mostrado útil e promissora na identificação e caracterização de áreas cafeeiras (COLTRI et al., 2011; MOREIRA et al., 2010; RAMIREZ; ZULLO JÚNIOR, 2010), pois além de possibilitarem um conhecimento mais detalhado do comportamento espectral de plantios de café, auxiliam na identificação de pequenas lavouras com diferentes características (MOREIRA et al., 2010). Trabalhos de Bausch, Halvorson e Cibra (2008), Coltri et al. (2011) e Marujo et al. (2013); apresentam a eficiência da utilização de satélites de alta resolução espacial, mas também ressaltam a importância de novas pesquisas na classificação dessas imagens.

Alguns trabalhos ressaltam que, na classificação do uso e ocupação do solo, os tradicionais algoritmos pixel a pixel, como o Maxver, possuem eficiência reduzida em imagens de alta resolução espacial, por causa da ocorrência do aspecto granuloso nessas imagens (CAMPOS et al., 2013), e nesse caso, os métodos baseado em objetos ou regiões (como os algoritmos K-Nearest Neighbor-KNN- e support vector machine-SVM) tem sido indicados (DURO; FRANKLIN; DUBÉ,

2012; MARUJO et al., 2013; NOMA; KORTING; FONSECA, 2013), pois consideram não apenas a informação espectral, mas também a espacial e a de textura (CAMPOS et al., 2013). Pesquisas de classificação e caracterização de plantios de café em imagens de alta resolução, no entanto, ainda são escassas e há necessidade de aperfeiçoamento das técnicas a fim de obter resultados cada vez mais satisfatórios e com custos menores.

Diante do grande desafio que é a escolha do algoritmo para levantamento de dados e quantificação acurada da cultura cafeeira em imagens de alta resolução, objetivou-se, principalmente, no presente trabalho, realizar a comparação entre algoritmos classificadores supervisionados, utilizando análise de imagens orientada a objetos e análise de imagem pixel a pixel, na discriminação de áreas cafeeiras, em imagem Quickbird.

2 MATERIAIS E MÉTODOS

A área de estudo está localizada no Sul do estado de Minas Gerais, Sudeste do Brasil, no município de Campos Gerais (Figura 1a e 1b), uma das maiores regiões produtora de café do Brasil. Sua localização é determinada pelas coordenadas geográficas 21°7'30 Sul e 45°33'30" Oeste. Para realização do estudo, selecionou-se uma propriedade com produção de café (Figura 1c).

Utilizou-se imagem de alta resolução espacial do satélite Quickbird de 14 de março de 2012, contendo quatro bandas espectrais com 2,44 m e uma banda pancromática com 0,60 m de resolução espacial e 8 bits de resolução radiométrica. A metodologia utilizada no estudo é apresentada no fluxograma da Figura 2, e foi dividida em três grandes etapas: Fase I: elaboração do mapa de referência, Fase II: classificação das imagens e Fase III: análise estatística dos resultados.

Fase I: Após o recebimento da imagem foi realizado um mapa de referência do uso e ocupação do solo. Para tanto, foram realizadas visitas a campo para identificação dos diferentes tipos de usos de solo da área de estudo. A área experimental possui como uso e ocupação do solo corpos d' água, pastagem, mata, solo exposto e café. Em seguida, as bandas da imagem Quickbird foram fusionadas (4 bandas – azul, verde, vermelha e infravermelha - com a banda pancromática) para melhor detalhamento, e a imagem foi classificada manualmente com todas as classes encontradas em campo. O passo seguinte foi o refinamento das classes, agrupando-as em duas: “café” e “outros usos”.

