



CHRISTIANY MATTIOLI SARMIENTO

**MAPEAMENTO E CARACTERIZAÇÃO DE
ÁREAS CAFEIRAS UTILIZANDO IMAGENS
DE ALTA RESOLUÇÃO ESPACIAL.**

LAVRAS - MG

2014

CHRISTIANY MATTIOLI SARMIENTO

**MAPEAMENTO E CARACTERIZAÇÃO DE ÁREAS CAFEEIRAS
UTILIZANDO IMAGENS DE ALTA RESOLUÇÃO ESPACIAL.**

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

Orientadora:

Dra. Gláucia Miranda Ramirez

Coorientadora:

Dra. Priscila Pereira Coltri

LAVRAS – MG

2014

**Ficha Catalográfica Elaborada pela Coordenadoria de Produtos e
Serviços da Biblioteca Universitária da UFLA**

Sarmiento, Christiany Mattioli.

Mapeamento e caracterização de áreas cafeeiras utilizando
imagens de alta resolução espacial / Christiany Mattioli Sarmiento. –
Lavras : UFLA, 2014.

136 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2013.

Orientador: Gláucia Miranda Ramirez.

Bibliografia.

1. *Coffea arabica*. 2. Sensoriamento remoto. 3. Análise de
imagem orientada ao objeto - Exatidão. 4. Imagens de satélite -
Classificação. 5. Cultura cafeeira - Mapeamento. I. Universidade
Federal de Lavras. II. Título.

CDD – 621.3678

CHRISTIANY MATTIOLI SARMIENTO

**MAPEAMENTO E CARACTERIZAÇÃO DE ÁREAS CAFEEIRAS
UTILIZANDO IMAGENS DE ALTA RESOLUÇÃO ESPACIAL**

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

APROVADA em 24 de Setembro de 2013.

Dra. Margarete Marin Lordelo Volpato	EPAMIG
Dra. Tatiana Grossi Chquiloff Vieira	EPAMIG
Dra. Priscila Pereira Coltri	CEPAGRI/ UNICAMP

Orientadora:

Dra. Gláucia Miranda Ramirez

LAVRAS – MG

2014

A minha mãezinha, matriarca da família, chefe, tenente da casa, comandante e amiga querida Luzia Aparecida Mattioli Sarmiento;

Ao meu querido pai, Emilio Sarmiento Coello, pelo exemplo e por ser meu herói desde sempre!

Ao Luis Felipe Lima e Silva pelos momentos felizes repletos de amor, carinho e companheirismo!

Ao meu carinhoso Tio, Sebastião Donizetti Matioli (in memoriam), que me olha de longe e torce por mim em outro plano;

Dedico

AGRADECIMENTOS

À Universidade Federal de Lavras, pelas oportunidades oferecidas ao longo do Mestrado;

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro;

À minha querida orientadora Gláucia Miranda Ramirez, que acreditou em mim e abriu a primeira porta da minha vida profissional. Obrigada por todas as oportunidades de aprendizado e crescimento não apenas acadêmico, mas como ser humano. Seus ensinamentos e incentivos fizeram a diferença na minha vida!

À minha coorientadora, Priscila Pereira Coltri, por toda atenção, dedicação, paciência com o trabalho e por ter me proporcionado uma oportunidade de crescimento com seus ensinamentos e valiosas sugestões;

À minha banca de qualificação e defesa, composta por Helena Maria Ramos Alves, Margarete Marin Lordelo Volpato, Priscila Pereira Coltri e Tatiana Grossi Chquiloff Vieira por todas as importantes sugestões e contribuições para a evolução do trabalho;

Aos companheiros do Laboratório de Geoprocessamento do Departamento de Engenharia, em especial Jefferson Soares e Otávio Nassur;

Ao pessoal do Departamento de Engenharia, em especial Helem Cristina Carmo e Neuza;

Aos meus irmãos: Emilio Sarmiento Lopez, Cristian Sarmiento Lopez, Norman Arturo Sarmiento Lopez e Fabrício Mattioli Sarmiento, pelas energias positivas;

Aos meus tios e tias: José Antônio Matioli, Lenir Oliveira Matioli, Lourdes de Fátima Matioli e Marina Sarmiento Canizalles;

Aos meus primos: João Vitor Matioli, Laiany Matioli, Rita Rios, Renata Vieira, Roseli Santos, Suyapa Lebron, Thaís Matioli e Thiago Matioli, pelo carinho de sempre;

À Maria Carmen Lima e Silva, pelo carinho e por todos os conselhos;

Às minhas amigas e irmãs de alma: Amanda Andreatta, Geísa Moreira, Jaqueline Tavares, Layla Isadora Nonato Murad, Lyvia Oliveira, Marina Curi, Paula Tanure, Rafaella Abrascio e Tatiana Coelho, por todo apoio, carinho e amizade!!!!!!!!!!

Ao Cassiano Messias, pelos momentos de alegria quando nos encontrávamos;

Aos amigos e amigas da turma de Geografia bacharelado 2008/1- Universidade Federal de Alfenas, cuja amizade eu cultivo até os dias de hoje;

E por último e não menos importante, aos educadores e educadoras que contribuíram para minha formação desde criancinha, principalmente minha eterna e querida professora de Português (que além de tudo me ensinou qual a maior palavra da Língua Portuguesa e revisou o Português deste trabalho) Líbia Aparecida Carlos.

Obrigada pessoal!!!!!!!!!!!!!!

RESUMO

O café sempre foi sinônimo de progresso e contribuiu de maneira decisiva para a industrialização do país e, ainda hoje, é um dos produtos mais importantes na agricultura. No Brasil, a obtenção de informações oficiais referentes à cultura é realizada pela CONAB e pelo IBGE que utilizam informações municipais obtidas por meio da aplicação de questionários padrões. Os dados coletados seguindo esta metodologia são bastante suscetíveis a erros de análise humana, por isso torna-se necessário a ampliação de pesquisas que permitam caracterizar e localizar áreas com plantios de café de maneira mais rápida, precisa e com custos menores. Dentre as técnicas que podem ser consideradas neste contexto, o sensoriamento remoto é uma das que possuem um grande potencial de aplicação, representando um avanço significativo no levantamento de dados, no monitoramento e no planejamento agrícola. Considerando a dimensão da cafeicultura para o país e sabendo da disponibilidade da tecnologia de sensoriamento remoto fazem-se necessários estudos que viabilizem o emprego de imagens de satélite para automatizar a aquisição de dados sobre a cultura. .

Objetivou-se com este estudo mapear áreas cafeeiras a partir de métodos de classificação por análise de imagens orientada ao objeto e pixel-a-pixel no município de Campos Gerais - MG utilizando imagem de alta resolução espacial do satélite QUICKBIRD. O estudo foi dividido em duas partes, sendo que o objetivo da primeira foi discriminar classes de café de outros usos do solo; e o da segunda parte foi realizar o mapeamento de uso e ocupação da terra considerando classes de porcentagem de cobertura do terreno pelas plantas de café. Realizou-se primeiramente a discriminação de áreas "café" e "outros usos" a partir de técnicas de análise de imagem orientada ao objeto onde foram utilizados os algoritmos *k nearest neighbor* e *support vector machine*. Para fins de comparação, foram realizadas técnicas de classificação pixel a pixel utilizando o algoritmo *maximum likelihood*. A partir destas informações, analisou-se a exatidão resultante dos mapeamentos em comparação com o mapa de referência da área e foi constatado que a classificação pixel a pixel por *maximum likelihood* obteve os melhores resultados, com 0,78 de índice kappa e 94,61% de exatidão. Na segunda parte do estudo foram coletados dados referentes a 17 talhões da propriedade estudada a fim de categorizar o uso café em classes segundo sua porcentagem de cobertura. As classes consideradas foram: café classe 1 (30-36%), café classe 2 (45-50%), café classe 3 (50-54%), café classe 4 (> 54%), solo exposto, mata, pastagem e corpos d água. Foi realizado o mapeamento do uso e ocupação da terra utilizando análises de imagem orientada a objetos (empregando os algoritmos *k nearest neighbor* e *support vector machine*) e classificação pixel a pixel (empregando algoritmo *maximum likelihood*). Os resultados apontaram que a análise de imagens orientada a objetos utilizando o algoritmo *k nearest neighbor*, foi o melhor

método para mapeamento de uso e ocupação da terra considerando as classes de porcentagem de cobertura do terreno, com índice kappa 0,76 e exatidão global 86,34%.

Palavras-chave: *Coffea arabica*. Sensoriamento remoto. Classificação. Análise de imagem orientada ao objeto. Exatidão.

ABSTRACT

Coffee has always been synonym progress and it has contributed decisively to the industrialization of the country and, even today, it is one of the most important products in agriculture. In Brazil, official information about the crop is obtained by IBGE and CONAB (Brazilian Governmental Institutions), using local information acquired through standard questionnaires. Data collected using this approach is quite susceptible to human mistakes, so it becomes necessary to extend research to characterize and locate areas with coffee plantations faster, more accurately and with lower costs. Among the techniques that can be considered in this context, remote sensing is one of those that have great potential, representing a significant advance in data collection, monitoring, and agricultural planning. Given the size of the coffee production in the country and knowing the availability of remote sensing technology, research shows itself as necessary in order to enable the use of satellite images to automate the acquisition of data on the crop. This study aimed to compare methods of object-oriented image analysis in the distinction of coffee plantations in the city of Campos Gerais - MG using high resolution images from the QuickBird satellite. The study was divided in two, where the first goal was to discriminate coffee classes from other land uses, and the second part was to perform mapping of land usage and occupation considering classes of percentage of ground coverage by coffee plants. First, the areas were discriminated as "coffee" areas, and "other uses" through object-oriented image analysis in which k nearest neighbor and support vector machine algorithms were used. For purposes of comparison, classification techniques were performed pixel by pixel using the *maximum likelihood* algorithm. From this information, we analyzed the accuracy of the resulting maps in comparison to the reference map of the area and it was found that the classification pixel by pixel through *maximum likelihood* obtained the best results, with kappa index of 0,78 and 94,61% accuracy. In the second part of the study, data regarding 17 plots from the farm were collected, in order to categorize the use of coffee in classes according to their coverage percentage. The classes considered were: coffee class 1 (30-36 %) , coffee class 2 (45-50 %) , coffee class 3 (50-54 %) , coffee class 4 (> 54 %) , bare soil , forest, grassland and water bodies. Mapping of usage and land occupation were performed using object-oriented image analysis (using the algorithms k nearest neighbor and support vector machine) and classification pixel by pixel (using *maximum likelihood* algorithm). The results showed that the analysis of object-oriented images using the k nearest neighbor was the best method for mapping the land use and occupation considering the classes of percentage of land coverage , with kappa index of 0,76 and overall accuracy of 86,34% .

Key words: *Coffea arabica*. Remote sensing. Classification. Accuracy.

SUMÁRIO

	CAPÍTULO 1.....	15
1	INTRODUÇÃO.....	16
2	REFERENCIAL TEÓRICO.....	19
2.1	Aspectos gerais da cultura cafeeira	19
2.2	Sensoriamento remoto no estudo de culturas perenes	20
2.3	Imagens de alta resolução espacial na agricultura.....	23
2.4	Processamento Digital de Imagens	26
2.4.1	Conversão de níveis de cinza para valores físicos	27
2.4.2	Análise de imagens orientada a objetos	29
2.4.3	Classificação de imagens pixel a pixel	33
3	CONSIDERAÇÕES GERAIS.....	34
	REFERÊNCIAS.....	35
	CAPÍTULO 2 Discriminação da cultura cafeeira de outros usos.....	42
1	INTRODUÇÃO.....	43
2	MATERIAL E MÉTODOS.....	48
2.1	Material.....	50
2.2	Metodologia.....	52
2.2.1	Eliminação das nuvens e sombras	53
2.2.2	Correção atmosférica e radiométrica	54
2.2.3	Mapa de referência do uso e ocupação da terra.....	55
2.2.4	Análise de imagem orientada ao objeto.....	57
2.2.4.1	Segmentação.....	58
2.2.4.2	Classificação utilizando <i>k nearest neighbor</i> e <i>support vector machine</i>.....	60
2.2.5	Classificação pixel a pixel utilizando <i>maximum likelihood</i>..	61
2.2.6	Exatidão	61
3	RESULTADOS.....	64

3.1	Mapa de referência "café" e "outros usos"	64
3.2	Análise de imagem orientada ao objeto utilizando o algoritmo <i>K Nearest Neighbor</i>	65
3.3	Análise de imagem orientada ao objeto utilizando o algoritmo <i>Support vector machine</i>	70
3.4	Classificação pixel a pixel utilizando o algoritmo <i>maximum likelihood</i>	74
4	CONSIDERAÇÕES GERAIS.....	78
5	CONCLUSÃO.....	79
	REFERÊNCIAS.....	80
	CAPÍTULO 3 Mapeamento do uso da terra considerando as classes de cobertura do café.....	86
1	INTRODUÇÃO.....	87
2	MATERIAL E MÉTODOS.....	90
2.1	Material.....	92
2.2	Metodologia.....	97
2.2.1	Eliminação das nuvens e sombras	98
2.2.2	Correção atmosférica e radiométrica.....	99
2.2.3	Mapa de referência da área de estudo.....	100
2.2.4	Análise de imagem orientada ao objeto.....	101
2.2.4.1	Segmentação.....	102
2.2.4.2	Classificação utilizando <i>k nearest neighbor</i> e <i>support vector machine</i>	104
2.2.5	Classificação pixel a pixel utilizando <i>maximum likelihood</i> ...	105
2.2.6	Exatidão	106
3	RESULTADOS.....	108
3.1	Mapa de referência da área de estudo.....	108
3.1	Análise de imagem orientada ao objeto utilizando o algoritmo <i>K Nearest Neighbor</i>	109
3.2	Análise de imagem orientada ao objeto utilizando o algoritmo <i>Support vector machine</i>	116

3.3	Classificação pixel a pixel utilizando o algoritmo <i>maximum likelihood</i>	123
4	CONSIDERAÇÕES GERAIS	131
5	CONCLUSÃO	132
	REFERÊNCIAS	133
	CONSIDERAÇÕES FINAIS	137
	Capítulo 2	137
	Capítulo 3	137

CAPÍTULO 1

Introdução Geral

1 INTRODUÇÃO

O café sempre foi sinônimo de progresso e contribuiu de maneira decisiva para a industrialização do país e, ainda hoje, é um dos produtos mais importantes na agricultura. O Brasil é responsável por aproximadamente 35% da produção mundial de café e 25% das exportações de grãos verdes (BRASIL, 2013). Os estados de Minas Gerais, Espírito Santo e São Paulo são os maiores produtores, responsáveis por 52%, 26% e 9% da produção nacional (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2013). Na região sul de Minas Gerais, a produção de café se configura como atividade econômica dominante, produzindo no ano de 2011 um total de 519.908 toneladas considerada a principal região produtora do território brasileiro (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2013).

Considerando o produto como fonte geradora de renda e ao mesmo tempo, suscetível à instabilidade comercial, devido a diversos fatores, torna-se necessário a efetiva utilização de tecnologia para obtenção de informações, na busca por medidas que visem manter a produção estável e sustentável (BERNARDES, 2013).

No Brasil, a obtenção de informações oficiais referentes à cultura (tais como área plantada, quantidade produzida e área colhida, por exemplo) é realizada pela CONAB - Companhia Nacional de Abastecimento - e pelo IBGE - Instituto Brasileiro de Geografia e Estatística - que utilizam informações municipais obtidas por meio da aplicação de questionários padrões a produtores, cooperativas e representantes de órgãos públicos e privados.

Segundo Collares, Lauria e Carrilho (1993), Ippoliti-Ramilo et al. (1999) e Souza et al. (2012), os dados coletados seguindo esta metodologia são bastante

suscetíveis a erros de análise humana, podendo os resultados diferirem entre as diversas instituições governamentais, pois as informações coletadas encontram-se fragmentadas e são de difícil visualização, tornando complexo o entendimento por completo além de dificultar a estimativa da precisão dos dados obtidos. Outro problema relacionado à aquisição de dados da cafeicultura brasileira, segundo Duarte e Brito (2007), é o alto custo financeiro e de pessoal demandados pela metodologia citada anteriormente. É necessária a ampliação de pesquisas que permitam caracterizar e localizar áreas com plantios de café de maneira mais rápida, precisa e com custos menores (MOREIRA et al., 2007a).

Dentre as técnicas que podem ser consideradas neste contexto, o sensoriamento remoto é uma das que possuem um grande potencial de aplicação, pois representa, segundo Dallemand et al. (1988) e Epiphonio, Leonardi e Formaggio (1994), um avanço significativo no levantamento de dados, no monitoramento e no planejamento agrícola. Ainda são necessárias pesquisas que permitam que o sensoriamento remoto seja utilizado de maneira efetiva no levantamento, mapeamento e monitoramento de áreas cafeeiras, servindo de apoio aos métodos operacionais empregados atualmente.

Considerando a dimensão da cafeicultura para o país, a necessidade de previsão de safras eficaz e sabendo da disponibilidade da tecnologia de sensoriamento remoto fazem-se necessários estudos que viabilizem o emprego de imagens de satélite para automatizar a aquisição de dados sobre a área plantada e as características biofísicas de cafezais. O uso de imagens de alta resolução espacial possibilita um conhecimento mais detalhado do comportamento espectral de plantios de café de modo a diminuir os trabalhos de campo e apoiar os métodos operacionais utilizados atualmente. Assim sendo, técnicas de sensoriamento remoto permitem mapear e monitorar de maneira efetiva a cultura cafeeira por meio do levantamento de informações sobre o meio físico com imagens de alta resolução espacial.

Desta maneira, com este trabalho buscou-se realizar o mapeamento e caracterização de plantios de café utilizando imagens de alta resolução espacial juntamente com técnicas de análise de imagens orientada a objetos. O estudo se iniciou com base na necessidade em localizar, quantificar e caracterizar plantios de café. As questões levantadas neste trabalho foram:

- a) Imagens de alta resolução espacial são eficientes no mapeamento e caracterização de plantios de café?
- b) A técnica de análise de imagens orientada a objetos discrimina café de outros usos?
- c) O *software* ENVI EX classifica uso e ocupação da terra tendo em vista o uso café categorizado em classes de porcentagem de cobertura do terreno?
- d) O uso de imagens de alta resolução espacial aliado à classificação orientada a objetos produz resultados satisfatórios?

Esta dissertação é composta por três capítulos. O primeiro capítulo apresenta uma introdução geral e o referencial teórico do tema proposto na dissertação. O segundo capítulo expõe o mapeamento de plantios de café diferenciando-o de outros usos, utilizando classificações automáticas. O terceiro capítulo apresenta o mapeamento e caracterização do uso e ocupação da terra considerando a categorização do uso café em porcentagens de cobertura do terreno pelas plantas de café.

2 REFERENCIAL TEÓRICO

2.1 Aspectos gerais da cultura cafeeira

O cafeeiro (*Coffea arabica*) é originário da Etiópia, se expandiu para Arábia no século XVII e em seguida para Holanda. No Brasil, inicialmente as sementes foram trazidas do Suriname para o Pará em 1727, se disseminando para o Estado do Maranhão, Bahia, Rio de Janeiro, São Paulo e Minas Gerais (ROSA, 2007). Caracteriza-se como planta perene de sub-bosque, adaptada ao clima subtropical com temperaturas amenas variando entre 18 °C e 22 °C. Pertence à família das rubiáceas tendo como peculiaridade visível seus frutos vermelhos que, quando maduros se assemelham a rubis, daí o nome rubiáceo (SOARES, 2012).

Para Silva (2011), o café é uma *commodity* onde o valor aumenta com o nível da qualidade, quanto melhor a sanidade, a aparência e a qualidade da bebida, mais valorizado é o produto. A busca por produção com qualidade e os melhores meios de comercialização são as principais metas deste segmento. Zambolim (2001) afirma que o desempenho da cafeicultura ocorre em virtude de vários fatores, onde se destacam a redução dos custos de produção, o aumento na produtividade, a busca constante de qualidade, a preservação do meio ambiente, a conquista de novos mercados consumidores e a definição de políticas agrícolas para o setor.

A aplicação de técnicas agronômicas cada vez mais modernas, objetiva principalmente a produtividade e, neste caso a utilização do sensoriamento remoto e, conseqüentemente o emprego das geotecnologias podem contribuir para esse fim.

Moreira et al. (2007a) salientam que a cafeicultura brasileira ainda carece de informações sobre seu sistema produtivo, principalmente sobre sua extensão, localização e ambiente em que é cultivada, ou seja, há a necessidade

da caracterização dos plantios de café de forma a obter não apenas sobre sua área plantada, mas também dados de seus parâmetros biofísicos.

2.2 Sensoriamento remoto no estudo de culturas perenes

Nas culturas perenes, onde o desenvolvimento da planta é lento, fatores como o solo, o uso de implementos agrícolas, os tratamentos culturais, o sombreamento intra e entre fileiras e as características sazonais da planta são fundamentais no estudo do comportamento espectral dessas culturas (EPIPHANIO; LEONARDI; FORMAGGIO, 1994). Já os fatores relacionados à atmosfera, topografia e tipo do sensor afetam de maneira parecida as culturas anuais e as perenes.

Trabalhos realizados em culturas perenes, tais como citros e café, mostram que, apesar das dificuldades para a compreensão da resposta espectral, a utilização do sensoriamento remoto orbital é viável para o levantamento e monitoramento dessas culturas.

Em Minas Gerais, Moreira, Adami e Rudorff (2004) mostraram que a cultura do café, embora apresente variações no comportamento espectral devido a fatores como espaçamento, idade, estágio fenológico, época do ano, pode ser identificada e mapeada em imagens de satélites com razoável precisão, desde que existam informações complementares sobre a cultura, quer seja de levantamentos ou de técnicos que trabalham no local de interesse.

A oscilação na quantidade de café produzido ocorre normalmente devido à variação do preço do produto no mercado, cuja quantidade da produção está relacionada à diminuição da área plantada (erradicação e abandono de cafezais), como também, a menor aplicação de recursos financeiros (adubação, tratamento fitossanitários etc. no manejo da cultura. Diante disso, a realização de levantamentos e dimensionamento destas áreas, bem como, o estabelecimento de

uma metodologia ágil e confiável, que possibilite atualização periódica das informações é de grande importância para o setor cafeeiro (MOREIRA et al., 2007b).

Conhecer a dinâmica do uso do solo torna-se indispensável para análise dos processos agrícolas referentes à cultura cafeeira. Para Machado et al. (2010), a imagem orbital é uma ferramenta valiosa para fins de mapeamento em razão de sua característica multiespectral e multitemporal, por abranger uma grande área, pela possibilidade visual e digital e ao baixo custo quando comparado aos métodos tradicionais. Desde o lançamento do Landsat, na década de 70, vários métodos de mapeamento de áreas cafeeiras têm sido desenvolvidos.

Tardin, Assunção e Soares (1992) realizaram estudos envolvendo café, cana-de-açúcar e citrus na região de Furnas, MG, a partir de imagem Landsat TM. O autor mapeou a região utilizando as bandas 3 (vermelho), 4 (infravermelho) e 5 (infravermelho médio) e o método de classificação supervisionada por máxima verossimilhança. A banda 3 foi considerada fundamental para discriminação de café.

Adami (2003), com o propósito de estimar áreas cultivadas com café, milho e soja, utilizou técnicas de geoprocessamento associadas a estimadores por expansão direta e análises de regressões e, concluiu que é possível estimar áreas com café a partir da metodologia utilizada. Segundo o autor, para a cultura do café, o estimador de regressão teve eficiência relativa bem maior que o estimador por expansão direta devido à disponibilidade de imagens livres de cobertura de nuvens. Além disso, o coeficiente de variação passou de 34,9% na expansão direta para 12,9% na regressão.

Moreira, Adami e Rudorff (2003), estudando o comportamento espectral de áreas de café em imagens dos sensores TM e ETM+ do LANDSAT, com o objetivo de mapear a cultura, mostraram que as imagens apropriadas para o mapeamento de áreas cafeeiras em formação e produção foram as das bandas 4

(infravermelho próximo) desses sensores, adquiridas na época mais seca do ano (agosto e setembro).

Alguns trabalhos foram desenvolvidos com o propósito de avaliar os parâmetros agronômicos de culturas perenes em comparação com a sua resposta espectral, entre eles pode-se citar o de Covre (1989), que avaliou a influência de parâmetros culturais de plantios de citros sobre os dados do TM/LANDSAT. Dentre os parâmetros culturais avaliados, a porcentagem de cobertura do terreno por árvores de citros e a proporção de vegetação nas entrelinhas dos talhões foram as que influenciaram mais significativamente a resposta espectral dos pomares. O parâmetro “porcentagem de cobertura do terreno por árvores de citros” não apresentou relacionamento significativo com a banda 4. Segundo o autor, tal fato deveu-se ao aumento de sombras associado ao aumento deste parâmetro.