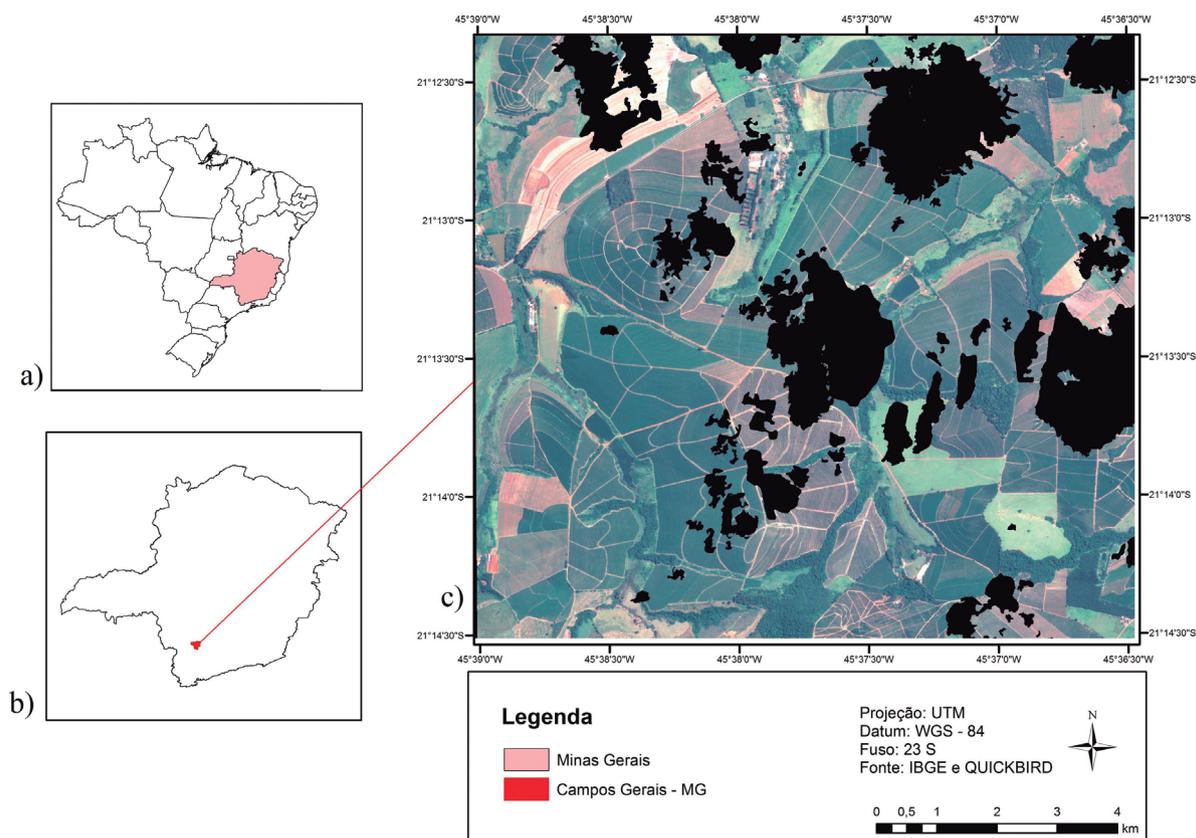


FIGURA 1 - Área de estudo: a) Localização de Minas Gerais; b) Localização de Campos Gerais; c) imagem RGB do satélite Quickbird do dia 14/03/2012.

Fase II: A segunda fase do trabalho consistiu no pré-processamento e classificação da imagem não fusionada, utilizando as bandas 4 - 3 - 2 - 1. Primeiro, houve a digitalização das nuvens e de suas sombras para que as mesmas fossem eliminadas da imagem de forma a não comprometer os resultados. A vetorização foi realizada eliminando todos os pixels contaminados. A correção atmosférica das imagens foi efetuada com o software SCORADIS (Sistema de Correção Radiométrica de Imagens de Satélite) (ZULLO JÚNIOR, 1994), segundo a metodologia descrita por Nascimento e Zullo Júnior (2010). Para tanto, utilizaram-se imagens MOD04, MOD05 e MOD07 do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) do satélite Terra, obtidas na mesma data da imagem Quickbird. Para discriminação de áreas cafeeiras houve a comparação dos dois métodos classificadores supervisionados: i) análise de imagem orientada a objeto, utilizando os algoritmos *k nearest neighbor* (KNN) e *support vector machine* (SVM)

e, ii) classificação pixel a pixel, utilizando o algoritmo *maximum likelihood* (Maxver). Para a análise orientada a objeto, houve a necessidade de realizar, anterior à classificação, o processo de segmentação.

O processo de segmentação por extração de características foi executado, utilizando o algoritmo *watersheds by immersion* (CAMPOS et al., 2013; VINCENT; SOILLE, 1991), que utiliza as características espaciais, espectrais (brilho e cor) e texturais de uma região de interesse (AGUIRRE-GUTIÉRREZ; SEIJMONSBERGEN; DUIVENVOORDEN, 2012; BLASCHKE, 2010; YAN et al., 2006). Também foi utilizada a variável de razão de bandas para melhor discriminar as diferenças do comportamento espectral de alvos distintos (ARAÚJO; MELLO, 2010). Foram utilizadas as bandas do vermelho e do infravermelho próximo, formando o NDVI (ROUSE et al., 1973), índice de vegetação por diferença normalizada.

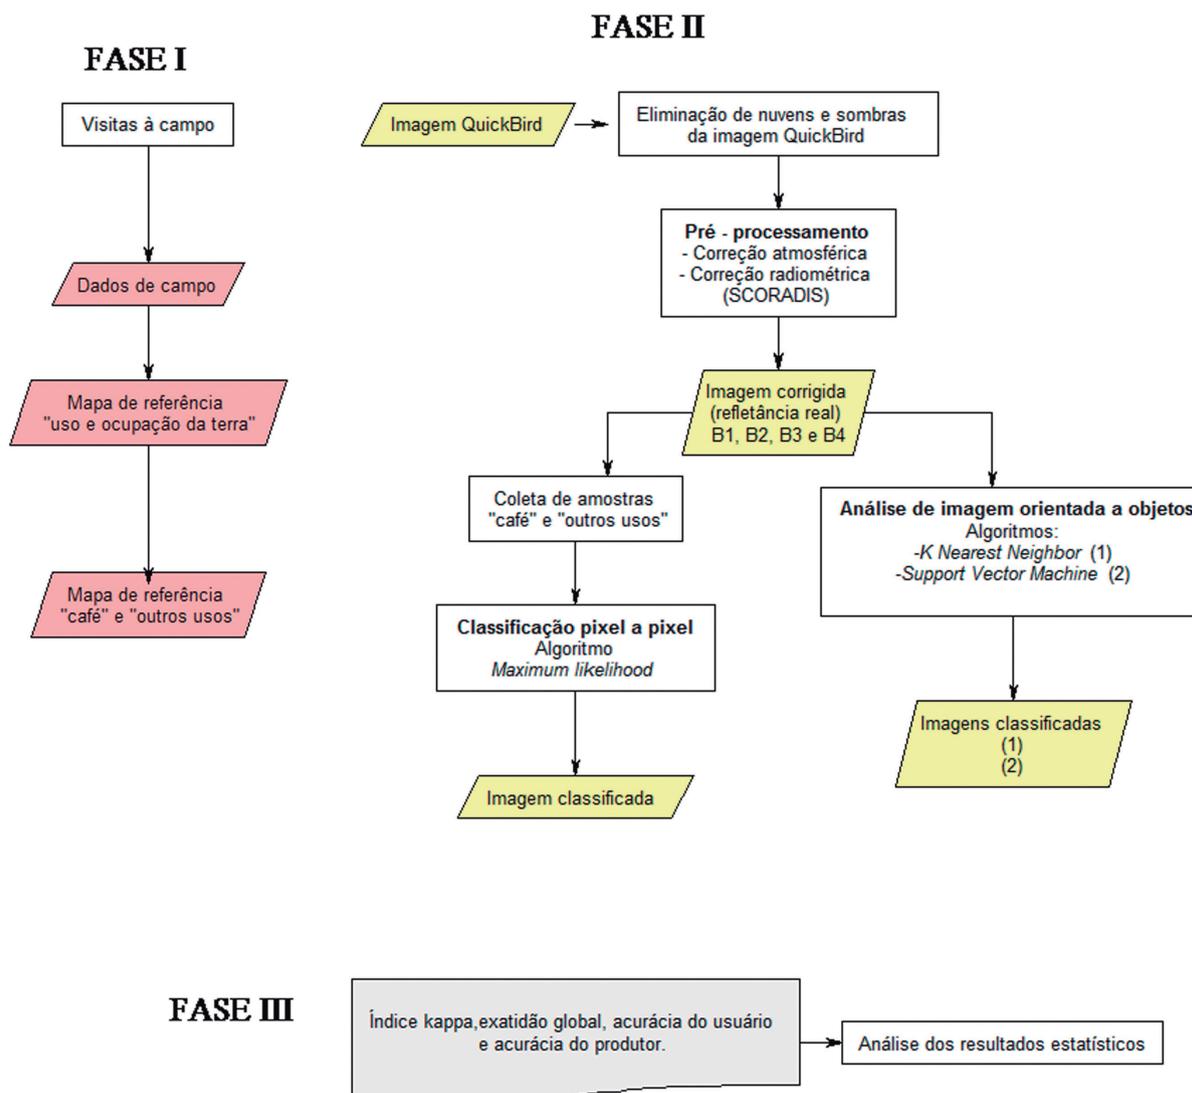


FIGURA 2 - Fluxograma da metodologia utilizada.

Após a segmentação, realizou-se a classificação com os algoritmos KNN e SVM. O algoritmo de classificação KNN, proposto por Fukunaga e Narendra (1975), é uma técnica empregada no reconhecimento de padrões, baseada na técnica do vizinho mais próximo (*nearest neighbor- NN*), que utiliza os ‘k’ vizinhos mais próximos do padrão de consulta, ao invés de apenas o vizinho mais próximo (XU et al., 2013). Já o algoritmo SVM, originalmente formulado por Vapnik em 1979, tem como objetivo a determinação do limite de decisão que produzam uma separação ótima entre as classes por meio da minimização dos erros (MOUNTRAKIS; IM; OGOLE, 2011).

Para a realização dessa etapa, foram coletadas amostras aleatórias de objetos das classes “café” e “outros usos”. Nessas amostras, todos os parâmetros de atributos espaciais, de textura, e espectral foram considerados. O mesmo não ocorreu na classificação pixel a pixel Maxver, pois nesse procedimento apenas a informação espectral é considerada.

O algoritmo Maxver considera a ponderação das distâncias entre médias e valores das classes e o pixel, utilizando parâmetros estatísticos, isso é, considerando a distribuição de probabilidade normal para cada classe (HUANG; DAVIS; TOWNSHEND, 2002). Para tanto foram coletadas amostras aleatórias, sendo considerados 400 pixels para áreas com “café” e 400 pixels para áreas com “outros usos”.

Fase III: A terceira fase do trabalho consistiu na análise estatística das imagens classificadas com os dados oriundos do mapa de referência da fase I. A exatidão das classificações foi avaliada a partir da matriz de confusão, tendo como resultado as análises estatísticas do (i) índice kappa, (ii) exatidão global, (iii) acurácia do usuário e (iv) acurácia do produtor.

A exatidão global representa os resultados em porcentagem de acertos, e o mínimo aceito para mapas de uso do solo é de 85%, pois representa o limiar de confiabilidade proposto por Jensen (1996). O índice kappa, proposto por Landis e Koch (1977), considera toda a matriz de confusão no seu cálculo, os quais representam as discordâncias na classificação. Para conceituar os resultados obtidos pelo coeficiente Kappa, foram utilizados os intervalos definidos por Landis e Koch (1977). A acurácia do usuário refere-se aos erros de comissão, ou seja, a delimitação excessiva de determinada classe (FERREIRA; DANTAS; MORAIS, 2007) a partir da probabilidade que um pixel classificado na imagem tem de representar essa classe no campo. Por outro lado, a acurácia do produtor se refere aos erros de omissão, sendo a probabilidade de um pixel de referência ser corretamente classificado. Segundo Ferreira, Dantas e Morais (2007), a omissão se refere a uma imperfeita definição de determinada classe.

3 RESULTADOS E DISCUSSÃO

3.1 Mapa de referência “café” e “outros usos”

O mapa de referência de campo pode ser visualizado na Figura 3. Foram identificados 578,73 ha (32,35%) da classe “café” e 1209,84 ha (67,64%) da classe “outros usos”.

3.2 Análise de imagem orientada a objetos utilizando os algoritmos *k nearest neighbor* (KNN) e *support vector machine* (SVM)

Os resultados obtidos pela análise de imagem orientada a objeto, a partir dos algoritmos classificadores KNN e SVM podem ser visualizados na Figura 4a e 4b, respectivamente. A comparação dos dados obtidos nas classificações com os dados do mapa de referência são descritos na Tabela 1.

Nos valores resultantes da classificação KNN, o uso do solo “café” obteve 43,72% do total área mapeada, e a classe “outros usos” obteve 56,28%. Já nos valores do mapa de referência, a classe “café” apresentou 32,35% do total da área

mapeada, e “outros usos” apresentaram 67,64%. Observa-se que a classe “café” foi superestimada nessa classificação e apresentou 203,31 hectares a mais que o mapa de referência. Assim como o algoritmo KNN, a classe “café” também foi superestimada na classificação SVM, e obteve cerca de 159,64 hectares a mais de área, em relação ao mapa de referência. A superestimativa na área de café classificada pelo SVM é um pouco inferior quando comparada à classificação do KNN.