Ainda segundo Covre (1989), a complexidade da resposta espectral dos pomares de citros pode ser expressa em função da variação de três parâmetros básicos da superfície: as plantas de citros, as sombras produzidas por elas e o substrato. A variabilidade de situações encontradas em cada um destes componentes e as influências de uns sobre os outros, causam uma grande heterogeneidade de respostas para o sensor TM do satélite LANDSAT.

Leonardi (1990) utilizou dados do TM/LANDSAT e dados levantados em campo para avaliar a influência dos parâmetros culturais do café sobre sua resposta espectral. Os resultados mostraram que parâmetros relativos às características das plantas (tais como ano de poda, altura, porcentagem de cobertura do terreno, idade, vigor vegetativo e tipo de poda) são mais correlacionados com a refletância do cafezal do que parâmetros relativos às características do substrato (tais como matéria orgânica, ervas daninhas verdes e solo exposto) ou da geometria (orientação das fileiras de plantio, declividade e orientação do declive, por exemplo).

Ramirez et al. (2006) avaliaram o impacto do aumento das resoluções radiométrica e espacial da imagem pancromática Ikonos-II em comparação com as imagens do Landsat/ETM+ com o objetivo de identificar plantios de café. Concluiu que as imagens do satélite Ikonos- II identificam 1,5 vezes mais talhões do que o satélite Landsat/ETM+, possuindo melhor desempenho.

Machado et al. (2010) estabeleceram uma metodologia para mapeamento de áreas cafeeiras na Zona da Mata mineira por meio de imagens de satélite e fotografias aéreas não convencionais. Os autores realizaram classificações utilizando combinações entre as bandas do sensor, além de imagens NDVI (Índice de vegetação por diferença normalizada), SAVI (Índice de Vegetação Ajustado ao Solo) e Principais componentes 1 e 2. As melhores classificações foram alcançadas com as combinações das bandas 3 - 4, 3 - 4 -5 e 3 - 4 - 7.

2.3 Imagens de alta resolução espacial na agricultura

A partir da segunda metade da década 90, visando superar algumas limitações das imagens adquiridas pelos satélites de média resolução espacial, novos satélites de recursos naturais começaram a ser desenvolvidos. Esses satélites, com mudanças tecnológicas significativas nos sensores, principalmente na resolução espacial, geraram grande expectativa na utilização desses dados na agricultura.

Dentre os satélites de alta resolução disponíveis no mercado, seguem os mais comercializados (Quadro 1):

Quadro 1: Informações sobre os satélites de alta resolução mais comercializados.

Satélites	Resolução espacial	Data de lançamento
Ikonos	1 m (pancromático) / 4 m (multiespectral)	24/09/1999
QUICKBIRD	0,60 m (pancromático) / 2,4 m (multiespectral)	18/10/2001
WorldView - 1	0,5 m no nadir/0,59 m off- nadir	18/09/2007
GeoEye - 1	0,50 m (pancromático) / 2,0 m (multiespectral)	06/09/2008
RapidEye	5 m	29/08/2008
WorldView - 2	0,50 m (pancromático) / 2,0 m (multiespectral)	08/10/2009

Fonte: GlobalGeo (2013)

No entanto, devido ao amplo número de sucedidas pesquisas envolvendo o satélite QUICKBIRD na análise de culturas agrícolas, o mesmo foi escolhido para realização deste trabalho. O satélite QUICKBIRD é considerado o primeiro satélite submétrico do mundo, apresentando imagens com 60 cm de resolução espacial no modo pancromático e 4 bandas multiespectrais com resolução espacial de 2,44 m (DIGIBASE, 2014).

Com relação à utilização de imagens de alta resolução espacial no estudo de áreas cafeeiras, é notória a necessidade de estudos mais aprofundados. No Brasil, onde se realiza a maior quantidade de pesquisas sobre a cultura, foram realizados alguns estudos utilizando imagens de alta resolução espacial do satélite QUICKBIRD, entre eles os desenvolvidos por Tewelde e Cabral (2011), que utilizaram imagens QUICKBIRD em seu estudo sobre a perda de áreas agrícolas devido à expansão urbana em Eritrea.

Ramirez (2009) utilizou imagens QUICKBIRD visando identificar a interação entre os parâmetros físicos de áreas cafeeiras e a resposta espectral

registrada nas bandas do satélite. Ramirez e Zullo-Junior (2010) avaliaram a utilização do satélite QUICKBIRD na determinação dos parâmetros biofísicos de plantios de café na Região da Alta Mogiana.

Como ainda são poucas as pesquisas desenvolvidas com imagens de alta resolução espacial na cafeicultura, para o embasamento teórico de trabalhos que visem à aplicação de imagens de alta resolução espacial na agricultura, utilizam-se estudos realizados em outras culturas, que na sua maioria são desenvolvidos fora do país.

Utilizando imagem QUICKBIRD (bandas 1, 2, 3 e 4) em comparação com a imagem gerada por uma câmera Kodak MegaPlus (possuindo bandas espectrais correspondentes às do QUICKBIRD), Yang, Everitt e Bradford (2006) que avaliaram plantações de sorgo. As melhores correlações entre os dados espectrais das imagens e o rendimento da cultura foram com as bandas do azul e do verde e com um índice de vegetação denominado GVI - Índice de vegetação verde-proposta por Rouse et al. (1973). A imagem do QUICKBIRD também explicou de 38% a 71% (para o pior e melhor resultado encontrado, respectivamente) da variabilidade da produção existente na área analisada.

Bauschet, Halvorson e Cipra (2008) apontam em seu estudo que imagens multiespectrais do satélite QUICKBIRD podem estimar parâmetros agrônômicos, fornecendo informações quantitativas sobre os parâmetros biofísicos de várias plantas.

Yang, Everitt e Bradford (2004) analisaram o desenvolvimento e o rendimento de plantios de algodão, utilizando imagem QUICKBIRD (bandas 1, 2, 3 e 4) e imagens obtidas a partir do sensor CCD aerotransportado de uma câmera Kodak MegaPlus. Embora a imagem do QUICKBIRD possuísse resolução espacial inferior à da câmera, 2,4 m contra 0,67 m, os dois sensores obtiveram correlações significativas com o rendimento da cultura, mostrando que a resolução de 2,8 m foi suficiente para traçar os diferentes níveis de

produção da cultura do algodão para a área analisada. De acordo com os autores, os resultados deixaram evidente que a utilização de imagens do QUICKBIRD possui a vantagem de cobrir uma área maior e sua obtenção é menos dispendiosa e trabalhosa, quando comparada com a cobertura aerotransportada.

2.4 Processamento Digital de Imagens

Uma imagem é definida como uma função bidimensional, $f(x, y)$, em que x e y são coordenadas espaciais e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de nível de cinza da imagem. Quando x , y e os valores de nível de cinza de f são quantidades finitas e discretas, denomina-se imagem digital. A imagem é composta por um número finito de elementos, chamados pixels, com localização e valor específico (GONZALES; WOODS, 2010).

O processamento digital de imagens teve um impulso na década de 50, com o desenvolvimento dos computadores digitais e o início do programa espacial norte - americano, onde havia a captura de imagens da Lua via sonda Ranger (NATIONAL AERONAUTICS AND SPACE ADMINISTRATION - NASA, 2013), seguido do processamento destas imagens para correção de distorções inerentes à câmara de TV acoplada na sonda.

O progresso do processamento digital de imagens possui estreita relação com o desenvolvimento dos computadores, visto que o uso de imagens digitais depende da capacidade de armazenamento e do desempenho computacional do hardware. Da década de 1960 até os dias atuais, a área de processamento digital de imagens cresceu rapidamente, sendo utilizada para diversas aplicações. Segundo Gonzales e Woods (2010), procedimentos computacionais como realce do contraste e codificação de níveis de cinza em cores são utilizados para facilitar a interpretação de imagens.

Ponzoni, Shimabukuro e Kuplich (2012) afirmam que no processamento digital de imagens estão incluídas técnicas voltadas para o processamento de dados, sendo estas o pré - processamento, o realce visual e a classificação digital. O pré-processamento visa corrigir as imperfeições geométricas e radiométricas, bem como a correção atmosférica. Segundo Ramirez (2009), o pré-processamento de imagens tem a finalidade de minimizar os problemas resultantes de perturbações que ocorrem na atmosfera e no sistema sensor, as quais interferem na interpretação dos dados.

O realce visa melhorar a qualidade da imagem para melhor discriminação dos objetos e a classificação digital envolve a utilização de métodos onde os pixels são associados às classes de acordo com determinadas características.

Na classificação digital, são empregados dois tipos de algoritmos classificadores, sendo estes pixel a pixel e por regiões ou objetos. Na classificação pixel a pixel, há o emprego da informação espectral de cada pixel sem considerar os atributos textura e espacial (YAN et al., 2006). Utilizando os algoritmos classificadores por regiões ou objetos, na análise de imagem orientada a objetos há a segmentação da imagem, onde são considerados atributos espaciais, espectrais e de textura (BLASCHKE, 2010).

Posterior a isto, métodos de exatidão são acionados como forma de avaliar a classificação. Aguirre-Gutiérrez, Seijmonsbergen e Duivenvoorden (2012) afirmam que a avaliação do conjunto de dados classificados indica que houve concordância ou não com os resultados de referência.

2.4.1 Conversão de níveis de cinza para valores físicos

Para caracterizar espectralmente objetos existentes na superfície terrestre mediante utilização de imagens de satélite, Ponzoni, Shimabukuro e Kuplich

(2012) enfatizam a respeito da conversão de níveis de cinza para valores físicos, afirmando que os valores de níveis digitais originais não servem como referência para caracterização espectral de objetos.

As imagens originais do satélite QUICKBIRD são quantizadas em níveis de cinza. Porém, segundo Bernardes (2013), estes valores conflitam entre si devido às características específicas do sensor em cada faixa do espectro eletromagnético, bem como as condições ambientais em que as imagens são geradas. Pereira, Batista e Roberts (1996) afirmam que a utilização de valores físicos, sobretudo da refletância, possibilita um melhor monitoramento do comportamento de uma determinada cobertura, uma vez que mudanças na sua resposta espectral estariam relacionadas somente às mudanças nas propriedades estruturais/espectrais da cobertura e não às mudanças no ângulo de iluminação solar ou variações dos sensores (degradação).

A conversão dos números digitais para valores de refletância objetiva permitir a caracterização espectral dos objetos bem como a realização de cálculos que incluem dados de imagens de diferentes bandas espectrais e/ou diferentes sensores (PONZONI; SHIMABUKURO; KUPPLICH, 2012). Para conversão de níveis digitais em valores físicos, é necessário o conhecimento de algumas características do sensor e as características ambientais nas quais as imagens são geradas.

A correção atmosférica é realizada com a finalidade de minimizar o efeito da atmosfera sobre dados orbitais, utilizando dados provenientes da caracterização da atmosfera, especificamente em relação às concentrações de vapor d'água, O_3 , profundidade óptica e tipo e concentração de aerossóis.

Vários métodos têm sido desenvolvidos objetivando a correção atmosférica e radiométrica de imagens de satélite, a exemplo do SCORADIS - Sistema de Correção Radiométrica de Imagens de Satélite - elaborado por Zullo-Junior (1994). Este *software* é baseado na teoria e nos parâmetros atmosféricos

calculados pelo MODELO 5S - *Simulation du Signal Satellitaire dans le Spectre Solarie* - realiza a correção atmosférica e radiométrica e foi desenvolvido a partir de trabalhos experimentais de acordo com as condições atmosféricas brasileiras.

Trabalhos desenvolvidos por Nascimento e Zullo-Junior (2010), Ponzoni et al. (2000), Ramirez e Zullo-Junior (2010), Volpato (2002) e Watanabe, Imai e Samizava (2009), utilizaram o *software* SCORADIS para correção atmosférica.

Mercante et al. (2009) em seu estudo sobre as características espectrais da soja ao longo do ciclo vegetativo, realizaram a correção atmosférica em imagens Landsat a partir de imagens do sensor MODIS - *Moderate Resolution Imaging Spectroradiometer* - utilizando o *software* SCORADIS. A partir de dados MODIS, houve a correção atmosférica e o cálculo da FRB - fator de refletância bidirecional de superfície. O autor conclui seu trabalho afirmando que a curva espectral do FRB de superfície apresentou coerência com o comportamento espectral típico da vegetação.

Coltri (2012) em seu estudo sobre a cafeicultura brasileira no contexto das mudanças climáticas utilizou dados do sensor MODIS para correção atmosférica e radiométrica utilizando o *software* SCORADIS.

2.4.2 Análise de imagens orientada a objetos

Segundo Hay e Castilla (2007), análise de imagem orientada a objetos é um subcampo da ciência da informação geográfica onde há o desenvolvimento de métodos automáticos de particionamento de imagens considerando não somente o valor do pixel, mas também o objeto no espaço. O processo inicia-se na segmentação, onde há o particionamento de imagem pancromática ou multiespectral de alta resolução espacial cujo nível de detalhe está associado à detecção de objetos e regiões de interesse. Supondo que R represente toda a região espacial ocupada por uma imagem, o processo da segmentação particiona

R em n sub-regiões, $R_1, R_2... R_n$, de tal forma que cada pixel se enquadre dentro de uma região requerendo que os pontos estejam conectados de alguma forma predefinida, no entanto, as regiões devem estar separadas (GONZALES; WOODS, 2010). O fator fundamental da segmentação é a divisão de regiões que satisfaça as condições mencionadas acima. Cada região é homogênea com relação a alguma propriedade, como valor de cinza ou textura (ROEDINK; MEIJSTER, 2001) e é nessa fase que ocorre a extração de informações com base em características espectrais, espaciais e de textura.

Segundo Gonzales e Woods (2010), existem várias técnicas de segmentação: Por detecção de ponto, linha e borda, por limiarização, baseada em região, utilizando *watersheds* e, por último, pelo uso do movimento.

A principal técnica de segmentação é baseada na transformada watershed, conhecida como divisor de águas (MEDEIROS, 2003), considerada não hierárquica e por simulação de imersão (VINCENT; SOILLE, 1991).

Imagens Landsat/TM e Landsat/ETM+ podem ser utilizadas para segmentação de imagens, onde Medeiros (2003) afirma que a principal ferramenta da técnica de segmentação é baseada na transformada watershed. Andrade (1998) obteve resultados promissores a partir da segmentação por *watersheds*, onde afirma que o algoritmo segmenta as imagens diretamente, executando-as em tempo linear e com baixas taxas de super e subsegmentação.

O *software* ENVI EX, realiza segmentação das imagens utilizando o algoritmo *watershed by immersion*. Campos et al. (2013) compararam a eficácia de dois métodos de segmentação, por crescimento de regiões e por *watersheds by immersion*, disponibilizados pelos *softwares* SPRING - Sistema de Processamento de Imagens Georeferenciadas - e pelo ENVI EX, respectivamente. O estudo apontou que a segmentação por *watersheds* demonstrou melhores resultados em comparação com a segmentação por

crescimento de regiões, descrevendo com maior eficácia a dinâmica ambiental da área de estudo.

Pedrassoli (2011) em seu estudo sobre técnicas de análise de imagens orientada a objetos para mapeamento de favelas obteve resultados satisfatórios a partir do *software* ENVI EX.

Os métodos de classificação automáticos mais utilizados se baseiam em métodos supervisionados, não supervisionados ou híbridos e são mais apurados quando utilizados em imagens de baixa resolução espacial. No entanto, em imagens com alta resolução espacial estes métodos não apresentam resultados satisfatórios devido à quantidade e diversidade de informações (PEDRASSOLI, 2011).

Classificação é o processo de extração de informação em imagens para reconhecimento de padrões e objetos homogêneos, sendo utilizado em sensoriamento remoto para mapear áreas da superfície terrestre que correspondem aos temas de interesse. A classificação de objetos ou fenômenos é feita pela escolha das características que os descrevem para diferenciá-los entre si. Os classificadores podem ser divididos em "pixel a pixel" ou por regiões.

Conforme Solutions... (2013), técnicas tradicionais de classificação de imagens são baseadas em pixels, o que significa que a informação espectral de cada pixel é utilizada para classificar imagens. Esta técnica funciona bem com dados hiperespectrais, mas não é o ideal em termos de imageamento pancromático ou multiespectral. Os tradicionais classificadores pixel a pixel possuem eficiência reduzida em imagens de alta resolução espacial, onde o mapa resultante apresenta um aspecto granuloso. Para driblar esse problema, utiliza-se o método baseado em objeto, o qual oferece mais flexibilidade nos tipos de recursos a serem extraídos.

Campos et al. (2013) ressaltam a ocorrência do aspecto granuloso na classificação de imagens de alta resolução espacial utilizando classificadores

pixel a pixel. O autor sugere a utilização do método baseado em objetos ou regiões para driblar este problema.

Os classificadores por regiões utilizam a informação espectral de cada pixel, além da informação espacial que envolve a relação com seus vizinhos, reconhecendo áreas homogêneas e, para esta classificação, primeiramente realiza-se a segmentação das imagens.

Marujo et al. (2013) utilizaram o algoritmo classificador *K - Nearest Neighbor* em uma imagem do satélite Rapideye para mapeamento do uso e ocupação da cultura do café. Os autores utilizaram o algoritmo *K - Nearest Neighbor* para dois métodos de classificação supervisionada: por regiões e orientada a objetos. Os melhores resultados foram obtidos a partir da classificação orientada a objetos, sendo esta recomendada para cultivos cafeeiros em imagens de alta resolução espacial.

Soares e Beppler (2013) compararam a eficiência dos *softwares* SPRING e ENVI na classificação de uma imagem QUICKBIRD. Os autores avaliaram os algoritmos classificadores: *Battacharya* disponível no *software* SPRING e *K - Nearest Neighbor* disponível no ENVI EX. O estudo apontou que a classificação utilizando o algoritmo *K - Nearest Neighbor* foi mais eficiente, apresentando resultado mais próximo do esperado.

Huang, Davis e Townshend (2002) desenvolveram um estudo sobre o algoritmo *support vector machine* avaliando seu desempenho em relação a três outros algoritmos classificadores. O algoritmo forneceu melhor exatidão global que os outros classificadores quando processado em todas as bandas do satélite Landsat.

Nascimento et al. (2009) avaliaram a separação de classes de uso e ocupação do solo em imagens CCD-CBERS-2 utilizando o algoritmo *support vector machine*. A classificação foi considerada muito boa e mostrou uma minimização de erros pelo algoritmo. Os autores concluíram que este tipo de

operação permite que a classificação seja realizada com menor esforço sem a necessidade de edição matricial.

2.4.3 Classificação de imagens pixel a pixel

Neste tipo de análise utiliza-se da informação espectral contida no pixel. Esta técnica é desenvolvida desde a década de 70 e mesmo com a atual disponibilidade de novos sensores e novas imagens de alta resolução espacial, ainda é bastante utilizada (PEDRASSOLI, 2011). A maioria dos estudos em sensoriamento remoto é baseada na informação fornecida pelo pixel (CASTILLEJO-GONZÁLEZ et al., 2009).

Segundo Moreira et al. (2007b), na classificação procura-se rotular cada pixel da imagem segundo sua ocupação na terra. Na classificação pixel a pixel, o usuário cria um conjunto de treinamento de acordo com as características espectrais de cada uma das classes de uso e ocupação da terra. Assim, o usuário procura associar determinado pixel da imagem a uma das classes contidas no conjunto de treinamento.

Na classificação de imagens multiespectrais, há a coleta de amostras de treinamento que representam o comportamento médio de classes a serem mapeadas de maneira automática. O princípio básico se baseia no uso de algoritmos que determinam os pixels que apresentam valores característicos para determinada classe. A classificação via interpretação visual se limita ao uso de três bandas espectrais, já as classificações automáticas podem ser utilizadas quantas bandas o usuário desejar (CARVALHO, 2004).

3 CONSIDERAÇÕES GERAIS

O mapeamento de cultivos de café é de grande importância para obtenção de informações sobre a localização e a quantificação da cultura. Imagens de alta resolução espacial se mostram eficientes, sobretudo devido à riqueza de detalhes. Análise de imagens orientada a objetos é uma técnica que permite a classificação de alvos presentes na superfície da terra considerando atributos textura, espacial e espectral.

REFERÊNCIAS

- ADAMI, M. **Estimativa de áreas agrícolas por meio da técnica de sensoriamento remoto, geoprocessamento e amostragem**. 2003. 183 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.
- 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, M. C. **Um método topológico de segmentação de imagens por atributos**. 1998. 140 p. Tese (Doutorado em Ciência da Computação) - Universidade Federal de Minas Gerais, Belo Horizonte, 1998.
- 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. **Modelagem de dados espectrais e agrometeorológicos para estimativa da produtividade de café**. 2013. 156 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3DLLLQ8>>. Acesso em: 31 jul. 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.
- 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.

CARVALHO, L. M. T. de. **Sistemas de informações geográficas e sensoriamento remoto dos recursos florestais**. Lavras: UFLA/FAEPE, 2004. 94 p.

CASTILLEJO-GONZÁLEZ, I. L. et al. Object- and pixel-based analysis for mapping crops and their agro-environmental. **Computers and Electronics in Agriculture**, New York, v. 68, p. 207-215, June 2009.

COLLARES, J. E. R.; LAURIA, C. A.; CARRILHO, M. M. Pesquisa de previsão e acompanhamento de safras baseada em painéis de amostras de áreas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 1993, Curitiba. **Anais...** Curitiba: INPE, 1993. p. 450-453.

COLTRI, P. P. **Mitigação de emissões de gases de efeito estufa e adaptação do café Arábica à condições climáticas adversas**. 2012. 148 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2012.

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.

COVRE, M. **Influência de parâmetros culturais de citros sobre os dados TM/LANDSAT**. 1989. 241 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1989.

DALLEMAND, J. F. et al. Sensoriamento remoto e agricultura. **Ciência Hoje**, São Paulo, v. 8, n. 43, p. 44-51, 1988.

DIGIBASE. **Informações dos produtos do QUICKBIRD**. Disponível em: <<http://www.digibase.com.br/novo/area.php>>. Acesso em: 7 jan. 2014.

DUARTE, W. O.; BRITO, J. L. N. S. W. Mapeamento da Cultura do Café no município de ARAGUARI-MG utilizando imagens do Sensor CCD do satélite CBERS-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO,

13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 161-167.

EPIPHANIO, J. C. N.; LEONARDI, L.; FORMAGGIO, A. R. Relações entre parâmetros culturais e resposta espectral de cafezais. **Pesquisa Agropecuária Brasileira**, Brasília, v. 29, n. 3, p. 379-386, mar. 1994.

GLOBALGEO. **Imagens de satélite**. Disponível em: <<http://www.globalgeo.com.br/imagens-de-satelite/>>. Acesso em: 10 out. 2013.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo: Pearson, 2010. 624 p.

HAY, G. J.; CASTILLA, G. Geographic Object-based Image Analysis (GEOBIA): a new name for a new discipline. In: _____. **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer, 2008. p. 75-89.

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.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Tabela 1613: área plantada, área colhida, quantidade produzida e valor da produção da lavoura permanente**. Disponível em: <<http://www.sidra.ibge.gov.br/bda/tabela/listabl.asp?z=t&c=1613>>. Acesso em: 7 set. 2013.

IPPOLITI-RAMILO, G. A. et al. Sensoriamento remoto orbital como meio auxiliar na previsão de safras. **Agricultura em São Paulo**, São Paulo, v. 46, n. 1, p. 89-101, 1999.

LEONARDI, L. **Influência de parâmetros culturais de cafezais sobre os dados TM/LANDSAT-5**. 1990. 171 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1990.

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.

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.

MEDEIROS, N. G. **Segmentação morfológica aplicada à cartografia**. 2003. 123 p. Dissertação (Mestrado em Ciências Cartográficas) - Universidade Estadual Paulista, Presidente Prudente, 2003.

MERCANTE, E. et al. Características espectrais da soja ao longo do ciclo vegetativo com imagens Landsat 5/TM em área agrícola no oeste do Paraná. **Revista Engenharia Agrícola**, Jaboticabal, v. 29, n. 2, p. 328-338, jun. 2009.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Análise do comportamento espectral de café em imagens TM e ETM+ do Landsat 5 e 7. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2003, Belo Horizonte. **Anais...** Belo Horizonte: INPE, 2003. p. 189-196.