Foi possível observar que a superestimativa do café ocorreu em ambos os classificadores, principalmente, porque houve confusão de café com alvos como mata e pastagem. Isso ocorreu porque pastagem, café e mata, possuem características semelhantes, e, portanto, respostas espectrais também muito próximas. A confusão com pastagem ocorreu devido à época de aquisição da imagem, que foi no final do período chuvoso. Nessa época do ano, tanto a classe café quanto o pasto apresentaram alto valor de biomassa verde, e conseqüente alto valor de NDVI, que é utilizado pelos dois algoritmos como um dos critérios na classificação. Com isso, as respostas espectrais também se tornaram parecidas, dificultando a discriminação das classes pelos algoritmos. Resultados semelhantes de proximidade do padrão espectral foram encontrados nos trabalhos de Andrade et al. (2013), Cordero-Sancho e Sanders (2005) e Moreira, Adami e Rudorff (2004).

Por outro lado, também foi possível observar que, em alguns casos, houve a não identificação da classe “café” pelo algoritmo KNN, sendo considerada “outros usos”. Isso ocorreu devido à influência do solo exposto que ocorre em plantios novos de café, como é o caso de 23,43 ha do plantio da área de estudo. O solo exposto interferiu na resposta espectral do café, dificultando a classificação. Resultados semelhantes foram encontrados por Moreira et al. (2010).

As estatísticas indicaram um índice kappa de 0,67, para ambos os classificadores (KNN e SVM), o que configura a qualidade da classificação ‘muito boa’ e a exatidão global foi de 91,07% para o KNN e 90,65% para o SVM, consideradas “aceitável” segundo a qualidade de classificação de Jensen (1996). A matriz de confusão é apresentada na tabela 2. Verificou-se que o algoritmo KNN apresentou confusão da classe “outros usos” com “café” em 6,95% dos casos, e mapearam 93,05% da área corretamente. A classe “café” obteve 90,78% de conferência com os dados de referência.

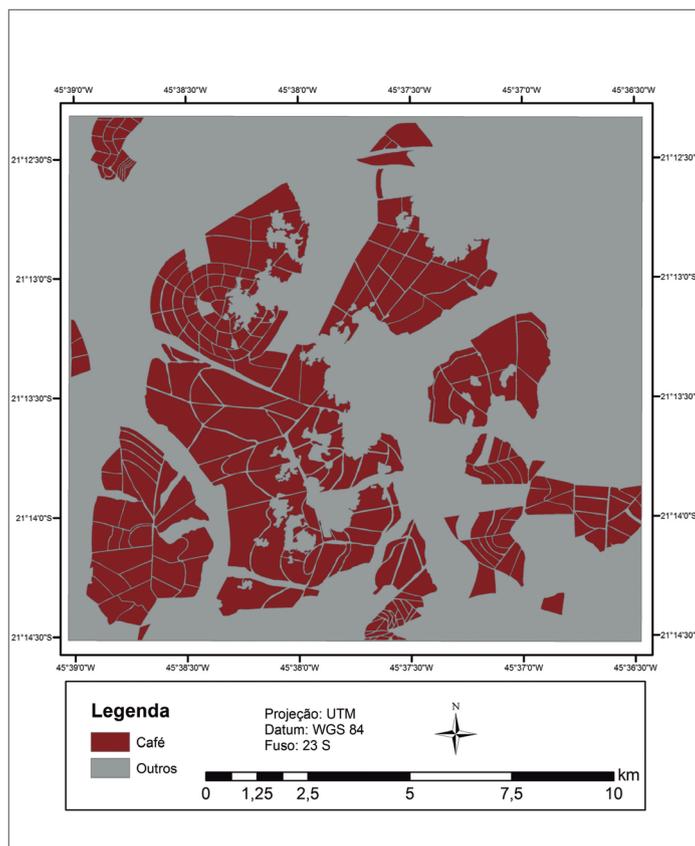


FIGURA 3 - Mapa de referência de café e outros usos.

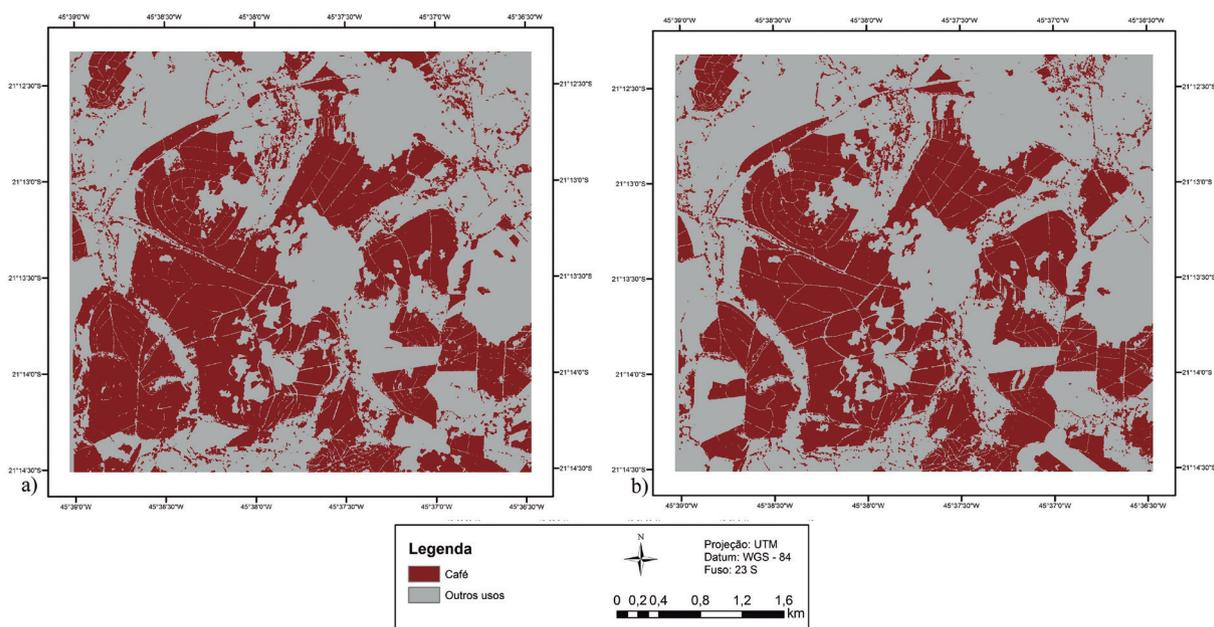


FIGURA 4 - Em a) Mapa da análise de imagem orientada a objetos utilizando o algoritmo KNN e em b) Mapa da análise de imagem orientada a objetos utilizando o algoritmo SVM.

TABELA 1- Quantificação das áreas com café e de outros usos no mapa de referência e nas classificações utilizando os algoritmos KNN e SVM

Classes	Mapa de Referência		Classificação KNN		Classificação SVM	
	ha	%	ha	%	ha	%
Café	578,73	32,35	782,04	43,72	738,37	41,28
Outros usos	1209,84	67,64	1006,53	56,28	1050,20	58,72
Total	1788,57	100,00	1788,57	100,00	1788,57	100,00

TABELA 2 - Matriz de Confusão (%) dos classificadores KNN e SVM.

Dados da Classificação	Dados de referência KNN			Dados de referência SVM		
	Café	Outros usos	Total	Café	Outros usos	Total
Café	90,78	6,95	80,02	89,47	1,29	78,15
Outros usos	9,22	93,05	19,98	10,53	98,71	21,85
Total	100,00	100,00	100,00	100,00	100,00	100,00

Por outro lado, o algoritmo SVM apresentou confusão de “outros usos” com a classe “café” em apenas 1,29% e “café” como “outros usos” em 10,53% de toda área classificada, ou seja, a classe “café” apresentou maior confusão com “outros usos” do que “outros usos” com “café”.

A Tabela 3 apresenta os dados da acurácia do usuário e do produtor dos algoritmos da classificação orientada a objeto. Para o algoritmo KNN, é possível observar que 59,78% da classe “outros usos” e 98,89% da classe “café” representaram a mesma categoria do campo. A acurácia do produtor indicou que as classes “outros usos” e “café” tiveram respectivamente 93,05 e 90,78% de acerto com os dados de referência. O algoritmo SVM apresentou resultados semelhantes ao KNN, sendo um pouco superior para o café na acurácia do usuário e um pouco inferior na acurácia do produtor. Para outros usos, 98,71% da área apresentaram a mesma categoria em campo. Resultados semelhantes, em café, foram encontrados por Faria et al. (2012) utilizando o satélite SPOT, que apresenta uma alta resolução espacial.

O algoritmo KNN vem sendo difundido nos últimos anos para uso e ocupação do solo devido à sua simplicidade e seu desempenho (CAMPOS et al., 2013), e vem sendo utilizado tanto em imagens de média resolução (BUDRESKI et al., 2007; CAMPOS et al., 2013; FERNANDES; NUNES; SILVA, 2012), quanto em alta resolução (YU et al., 2006), obtendo valores razoáveis de classificação, mas descrevendo com acurácia a dinâmica do uso e ocupação do solo (BUDRESKI et al., 2007; CAMPOS et al., 2013). Nesse caso, observou-se que, embora as classificações tenham apresentado valores muito próximos, o KNN apresentou resultados ligeiramente superiores.

O algoritmo SVM é um classificador binário padrão, portanto sua habilidade é conhecida por ser eficiente em classificar duas classes (MOUNTRAKIS; IM; OGOLE, 2011). Embora o índice Kappa da classificação SVM tenha sido igual ao da classificação KNN, e a exatidão global um pouco inferior, foi possível observar índices altos e significativos de acurácia (tanto do produtor quanto do usuário), indicando essa habilidade binária de classificação. Resultados semelhantes foram encontrados por Noma, Korting e Fonseca (2013), que utilizaram algoritmos classificadores na identificação de apenas duas classes: agricultura e não-agricultura. Na classificação de áreas de café, o algoritmo SVM também foi utilizado por Bispo (2013), em imagens do sensor MODIS. O autor obteve 45,75% de acurácia do usuário e 39,19% de acurácia do produtor para a classe café, 65% de exatidão global e 0,32 de índice kappa, considerada razoável. Na classificação do presente trabalho, os índices estatísticos foram superiores quando comparados aos de Bispo (2013) e isso se deve tanto ao fato da classificação ter sido precedida de segmentação, quanto à resolução espacial do Quickbird, que é maior quando comparada à do satélite MODIS. Assim, os resultados sugerem que a resolução espacial mais refinada, associada à técnica de segmentação, aparenta ser um fator preponderante na obtenção de mapeamentos mais acurados de café. Mesmo com a superestimativa de áreas de café por ambos os algoritmos, as técnicas se apresentaram promissoras, onde Marujo et al. (2013) recomenda o uso da classificação orientada a objeto, utilizando imagens de alta resolução espacial em cultivos cafeeiros.

TABELA 3 - Acurácia do usuário e acurácia do produtor dos classificadores KNN e SVM.

Classe	KNN		SVM	
	Acurácia do Usuário	Acurácia do Produtor	Acurácia do Usuário	Acurácia do Produtor
Café	98,89 %	90,78 %	99,79 %	89,47 %
Outros usos	59,78 %	93,05 %	58 %	98,71 %

3.2 Classificação pixel a pixel utilizando o algoritmo *Maximum likelihood* (Maxver)

A Figura 5 apresenta o mapa resultado da classificação utilizando o algoritmo Maxver, e na Tabela 4 se encontra descrita a quantificação do mapa de referência e da classificação utilizando o algoritmo Maxver.