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. 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. 2007a.

MOREIRA, M. A. et al. **Uso da geotecnologia para avaliar e monitorar a cafeicultura brasileira: fase I**, Estado de Minas Gerais. São José dos Campos: INPE, 2007b. 90 p. Disponível em: <<http://www.dsr.inpe.br/laf/cafesat/artigos/GeotecnologiaAvaliarCafeiculturaBrasileira.pdf>>. Acesso em: 20 ago. 2013.

NASCIMENTO, C. R.; ZULLO-JUNIOR, 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, jun. 2010.

NASCIMENTO, R. F. F. et al. O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, São José dos Campos. **Anais...** São José dos Campos: INPE, 2009. p. 2079-2086.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **Ranger:** 1961 - 1965. Greenbelt, 2005. Disponível em: <<http://nssdc.gsfc.nasa.gov/planetary/lunar/ranger.html>>. Acesso em: 10 jun. 2013.

PEDRASSOLI, J. C. **Análise orientada a objeto para detecção de favelas e classificação do uso do solo em Taboão da Serra/SP.** 2011. 109 f. Dissertação (Mestrado em Geografia Física) - Universidade de São Paulo, São Paulo, 2011.

PEREIRA, J. L. G.; BATISTA, G. T.; ROBERTS, D. Refletância de coberturas vegetais na Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 551-556.

PONZONI, F. J. et al. Evaluation of the “Salar de Uyuni/Bolivia” as radiometric calibration test site for satellite sensors. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, 32., 2000, Amsterdam. **Proceedings...** Amsterdam: International Society for Photogrammetry and Remote Sensing, 2000. p. 231-238.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação.** 2. ed. São Paulo: Oficina de Textos, 2012. 160 p.

RAMIREZ, G. M. **Uso de imagens de alta e média resolução espacial no estudo de áreas cafeeiras.** 2009. 132 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2009.

RAMIREZ, G. M. et al. Comparação de dados do satélites Ikonos-II e Landsat/ETM+ no estudo de áreas cafeeiras. **Pesquisa Agropecuária Brasileira**, Brasília, v. 41, n. 4, p. 661-666, abr. 2006.

RAMIREZ, G. M.; ZULLO-JUNIOR, 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.

ROERDINK, J. B. T. M.; MEIJSTER, A. The watershed transform: definitions, algorithms and parallelization strategies. **Fundamenta Informatica**, Wageningen, v. 41, n. 1, p. 187-228, 2001.

ROSA, V. G. C. **Modelo agro meteorológico-espectral para monitoramento e estimativa da produtividade do café na região Sul/Sudoeste do Estado de**

Minas Gerais. 2007. 142 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

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, J. S. et al. **Infraestrutura mínima para produção de café com qualidade:** a opção para a cafeicultura familiar. Viçosa, MG: UFV, 2011. v. 1, 62 p. Disponível em: <<http://www.poscolheita.com.br/poscolheita/Infraestrutura%20Minima%20para%20cafe%20de%20Qualidade%20.pdf>>. Acesso em: 8 set. 2013.

SOARES, A. R.; BEPLER, M. Estudo comparativo entre softwares na classificação de imagens de alta resolução espacial. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 1205-1212.

SOARES, S. C. **Distribuição da cafeicultura em parte do estado do Espírito Santo, em relação às variáveis morfométricas e tipos de solos, usando dados de sensoriamento remoto.** 2012. 123 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012. Disponível em: <<http://mtc-m19.sid.inpe.br/col/sid.inpe.br/mtc-19/2012/12.17.09.07/doc/publicacao.pdf>>. Acesso em: 31 jul. 2013.

SOLUTIONS, exelis visual information. Disponível em: <<http://www.exelisvis.com/Learn/Resources/Tutorials.aspx>>. Acesso em: 11 set. 2013.

SOUZA, V. C. O. et al. Especialização 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.

TEWOLDE, M. G.; CABRAL, P. Urban sprawl analysis and modeling in Asmara, Eritrea. **Remote Sensing**, Lisboa, v. 3, p. 2148-2165, Sept. 2011.

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.

VOLPATO, M. M. L. **Imagens AVHRR-NOAA para determinação do potencial de incêndios em pastagens**. 2002. 97 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2002.

WATANABE, F. S. Y.; IMAI, N. N.; SAMIZAVA, T. M. Classificação da vegetação da Planície Fluvial do Alto Rio Paraná baseado em redes neurais artificiais. In: CONGRESSO DE INICIAÇÃO CIENTÍFICA DA UNESP, 21., 2009, São José do Rio Preto. **Anais...** São José do Rio Preto: UNESP, 2009. p. 5186-5189.

YANG, C.; EVERITT, J. H.; BRADFORD, J. M. Comparison of QuickBird satellite imagery and airborne imagery for mapping grain sorghum yield patterns. **Precision Agriculture**, Dordrecht, v. 7, n. 1, p. 33-44, 2006.

YANG, C.; EVERITT, J. H.; BRADFORD, J. M. Using high resolution QuickBird satellite imagery for cotton yield estimation. In: AMERICAN SOCIETY OF AGRICULTURAL ENGINEERS MEETINGS PAPERS, 19., 2004, Saint Joseph. **Proceedings...** Saint Joseph: ASAE, 2004. p. 1-12.

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.

ZAMBOLIM, L. **Tecnologias de produção de café com qualidade**. Viçosa, MG: UFV, 2001. 648 p.

ZULLO-JUNIOR, J. **Correção atmosférica de imagens de satélite e aplicações**. 1994. 204 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 1994.

CAPÍTULO 2

Discriminação da cultura cafeeira de outros usos

1 INTRODUÇÃO

A cafeicultura é uma atividade de grande importância internacional (SOUZA et al., 2012), sendo desenvolvida no Brasil desde 1727 (COLTRI, 2012; ROSA, 2007). Atualmente o Brasil é responsável por aproximadamente 34,99% da produção mundial de café e 25,39% das exportações de grãos verdes.

O estado de Minas Gerais é o maior produtor de café, sendo responsável por 53% da produção nacional, seguido por Espírito Santo e São Paulo com 24,59% e 10,53%, respectivamente (BRASIL, 2013). Na região sul de Minas Gerais, a produção de café se configura como atividade econômica dominante, responsável no ano de 2012 pelo montante de 51,18% do total da produção anual, sendo considerada a principal região produtora do território brasileiro (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2013).

No Brasil, a obtenção de informações oficiais referentes à cultura (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 por meio da aplicação de questionários padrões a produtores, cooperativas e representantes de órgãos públicos e privados. Para análise da extensão, distribuição e localização do ambiente em que plantios de café são cultivados, as geotecnologias tem sido de grande valia. Com o objetivo de analisar a acurácia dos dados oficiais, Trabaquini et al. (2011) realizaram uma comparação entre os dados obtidos via mapeamento de plantios de café a partir de imagens Landsat/TM 5 com dados oficiais no município Umuarama - PR, e observaram que a quantificação da cultura apresentou divergências entre os dados disponibilizados pelo IBGE - Instituto Brasileiro de Geografia e

Estatística - e pela SEAB - Secretaria Estadual de Abastecimento. Segundo Collares, Lauria e Carrilho (1993), Ippoliti-Ramilo et al. (1999) e Souza et al. (2012), os dados coletados seguindo a metodologia utilizada pelos órgãos oficiais são bastante suscetíveis a erros de análise humana. Além disso, os resultados podem diferir entre as instituições governamentais, pois as informações coletadas encontram-se fragmentadas e são de difícil visualização, tornando complexo o entendimento por completo além de dificultar a estimativa da precisão dos dados obtidos.

Outro problema relacionado à aquisição de dados da cafeicultura brasileira, segundo Duarte e Brito (2007), é o alto custo financeiro e de pessoal demandados pela metodologia citada anteriormente. É necessária a ampliação de pesquisas que permitam caracterizar e localizar áreas com plantios de café de maneira mais rápida, precisa e com custos menores (MOREIRA et al., 2007).

Considerando a dimensão da cafeicultura para o país, o emprego de geotecnologias possui significativo potencial de aplicação no setor e representa um avanço no levantamento e análise dos dados. Ramirez e Zullo-Junior (2010) afirmam que no estudo de áreas cafeeiras, a utilização de imagens de alta resolução espacial se mostra promissora. O uso de imagens de satélite com alta resolução espacial possibilita um conhecimento mais detalhado do comportamento espectral de plantios de café de modo a diminuir os trabalhos de campo e apoiar os métodos operacionais utilizados atualmente.

Mapear e quantificar as relações da cultura cafeeira com o meio físico é de suma importância, pois caracterizar fatores que definem o ambiente de cultivo do cafeeiro juntamente com a utilização de imagens de satélite na análise da distribuição espacial das lavouras pode favorecer ações de planejamento e servir de material para futuras pesquisas (BERNARDES et al., 2012). Trabalhos como os desenvolvidos por Moreira et al. (2010), Moura et al. (2009), Ortega-Huerta et al. (2012), Souza et al. (2009, 2012) e Vieira et al. (2007) ilustram a

aplicabilidade das geotecnologias no mapeamento de áreas cafeeiras. Moreira et al. (2010) mapearam áreas cafeeiras cultivadas nos estados de Minas Gerais e São Paulo e constataram que em Minas Gerais as áreas onde mais se concentram lavouras cafeeiras são nas regiões Sul - Sudoeste (46,0%), Zona da Mata (16,3%) e Triângulo Mineiro - Alto Paranaíba (16,3%), onde juntas respondem por 78,6% da área cultivada com café no Estado. Já em São Paulo as regiões que se concentram as lavouras de café são Marília (14,20%), Assis (9,71%) e Bauru (8,42%). Na caracterização de áreas ocupadas por vegetação natural e plantios de café em uma análise multitemporal, Ortega-Huerta et al. (2012) aplicaram técnicas de classificação supervisionada em imagens Landsat/TM em El Salvador e discriminaram áreas cafeeiras de áreas de vegetação natural, obtendo 81,6% de acurácia. Souza et al. (2012) analisaram a espacialização e a dinâmica da cafeicultura mineira entre 1990 e 2008 utilizando um banco de dados geográficos para análise das variáveis área plantada e produção de café dos 853 municípios do estado de Minas Gerais. Foi observado que a área plantada cresceu na região Sul/Sudoeste de Minas e diminuiu na região Central. As regiões Sul e a Zona da Mata mineira demonstraram maior aumento de produtividade, assumindo grande importância na economia da região.

Como mencionado anteriormente, Moreira et al. (2010), Ortega-Huerta et al. (2012), Souza et al. (2012) e Trabaquini et al. (2011) aplicaram técnicas de classificação supervisionada no mapeamento de áreas cafeeiras. Técnicas de classificação supervisionada a exemplo da análise de imagem pixel a pixel e análise de imagem orientada ao objeto são as mais utilizadas em sensoriamento remoto.

Análise de imagem pixel a pixel é baseada em pixels, ou seja, a informação espectral de cada pixel é utilizada para classificar imagens. Os tradicionais algoritmos classificadores pixel a pixel possuem eficiência reduzida em imagens de alta resolução espacial, onde Campos et al. (2013) ressaltam a

ocorrência do aspecto granulado na classificação de imagens de alta resolução espacial utilizando classificadores pixel a pixel. O autor sugere a utilização do método baseado em objetos ou regiões para driblar este problema, pois estes consideram não apenas a informação espectral, mas espacial e de textura. Marujo et al. (2013) utilizaram o algoritmo classificador *K - Nearest Neighbor* em imagem do satélite Rapideye para mapeamento do uso e ocupação da cultura do café. Os autores obtiveram resultados positivos na análise de imagem orientada a objetos onde recomendam a utilização da técnica para cultivos cafeeiros em imagens de alta resolução espacial. Noma, Korting e Fonseca (2013) testaram em seu estudo sobre identificação e caracterização de padrões na Amazônia a eficácia do método *support vector machine* frente a outras classificações. Segundo os autores, esta técnica é originalmente desenvolvida para avaliar duas classes obtendo resultados satisfatórios. Utilizando técnicas de análise de imagem pixel a pixel, Tardin, Assunção e Soares (1992) realizaram a discriminação das culturas do café, citrus e cana-de-açúcar por meio do processamento digital de imagens utilizando dados Landsat/TM das 4 bandas. O autor realizou a classificação pelo método *maximum likelihood* e constatou que este classificador foi eficiente para discriminar a cultura do café de outros alvos.

A escolha do *software* para realização da análise de imagem orientada a objetos tem importância significativa, pois os resultados satisfatórios dependem não somente do usuário, mas do processamento como um todo. Campos et al. (2013) testaram dois métodos segmentadores presentes na análise de imagem orientada a objetos e constaram que a segmentação pelo algoritmo *watersheds by immersion*, utilizada pelo *software* ENVI EX, proporciona melhores resultados. Pedrassoli (2011) em seu estudo sobre técnicas de análise de imagens orientada a objetos para mapeamento de favelas utilizando imagem de alta resolução espacial obteve resultados satisfatórios a partir do *software* ENVI EX.

Dessa forma, observa-se a importância do levantamento de dados para obtenção de informações relativas à localização e quantificação da cultura cafeeira utilizando técnicas de análise de imagem orientada ao objeto e análise de imagem pixel a pixel em imagens de alta resolução espacial. Com a finalidade classificar áreas cafeeiras efetuou-se a discriminação da classe "café" de "outros usos", onde foram mapeadas e quantificadas. Neste contexto, o objetivo com esse trabalho foi discriminar e quantificar áreas de café de outros usos a partir da análise de imagens orientada a objetos e da análise de imagem pixel a pixel em imagens de alta resolução espacial para posterior comparação e avaliação dos resultados.

2 MATERIAL E MÉTODOS

A área de estudo está inserida na mesorregião sul do estado de Minas Gerais/Brasil, no município de Campos Gerais (Figura 1). Sua localização é determinada pelas coordenadas geográficas 21° 7 '30 de latitude sul e 45° 33 '30" de longitude oeste.

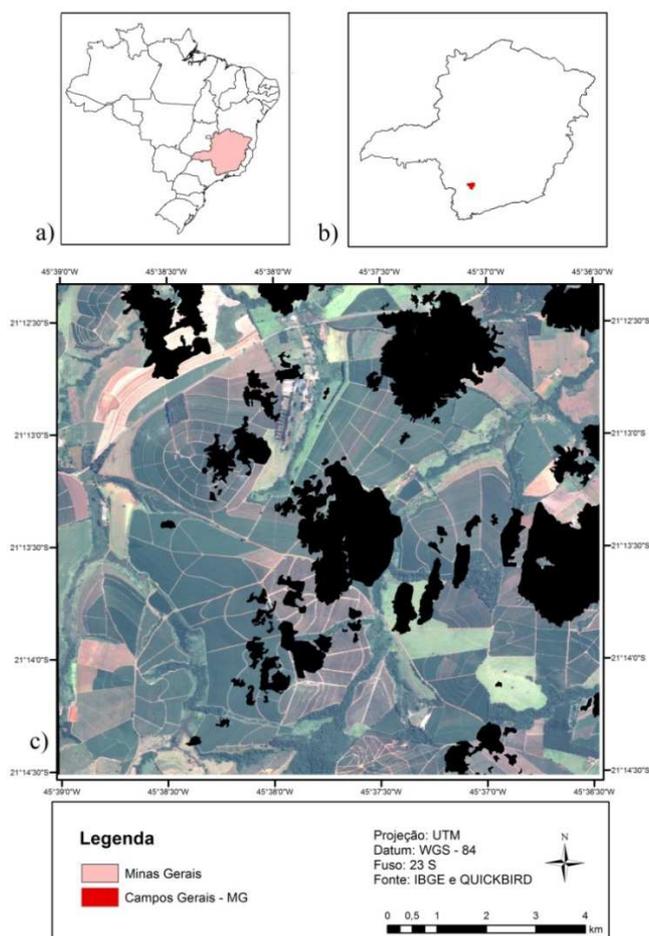


Figura 1: Área de estudo: a) Localização de Minas Gerais; b) Localização de Campos Gerais; c) imagem RGB do satélite QUICKBIRD do dia 14/03/2012.

Para realização do estudo, escolheu-se uma propriedade com produção de café especial (bebida fina) destinada à exportação localizada no município de Campos Gerais – MG, na região Sul de Minas Gerais, uma das maiores regiões produtora de café do estado.

2.1 Material

Foram utilizados os seguintes dados e *softwares* para realização deste trabalho:

1) Imagem do satélite QUICKBIRD de 14 de março de 2012, contendo quatro bandas multiespectrais com 2,44 m de resolução espacial, conforme indica Tabela 1, e 8 bits de resolução radiométrica. A empresa contratada forneceu a imagem com 8 bits de resolução radiométrica, e para não comprometer os resultados do trabalho do ponto de vista radiométrico, os níveis de cinza foram convertidos em valores de refletância real. A geometria de iluminação da cena no momento da obtenção de imagem possuía as seguintes características: ângulo de elevação do satélite de 75,4°; ângulo azimutal do satélite de 91,8°; ângulo de elevação do sol de 48,6° e ângulo azimutal do sol de 68°.

Tabela 1: Bandas do satélite QuickBird

Banda	Faixa espectral (μ)	Resolução espacial (m)
Banda do azul	0,450 – 0,520	2,44
Banda do verde	0,520 – 0,600	2,44
Banda do vermelho	0,630 – 0,690	2,44
Banda do infravermelho	0,760 – 0,900	2,44

2) Imagens MOD04, MOD05 e MOD07 do sensor MODIS (Moderate Resolution Imaging Spectroradiometer) satélite Terra, obtida no dia 14 de março de 2012, para correção atmosférica no *software* SCORADIS.

3) Conferência em campo da imagem de alta resolução adquirida (QUICKBIRD), para verificar áreas ocupadas por café e outros usos. A partir desta análise, foi gerado o mapa de referência de campo, utilizado para validação do índice kappa e de exatidão global (Figura 2).

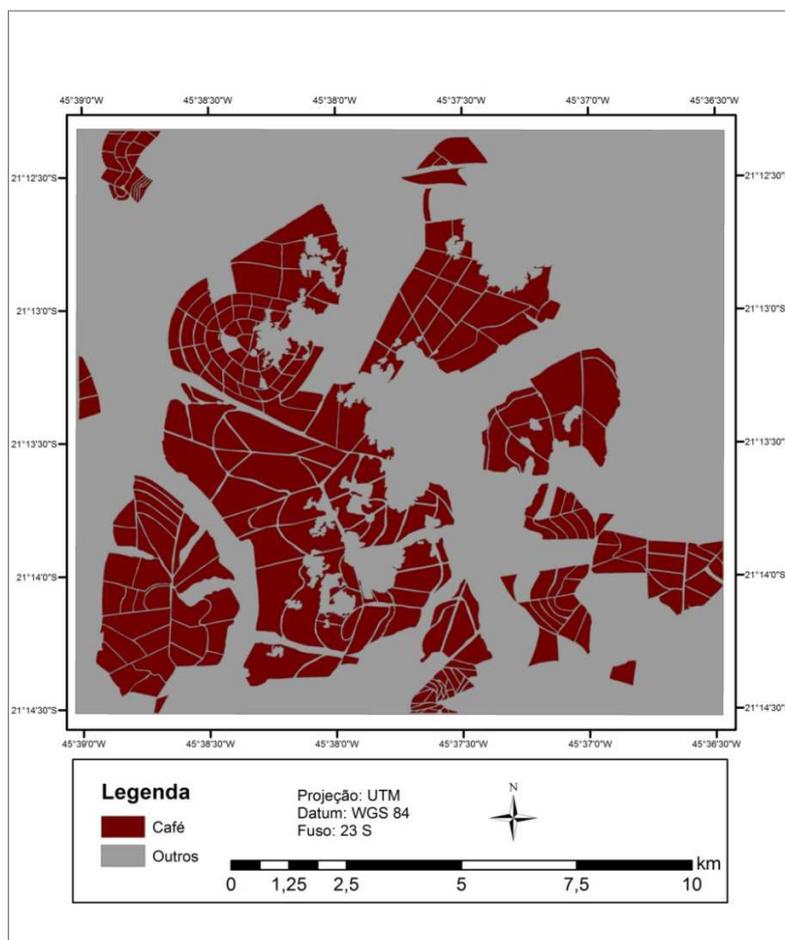


Figura 2: Mapa de referência das classes "café" e "outros usos".

4) Softwares:

- SCORADIS para correção atmosférica e radiométrica (conversão de níveis de cinza para valores de refletância real).
- ArcGis 10 para elaboração do mapa de referência correspondente aos usos café e outros e layout dos mapas;

c) Envi 4.8 para classificação supervisionada pelo método *Maximum likelihood* e para geração da matriz de confusão e a partir dela obter o índice kappa, exatidão global, acurácia do usuário e acurácia do produtor.

d) Envi EX para realizar o processo de análise de imagem baseada em objeto.

2.2 Metodologia

A metodologia utilizada neste trabalho seguiu os procedimentos descritos no fluxograma (Figura 3).

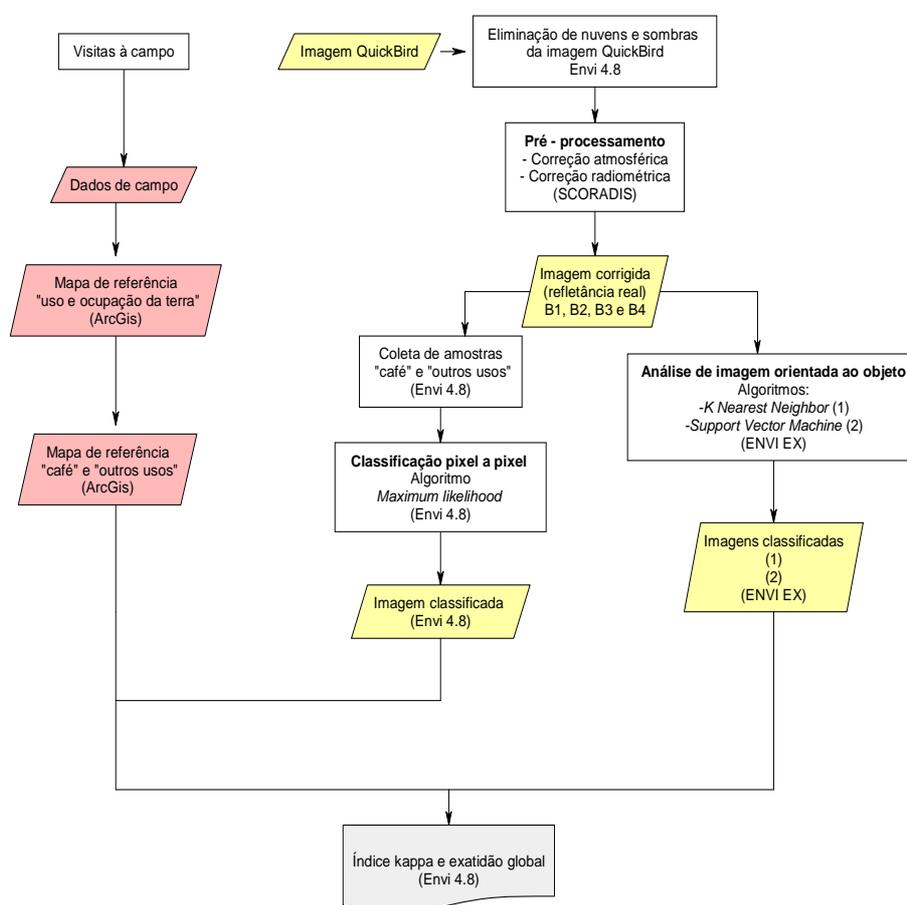


Figura 3: Fluxograma da metodologia utilizada.

2.2.1 Eliminação das nuvens e sombras

Após o recebimento da imagem foi necessária 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 de modo a eliminar todos os pixels contaminados. Na Figura 4 é possível observar a imagem original, enviada pela empresa contratada e na Figura 5 a imagem após a eliminação das nuvens e sombras.



Figura 4: Imagem original RGB 321

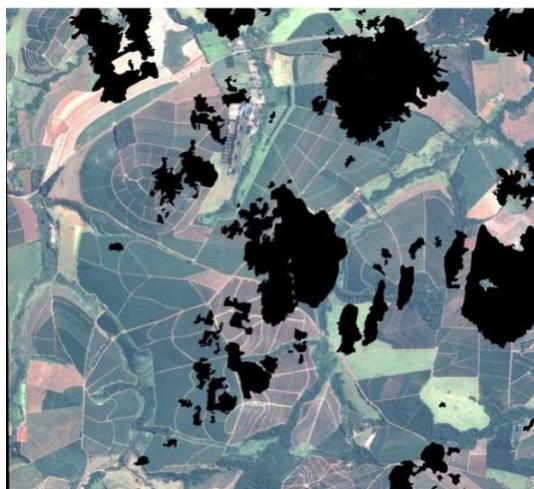


Figura 5: Imagem RGB 321 com nuvens e sombras eliminadas.