Assim como os demais algoritmos, é possível observar que a classificação Maxver também apresentou uma superestimativa da classe “café”, com relação ao dado de referência. A classificação identificou 50,04% de café na área de estudo enquanto o mapa de referência identificou 32,35%, totalizando 316,17 ha a mais de café. Esse valor foi superior quando comparados aos algoritmos KNN e SVM. A Tabela 5 apresenta os resultados da matriz de confusão e os valores de acurácia do usuário e acurácia do produtor, respectivamente.

Na análise da matriz de confusão, observou-se que a classe “café” foi classificada como “outros usos” em 5,09% e, “outros usos” foram classificados como “café” em 7,43%. Em comparação com as matrizes de confusão dos algoritmos da classificação orientada a objeto, os resultados obtidos pelo classificador Maxver foram melhores. O classificador Maxver obteve 94,91% de conferência entre os dados de referência e os dados classificados para a classe café, enquanto os algoritmos KNN e SVM obtiveram 90,78% e 89,47%, respectivamente. Esses resultados sugerem que, para a cultura do café, nessa época do ano, as informações referentes ao pixel parecem ser mais importantes do que a somatória das demais informações utilizadas pelos algoritmos KNN e SVM.

Analisando-se a acurácia do usuário (Tabela 5) é observado que 98,86% da classe café representaram a mesma categoria em campo. Na acurácia do produtor, a probabilidade da classe “café” ter sido classificada de acordo com os dados de referência foi de 94,91%. Os resultados encontrados na classificação Maxver são superiores quando comparados aos trabalhos de Machado et al. (2010), Marujo et al. (2013) e Tardin, Assunção e Soares (1992), que classificaram café com

satélites de média resolução espacial. Foi possível constatar, também, que a acurácia da classificação melhorou no trabalho de Martínez-Verduzco, Galeana-Pizaña e Cruz-Bello (2011), que classificaram café utilizando o satélite SPOT (que tem uma resolução espacial mais refinada). Assim, verifica-se que a resolução espacial parece ter um peso significativo no mapeamento e classificação do café.

Os principais resultados obtidos a partir dos classificadores são sumarizados na Tabela 6, onde observa-se que a classificação por Maximum likelihood apresenta resultados superiores quando comparados aos demais. Aparentemente, os atributos espectrais considerados na classificação pixel a pixel parecem ser determinantes em imagens de alta resolução para classificação do café. Resultados semelhantes foram encontrados por Duro, Franklin e Dubé (2012), que comparam o resultado das classificações pixel a pixel com orientada a objetos em uma área agrícola, e constataram que as classificações pixel a pixel, utilizando menos classes de uso, produzem resultados semelhantes à classificações orientadas a objetos.

Com base nas análises de imagem orientada a objetos e na classificação pixel a pixel, resultantes da utilização da imagem de alta resolução espacial QUICKBIRD, foi constatado que é possível obter resultados satisfatórios na discriminação da classe ‘café’ de ‘outros usos’, utilizando os métodos aqui propostos. Ressalta-se que a classificação pixel a pixel, utilizando o algoritmo Maximum likelihood, além de ser menos trabalhosa e mais rápida com relação à análise de imagem orientada a objeto, produziu resultados superiores, sugerindo que, para a classificação da cultura do café em imagens de alta resolução, considerar apenas as informações espectrais é uma boa técnica. Além disso, verificou-se que todas as classificações superestimaram a área da classe café, confundindo com os usos como mata e pastagem.

A utilização da imagem de alta resolução espacial teve importância significativa na obtenção de resultados superiores, em comparação com trabalhos que utilizaram imagens de resolução espacial inferior.