2.2.2 Correção atmosférica e radiométrica

Para a correção radiométrica e atmosférica, foi utilizado o sistema computacional SCORADIS (Sistema de Correção Radiométrica de Imagens de Satélite), desenvolvido por Zullo-Junior (1994). Este sistema baseia-se no modelo de transferência radiativa 5S e foi desenvolvido a partir de trabalhos experimentais realizados nas condições brasileira de atmosfera e clima. Os dados de entrada, para correção atmosférica, foram obtidos de acordo com a metodologia descrita por Nascimento (2006). Os dados obtidos a partir do sensor MODIS Terra, tais como, espessura óptica dos aerossóis, coluna total de vapor d'água e carga total de ozônio dos arquivos MOD04, MOD05 e MOD07 estavam disponíveis no site da NASA - Empresa que disponibiliza imagens do satélite Terra (Tabela 3).

Tabela 2: Descrição dos dados obtidos a partir do MODIS para entrada no SCORADIS.

Dados	Valores
Espessura óptica dos aerossóis	0,09
Coluna total de vapor d'água (g/cm ²)	2,60
Carga total de ozônio (cm.atm)	0,26

2.2.3 Mapa de referência do uso e ocupação da terra

A área de estudo possui água, áreas de vegetação natural e áreas antrópicas agrícolas compostas por cultura temporária e permanente, pastagem e silvicultura (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2006). No estudo, os usos encontrados foram generalizados como corpos d'água, pastagem, mata, solo exposto e café. Em seguida, corpos d'água, pastagem, mata e solo exposto foram considerados como "outros usos". Há de se ressaltar as nuvens na imagem não são consideradas como uso e ocupação da terra, no entanto, na análise de imagem orientada ao objeto e na classificação pixel a pixel as mesmas foram inseridas em "outros usos". Por fim, houve a classificação final das classes "café" e "outros usos".

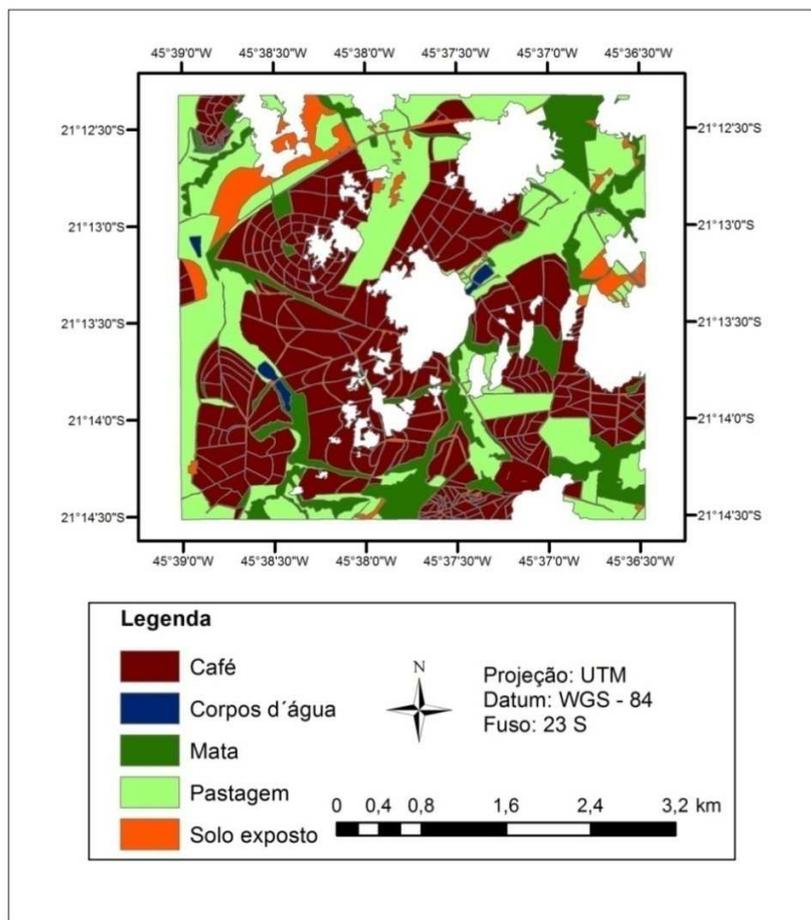


Figura 6: Mapa de referência contendo todos os usos da área de estudo.

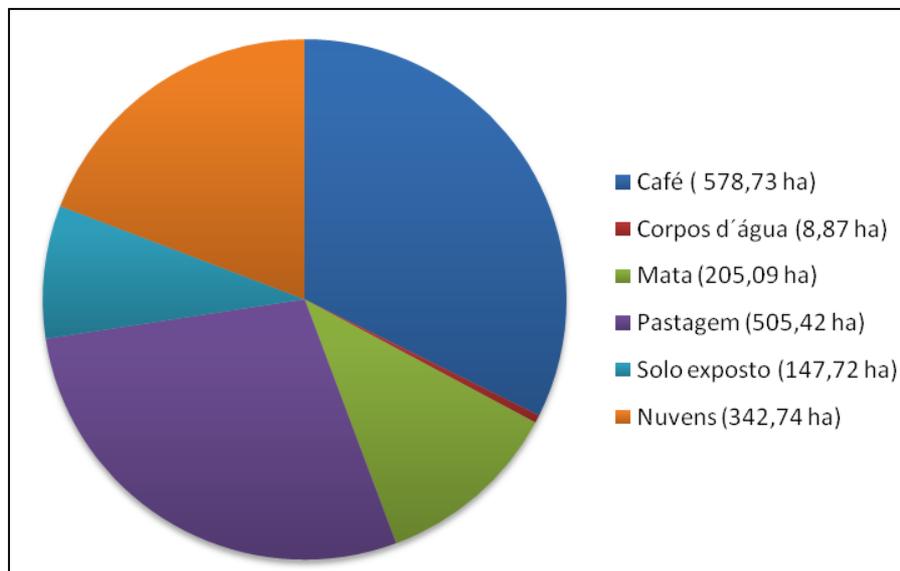


Gráfico 1: Área mapeada das classes de uso e ocupação da Terra.

Na discriminação de áreas cafeeiras houve a comparação do mapeamento de referência do uso e ocupação da terra com dois métodos classificadores supervisionados:

- 1) análise de imagem orientada ao objeto utilizando os algoritmos *support vector machine* e *k nearest neighbor*,
- 2) classificação pixel a pixel utilizando o algoritmo *maximum likelihood*.

2.2.4 Análise de imagem orientada ao objeto

Neste procedimento, foram realizadas a segmentação e a classificação orientada a objetos utilizando as bandas do satélite QUICKBIRD processadas com o *software* ENVI EX.

2.2.4.1 Segmentação

Segmentação é um processo que particiona uma imagem, subdividindo-a, cujo nível de detalhe está associado à detecção de objetos e regiões de interesse. O processo de segmentação por extração de características utilizado no *software* é baseado no algoritmo que simula uma bacia hidrográfica por imersão, o chamado *watersheds by immersion* (CAMPOS et al., 2013; VINCENT; SOILLE, 1991). O *software* ENVI EX utiliza esse algoritmo para segmentar imagens. O passo inicial é a extração de características da imagem, a partir da ferramenta *feature extraction*, que extrai informações a partir de imagens pancromáticas e multiespectrais. Este recurso utiliza uma abordagem baseada em objetos para segmentar imagens, definidos a partir de uma região de interesse com características espaciais, espectrais (brilho e cor) e texturais que definem a região (AGUIRRE-GUTIÉRREZ; SEIJMONSBERGEN; DUIVENVOORDEN, 2012; BLASCHKE, 2010; YAN et al., 2006). O *software* ENVI EX emprega um algoritmo de segmentação baseado no conhecimento e requer apenas um parâmetro de entrada, nível de escala, onde se define a similaridade dos pixels. Escolhendo um alto nível de escala, menos segmentos são definidos, já em uma escala de baixo nível, surgem mais segmentos a serem definidos, ou seja, numa escala de 0 a 100, 0 se refere a uma supersegmentação e 100 a nenhuma segmentação. Em seguida, há a fusão de segmentos por meio de da ferramenta *merge*. Essa ferramenta é utilizada para agregar pequenos segmentos dentro de grandes áreas. O parâmetro *merge* ou nível de fusão varia de 0 a 100, onde há a fusão de segmentos adjacentes com base em uma combinação de informação espacial e espectral. Estes valores, atribuídos ao nível de escala e fusão, foram definidos com base na pré-visualização disponibilizada pelo *software*.

Na etapa seguinte, há a opção de refinar os resultados obtidos a partir da ferramenta *thresholding*, onde sua utilização é recomendada quando os objetos de interesse possuem um alto contraste em relação ao restante da imagem. Este procedimento facilita a segmentação e posterior extração das feições. Seguindo este critério, para este trabalho a ferramenta *thresholding* não foi adotada.

Ainda neste procedimento, no modo avançado são oferecidas duas opções: espaço de cores e razão de bandas. Em espaço de cores, foram selecionadas as bandas 4 - 3 - 2, e em razão de bandas, 3 e 4.

Em espaço de cores, utilizam-se as bandas selecionadas visando representar as cores em termos de intensidade e isto ocorre quando há três ou mais bandas. Em razão de bandas há o cálculo normalizado entre duas bandas. Foram escolhidas as bandas do vermelho e do infravermelho próximo, formando o NDVI - índice de vegetação por diferença normalizada. O valor de NDVI varia de -1 a 1, sendo que em vegetações verdes e saudáveis, o índice varia de 0,2 a 0,8 (ROUSE et al., 1973).

$$\text{NDVI} = ((\text{IVP}-\text{V}) / ((\text{IVP}+\text{V}))) \quad (1)$$

onde, IVP é a refletância na faixa espectral do infravermelho próximo e V é a refletância na faixa espectral do vermelho.

Na região do vermelho, nota-se que a clorofila absorve a energia solar, ocasionando baixa refletância, enquanto na faixa do infravermelho próximo, tanto a morfologia interna das folhas quanto a estrutura da vegetação ocasionam a alta refletância da energia solar incidente. Quanto maior o contraste, maior o vigor da vegetação na área imageada. A combinação destas duas faixas espectrais realça as áreas de vegetação nas imagens, sendo este o princípio em se baseiam as diferenças de vegetação. Uma boa segmentação garante que os

resultados da classificação sejam mais precisos. Terminada a segmentação, realizaram-se as classificações.

2.2.4.2 Classificação utilizando *k nearest neighbor* e *support vector machine*

Para a classificação foram coletadas amostras de café e outros usos. Coletadas as amostras, todos os parâmetros disponibilizados pelo *software* ENVI EX para os atributos; espacial, textura, espectral e customizado, descritos a seguir foram considerados:

- a) Espacial: área (*area*), comprimento (*length*), compactidade (*compact*), convexidade (*convexity*), solidez (*solidity*), arredondamento (*roundness*), fator forma (*formfactor*), alongamento (*elongation*), medida do retângulo (*rect_fit*), direção principal (*maindir*), comprimento do eixo maior (*majaxislen*), comprimento do eixo menor (*minaxislen*), número de orifícios do polígono (*numholes*) e área total do polígono da zona de contorno externo (*holesolrat*),
- b) Textura: distância da textura (*tx_range*), média da textura (*tx_mean*), variância da textura (*tx_variance*), entropia da textura (*tx_entropy*),
- c) Espectral: valor mínimo dos pixels que compõem as bandas 1, 2, 3, 4 e combos (*minband_x*), valor máximo dos pixels que compõem as bandas 1, 2, 3, 4 e combos (*maxband_x*), valor médio dos pixels que compõem as bandas 1, 2, 3, 4 e combos (*avgband_x*) e valor do desvio padrão dos pixels que compõem as bandas 1, 2, 3 e 4 e combos (*stdband_x*),
- d) Customizado: razão entre bandas (*bandratio*), matiz (*hue*), saturação (*saturation*), intensidade (*intensity*), considerado apenas para as bandas 1,2,3 e 4.

Com a finalidade de extrair informações e reconhecer padrões e objetos homogêneos, foram adotados os métodos de classificação supervisionada

disponíveis pelo *software*, sendo estes, *K Nearest Neighbor* e *support vector machine*.

O algoritmo de classificação baseado no *k nearest neighbor* é uma técnica empregada no reconhecimento de padrões onde o *software* exige a seleção de valores para o parâmetro *k*, sendo este o número de vizinhos considerados durante a classificação (XU et al., 2013). Foram testados os valores 1, 3, 5 e 7 (só é possível utilizar valores ímpares) para o parâmetro *K* - representa o número de vizinhos testados na classificação -, sendo selecionado o valor 1 por apresentar melhores resultados.

O algoritmo *support vector machine*, determina-se limites de decisão para a separação das classes bem como a minimização dos erros (MOUNTRAKIS; JUNGHOIM, 2010). Foi selecionado a função *kernel radial basis*, recomendado por Pereira et al. (2011) e Roza e Ribeiro (2013). Os valores *gamma* e parâmetro de penalidade foram 0,03 e 100.00, valores padrões sugeridos pelo *software*.

2.2.5 Classificação pixel a pixel utilizando *maximum likelihood*

Para analisar a eficácia dos resultados das análises de imagens baseada em objetos, realizou-se a classificação pixel a pixel, utilizando o algoritmo *maximum likelihood*. Esta classificação foi realizada a partir das bandas 1- 2 - 3 e 4. Em seguida foram coletadas amostras aleatórias, sendo considerados 400 pixels para áreas com "café" e 400 pixels para áreas com "outros usos".

2.2.6 Exatidão

Posterior às classificações utilizando os algoritmos *k nearest neighbor* e *support vector machine* e o algoritmo *maximum likelihood*, houve a pós-classificação, ou seja, a comparação das imagens resultantes classificadas com os dados oriundos do mapa de referência para análise da exatidão.

Na pós-classificação avaliou-se a exatidão das classificações a partir da matriz de confusão tendo como resultado as seguintes análises: índice kappa, exatidão global, acurácia do usuário e acurácia do produtor. O índice kappa proposto por Landis e Koch (1977) considera toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação. Para obter o índice Kappa é necessária a utilização da seguinte equação:

$$k = \frac{N \sum X_{ii} - \sum X_{i+} X_{+i}}{N^2 - \sum X_{i+} X_{+i}} \quad (2)$$

Onde:

k = Índice *Kappa* de concordância; N = número de observações (verdades de campo); X_{ii} = observações na linha i e coluna i (diagonal principal); X_{i+} = total marginal da linha i ; X_{+i} = total marginal da coluna i .

Para conceituar os resultados obtidos pelo coeficiente Kappa, foram utilizados os intervalos definidos por Landis e Koch (1977) como mostra a Tabela 3.

Tabela 3: Índice Kappa

Valor de Kappa	Qualidade da Classificação
< 0,0	Péssima
0,0 – 0,2	Ruim
0,2 – 0,4	Razoável
0,4 – 0,6	Boa
0,6 – 0,8	Muito boa
0,8 – 1,0	Excelente

Fonte: Landis e Koch (1977)

A Exatidão Global é obtida dividindo o somatório dos pixels classificados corretamente contidos na diagonal principal pelo número total de pixels com o resultado em porcentagem de acertos, e o mínimo aceito para mapas de uso é de 85% (JENSEN, 1996).

A acurácia do usuário é calculada dividindo o número total de pixels corretamente classificados em uma classe pelo número total de pixels classificados nessa classe e refere-se aos erros de comissão a partir da probabilidade que um pixel classificado na imagem tem de representar a classe no campo, onde para Ferreira, Dantas e Morais (2007), a comissão se refere à delimitação excessiva de determinada classe. A acurácia do produtor é calculada dividindo o número total de pixels corretamente classificados em uma classe pelo número total de pixels desta classe, indicado na referência de campo. Para Suarez e Candeias (2012), a acurácia do produtor se refere aos erros de omissão, sendo a probabilidade de um pixel de referência ser corretamente classificado. Ainda segundo Ferreira, Dantas e Morais (2007), a omissão se refere a uma imperfeita definição de determinada classe.

3 RESULTADOS

3.1 Mapa de referência "café" e "outros usos"

O mapa de referência de campo (Figura 7), obtido a partir da classificação visual da imagem de alta resolução espacial do satélite Quickbird, serviu de apoio na averiguação da acurácia do mapeamento realizado. Foram identificados (Tabela 4) 578,73 ha da classe "café" e 1209,84 ha da classe "outros usos" (Gráfico 2).

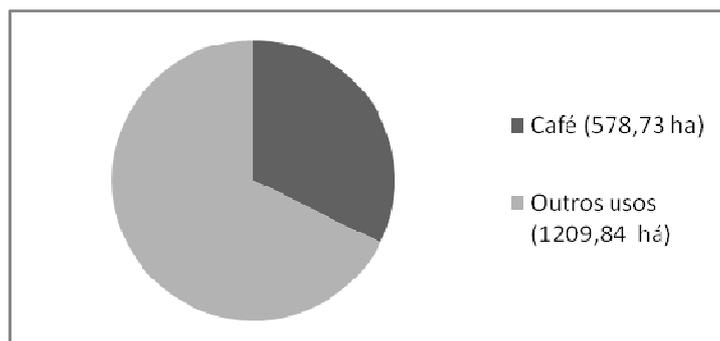


Gráfico 2: Área mapeada das classes "café" e "outros usos"

Tabela 4: Quantificação da área classificada visualmente

Classes	Área classificada (ha)	Área classificada (%)
Café	578,73	32,35
Outros usos	1209,84	67,64
Total	1788,57	100

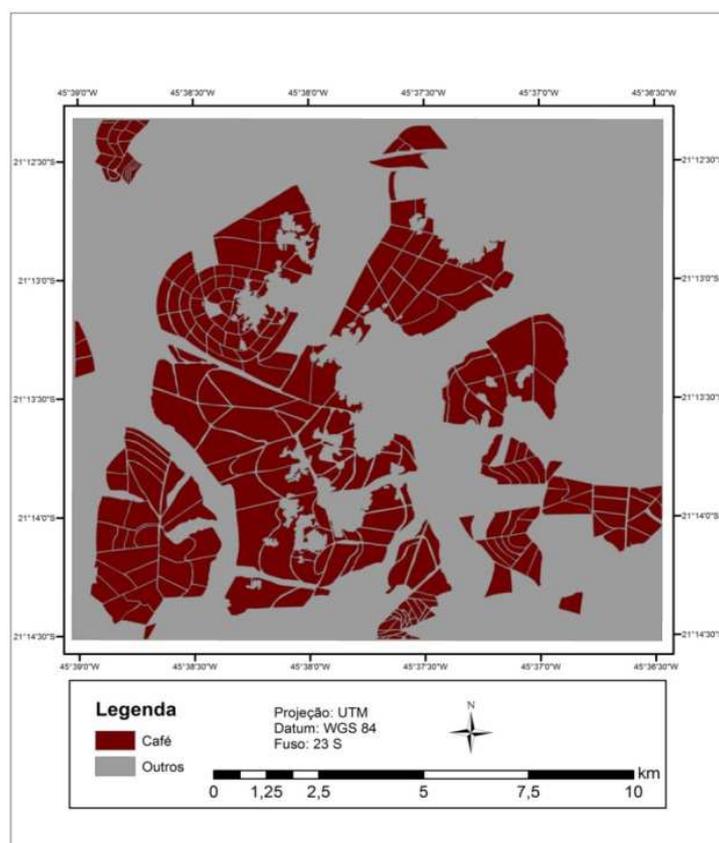


Figura 7: Mapa de referência de "café" e "outros usos".

3.2 Análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor*

O resultado obtido pela análise de imagem orientada ao objeto a partir do algoritmo classificador *k nearest neighbor* é visualizado na Figura 8, onde há a discriminação visual das classes "café" e "outros usos".

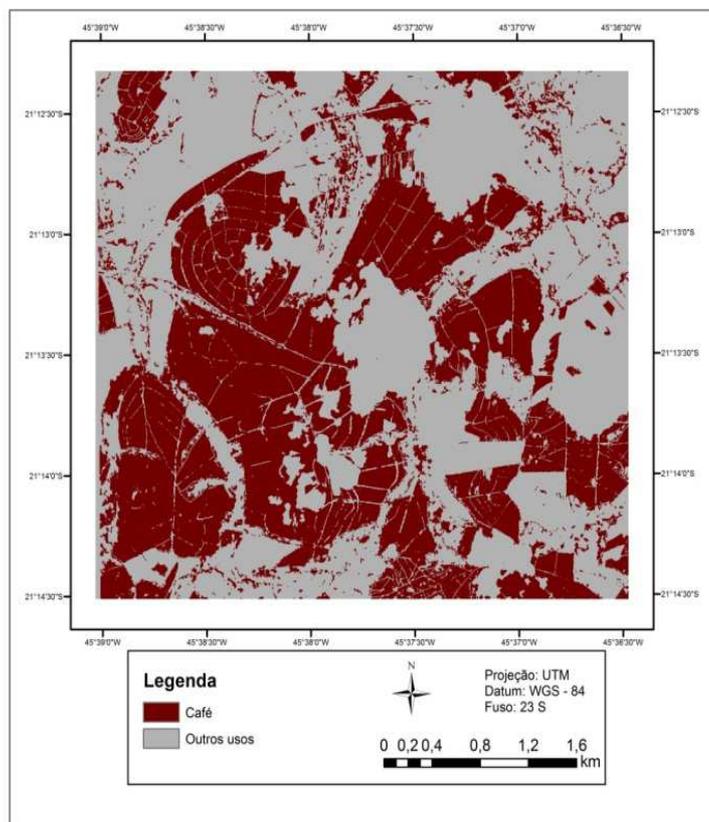


Figura 8: Mapa da Análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor*

Os valores obtidos por meio do mapa de referência e da análise de imagem orientada ao objeto são descritos na Tabela 5.

Tabela 5: Quantificação do mapa de referência e da classificação utilizando o algoritmo *K Nearest Neighbor*.

Classes	Quantificação do mapa de referência		Quantificação da classificação <i>K Nearest Neighbor</i>	
	Área classificada (ha)	Área classificada (%)	Área classificada (ha)	Área classificada (%)
Café	578,73	32,35	782,04	43,72
Outros usos	1209,84	67,64	1006,53	56,28
Total	1788,57	100	1788,57	100

Nos valores resultantes da classificação, conforme observado na tabela 3, o uso "café" obteve 43,72% da área mapeada, enquanto que a classe "outros usos" obteve 56,28%. Os valores obtidos por meio do mapa de referência das classes "café" e outros "usos" apresentaram 32,35% da área mapeada por "café" e 67,64% de 'outros usos'. Observa-se que a classe "café" foi superestimada na classificação (Tabela 5), com uma diferença de 203,31 hectares a mais de acordo com o mapa de referência. Isso ocorreu devido à confusão espectral de mata e pastagem presentes na classe 'outros usos' com a classe "café". Devido ao período de aquisição da imagem considerado período chuvoso, a classe "café" foi menos discriminada de mata e pastagem. Andrade et al. (2013) em seu estudo sobre aplicação de redes neurais na classificação de áreas cafeeiras encontrou confusão espectral do uso mata com a classe "café", devido a proximidade do padrão espectral de ambos. Em alguns casos, houve a não identificação da classe "café", sendo considerada 'outros usos' e isso ocorreu devido à resposta espectral do solo exposto em plantios de café com menos de 2 anos de idade, conforme exemplifica Moreira et al. (2010). Na análise do uso e ocupação do solo em uma região do município de Rio Acima - MG, Campos et al. (2013) realizaram a comparação entre métodos de classificação baseada em

objeto onde testaram a eficiência de dois *softwares* com diferentes algoritmos classificadores. Foram utilizados os algoritmos classificadores *Bhattacharya* e *K Nearest Neighbor* dos *softwares* SPRING 5.2 e ENVI EX, respectivamente. A acurácia do algoritmo *Bhattacharya* foi de 87,5% e do algoritmo *K Nearest Neighbor* 86,8%. No entanto, os autores ressaltaram que apesar do algoritmo *K Nearest Neighbor* ter apresentado uma acurácia da classificação ligeiramente inferior, ele foi o que melhor descreveu a dinâmica ambiental da região de estudo. No presente estudo, a classificação utilizando o algoritmo *K Nearest Neighbor* obteve índice kappa 0,67, o que configura a qualidade da classificação como 'muito boa' e exatidão global 91,07%, considerada uma exatidão aceitável, segundo Jensen (1996). A partir da matriz de confusão (Tabela 6) observam-se os valores em porcentagem das classes classificadas e das classes quantificadas pelo mapa de referência.