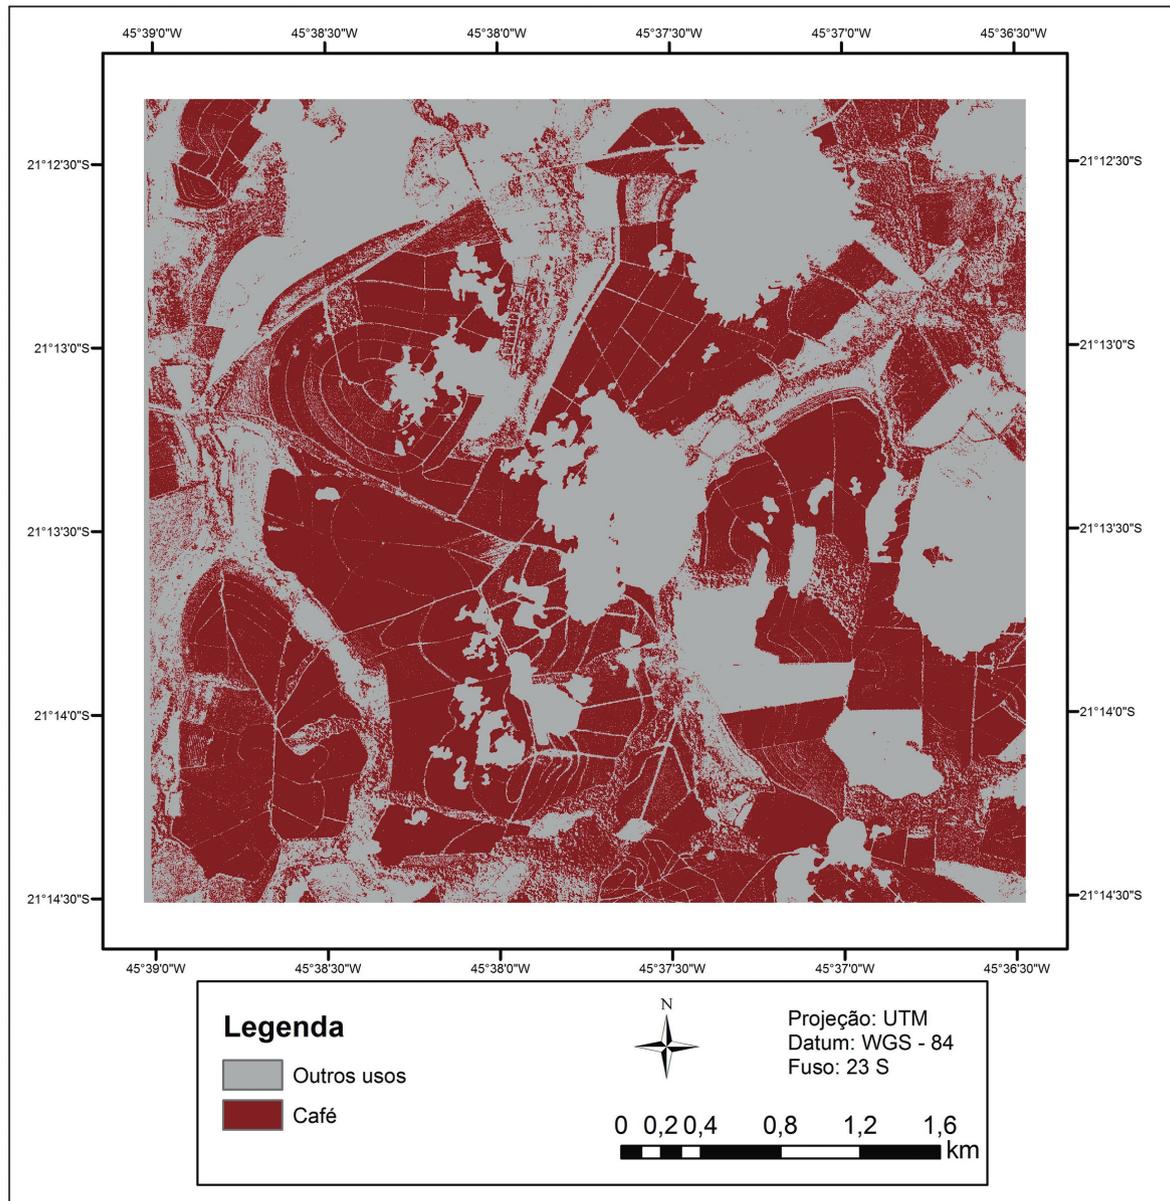


FIGURA 5 - Mapa classificação pixel a pixel utilizando o algoritmo Maxver.

TABELA 4 - Quantificação do mapa de referência e da classificação pelo algoritmo Maxver.

Classes	Mapa de referência		Classificação Maxver	
	ha	%	Ha	%
Café	578,73	32,35	894,9	50,04
Outros usos	1209,84	67,64	893,6	49,96
Total	1788,57	100	1788,57	100

TABELA 5 - Matriz de confusão (%) e acurácia do usuário e do Produtor para a classificação por Maxver.

Dados da Classificação	Matriz de Confusão		Total	Acurácia	
	Dados de referência			Usuário	Produtor
Classes	Café	Outros usos			
Café	94,91%	7,43 %	83,68	98,86 %	94,91 %
Outros usos	5,09 %	92,57 %	16,32	72,83 %	92,57 %
Total	100,00 %	100,00 %	100,00		

TABELA 6 - Valores de índice kappa e exatidão global para cada método de classificação analisado.

Classificações	Kappa	Exatidão Global
<i>K Nearest Neighbor</i> (KNN)	0,67	91,07%
<i>Support vector machine</i> (SVM)	0,67	90,65%
<i>Maximum likelihood</i> (Maxver)	0,78	94,61%

4 CONCLUSÕES

O uso do algoritmo classificador Maxver apresentou maior potencial para discriminação de áreas cafeeiras em imagem de alta resolução espacial. Recomenda-se o uso desse algoritmo de análise de imagem pixel a pixel, quando forem considerados dois tipos de uso da terra, café e não café.

5 REFERÊNCIAS

AGUIRRE-GUTIÉRREZ, J.; SEIJMONSBERGEN, A. C.; DUIVENVOORDEN, J. F. Optimizing land cover classification accuracy for change detection, a combined pixel-based and object-based approach in a mountainous area in Mexico. **Applied Geography**, Amsterdam, v. 34, n. 1, p. 29-37, 2012.

ANDRADE, L. N. de 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, mar. 2013.

ARAÚJO, T. P.; MELLO, F. M. Processamento de imagens digitais: razão entre bandas. **Geociências**, São Paulo, v. 1, p. 121-131, 2010.

BAUSCH, W. C.; HALVORSON, A. D.; CIPRA, J. Quickbird satellite and ground-based multispectral data correlations with agronomic parameters of irrigated maize grown in small plots. **Biosystems Engineering**, New York, v. 101, n. 1, p. 306-315, 2008.

BERNARDES, T. et al. Diagnóstico físico-ambiental da cafeicultura no estado de Minas Gerais, Brasil. **Coffee Science**, Lavras, v. 7, n. 2, p. 139-151, ago. 2012.

BISPO, R. C. **Utilização de dados do sensor modis no monitoramento e mapeamento da cultura de café**. 2013. 69 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2013.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 65, n. 1, p. 2-16, 2010.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Informe estatístico do café, julho de 2013**. Disponível em: <http://www.agricultura.gov.br/arq_editor/file/vegetal/Estatistica/Caf%C3%A9/Informe%20Caf%25E9%20-%20Julho-2013.xls>. Acesso em: 7 set. 2013.

BUDRESKI, K. A. et al. Comparison of segment and pixel-based non-parametric land cover classification in the Brazilian Amazon using multitemporal landsat TM/ETM imagery. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 73, n. 7, p. 813-827, July 2007.