Tabela 6: Matriz de confusão (%).

Dados da Classificação Classes	Dados de referência		Total
	Café	Outros usos	
Café	90,78	6,95	80,02
Outros usos	9,22	93,05	19,98
Total	100,00	100,00	100,00

De acordo com a matriz de confusão expressa na Tabela 6, observa-se que os dados de referência da classe "outros usos" apresentaram confusão com a classe "café" em 6,95% e mapearam a área corretamente em 93,05%. A classe "café" obteve 90,78% de conferência entre a classificação e os dados de referência. Yu et al. (2006) classificaram áreas com vegetação e sem vegetação utilizando fotografia aérea de alta resolução espacial e encontraram a exatidão global de 58% utilizando o algoritmo *k nearest neighbor*. O resultado apresentado foi baixo, no entanto os autores recomendam o uso deste algoritmo na fase da classificação da análise de imagem orientada ao objeto. Conforme apresenta a Tabela 7, a acurácia do usuário para a classe "outros usos" indica

que 59,78% desta categoria classificada representou a mesma categoria em campo, já a classe "café", obteve 98,89% de acurácia do usuário. A acurácia do produtor (Tabela 7) indicou que as classes "outros usos" e "café" tiveram respectivamente 93,05 e 90,78% de probabilidade de terem sido classificadas de acordo com os dados de referência.

Tabela 7: Acurácia do usuário e acurácia do produtor.

Acurácia	Classes	%
Usuário	Café	98,89
	Outros usos	59,78
Produtor	Café	90,78
	Outros usos	93,05

Nos resultados foi possível observar que a classe "café" foi superestimada, pois, além de sua área classificada ter sido superior à área do mapa de referência, observa-se que a classe "outros usos" é classificada como "café". Isso ocorre devido aos usos contidos na classe "outros usos", a exemplo de áreas com mata e pastagem, que possuem recorrente confusão espectral com as classes de café. Budreski et al. (2007) objetivando produzir anualmente mapas acurados do uso e ocupação da terra da Amazônia, analisou o algoritmo *K Nearest Neighbor* utilizando imagens Landsat TM/ETM. Foram analisadas áreas com re-vegetação, floresta primária e áreas limpas (abandonadas ou desmatadas). No período de 1992 a 2002, a média de exatidão global foi de 83,1% e o índice kappa 0,74 com qualidade de classificação considerada "muito boa". Fernandes, Nunes e Silva (2012) realizaram a classificação orientada a objetos em imagens Landsat/TM a fim de caracterizar classes de uso e cobertura da terra na região do Médio Araguaia. Os autores utilizaram o algoritmo *K Nearest Neighbor* obtendo um índice de exatidão global de 83,3% e índice kappa 0,72. Os autores concluem afirmando que a técnica de classificação orientada a objetos apresenta resultados promissores no delineamento das classes de uso e cobertura da terra e sugerem que este método seja aplicado em

outras áreas para análise da distribuição espacial de determinado uso. Em Monte Santo de Minas, tradicional área de cultivo de café, Faria et al. (2010) utilizaram imagens do satélite SPOT para classificar áreas de café e não-café e concluíram que o algoritmo *K Nearest Neighbor*, onde $k=5$, apresentou melhores resultados que os demais algoritmos testados, com 87,9% de exatidão global e 0,59 de índice kappa. No presente trabalho, o índice kappa foi menor (0,67) que os valores focados na análise de uso e ocupação apresentados por Budreski et al. (2007) e Fernandes, Nunes e Silva (2012). Porém, visando discriminar café de outros usos, o índice kappa apresentado por Faria et al. (2010) se mostrou inferior em comparação com o resultado do presente trabalho. O valor de exatidão global foi superior em comparação com os trabalhos citados acima, com 91,07%.

3.3 Análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine*

No mapa da imagem classificada (Figura 9), é possível observar as classes 'outros usos' e 'café', obtidas utilizando o algoritmo *support vector machine*.

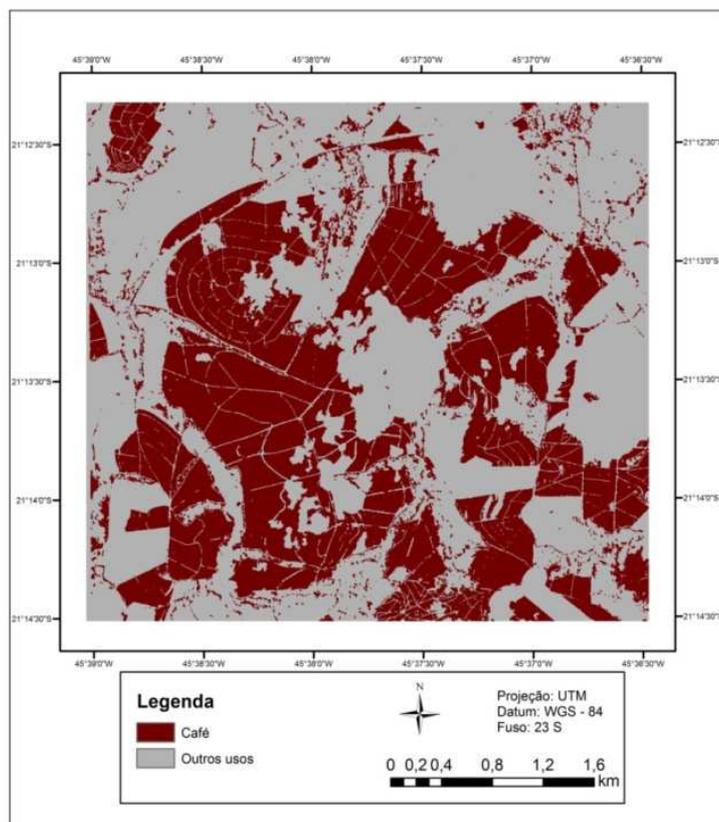


Figura 9: Mapa da Análise de imagem orientada ao objeto utilizando o algoritmo *support vector machine*.

Os valores obtidos por meio do mapa de referência e da análise de imagem orientada ao objeto são descritos na Tabela 8.

Tabela 8: Quantificação do mapa de referência e da classificação utilizando o algoritmo *support vector machine*.

Classes	Quantificação do mapa de referência		Quantificação da classificação <i>support vector machine</i>	
	Área classificada (ha)	Área classificada (%)	Área classificada (ha)	Área classificada (%)
Café	578,73	32,35	738,37	41,28
Outros usos	1209,84	67,64	1050,20	58,72
Total	1788,57	100	1788,57	100

Por meio da Tabela 8 observa-se que a classe "café" é superestimada, classificando 159,64 hectares a mais de área de acordo com o mapa de referência. Isto pode ser explicado devido à confusão espectral entre pastagem e mata com café (CORDERO-SANCHO; SANDERS, 2005).

A partir da matriz de confusão (Tabela 9) observam-se os valores em porcentagem das classes classificadas e das classes quantificadas pelo mapa de referência.

Tabela 9: Matriz de confusão (%)

Dados da Classificação	Dados de referência		Total
Classes	Café	Outros usos	
Café	89,47	1,29	78,15
Outros usos	10,53	98,71	21,85
Total	100,00	100,00	100,00

A matriz de confusão (Tabela 9) demonstra a confusão entre as classes "café" e "outros usos". Nota-se que a classe "outros usos" foi considerada como "café" em 1,29% e "café" como "outros usos" em 10,53%. A Tabela 10 ilustra os valores obtidos de acurácia do usuário e acurácia do produtor.

Tabela 10: Acurácia do usuário e do produtor

Acurácia	Classes	%
Usuário	Café	99,79
	Outros usos	58
Produtor	Café	89,47
	Outros usos	98,71

Utilizando o algoritmo *support vector machine* na classificação de imagens MODIS para discriminação de café, mata e outros usos, Bispo (2013) obteve em seu estudo 45,75% de acurácia do usuário e 39,19% de acurácia do produtor para a classe café. Neste estudo os valores obtidos para análise do usuário e do produtor foram superiores, podendo ser observado que na acurácia do usuário (Tabela 10) 99,79% da classe café representaram a mesma categoria em campo. Com relação à acurácia do produtor (Tabela 10), a probabilidade da classe "café" ter sido classificada de acordo com os dados de referência foi de 89,47%. Para testar a eficiência do algoritmo classificador *support vector machine*, Noma, Korting e Fonseca (2013) utilizaram algoritmos classificadores na identificação do uso e ocupação da terra em áreas desmatadas no estado do Mato Grosso, onde generalizaram os usos considerando as classes agricultura e não-agricultura. A eficácia do método *support vector machine* frente às classificações dos algoritmos *Optimum Path Forest*, *Decision trees*, *Naive Bayes* e *Nearest Neighbor* se mostrou superior. O algoritmo *support vector machine* apresentou 88% de acurácia, enquanto que algoritmos *Optimum Path Forest*, *Decision trees*, *Naive Bayes* e *Nearest Neighbor* apresentaram 82%, 82%, 84% e 83%, respectivamente. Segundo os autores, esta técnica é originalmente desenvolvida para avaliar duas classes obtendo resultados satisfatórios. Bispo (2013) utilizou imagens do sensor MODIS, satélite Terra para geração de imagens - fração solo, café e água/sombra. Aplicando o algoritmo *support vector machine* na composição R(imagem- fração solo)- G (imagem-fração café)- B (imagem-fração água/sombra) o autor obteve 65% de exatidão global e 0,32 de

índice kappa, cuja classificação é considerada razoável. Na classificação do presente trabalho os valores de exatidão foram 90,65% e índice kappa de 0,67 configurando a qualidade da classificação como "muito boa". Há de se ressaltar que a classificação foi precedida a uma segmentação, o que aumentaria a possibilidade de melhores resultados.

3.4 Classificação pixel a pixel utilizando o algoritmo *maximum likelihood*

A Figura 10 apresenta o mapa resultado da classificação utilizando o algoritmo *maximum likelihood*.

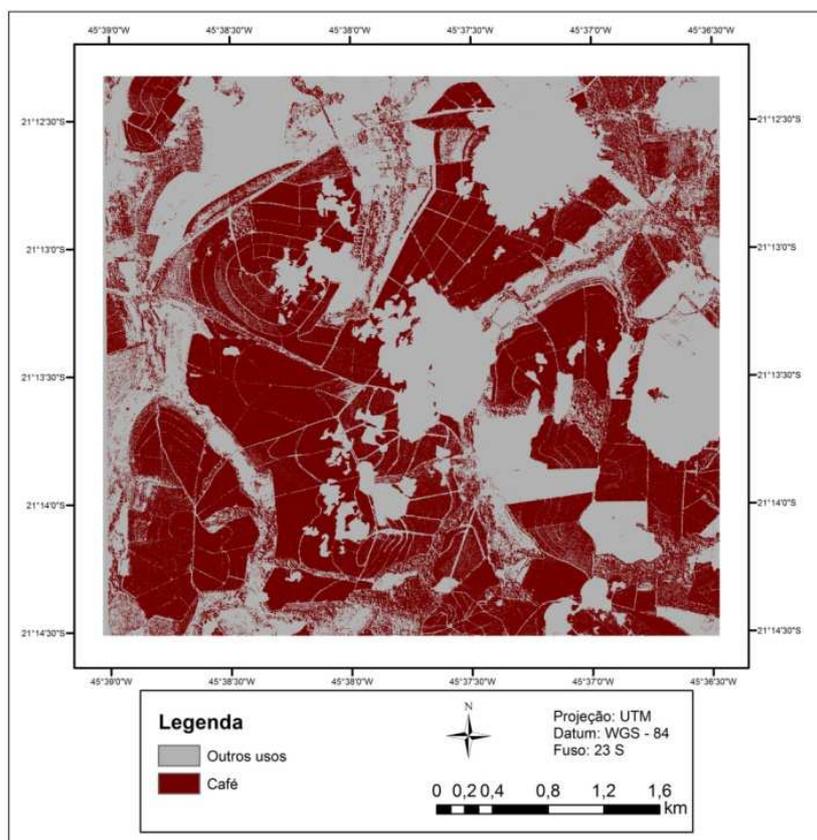


Figura 10: Mapa da Análise de imagem orientada ao objeto utilizando o algoritmo *maximum likelihood*

A quantificação do mapa de referência e da análise de imagem orientada ao objeto é descrita na Tabela 11.

Tabela 11: Quantificação do mapa de referência e da classificação pelo algoritmo *maximum likelihood*

Classes	Quantificação do mapa de referência		Quantificação da classificação <i>maximum likelihood</i>	
	Área classificada (ha)	Área classificada (%)	Área classificada (ha)	Área classificada (%)
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

A Tabela 11 demonstra a superestimação da classificação da classe "café" com relação ao dado de referência obtido via classificação visual. A classificação identificou 50,04% de café na região enquanto o mapa de referência identificou 32,35%, ou seja, a classificação identificou 316,17 ha a mais. A Tabela 12 apresenta a matriz de confusão derivada da tabulação cruzada entre a imagem classificada e os dados de referência.

Tabela 12: Matriz de confusão (%)

Dados da Classificação Classes	Dados de referência		Total
	Café	Outros usos	
Café	94,91	7,43	83,68
Outros usos	5,09	92,57	16,32
Total	100,00	100,00	100,00

Na análise da matriz de confusão (Tabela 12), é observado que a classe café foi classificada como outros usos em 5,09% e outros usos foi classificado como café em 7,43%. No entanto, em comparação com as matrizes de confusão aqui apresentadas, os resultados relatados pela Tabela 12 apontam que a classe "café" foi considerada "café" em 94,71%, o que difere com os valores obtidos

pelos algoritmos *k nearest neighbor* e *support vector machine*, com 90,78% e 89,47% respectivamente.

A Tabela 13 descreve os valores de acurácia do usuário e acurácia do produtor obtidos na fase da pós-classificação.

Tabela 13: Acurácia do usuário e do produtor

Acurácia	Classes	%
Usuário	Café	98,86
	Outros usos	72,83
Produtor	Café	94,91
	Outros usos	92,57

Analisando a acurácia do usuário (Tabela 13) é observado que 98,86% da classe café representaram a mesma categoria em campo. Na acurácia do produtor (Tabela 13), a probabilidade da classe "café" ter sido classificada de acordo com os dados de referência foi de 94,91%. Marujo et al. (2013) mapeando cultivos cafeeiros obteve 77,5% de acurácia do produtor e 54,69% de acurácia do usuário para a classe café, sendo estes resultados inferiores quando comparados a este trabalho. Machado et al. (2010) em seu estudo sobre o desenvolvimento de uma metodologia para mapeamento de áreas cafeeiras na Zona da Mata mineira utilizaram imagens Landsat/ETM+ e fotografias aéreas aliadas à técnica de classificação supervisionada pelo algoritmo *maximum likelihood*, obtendo um índice global de acertos de 0,42 para as bandas 3-4, NDVI e 3-4-5. Tardin, Assunção e Soares (1992) objetivaram discriminar as culturas do café, citrus e cana-de-açúcar por meio do processamento digital de imagens utilizando dados Landsat/TM das 4 bandas. Os autores utilizaram o algoritmo *maximum likelihood* implementado em um sistema de análise de imagens e constataram a eficiência do mesmo em discriminar a cultura do café de outros alvos. Martínez-Verduzco, Galeana-Pizaña e Cruz-Bello (2011),

realizaram o mapeamento objetivando discriminar vegetação natural de plantios de café. A partir de imagens SPOT, os autores classificaram o uso do solo com o intuito de gerar um mapa de áreas cafeeiras e obtiveram 70% de exatidão para a classe café sombreado. Duro, Franklin e Dubé (2012) 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 orientada a objetos.

4 CONSIDERAÇÕES GERAIS

Os resultados obtidos a partir dos classificadores são descritos na Tabela 14.

Tabela 14: Valores de índice kappa e exatidão global para cada método de classificação analisado.

Classificações	Kappa	Exatidão Global
<i>K NearestNeighbor</i>	0,67	91,07%
<i>Support vector machine</i>	0,67	90,65%
<i>Maximum likelihood</i>	0,78	94,61%

Foi observado que o índice kappa e exatidão global resultantes da classificação por *Maximum likelihood* foram superiores aos demais. Como mencionado, na classificação pixel a pixel o algoritmo classificador considera apenas a informação espectral, diferentemente da análise de imagem orientada ao objeto, onde são considerados os atributos espectral, espacial e de textura. Por meio deste resultado foi constatado que o classificador pixel a pixel, onde apenas a informação espectral é considerada, desempenha suas funções satisfatoriamente utilizando um número menor de classes.

5 CONCLUSÃO

Com base nas análises de imagem orientada ao objeto e na classificação pixel a pixel resultantes da utilização da imagem de alta resolução espacial QUICKBIRD foi constatado a partir do índice kappa que é possível obter resultados satisfatórios na discriminação da classe 'café' de 'outros usos' utilizando os métodos aqui propostos. No entanto, 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 ao objeto, produziu resultados ligeiramente superiores. Além disso, observam-se alguns pontos em questão: a) todas as classificações superestimaram a área da classe café, confundindo com os usos mata e pastagem; b) a utilização da imagem de alta resolução espacial teve importância significativa na obtenção de resultados superiores em comparação aos trabalhos desenvolvidos por outros autores em que ela não foi utilizada. c) A classificação utilizando o algoritmo *Maximum likelihood* é recomendada para se discriminar duas classes em imagens de alta resolução espacial; d) Nota-se que é possível obter resultados favoráveis utilizando métodos menos trabalhosos que considerem apenas os atributos espectrais para um pequeno número de classes.

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.
- 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. **Informe estatístico do café**. 14. ed. Brasília, 2013. 16 p.
- 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.
- COLLARES, J. E. R.; LAURIA, C. A.; CARRILHO, M. M. Pesquisa de previsão e acompanhamento de safras baseada em painéis de amostras de áreas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 1993, Curitiba. **Anais...** Curitiba: INPE, 1993. p. 450-453.

COLTRI, P. P. **Mitigação de emissões de gases de efeito estufa e adaptação do café Arábica à condições climáticas adversas**. 2012. 148 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2012.

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.

DUARTE, W. O.; BRITO, J. L. N. S. W. Mapeamento da cultura do café no município de Araguari-MG utilizando imagens do Sensor CCD do satélite CBERS-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 161-167.

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, 2010. 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.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual técnico de uso da terra**: manuais técnicos em geociências. 2. ed. Rio de Janeiro, 2006. 91 p.

IPPOLITI-RAMILO, G. A. et al. Sensoriamento remoto orbital como meio auxiliar na previsão de safras. **Agricultura em São Paulo**, São Paulo, v. 46, n. 1, p. 89-101, 1999.

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. 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.; JUNGHOIM, C. O. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, New York, v. 2011, n. 66, 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. **Correção atmosférica de imagens do sensor AVHRR/NOAA utilizando produtos atmosféricos do sensor MODIS/TERRA**. 2006. 129 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2006.

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.

PEDRASSOLI, J. C. **Análise orientada a objeto para detecção de favelas e classificação do uso do solo em Taboão da Serra/SP**. 2011. 109 f. Dissertação (Mestrado em Geografia Física) - Universidade de São Paulo, São Paulo, 2011.

PEREIRA, L. O. et al. Análise comparativa dos métodos de classificação SVM e Maxver-ICM polarimétrico em imagem de radar ALOS PALSAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 8223-8230.

RAMIREZ, G. M.; ZULLO-JUNIOR, 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.

ROSA, V. G. C. **Modelo agro meteorológico-espectral para monitoramento e estimativa da produtividade do café na região Sul/Sudoeste do Estado de Minas Gerais**. 2007. 142 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

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.

ROZA, W. S. S.; RIBEIRO, S. R. A. 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. 3464-3471.

SOUZA, V. C. O. et al. Análise e classificação textural de áreas de mata e café na região de Machado, MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7925-7932.

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.

SUAREZ, A. F.; CANDEIAS, A. L. B. Avaliação de acurácia da classificação de dados de sensoriamento remoto para o Municí. In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, 4., 2012, Recife. **Anais...** Recife: INPE, 2012. p. 2-10.

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, dez. 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-JUNIOR, J. **Correção atmosférica de imagens de satélite e aplicações**. 1994. 204 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 1994.

CAPÍTULO 3

Mapeamento do uso da terra considerando as classes de cobertura do café

1 INTRODUÇÃO

O mapeamento e monitoramento da Terra é uma das principais aplicações de dados de sensores remotos e tem sua importância voltada para compreensão da dinâmica da superfície (RODRIGUEZ-GALIANO et al., 2013).

Dados de sensoriamento remoto podem ser utilizados a fim de definir o uso e ocupação da terra por meio de observações. Discriminar o uso do solo é fundamental para análise de paisagens onde há a dificuldade em separar determinados alvos espectralmente. Uma maneira de extrair informações do uso e ocupação da terra a partir de dados de sensoriamento remoto é com a utilização de classificações automáticas de imagens de satélites (ROZENSTEIN; KARNIELI, 2011).

Uma variedade de métodos de classificação tem sido usada para mapeamento da cobertura da Terra utilizando sensoriamento remoto (RODRIGUEZ-GALIANO et al., 2013).

Utilizando imagens radar, Silva et al. (2008) objetivaram distinguir diferentes culturas agrícolas no oeste do estado da Bahia. Os autores discriminaram café, algodão e pastagem utilizando um algoritmo classificador específico para imagens de radar. O melhor resultado foi obtido na discriminação do uso café, com índice kappa de 0,73 e exatidão global 98,5%.

Objetivando quantificar classes de uso da terra no sul da China, Jiao, Liu e Li (2012) propuseram um estudo utilizando imagens do satélite SPOT-5. Os autores quantificaram seis classes de uso: estradas, áreas agrícolas, assentamentos, rios, áreas florestadas e grama, obtendo resultados satisfatórios.

Comparando resultados de cinco métodos classificadores na identificação de áreas agrícolas, South, Qi e Lusch (2004) realizaram um estudo em imagens Landsat/ETM+. Os autores utilizaram os classificadores: distância mínima, distância de *mahalanobis*, *maximum likelihood* e, ângulo espectral de mapeamento -*spectral angle mapping* - e *cosine of the angle concept* e em seguida analisaram sua exatidão, concluindo que os melhores métodos foram o ângulo espectral de mapeamento -*spectral angle mapping* - e *cosine of the angle concept*, com exatidão global de 91,58% e 93,52%, respectivamente.

Utilizando imagens Landsat/TM, Meyfroidt, Phuong e Anh (2013) analisaram o desmatamento em uma região do planalto central do Vietnã a partir da caracterização das mudanças do uso e cobertura da terra. Os autores optaram pelo uso do classificador por *maximum likelihood* e concluíram que os cultivos agrícolas, em especial as culturas anuais do arroz e do milho, foram a principal causa do desmatamento.

Para caracterizar a cobertura do solo agrícola no estado de Oregon, EUA, Oetter et al. (2000) utilizaram o algoritmo classificador por *maximum likelihood* em imagens Landsat/TM. Os autores concluíram seu estudo produzindo um mapa com 60 classes de cobertura representando uma grande variedade de tipos de cobertura do solo em áreas urbanas, florestais e não-florestais e obtiveram exatidão global de 73,8%.

A partir de uma imagem do satélite QUICKBIRD da região de Córdoba, Espanha, Castillejo-González et al. (2009) compararam os resultados de análises das imagens baseadas em pixels e em objetos. Os autores utilizaram os classificadores pixel a pixel: paralelepípedo, distância mínima, mahalanobis, *maximum likelihood* e ângulo espectral de mapeamento - *Spectral Angle Mapper*, bem como o algoritmo de segmentação por regiões do *software* Definiens Developer 7. Na análise do uso e cobertura da terra em imagens multiespectrais, os autores alcançaram melhores resultados utilizando a

informação do pixel e do objeto juntamente com o algoritmo *maximum likelihood*, obtendo 91,71% de exatidão global e 0,90 de índice kappa.

A importância do mapeamento do uso e ocupação da terra é devido à necessidade em compreender as mudanças e a dinâmica local. Tratando-se de uma região com grande presença de plantios de café, sendo estes importantes economicamente, há a necessidade em detectar a dimensão dos mesmos a fim de categorizá-los segundo determinadas características. A partir da correlação entre os parâmetros culturais da cultura cafeeira em imagens Landsat/TM, Vieira et al. (2006) objetivaram estabelecer padrões de identificação da cultura e observaram uma alta correlação entre a refletância medida no infravermelho próximo e a porcentagem da área coberta pelas plantas. Os autores concluem afirmando que analisar o percentual ocupado pelas plantas de café no terreno é a variável mais indicada para avaliar a resposta espectral de lavouras cafeeiras.

Ramirez (2009) sugere em sua tese que a geração de um índice agregando os parâmetros biofísicos "porcentagem de cobertura do terreno" e "densidade populacional de plantios de café" poderia ser de grande utilidade na classificação automática de áreas com café.

Imagens de satélites são fontes de dados para classificação do uso e cobertura da terra. O conhecimento de um pixel pertencente a uma classe aumenta a probabilidade de que seus pixels vizinhos pertençam a essa mesma classe. Segundo Stuckens, Coppin e Bauer (2000), classificadores pixel a pixel levam em consideração apenas a informação espectral do pixel, ignorando os outros atributos, diferentemente dos classificadores por região, que consideram os atributos espacial, espectral e de textura.

Tendo em vista a importância do mapeamento do uso e ocupação da terra reafirmada pelos autores acima citados, com o presente trabalho objetivou-se diferenciar as áreas cafeeiras em classes de porcentagem de cobertura do terreno, bem como a discriminação dos demais usos. Utilizando a fórmula

desenvolvida por Ramirez (2009) para porcentagem de cobertura no terreno, onde se realizou a categorização de "café" em classes.

2 MATERIAL E MÉTODOS

Para este capítulo foi utilizada a mesma imagem QUICKBIRD do capítulo 2, porém recortada de modo a abranger apenas a área (Figura 1c) onde foram coletadas informações sobre os plantios de café (Fazenda Pinheiros, localizada no município de Campos Gerais, MG).

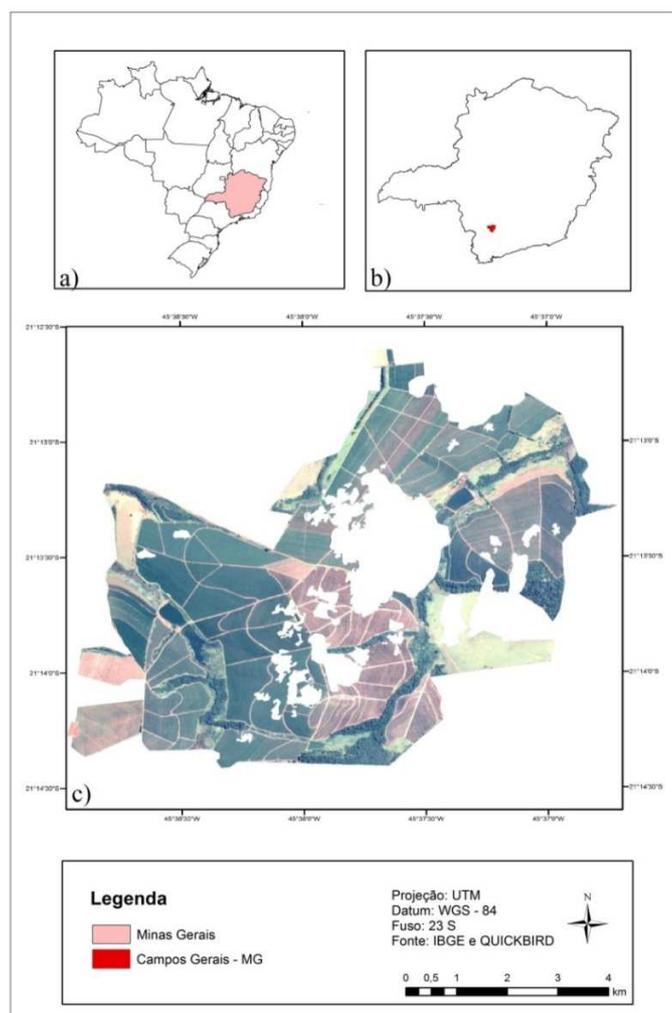


Figura 1: Área de estudo: a) Localização de Minas Gerais; b) Localização de Campos Gerais- MG; c) imagem RGB do satélite QUICKBIRD do dia 14/03/2012.

A área de estudo está inserida na mesorregião sul do estado de Minas Gerais/Brasil, no município de Campos Gerais (Figura 8). Sua localização é determinada pelas coordenadas geográficas $21^{\circ} 7' 30''$ de latitude sul e $45^{\circ} 33' 30''$ de longitude oeste. A propriedade escolhida possui toda a área irrigada por

gotejamento e produz somente café especial (bebida fina), sendo que toda a produção é destinada à exportação.

2.1 Material

Foram utilizados os seguintes dados e *softwares* para realização deste trabalho:

1) Imagem do satélite QUICKBIRD de 14 de março de 2012, contendo quatro bandas multiespectrais com 2,44 m de resolução espacial, conforme indica Tabela 1, e 8 bits de resolução radiométrica. A empresa contratada forneceu a imagem com 8 bits de resolução radiométrica, e para não comprometer os resultados do trabalho do ponto de vista radiométrico, os níveis de cinza foram convertidos em valores de refletância real. A geometria de iluminação da cena no momento da obtenção de imagem possuía as seguintes características: ângulo de elevação do satélite de 75,4°; ângulo azimutal do satélite de 91,8°; ângulo de elevação do sol de 48,6° e ângulo azimutal do sol de 68°.

Tabela 1: Bandas do satélite QuickBird

Banda	Faixa espectral (μ)	Resolução espacial (m)
Banda do azul	0,450 – 0,520	2,44
Banda do verde	0,520 – 0,600	2,44
Banda do vermelho	0,630 – 0,690	2,44
Banda do infravermelho	0,760 – 0,900	2,44

2) Imagens MOD04, MOD05 e MOD07 do sensor MODIS (Moderate Resolution Imaging Spectroradiometer) satélite Terra, obtida no dia 14 de março de 2012, para correção atmosférica no *software* SCORADIS.

3) Conferência em campo utilizando a imagem de alta resolução adquirida (QUICKBIRD) para coleta de dados referente aos plantios de café. Para análise da porcentagem de cobertura do terreno pelos plantios de café, houve a coleta de dados de dezessete talhões (Figura 2).

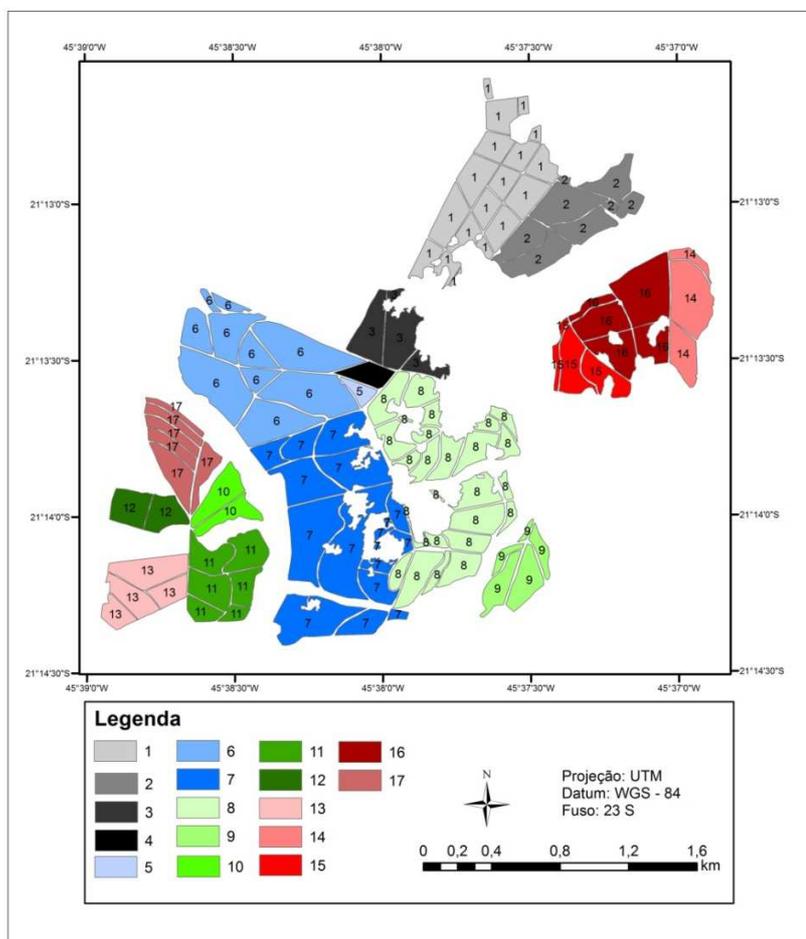


Figura 2: Talhões de café da Fazenda Pinheiros, Campos Gerais - Minas Gerais.

Em cada um dos dezessete talhões foram analisadas 15 plantas por meio da medição do diâmetro (m) e do espaçamento entre linhas de plantio (m). As quinze plantas foram escolhidas por sorteio aleatório.

A partir destes dois dados calculou-se a porcentagem de cobertura do terreno por plantios de café, utilizando a fórmula desenvolvida por Ramirez (2009).

A porcentagem de cobertura do terreno pelas plantas de café (% Cob) foi calculada a partir da área ocupada pelas plantas de café de acordo com a Equação 1, utilizada onde há a formação em renque (Figura 3) dos plantios de café.

$$\% \text{ Cob} = \left(\frac{D}{EL} \right) \cdot 100 \quad (1)$$

onde,

%Cob é a porcentagem de cobertura do terreno pelas plantas de café,

D é o diâmetro da planta

EL é o espaçamento entre linhas de plantio.



Figura 3: Formação em renque

A partir do levantamento em campo, o uso café foi categorizado em classes segundo intervalos de porcentagem de cobertura no terreno (Tabela 24).

Tabela 2: Classes de porcentagem de cobertura do terreno pelos plantios de café

Usos	Talhões	% de cobertura
Café 1	12,13	30 - 36%
Café 2	8, 9, 14, 15, 16,17	45 - 50%
Café 3	2, 6, 10,11	50 - 54%
Café 4	1, 3, 4, 5,7	> 54%

A Figura 4 ilustra a localização e distribuição espacial das classes de café.

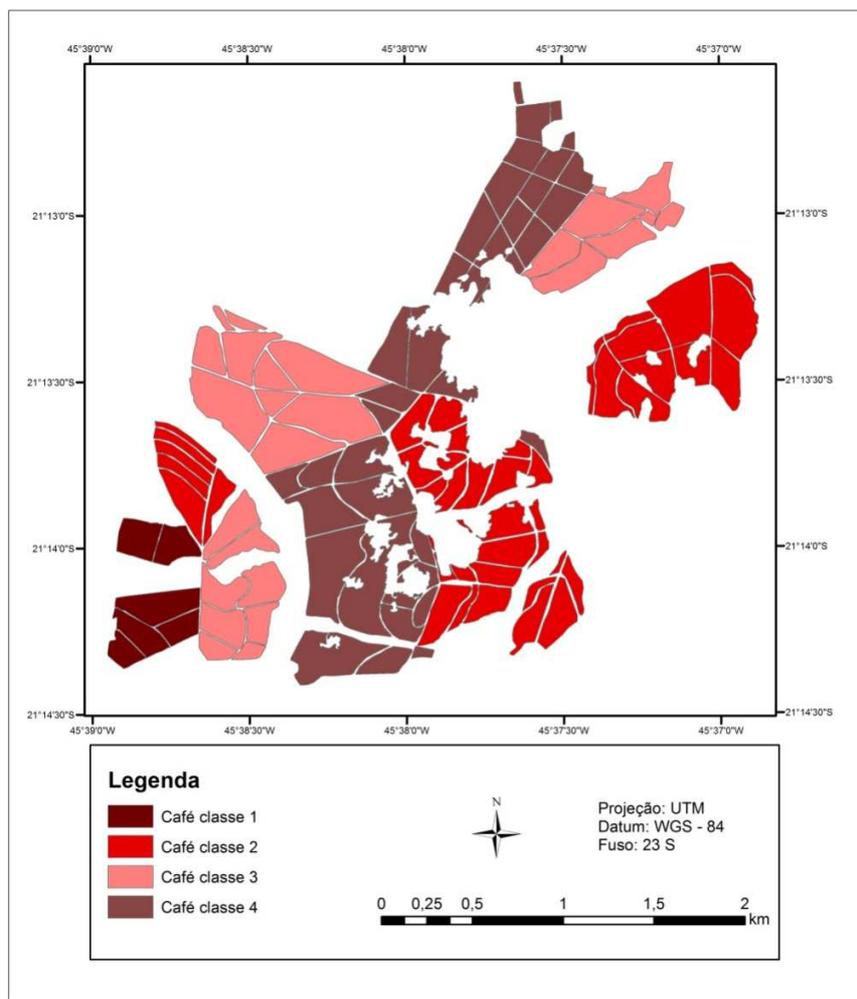


Figura 4: Classes de porcentagem de cobertura

2.2 Metodologia

A Figura 5 mostra o fluxograma de acordo com as atividades desenvolvidas.

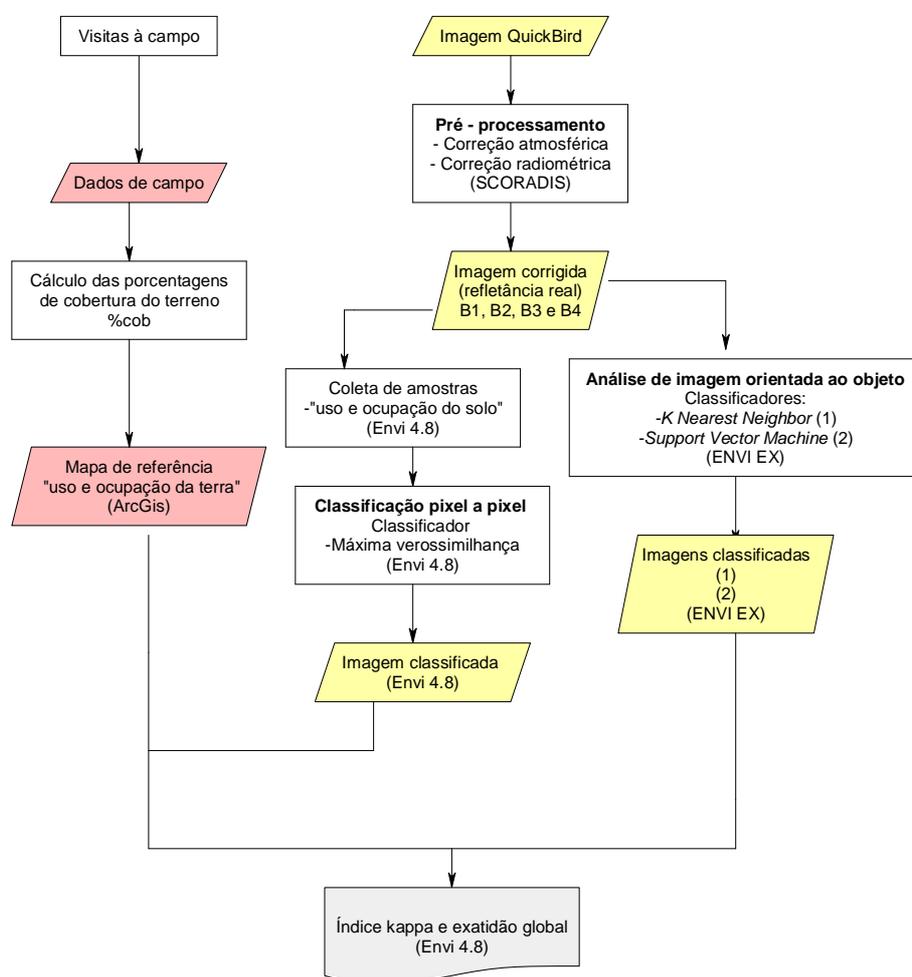


Figura 5: Fluxograma das atividades desenvolvidas

2.2.1 Eliminação das nuvens e sombras

Após o recebimento da imagem foi necessária 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 de modo a eliminar todos os pixels contaminados. Na Figura 6 é possível observar a imagem original, enviada pela empresa contratada e na Figura 7 a imagem após a eliminação das nuvens e sombras.



Figura 6: Imagem original RGB 321

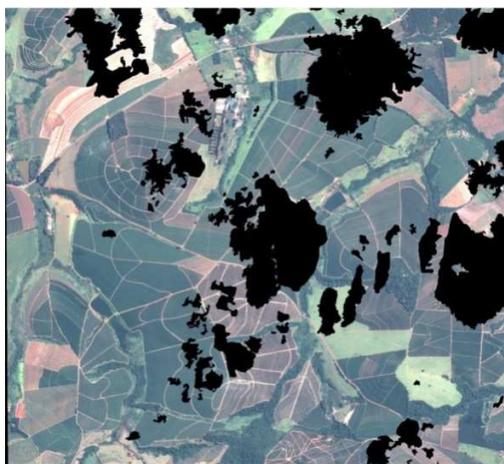


Figura 7: Imagem RGB 321 com nuvens e sombras eliminadas.

2.2.2 Correção atmosférica e radiométrica

Para a correção radiométrica e atmosférica, foi utilizado o sistema computacional SCORADIS (Sistema de Correção Radiométrica de Imagens de Satélite), desenvolvido por Zullo-Junior (1994). Este sistema baseia-se no modelo de transferência radiativa 5S e foi desenvolvido a partir de trabalhos experimentais realizados nas condições brasileira de atmosfera e clima. Os dados de entrada, para correção atmosférica, foram obtidos de acordo com a metodologia descrita por Nascimento (2006). Os dados obtidos a partir do sensor MODIS Terra, tais como, espessura óptica dos aerossóis, coluna total de vapor d'água e carga total de ozônio dos arquivos MOD04, MOD05 e MOD07 estavam disponíveis no site da NASA - Empresa que disponibiliza imagens do satélite Terra (Tabela 3).

Tabela 3: Descrição dos dados obtidos a partir do MODIS para entrada no SCORADIS.

Dados	Valores
Espessura óptica dos aerossóis	0,09
Coluna total de vapor d'água (g/cm ²)	2,60
Carga total de ozônio (cm.atm)	0,26

2.2.3 Mapa de referência da área de estudo

A área de estudo foi categorizada em classes com ênfase na diferenciação de áreas cafeeiras segundo porcentagem de cobertura dos plantios de café (Tabela 2 e Figura 4). Houve a geração de um mapa de referência (Figura 8) abrangendo a área de coleta dos dados e os usos presentes em seu entorno. Tal mapa contém as seguintes classes: café classe 1, café classe 2, café classe 3, café classe 4 (de acordo com os valores de porcentagem de cobertura do terreno pelas plantas de café, descritos na Tabela 2), solo exposto, corpos d'água, mata e pastagem.

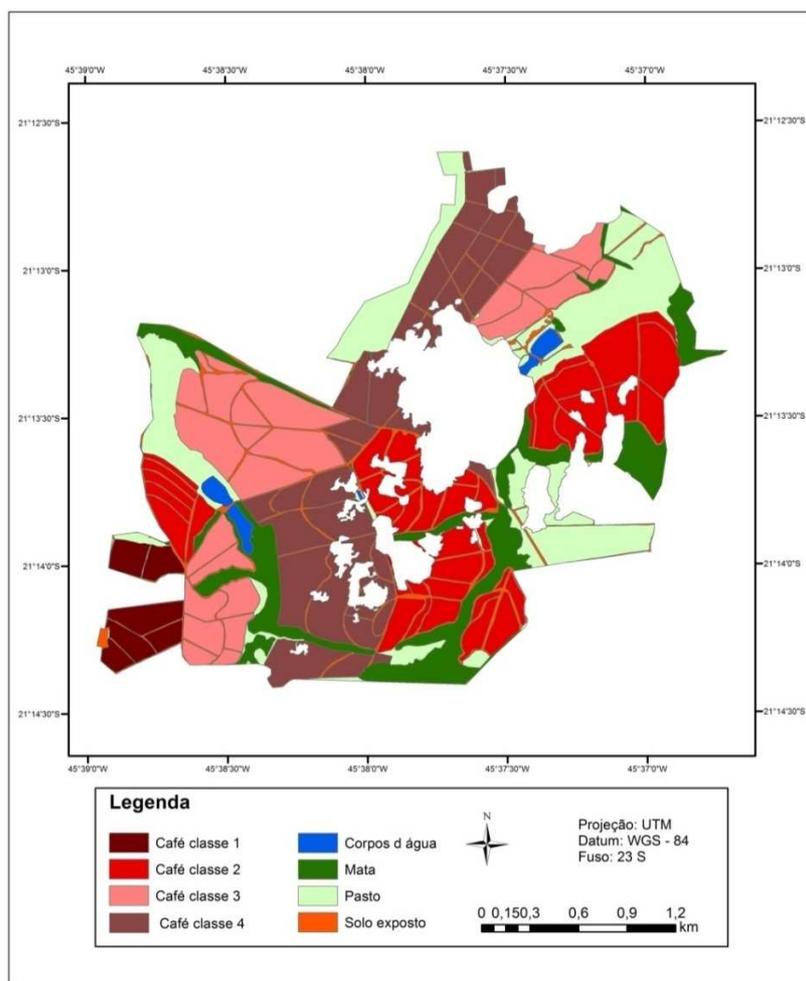


Figura 8: Mapa de referência da Fazenda Pinheiros.

2.2.4 Análise de imagem orientada ao objeto

Neste procedimento, foram realizadas a segmentação e a classificação orientada a objetos utilizando as bandas do satélite QUICKBIRD processadas com o *software* ENVI EX.

2.2.4.1 Segmentação

Segmentação é um processo que particiona uma imagem, subdividindo-a, cujo nível de detalhe está associado à detecção de objetos e regiões de interesse. O processo de segmentação por extração de características utilizado no *software* é baseado no algoritmo que simula uma bacia hidrográfica por imersão, o chamado *watersheds by immersion* (CAMPOS et al., 2013; VINCENT; SOILLE, 1991). O *software* ENVI EX utiliza esse algoritmo para segmentar imagens. O passo inicial é a extração de características da imagem, a partir da ferramenta *feature extraction*, que extrai informações a partir de imagens pancromáticas e multiespectrais. Este recurso utiliza uma abordagem baseada em objetos para segmentar imagens, definido a partir de uma região de interesse com características espaciais, espectrais (brilho e cor) e texturais que definem a região (AGUIRRE-GUTIÉRREZ; SEIJMONSBERGEN; DUIVENVOORDEN, 2012; BLASCHKE, 2010; YAN et al., 2006). O *software* ENVI EX emprega um algoritmo de segmentação baseado no conhecimento e requer apenas um parâmetro de entrada, nível de escala, onde se define a similaridade dos pixels. Escolhendo um alto nível de escala, menos segmentos são definidos, já em uma escala de baixo nível, surgem mais segmentos a serem definidos, ou seja, numa escala de 0 a 100, 0 se refere a uma super-segmentação e 100 a nenhuma segmentação. Em seguida, há a fusão de segmentos por meio da ferramenta *merge*. Essa ferramenta é utilizada para agregar pequenos segmentos dentro de grandes áreas. O parâmetro *merge* ou nível de fusão varia de 0 a 100, onde há a fusão de segmentos adjacentes com base em uma combinação de informação espacial e espectral. Estes valores, atribuídos ao nível de escala e fusão, foram definidos com base na pré-visualização disponibilizada pelo *software*.

Na etapa seguinte, há a opção de refinar os resultados obtidos a partir da ferramenta *thresholding*, onde sua utilização é recomendada quando os objetos

de interesse possuem um alto contraste em relação ao restante da imagem. Este procedimento facilita a segmentação e posterior extração das feições. Seguindo este critério, para este trabalho a ferramenta *thresholding* não foi adotada.

Ainda neste procedimento, no modo avançado são oferecidas duas opções: espaço de cores e razão de bandas. A Tabela 4 apresenta os valores empregados na segmentação.

Tabela 4: Segmentação: Valores de nível de escala e fusão, espaço de cores e razão de bandas.

Imagem recortada	Nível de escala	Fusão	Espaço de cores	Razão de bandas
	75	80	4 - 3 - 2	3 - 4

Em espaço de cores, utilizam-se as bandas selecionadas visando representar as cores em termos de intensidade e isto ocorre quando há três ou mais bandas. Em razão de bandas há o cálculo normalizado entre duas bandas. Foram escolhidas as bandas do vermelho e do infravermelho próximo, formando o NDVI - índice de vegetação por diferença normalizada. O valor de NDVI varia de -1 a 1, sendo que em vegetações verdes e saudáveis, o índice varia de 0,2 a 0,8 (ROUSE et al., 1973).

$$NDVI = ((IVP-V))/ ((IVP+V)) \quad (2)$$

onde, IVP é a refletância na faixa espectral do infravermelho próximo e V é a refletância na faixa espectral do vermelho.