CAMPOS, A. R. et al. Classificação orientada à objeto para mapeamento do uso e cobertura do solo do município de Rio Acima, MG: por crescimento de regiões e por extração de objetos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 8035-8042.

COLTRI, P. P. et al. Classificação de áreas de café em Minas Gerais por meio do novo algoritmo QMAS em imagem espectral Geoeye-1. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 539-546.

- COMPANHIA NACIONAL DE ABASTECIMENTO. **Avaliação da safra agrícola cafeeira 2013, segunda estimativa, maio/2013**. Brasília, 2013. 20 p. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_05_14_09_35_12_boletim_cafe_maio_2013.pdf>. Acesso em: 8 set. 2013.
- 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**, Orono, v. 28, n. 7, p. 1577-1593, Apr. 2007.
- DURO, D. C.; FRANKLIN, S. E.; DUBÉ, M. G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, Ottawa, v. 118, n. 1, p. 259-272, Jan. 2012.
- FARIA, F. A. et al. Automatic fusion of region-based classifiers for coffee crop recognition. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SOCIETY, 30., 2010, Honolulu. **Proceedings...** Honolulu: IGARSS, 2012. p. 1-4.
- FERNANDES, R. F.; NUNES, G. M.; SILVA, T. S. F. Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p. 1251-1260, set. 2012.
- FERREIRA, E.; DANTAS, A. A. A.; MORAIS, A. R. de. Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no município de Lavras, MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 887-894.
- FUKUNAGA, K.; NARENDRA, P. M. A branch and bound algorithms for computing k-nearest neighbors. **IEEE Transactions on Computers**, New York, v. 24, n. 7, p. 750-753, 1975.
- HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, Maryland, v. 23, n. 4, p. 725-749, 2002.
- JENSEN, J. R. **Introductory digital image processing**. Englewood Cliffs: Prentice-Hall, 1996. 51 p.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, Washington, v. 33, n. 1, p. 159-174, 1977.
- 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 2010.
- MARTÍNEZ-VERDUZCO, G. C.; GALEANA-PIZAÑA, J. M.; CRUZ-BELLO, G. M. Coupling community mapping and supervised classification to discriminate Shade coffee from Natural vegetation. **Applied Geography**, Oxford, v. 34, p. 1-9, 2012.
- MARUJO, R. F. B. et al. Classificação orientada à 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.
- 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. **Revista Engenharia Agrícola**, Jaboticabal, v. 30, n. 6, p. 1123-1135, dez. 2010.
- MOREIRA, M. A. et al. Tecnologia de informação: imagens de satélite para o mapeamento de áreas de café de Minas Gerais. **Informe Agropecuário**, Belo Horizonte, v. 28, n. 241, p. 27-37, dez. 2007.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, New York, v. 66, n. 3, p. 247-259, Dec. 2010.
- 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.
- NASCIMENTO, C. R.; ZULLO JÚNIOR, J. Impacto da correção atmosférica de imagens AVHRR/NOAA-17 no cálculo do índice de vegetação NDVI. **Revista Brasileira de Ciências Agrárias**, Recife, v. 5, n. 2, p. 256-264, fev. 2010.
- NOMA, A.; KORTING, T. S.; FONSECA, L. M. G. Integração de dados orbitais de sensoriamento remoto para estimar áreas da floresta Ombrófila densa do Estado do Paraná. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 2250-2257.

- ORTEGA-HUERTA, M. A. et al. Mapping coffee plantations with Landsat imagery: an example from El Salvador. **International Journal of Remote Sensing**, La Libertad, v. 33, n. 1, p. 220-242, Jan. 2012.
- 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.
- ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. In: ERTS SYMPOSIUM, 3., 1973, Washington. **Proceedings...** Washington: NASA, 1973. p. 309-317.
- SILVA, F. M.; ALVES, M. C. **Cafecultura de precisão**. Lavras: UFLA, 2013. 227 p.
- 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.
- TARDIN, A. T.; ASSUNÇÃO, G. V.; SOARES, J. V. Análise preliminar de imagens TM visando a discriminação de café, citrus e cana-de-açúcar na região de Furnas, MG. **Pesquisa Agropecuária Brasileira**, Brasília, v. 27, n. 9, p. 1355-1361, set. 1992.
- TRABAQUINI, K. et al. Caracterização de lavouras cafeeiras, utilizando técnicas de geoprocessamento e sensoriamento remoto, no município de Umuarama, PR. **Ciência e Agrotecnologia**, Lavras, v. 35, n. 1, p. 35-44, fev. 2011.
- VIEIRA, T. G. C. et al. Geotechnologies in the assessment of land use changes in coffee regions of the state of Minas Gerais in Brasil. **Coffee Science**, Lavras, v. 2, n. 2, p. 142-149, Dec. 2007.
- VINCENT, L.; SOILLE, P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Paris, v. 13, n. 6, p. 583-598, June 1991.
- XU, Y. et al. Coarse to fine K nearest neighbor classifier. **Pattern Recognition Letters**, North-Holland, v. 34, p. 980-986, Feb. 2013.
- YAN, G. et al. Comparison of pixel-based and object-oriented image classification approaches-a case study in a coal fire area, Wuda, Inner Mongolia, China. **International Journal of Remote Sensing**, Basingstoke, v. 27, n. 18, p. 4039-4055, Mar. 2006.
- YU, Q. et al. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering & Remote Sensing**, Berkeley, v. 72, n. 7, p. 799-811, July 2006.
- ZULLO JÚNIOR, J. **Correção atmosférica de imagens de satélite e aplicações**. 1994. 204 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 1994.
- ZULLO JÚNIOR, J. et al. Potential for growing Arabica coffee in the extreme south of Brazil in a warmer world. **Climatic Change**, Wageningen, v. 109, p. 535-548, 2011.