Na região do vermelho, nota-se que a clorofila absorve a energia solar, ocasionando baixa refletância, enquanto na faixa do infravermelho próximo, tanto a morfologia interna das folhas quanto a estrutura da vegetação ocasionam a alta refletância da energia solar incidente. Quanto maior o contraste, maior o vigor da vegetação na área imageada. A combinação destas duas faixas

espectrais realça as áreas de vegetação nas imagens, sendo este o princípio em se baseiam as diferenças de vegetação. Uma boa segmentação garante que os resultados da classificação sejam mais precisos. Terminada a segmentação, realizaram-se as classificações.

2.2.4.2 Classificação utilizando *k nearest neighbor* e *support vector machine*

Na fase da classificação foram coletadas amostras dos usos café classe 1, café classe 2, café classe 3, café classe 4, solo exposto, corpos d água, mata e pastagem no *software* ENVI EX. Com a finalidade de extrair informações e reconhecer padrões e objetos homogêneos, foram adotados os métodos de classificação supervisionada disponíveis no *software*, sendo estes, *K Nearest Neighbor* e *support vector machine*. Ainda na classificação foram considerados os parâmetros disponibilizados pelo *software* para os atributos espacial, textura, espectral e customizado, descritos a seguir:

- a) Espacial: área (*area*), comprimento (*length*), compactidade (*compact*), convexidade (*convexity*), solidez (*solidity*), arredondamento (*roundness*), fator forma (*formfactor*), alongamento (*elongation*), medida do retângulo (*rect_fit*), direção principal (*maindir*), comprimento do eixo maior (*majaxislen*), comprimento do eixo menor (*minaxislen*), número de orifícios do polígono (*numholes*) e área total do polígono da zona de contorno externo (*holesolrat*);
- b) Textura: distância da textura (*tx_range*), média da textura (*tx_mean*), variância da textura (*tx_variance*), entropia da textura (*tx_entropy*);
- c) Espectral: valor mínimo dos pixels que compõem as bandas 1, 2, 3, 4 e combos (*minband_x*), valor máximo dos pixels que compõem as bandas 1, 2, 3, 4 e combos (*maxband_x*), valor médio dos pixels que compõem as bandas 1, 2, 3, 4 e combos (*avgband_x*) e valor do desvio padrão dos pixels que compõem as bandas 1, 2, 3 e 4 e combos (*stdband_x*);

d) Customizado: razão entre bandas (*bandratio*), matiz (*hue*), saturação (*saturation*), intensidade (*intensity*), considerado apenas para as bandas 1,2,3 e 4.

O algoritmo de classificação baseado no *k nearest neighbor* é uma técnica empregada no reconhecimento de padrões onde o *software* exige a seleção de valores para o parâmetro *k*, sendo este o número de vizinhos considerados durante a classificação (XU et al., 2013). Foram testados os valores 1, 3, 5 e 7 (só é possível utilizar valores ímpares) para o parâmetro *K* - representa o número de vizinhos testados na classificação -, sendo selecionado o valor 1 por apresentar melhores resultados.

O algoritmo *support vector machine*, determina-se limites de decisão para a separação das classes bem como a minimização dos erros (MOUNTRAKIS; JUNGHOIM, 2010). Foi selecionado o a função *kernel radial basis*, recomendado por Pereira et al. (2011) e Roza e Ribeiro (2013). Os valores *gamma* e parâmetro de penalidade foram 0,03 e 100.00, valores padrões sugeridos pelo *software*.

2.2.5 Classificação pixel a pixel utilizando *maximum likelihood*

Para analisar a eficácia dos resultados das análises de imagens baseada em objetos, realizou-se a classificação pixel a pixel, utilizando o algoritmo *maximum likelihood*. Esta classificação foi realizada a partir das bandas 1- 2 - 3 e 4. . Para a classificação pixel a pixel por *maximum likelihood* no *software* ENVI 4.8 foram coletadas amostras de 100 pixels por uso para: classe 1, café classe 2, café classe 3, café classe 4, solo exposto, corpos d água, mata e pastagem.

2.2.6 Exatidão

Posterior às classificações utilizando os algoritmos *k nearest neighbor* e *support vector machine* e o algoritmo *maximum likelihood*, houve a pós-classificação, ou seja, a comparação das imagens resultantes classificadas com os dados oriundos do mapa de referência para análise da exatidão.

Na pós-classificação avaliou-se a exatidão das classificações a partir da matriz de confusão tendo como resultado as seguintes análises: índice kappa, exatidão global, acurácia do usuário e acurácia do produtor. O índice kappa proposto por Landis e Koch (1977) considera toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação. Para obter o índice Kappa é necessária a utilização da seguinte equação:

$$k = \frac{N \sum x_{ii} - \sum x_{i+} x_{+i}}{N^2 - \sum x_{i+} x_{+i}} \quad (3)$$

Onde:

k = Índice *Kappa* de concordância; N = número de observações (verdades de campo); x_{ii} = observações na linha i e coluna i (diagonal principal); x_{i+} = total marginal da linha i ; x_{+i} = total marginal da coluna i

Para conceituar os resultados obtidos pelo coeficiente Kappa, foram utilizados os intervalos definidos por Landis e Koch (1977) como mostra a Tabela 5.

Tabela 5: Índice Kappa

Valor de Kappa	Qualidade da Classificação
< 0,0	Péssima
0,0 – 0,2	Ruim
0,2 – 0,4	Razoável
0,4 – 0,6	Boa
0,6 – 0,8	Muito boa
0,8 – 1,0	Excelente

Fonte: Landis e Kock (1977)

A Exatidão Global é obtida dividindo o somatório dos pixels classificados corretamente contidos na diagonal principal pelo número total de pixels com o resultado em porcentagem de acertos, e o mínimo aceito para mapas de uso é de 85% (JENSEN, 1996).

A acurácia do usuário é calculada dividindo o número total de pixels corretamente classificados em uma classe pelo número total de pixels classificados nessa classe e refere-se aos erros de comissão a partir da probabilidade que um pixel classificado na imagem tem de representar a classe no campo, onde para Ferreira, Dantas e Morais (2007), a comissão se refere a delimitação excessiva de determinada classe. A acurácia do produtor é calculada dividindo o número total de pixels corretamente classificados em uma classe pelo número total de pixels desta classe, indicado na referência de campo. Para Suarez e Candeias (2012), a acurácia do produtor se refere aos erros de omissão, sendo a probabilidade de um pixel de referência ser corretamente classificado. Ainda segundo Ferreira, Dantas e Morais (2007), a omissão se refere a uma imperfeita definição de determinada classe.

3 RESULTADOS

3.1 Mapa de referência da área de estudo

O mapa de referência da área de estudo (Figura 9) obtido a partir da classificação visual da imagem de alta resolução espacial do satélite QUICKBIRD, serviu de apoio na averiguação da acurácia do mapeamento realizado segundo os algoritmos analisados.

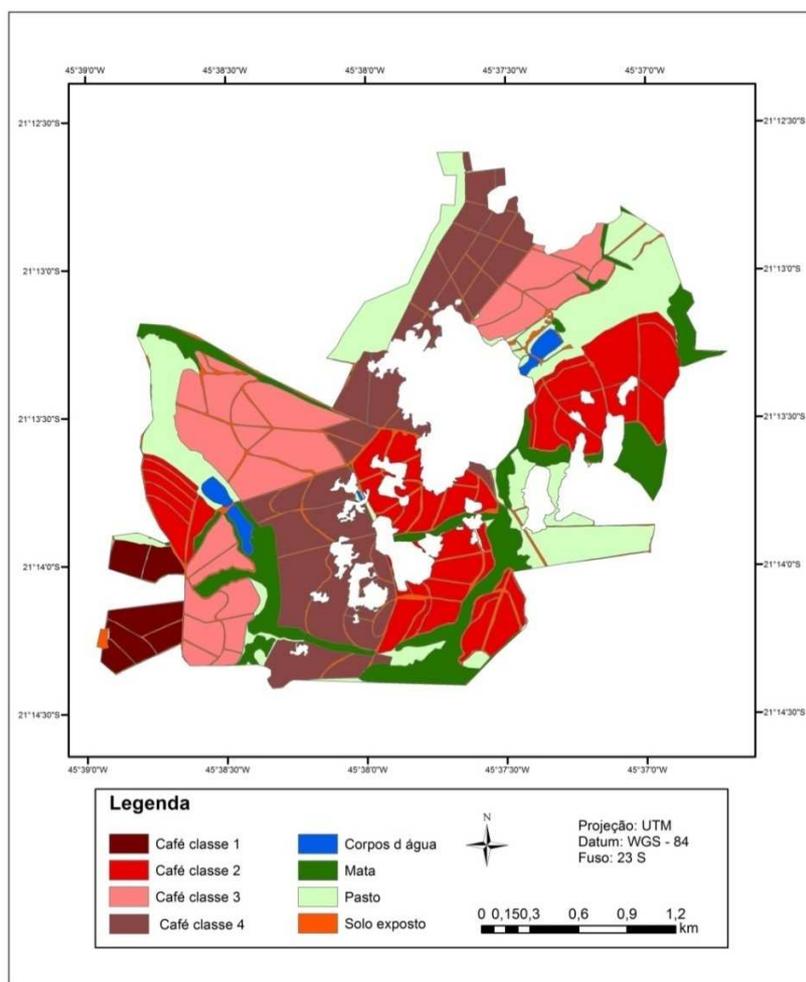


Figura 9: Mapa de referência da Fazenda Pinheiros.

O Gráfico 1 ilustra a distribuição dos usos de acordo com a quantificação do mapa de referência da área de estudo.

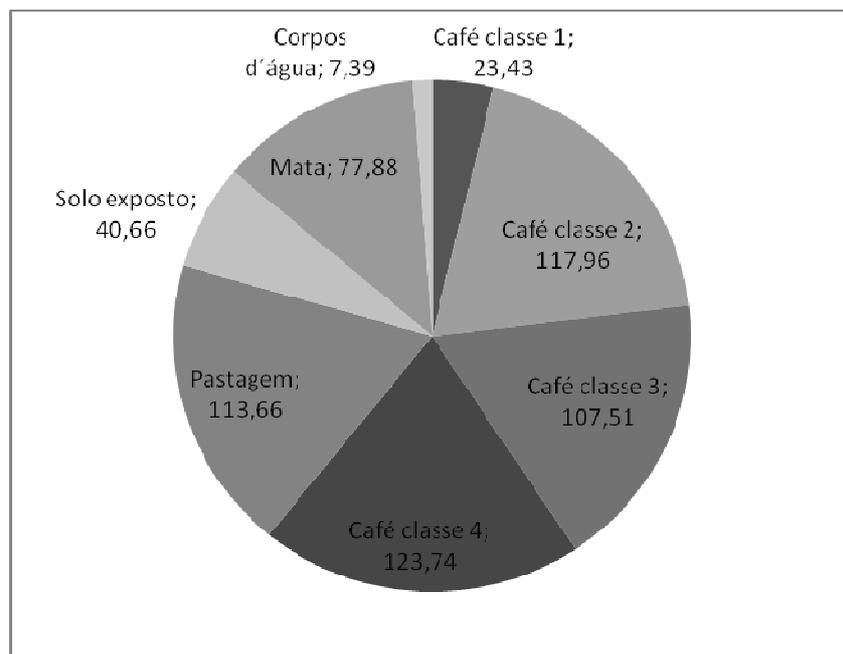


Gráfico 1: Distribuição dos usos, valores dados em hectares.

3.1 Análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor*

O resultado obtido pela análise de imagem orientada ao objeto a partir do algoritmo *K Nearest Neighbor* é apresentado na Figura 10.

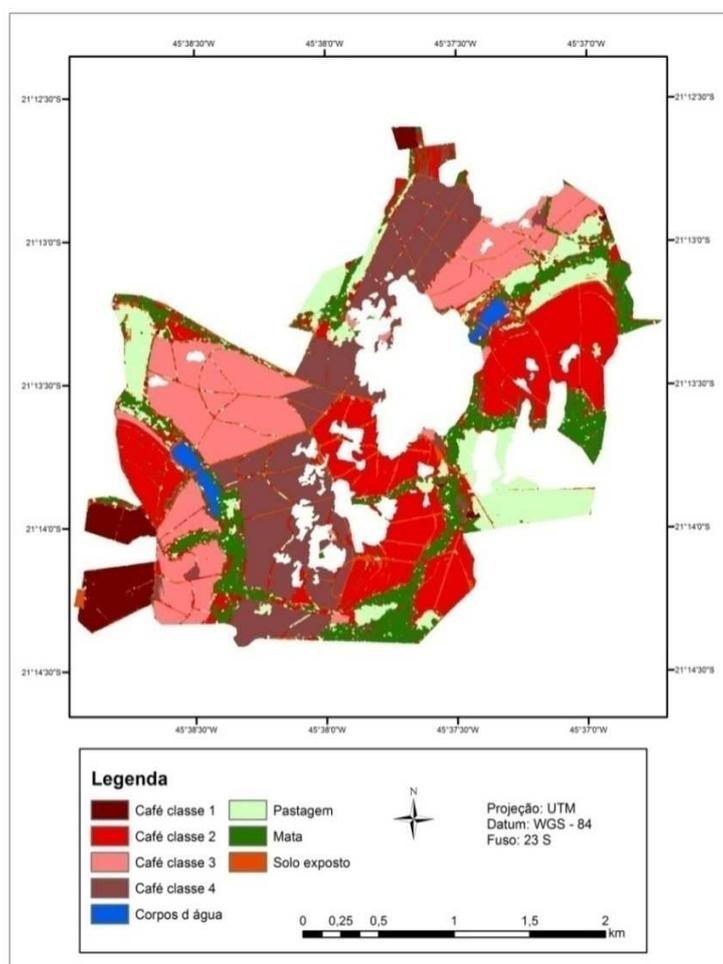


Figura 10: Mapa da análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor*

Os valores obtidos por meio de da análise de imagem orientada ao objeto podem ser visualizados nas Tabelas 6 e 7, onde há a comparação com a quantificação do mapa de referência.

Tabela 6: Quantificação do mapa de referência por classes de uso

Classes	Área classificada (hectares)	Área classificada (em porcentagem)
Café classe 1	23,43	3,82
Café classe 2	117,96	19,26
Café classe 3	107,51	17,56
Café classe 4	123,74	20,21
Pastagem	113,66	18,56
Solo exposto	40,66	6,64
Mata	77,88	12,72
Corpos d' água	7,39	1,20
Total	612,23	100

Tabela 7: Quantificação da análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor*

Classes	Área classificada (hectares)	Área classificada (em porcentagem)
Café classe 1	27,18	4,43
Café classe 2	154,04	25,16
Café classe 3	114,49	18,70
Café classe 4	125,74	20,53
Pastagem	76,15	12,43
Solo exposto	25,04	4,08
Mata	82,38	13,45
Corpos d' água	7,21	1,17
Total	612,23	100

Tabela 8: Diferenças entre resultados da análise de imagem orientada ao objeto com relação ao mapa de referência

Classes	Área (hectares)	Superestimado/ subestimado
Café classe 1	3,75	Superestimado
Café classe 2	36,08	Superestimado
Café classe 3	6,98	Superestimado
Café classe 4	2	Superestimado
Pastagem	37,51	Subestimado
Solo exposto	15,62	Subestimado
Mata	4,5	Superestimado
Corpos d' água	0,18	Subestimado

Observa-se, na Tabela 8, que a quantidade de área (hectares) superestimada e subestimada, sendo pastagem o uso mais subestimado e café classe 2 o mais superestimado. Os usos Corpos d'água e café classe 2 apresentaram menor diferença de área calculada na comparação entre classificação e mapa de referência.

Trabalhos de Campos et al. (2013) e Fernandes, Nunes e Silva (2012) utilizam o algoritmo *K Nearest Neighbor* na classificação orientada ao objeto para análise do uso do solo em Rio Acima - MG e Araguaia, respectivamente. Os autores verificaram a eficácia do algoritmo por meio dos resultados satisfatórios da discriminação de classes de uso e ocupação da terra. Neste trabalho também houve o emprego do algoritmo *k nearest neighbor*, onde foram obtidos os melhores resultados.

As Tabelas 9 e 10 apresentam o resultado da tabulação cruzada entre os dados resultantes da análise de imagem orientada ao objeto pelo algoritmo *K Nearest Neighbor* (Figura 9) e o mapa de referência (Figura 8).

Tabela 9: Matriz de confusão (pixels)

Classe	Mapa de referência obtido via classificação visual								
Uso	Café 1	Café 2	Café3	Café4	Pastagem	Solo	Mata	Água	Total
Café1	<u>40048</u>	29	28	63	4879	1877	145	1	47070
Café2	208	<u>195544</u>	4282	10168	24218	17660	14722	72	266874
Café3	15	578	<u>172676</u>	2221	14823	4970	2431	0	197714
Café4	34	1550	3963	<u>194461</u>	3938	5353	7595	34	216928
Pastagem	163	1695	584	702	<u>107511</u>	6621	9043	45	126364
Solo	230	3250	631	832	7806	<u>31105</u>	2732	279	46865
Mata	141	2069	1008	4363	33477	3080	<u>97928</u>	289	142355
Água	0	0	0	0	185	42	163	<u>12148</u>	12538
Total	40839	204715	183172	212810	196837	70708	134759	12868	<u>1056708</u>

Tabela 10: Matriz de confusão (porcentagem)

Classe	Mapa de referência obtido via classificação visual								
Uso	Café1	Café2	Café3	Café4	Pastagem	Solo	Mata	Água	Total
Café1	<u>98,06</u>	0,01	0,02	0,03	2,48	2,65	0,11	0,01	4,45
Café2	0,51	<u>95,52</u>	2,34	4,78	12,30	24,98	10,92	0,56	25,26
Café3	0,04	0,28	<u>94,27</u>	1,04	7,53	7,03	1,80	0,00	18,71
Café4	0,08	0,76	2,16	<u>91,38</u>	2,00	7,57	5,64	0,26	20,53
Pastagem	0,40	0,83	0,32	0,33	<u>54,62</u>	9,36	6,71	0,35	11,96
Solo	0,56	1,59	0,34	0,39	3,97	<u>43,99</u>	2,03	2,17	4,44
Mata	0,35	1,01	0,55	2,05	17,01	4,36	<u>72,67</u>	2,25	13,47
Água	0,00	0,00	0,00	0,00	0,09	0,06	0,12	<u>94,40</u>	1,19
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	<u>100,00</u>

Foram observados os resultados mais expressivos, obtidos pelos usos pastagem, solo exposto e mata. O uso pastagem foi classificado como mata (17,01 %) e café classe 2 (12,30%); solo exposto foi classificado como café classe 2 (24,98%) e mata como café classe 2 (10,92%).

As Tabelas 11 e 12 apontam os valores de acurácia do usuário e acurácia do produtor.

Tabela 11: Acurácia do usuário

Classes	Porcentagem	Pixels
Café classe 1	85,08	40048/47070
Café classe 2	73,27	195544/266874
Café classe 3	87,34	172676/197714
Café classe 4	89,64	194461/216928
Pastagem	85,08	107511/126364
Solo exposto	66,37	31105/46865
Mata	68,79	97928/142355
Corpos d'água	96,89	12148/12538

Tabela 12: Acurácia do produtor

Classes	Porcentagem	Pixels
Café classe 1	98,06	40048/40839
Café classe 2	95,52	195544/204715
Café classe 3	94,27	172676/183172
Café classe 4	91,38	194461/212810
Pastagem	54,62	107511/196837
Solo exposto	43,99	31105/70708
Mata	72,67	97928/134759
Corpos d'água	94,40	12148/12868

Na análise da acurácia do usuário (Tabela 11), observa-se que os usos que melhor representaram a mesma categoria em campo foram Corpos d'água (96,89%), café classe 4 (89,64%) e café classe 3 (87,34%). Na acurácia do produtor (Tabela 12), os usos que tiveram a maior probabilidade de serem classificados de acordo com o mapa de referência foram café classe 1 (98,06%) e café classe 2 (95,52%).

Como observado, pastagem foi mais subestimado, sendo classificado como outros usos. Como observado na matriz de confusão (Tabela 10), o uso pastagem foi classificado como mata (17,01%) e café classe 2 (12,30%).

A confusão com mata ocorreu devido à presença de vegetação natural menos densa. Já o uso café classe 2 foi mais superestimado, ou seja, outros usos foram classificados como tal, principalmente solo exposto (24,98) e pastagem (12,30). Esse fato se deu devido à presença de solo exposto nas entre linhas de plantio, havendo na imagem uma mistura espectral entre pixels correspondentes a solo exposto e aos plantios de café, dificultando a separação dos usos. Com relação à pastagem, a confusão ocorreu por conta do café classe 2 possuir entre 45 - 50% de porcentagem de cobertura do terreno, havendo também segundo Moreira, Adami e Rudorff (2004), a similaridade do comportamento espectral entre essas duas classes. Em linhas gerais, a utilização deste algoritmo rendeu os melhores resultados de classificação neste capítulo.

Os resultados derivados da tabulação cruzada entre análise de imagem orientada ao objeto pelo algoritmo *K Nearest Neighbor* e o mapa de referência apontaram que a qualidade da classificação foi "muito boa" sendo esta atribuída pelo índice kappa, 0,76. Este trabalho obteve 86,34% de exatidão global e, segundo Jensen (1996), o valor obtido está acima do patamar mínimo, 85%.

3.2 Análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine*

No mapa da análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine* (Figura 11) é possível observar as classes classificadas.

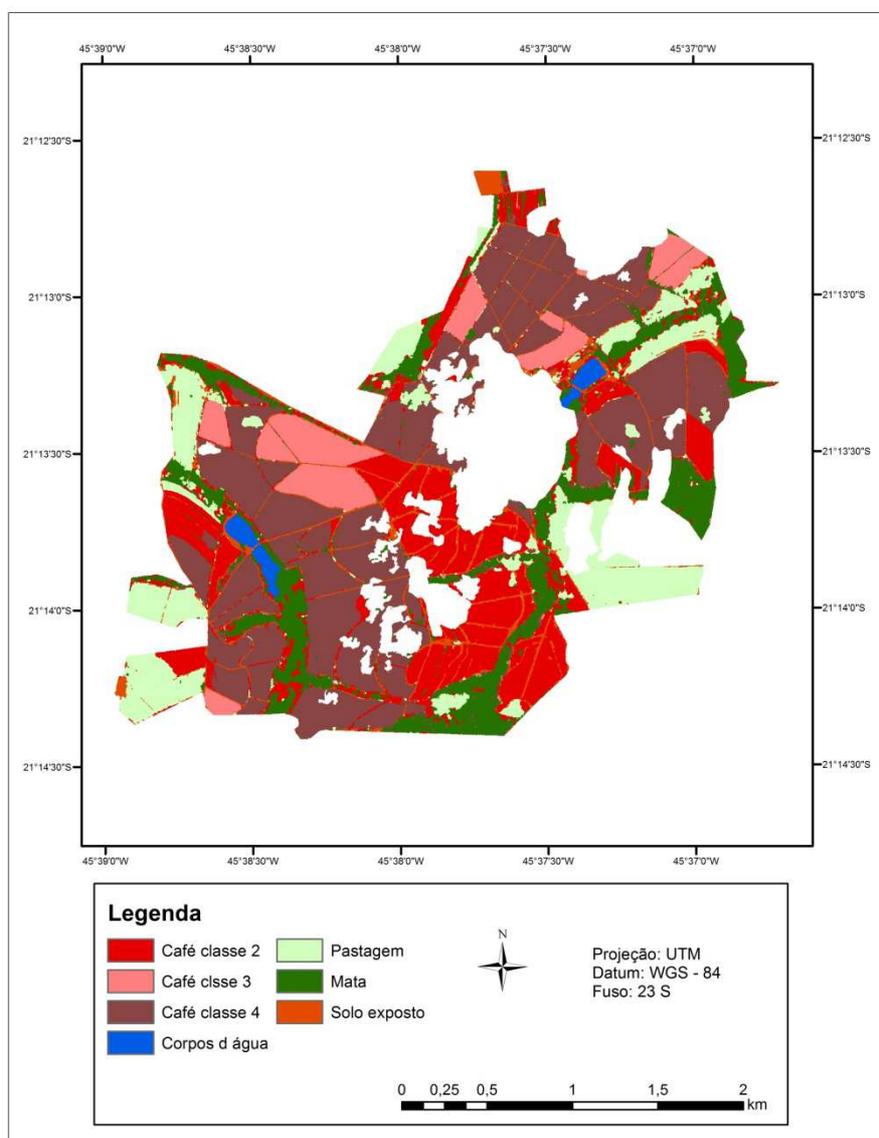


Figura 11: Mapa da análise de imagem orientada ao objeto utilizando o algoritmo *support vector machine*

Nas tabelas 13 e 14 podem ser observados os valores correspondentes à quantificação da área do mapa de referência e da análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine*.

Tabela 13: Quantificação do mapa de referência por classes de uso

Classes	Área classificada (hectares)	Área classificada (em porcentagem)
Café classe 1	23,43	3,82
Café classe 2	117,96	19,26
Café classe 3	107,51	17,56
Café classe 4	123,74	20,21
Pastagem	113,66	18,56
Solo exposto	40,66	6,64
Mata	77,88	12,72
Corpos d'água	7,39	1,20
Total	612,23	100

Tabela 14: Quantificação da análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine*

Classes	Área classificada (hectares)	Área classificada (em porcentagem)
Café classe 1	0,02	0,003
Café classe 2	127,33	20,79
Café classe 3	47,92	7,82
Café classe 4	225,93	36,90
Pastagem	87,04	14,21
Solo exposto	29,25	4,77
Mata	87,54	14,29
Corpos d'água	7,2	1,17
Total	612,23	100

A Tabela 15 mostra se determinado uso foi superestimado ou subestimado na comparação entre a classificação com o mapa de referência.

Tabela 15: Diferenças entre resultados da classificação com relação ao mapa de referência

Classes	Área (hectares)	superestimado/ subestimado
Café classe 1	23,41	Subestimado
Café classe 2	9,37	Superestimado
Café classe 3	59,59	Subestimado
Café classe 4	102,19	Superestimado
Pastagem	26,62	Subestimado
Solo exposto	11,41	Subestimado
Mata	9,66	Superestimado
Corpos d'água	0,19	Subestimado

Há de se ressaltar que houve a supressão de café classe 1, onde havia menor porcentagem de cobertura do terreno, referente aos talhões 12 e 13,

confundindo com o uso pastagem. Houve confusão de café classe 3 com café classe 4 e café classe 2 com café classe 4 devido à semelhança da porcentagem de cobertura, bem como características espectrais comuns. Nas Tabelas 16 e 17 são mostrados os resultados da matriz de confusão.

Tabela 16: Matriz de confusão (pixels)

Classe	Mapa de referência obtido via classificação visual								
Uso	Café 1	Café 2	Café3	Café4	Pastagem	Solo Exposto	Mata	Água	Total
Café1	<u>0</u>	0	0	0	7	18	8	0	33
Café2	5603	<u>126425</u>	3616	20349	30265	16556	17379	92	220285
Café3	4	7	<u>60676</u>	7967	11638	1826	1104	0	83222
Café4	37	71200	117181	<u>179079</u>	5212	9157	7872	2	389740
Pastagem	34678	1445	1278	202	<u>100890</u>	4655	1961	6	145115
Solo	284	3201	841	1003	12559	<u>35213</u>	2497	286	55884
Mata	233	2625	715	4211	36084	3242	<u>103782</u>	352	151244
Água	0	0	0	0	185	42	156	<u>12130</u>	12513
Total	40839	204903	184307	212811	196840	70709	134759	12868	<u>1058036</u>

Tabela 17: Matriz de confusão

Classe	Mapa de referência obtido via classificação visual									
	Uso	Café1	Café2	Café3	Café4	Pastagem	Solo Exposto	Mata	Água	Total
Café1	<u>0,00</u>	0,00	0,00	0,00	0,00	0,00	0,03	0,01	0,00	0,00
Café2	13,72	<u>61,70</u>	1,96	9,56	15,38	23,41	12,90	0,71	20,82	
Café3	0,01	0,00	<u>32,92</u>	3,74	5,91	2,58	0,82	0,00	7,87	
Café4	0,09	34,75	63,58	<u>84,15</u>	2,65	12,95	5,84	0,02	36,84	
Pastagem	84,91	0,71	0,69	0,09	<u>51,25</u>	6,58	1,46	0,05	13,72	
Solo	0,70	1,56	0,46	0,47	6,38	<u>49,80</u>	1,85	2,22	5,28	
Mata	0,57	1,28	0,39	1,98	18,33	4,58	<u>77,01</u>	2,74	14,29	
Água	0,00	0,00	0,00	0,00	0,09	0,06	0,12	<u>94,26</u>	1,18	
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	<u>100,00</u>	

Observa-se que café classe 1 foi confundido com pastagem em 84,91% devido ao estágio de desenvolvimento dos Talhões (12 e 13), com vegetação pouco expressiva. Café classe 2 apresentou confusão com café classe 4 em 34,75%, assim como café classe 3 foi classificada como café classe 4 em 63,58%, pois o algoritmo não soube discriminar as classes segundo sua porcentagem de cobertura de maneira eficiente. Pastagem foi confundida como mata em 18,33% pois havia a presença de mata rala. Solo exposto foi confundido com café classe 2 em 23,41% devido à topografia do terreno, onde a mesma expunha as entre linhas. Mata foi classificada como café classe 2 (12,90%) devido à recorrente confusão espectral entre as duas classes.

As Tabelas 18 e 19 apresentam os resultados da acurácia do usuário e do produtor.

Tabela 18: Acurácia do usuário

Classes	Porcentagem	Pixels
Café classe 1	0,00	0/33
Café classe 2	57,39	126425/220285
Café classe 3	72,91	60676/83222
Café classe 4	45,95	179079/389740
Pastagem	69,52	100890/145115
Solo exposto	63,01	35213/55884
Mata	68,62	103782/151244
Corpos d'água	96,94	12130/12513

Tabela 19: Acurácia do produtor

Classes	Porcentagem	Pixels
Café classe 1	0,00	0/40839
Café classe 2	61,70	126425/204903
Café classe 3	32,92	60676/184307
Café classe 4	84,15	179079/212811
Pastagem	51,25	100890/196840
Solo exposto	49,80	35213/70709
Mata	77,01	103782/134759
Corpos d'água	94,26	12130/12868

Na análise da acurácia do usuário (Tabela 18), observa-se que os usos que melhor representaram a mesma categoria em campo foram Corpos

d'água (96,94%) e café classe 3 (72,91%). Na acurácia do produtor (Tabela 19), os usos que tiveram a maior probabilidade de serem classificados de acordo com o mapa de referência foram Corpos d'água (94,26%) e café classe 4 (84,15%).

Puertas, Brenning e Meza (2013) analisaram as mudanças do uso e ocupação do solo a partir de imagens Landsat/ETM+ e do algoritmo *support vector machine* objetivando identificar os usos cobertura da neve, corpos d'água, solo urbano, agrícola, matas e pastagens. Os autores encontraram dificuldade para discriminar áreas de pastagem com solo exposto assim como solo exposto foi confundido com café classe 2 neste estudo.

Para este trabalho houve a dificuldade em discriminar o uso café classe 1, sendo este subestimado e classificado pela classe pastagem devido a sua característica espectral e seu estágio fenológico. O resultado da exatidão global foi 58,42% e o índice kappa 0,49, configurando a qualidade da classificação como sendo "boa". No entanto, considerando que 85% é o valor mínimo para uma qualificação satisfatória, observa-se que o algoritmo *support vector machine* não foi adequado.

3.3 Classificação pixel a pixel utilizando o algoritmo *maximum likelihood*

A Figura 12 ilustra o resultado da classificação pixel a pixel por *maximum likelihood*.

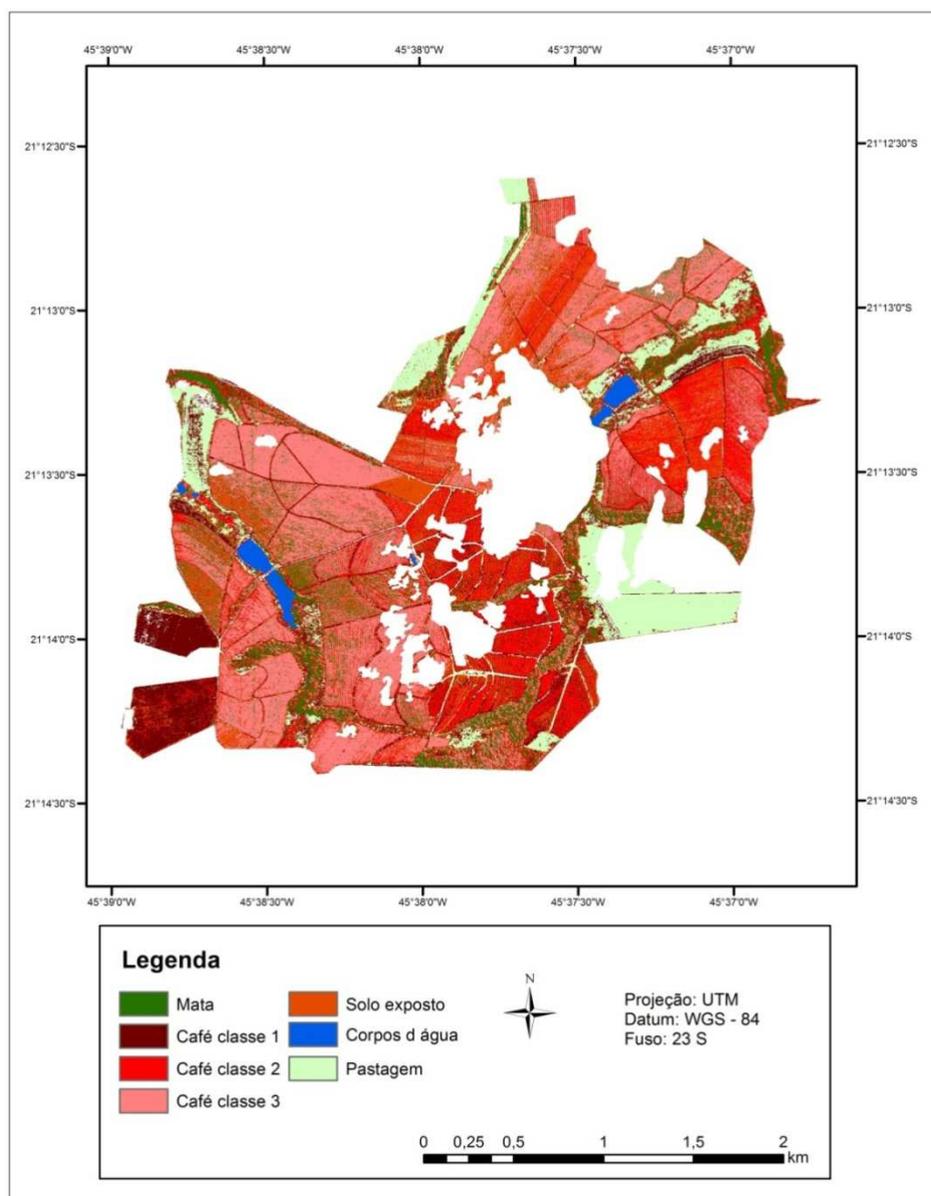


Figura 12: Resultado da classificação *maximum likelihood*

De acordo com as Tabelas 20 e 21 observam-se os resultados da área de cada uso obtido pelo mapa de referência e pela classificação.

Tabela 20: Quantificação do mapa de referência por classes de uso

Classes	Área classificada (hectares)	Área classificada (em porcentagem)
Café classe 1	23,43	3,82
Café classe 2	117,96	19,26
Café classe 3	107,51	17,56
Café classe 4	123,74	20,21
Pastagem	113,66	18,56
Solo exposto	40,66	6,64
Mata	77,88	12,72
Corpos d'água	7,39	1,20
Total	612,23	100

Tabela 21: Quantificação da classificação utilizando o algoritmo *maximum likelihood*

Classes	Área classificada (hectares)	Área classificada (em porcentagem)
Café classe 1	59,14	9,65
Café classe 2	107,75	17,59
Café classe 3	181,44	29,63
Café classe 4	-	-
Pastagem	75,30	12,29
Solo exposto	99,20	16,20
Mata	82,01	13,39
Corpos d'água	7,39	1,20
Total	612,23	100

A Tabela 22 mostra os valores das diferenças entre os resultados da classificação em comparação ao mapa de referência, onde é possível constatar que café classe 3 foi superestimado em 73,93% e café classe 2 subestimado em 10,21%.

Tabela 22: Diferenças entre resultados da classificação com relação ao mapa de referência

Classes	Área (hectares)	Superestimado/ subestimado
Café classe 1	35,71	Superestimado
Café classe 2	10,21	Subestimado
Café classe 3	73,93	Superestimado
Café classe 4	-	-
Pastagem	38,36	Subestimado
Solo exposto	58,54	Superestimado
Mata	4,13	Superestimado
Corpos d'água	0	-

Na matriz de confusão (Tabelas 23 e 24) observa-se o resultado da tabulação cruzada entre a imagem classificada e o mapa de referência.

Tabela 23: Matriz de confusão (pixels)

Classe	Mapa de referência obtido via classificação visual								
Uso	Café 1	Café 2	Café3	Café4	Pastagem	Solo	Mata	Água	Total
Café1	<u>34944</u>	23066	1064	3922	28392	26284	13191	86	130949
Café2	3048	<u>87421</u>	9576	40722	12878	6160	28337	343	188485
Café3	27	29903	<u>134185</u>	102021	13106	2526	24213	2	305983
Café4	1702	56222	22965	<u>48703</u>	15330	14908	13948	5	173783
Pastagem	346	976	120	284	<u>107673</u>	8451	6648	66	124564
Solo	700	1009	3520	1947	3862	<u>11864</u>	589	84	23575
Mata	85	6662	15410	17522	15776	1249	<u>48127</u>	327	105158
Água	2	1	2	0	661	7	214	<u>11956</u>	12843
Total	40854	204903	186842	215121	197678	71449	135267	12869	1065340

Tabela 24: Matriz de confusão (porcentagem)

Classe	Mapa de referência obtido via classificação visual								
	Uso	Café1	Café2	Café3	Café4	Pasto	Solo	Mata	Água
Café1	<u>85,53</u>	11,24	0,57	1,82	14,36	36,79	9,75	0,67	12,29
Café2	7,46	<u>42,59</u>	5,13	18,93	6,51	8,62	20,95	2,67	17,69
Café3	0,07	14,57	<u>71,82</u>	47,42	6,63	3,54	17,90	0,02	28,72
Café4	4,17	27,39	12,29	<u>22,64</u>	7,76	20,87	10,31	0,04	16,31
Pasto	0,85	0,48	0,06	0,13	<u>54,47</u>	11,83	4,91	0,51	11,69
Solo	1,71	0,49	1,88	0,91	1,95	<u>16,60</u>	0,44	0,65	2,21
Mata	0,21	3,25	8,25	8,15	7,98	1,75	<u>35,58</u>	2,54	9,87
Água	0,00	0,00	0,00	0,00	0,33	0,01	0,16	<u>92,91</u>	1,21
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

A partir da matriz de confusão (Tabelas 23 e 24) nota-se que os valores obtidos não são expressivos e se integraram, havendo intensa mistura de classes. Como exceção, tem-se a menor mistura de usos em café classe 1 (85,53%) e mata (92,91%).

Os demais usos sofreram consideráveis mistura espectral, fazendo com que as classes se desorganizassem entre si. Este fato se deu devido ao algoritmo utilizado, sendo calculado levando em consideração apenas o quesito espectral.

As Tabelas 25 e 26 ilustram a acurácia do usuário e produtor. Os valores mais expressivos da acurácia foram 93,09% para Corpos d'água e 85,53% de acurácia do produtor.

Tabela 25: Acurácia do usuário

Classes	Porcentagem	Pixels
Café classe 1	26,69	34944/130949
Café classe 2	46,38	87421/188485
Café classe 3	43,85	134185/305983
Café classe 4	28,03	48703/173783
Pastagem	86,44	107673/124564
Solo exposto	50,32	11864/23575
Mata	45,77	48127/105158
Corpos d'água	93,09	11956/12843

Tabela 26: Acurácia do produtor

Classes	Porcentagem	Pixels
Café classe 1	85,53	34944/40854
Café classe 2	42,59	87421/205260
Café classe 3	71,82	134185/186842
Café classe 4	22,64	48703/215121
Pastagem	54,47	107673/197678
Solo exposto	16,60	11864/71449
Mata	35,58	48127/135267
Corpos d'água	92,91	11956/12869

Para quantificar e avaliar o uso e ocupação das terras de 35 municípios do sul do Rio Grande do Sul, Bolfe et al. (2009) utilizaram imagens Landsat e técnicas de classificação por *maximum likelihood*. Os autores analisaram as classes: pastagem, natural e cultivada, floresta natural, reflorestamento, banhado e alagadiço, dunas e areia; lâmina d'água;

agricultura/solo exposto e área urbana. Os usos pastagem e agricultura foram os das classes mais expressivas, e correspondem a 83% da ocupação da área estudada. Os autores obtiveram exatidão de 88,07%, valor acima do patamar mínimo estabelecido por Jensen (1996).

No presente trabalho, registra-se o resultado obtido para exatidão global foi 45,51% e índice kappa 0,35 (qualidade razoável). Como exposto, a utilização do algoritmo *maximum likelihood* demonstrou não ser satisfatório para discriminação de várias classes de uso, havendo a mistura entre as mesmas bem como a presença do efeito salt-and-pepper.

4 CONSIDERAÇÕES GERAIS

Os resultados do índice kappa e exatidão global para cada método de classificação analisado são mostrados na Tabela 27.

Tabela 27: Resultado da avaliação das classificações.

Classificações	Kappa	Exatidão Global (%)
<i>K Nearest Neighbor</i>	0,76	86,34
<i>Support vector machine</i>	0,49	58,42
Máxima verossimilhança	0,35	45,51

Com base na Tabela 27, observa-se que a classificação utilizando o algoritmo *K Nearest Neighbor* obteve melhores resultados com relação aos demais. A seguir são descritos os resultados obtidos para cada algoritmo classificador.

5 CONCLUSÃO

Concluiu-se que a melhor técnica para classificação foi da análise de imagem orientada a objetos, se mostrando eficiente a partir do algoritmo *k nearest neighbor*. O número de classes é fator preponderante para obtenção de resultados satisfatórios e, a partir disso, a análise de imagens orientada ao objeto fornece resultados com maior precisão quando comparada à classificação pixel a pixel.

A utilização da metodologia de Ramirez (2009) aplicada na categorização do uso café em classes de porcentagem de cobertura do terreno possibilitou discriminar os plantios de café com eficácia conforme é analisado nos valores obtidos pelas classes na acurácia do usuário e do produtor. Sugere-se em estudos futuros a seleção de outros atributos de classificação conforme o objetivo do estudo, havendo a possibilidade em obter melhores resultados para determinado fim.

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.
- 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.
- BOLFE, E. L. et al. Uso, ocupação das terras e banco de dados geográficos
da metade sul do Rio Grande do Sul. **Ciência Rural**, Santa Maria, v. 39, n.
6, p. 1729-1737, set. 2009.
- 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.
- CASTILLEJO-GONZÁLEZ, I. L. et al. Object- and pixel-based analysis for
mapping crops and their agro-environmental. **Computers and Electronics
in Agriculture**, New York, v. 68, p. 207-215, June 2009.
- 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.
- JENSEN, J. R. **Introductory digital image processing**. Englewood Cliffs:
Prentice-Hall, 1996. 51 p.
- JIAO, L.; LIU, Y.; LI, H. Characterizing land-use classes in remote sensing
imagery by shape metrics. **ISPRS Journal of Photogrammetry and
Remote Sensing**, Beijing, v. 72, p. 46-55, July 2012.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, Washington, v. 33, n. 1, p. 159-174, 1977.

MEYFROIDT, P.; PHUONG, V. T.; ANH, H. V. Trajectories of deforestation, coffee expansion and displacement of shifting cultivation in the Central Highlands of Vietnam. **Global Environmental Change**, Oxford, v. 109, p. 1-12, Apr. 2013.

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.

MOUNTRAKIS, G.; JUNGHOIM, C. O. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, New York, v. 2011, n. 66, p. 247-259, Dec. 2010.

NASCIMENTO, C. R. **Correção atmosférica de imagens do sensor AVHRR/NOAA utilizando produtos atmosféricos do sensor MODIS/TERRA**. 2006. 129 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2006.

OETTER, D. R. et al. Land cover mapping in an agricultural setting using multiseasonal Thematic Mapper data. **Remote Sensing of Environment**, Oregon, v. 76, p. 139-155, Oct. 2000.

PEREIRA, L. O. et al. Análise comparativa dos métodos de classificação SVM e Maxver-ICM polarimétrico em imagem de radar ALOS PALSAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 8223-8230.

PUERTAS, O. L.; BRENNING, A.; MEZA, F. J. Balancing misclassification errors of land cover classification maps using support vector machines and Landsat imagery in the Maipo river basin: Central Chile, 1975-2010. **Remote Sensing of Environment**, New York, v. 137, p. 112-123, July 2013.

RAMIREZ, G. M. **Uso de imagens de alta e média resolução espacial no estudo de áreas cafeeiras**. 2009. 132 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2009.

RODRIGUEZ-GALIANO, V. F. et al. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 67, p. 93-104, July 2013.

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.

ROZA, W. S. S.; RIBEIRO, S. R. A. 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. 3464-3471.

ROZENSTEIN, O.; KARNIELI, A. Comparison of methods for land-use classification incorporating remote sensing and GIS inputs. **Applied Geography**, Oxford, v. 31, p. 533-544, 2011.

SILVA, W. F. et al. Discrimination of agricultural crops in a tropical semi-arid region of Brazil based on L-band polarimetric airborne SAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 64, p. 458-463, Oct. 2008.

SOUTH, S.; QI, J.; LUSCH, D. P. Optimal classification methods for mapping agricultural tillage practices. **Remote Sensing of Environment**, Michigan, v. 91, p. 90-97, Mar. 2004.

STUCKENS, J.; COPPIN, P. R.; BAUER, M. E. Integrating contextual information with per-pixel classification for improved land cover classification. **Remote Sensing of Environment**, New York, v. 71, p. 282-296, 2000.

SUAREZ, A. F.; CANDEIAS, A. L. B. Avaliação de acurácia da classificação de dados de sensoriamento remoto para o Municí. In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, 4., 2012, Recife. **Anais...** Recife: INPE, 2012. p. 2-10.

VIEIRA, T. G. C. et al. Parameters and spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, Lavras, v. 1, n. 2, p. 111-118, Dec. 2006.

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, p. 4039-4055, 2006.

ZULLO-JUNIOR, J. **Correção atmosférica de imagens de satélite e aplicações**. 1994. 204 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 1994.

CONSIDERAÇÕES FINAIS

Capítulo 2

1- A classificação que melhor apresentou resultados de índice Kappa e Exatidão Global em comparação com o mapa de referência foi a classificação pixel a pixel utilizando o algoritmo *maximum likelihood*.

2- Para a classe "café", a quantificação da área (hectares) resultante da análise de imagem orientada ao objeto utilizando o algoritmo *support vector machine* foi a que menos superestimou em comparação com o mapa de referência.

3- Para a classe "outros usos" em termos de área (hectares) classificada, a quantificação resultante da análise de imagem orientada ao objeto utilizando o algoritmo *support vector machine* mais se aproximou da quantificação resultante do mapa de referência.

Capítulo 3

1- A análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor* melhor apresentou resultados de índice Kappa e Exatidão Global em comparação com o mapa de referência.

2- Em comparação com a área quantificada do mapa de referência, a análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor* apresentou melhores resultados para a classe "Café classe 1".

3- Em comparação com a área quantificada do mapa de referência, a classe "Café classe 2" apresentou melhores resultados através da análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine*.

4- Em comparação com a área quantificada do mapa de referência, a análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor* apresentou melhores resultados para a classe "Café classe 3".

- 5- Em comparação com a área quantificada do mapa de referência, a análise de imagem orientada ao objeto utilizando o algoritmo *K Nearest Neighbor* apresentou melhores resultados para a classe "Café classe 4".
- 6- A classe "Pastagem" apresentou melhor quantificação de área classificada na análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine*.
- 7- Em comparação com a área quantificada no mapa de referência, a análise de imagem orientada ao objeto utilizando o algoritmo *Support vector machine* apresentou melhores resultados para a classe "Solo exposto".
- 8- Em comparação com a área quantificada no mapa de referência, a classificação pixel a pixel utilizando o algoritmo *maximum likelihood* apresentou melhores resultados para a classe "Mata".
- 9- Em comparação com a área quantificada no mapa de referência, a classificação pixel a pixel utilizando o algoritmo *maximum likelihood* apresentou melhores resultados para a classe "Corpos d água".