



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2016/01.26.12.53-TDI

**INFLUÊNCIA DOS ATRIBUTOS ESPECTRAIS,  
TEXTURAIS E FATOR DE ILUMINAÇÃO NA  
CLASSIFICAÇÃO BASEADA EM OBJETOS DE ÁREAS  
CAFEEIRAS**

Rennan de Freitas Bezerra Marujo

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Mauricio Alves Moreira,  
e Margarete Marin Lordelo  
Volpato, aprovada em 19 de  
fevereiro de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3L3KGLP>>

INPE  
São José dos Campos  
2016

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

## **COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):**

### **Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

### **Membros:**

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas (CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

Dr. Evandro Marconi Rocco - Coordenação de Engenharia e Tecnologia Espacial (ETE)

Dr. Hermann Johann Heinrich Kux - Coordenação de Observação da Terra (OBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SID)

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SID)

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

### **EDITORAÇÃO ELETRÔNICA:**

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2016/01.26.12.53-TDI

**INFLUÊNCIA DOS ATRIBUTOS ESPECTRAIS,  
TEXTURAIS E FATOR DE ILUMINAÇÃO NA  
CLASSIFICAÇÃO BASEADA EM OBJETOS DE ÁREAS  
CAFEEIRAS**

Rennan de Freitas Bezerra Marujo

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Mauricio Alves Moreira,  
e Margarete Marin Lordelo  
Volpato, aprovada em 19 de  
fevereiro de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3L3KGLP>>

INPE  
São José dos Campos  
2016

Dados Internacionais de Catalogação na Publicação (CIP)

---

Marujo, Rennan de Freitas Bezerra.

M368i      Influência dos atributos espectrais, texturais e fator de iluminação na classificação baseada em objetos de áreas cafeeiras / Rennan de Freitas Bezerra Marujo. – São José dos Campos : INPE, 2016.

xviii + 76 p. ; (sid.inpe.br/mtc-m21b/2016/01.26.12.53-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

Orientadores : Drs. Mauricio Alves Moreira, e Margarete Marin Lordelo Volpato.

1. Café. 2. Classificação baseada em objetos. 3. Mineração de dados. I.Título.

CDU 528.85:633.73

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

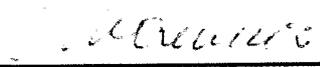
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Rennan de Freitas Bezerra Marujo**

Título: "INFLUÊNCIA DOS ATRIBUTOS ESPECTRAIS, TEXTURAIS E FATOR DE ILUMINAÇÃO NA CLASSIFICAÇÃO BASEADA EM OBJETOS DE ÁREAS CAFFEEIRAS".

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Mestre** em  
**Sensoriamento Remoto**

Dr. **Mauricio Alves Moreira**

  
\_\_\_\_\_  
**Presidente / Orientador(a) / INPE / SJC Campos - SP**

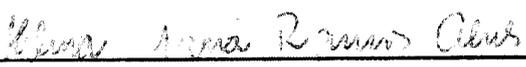
Dra. **Margarete Marin Lordelo Volpato**

  
\_\_\_\_\_  
**Orientador(a) / EPAMIG / Belo Horizonte - MG**

Dr. **Antonio Roberto Formaggio**

  
\_\_\_\_\_  
**Membro da Banca / INPE / SJC Campos - SP**

Dra. **Helena Maria Ramos Alves**

  
\_\_\_\_\_  
**Convidado(a) / EMBRAPA / Lavras - MG**

Este trabalho foi aprovado por:

( ) maioria simples

(X) unanimidade

São José dos Campos, 19 de Fevereiro de 2016



## **AGRADECIMENTOS**

Ao Instituto Nacional de Pesquisas Espaciais - INPE e em particular à Divisão de Sensoriamento Remoto, pela oportunidade de utilizar seus equipamentos e instalações.

Aos professores do INPE pelo conhecimento compartilhado.

Ao Dr. Maurício Alves Moreira e a Dra. Margarete Marin Lordelo Volpato, pela confiança e orientação ao aceitar serem meus orientadores.

A Fundação de Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pela bolsa concedida no decorrer do mestrado.

Aos colegas de do Curso de Pós-Graduação em Sensoriamento Remoto.

Aos amigos Pig, Lika, Willy, Valério, Diego, Felipe, Jú, Alê e Letícia pelo acompanhamento motivador.

Às companheiras Hina e Lilith pelo apoio fora do ambiente acadêmico.

Aos irmãos Rafael e Renata por acreditarem em mim.

A minha mãe Elizete, quem me proporcionou continuar estudando, com seu olhar, carinho e cuidados de uma mãe.



## RESUMO

O café, por ser um importante produto nas exportações brasileiras, necessita de constante monitoramento e pesquisas, para que os sistemas de previsão de safras existentes sejam confiáveis. Nesta pesquisa foi avaliado o desempenho da classificação baseada em objetos, associada a técnicas de mineração de dados, aplicada em imagens OLI/*Landsat-8*, com finalidade de mapeamento de lavouras cafeeiras na microrregião de Alfenas (MG). Foram feitas três análises, a primeira utilizando apenas atributos espectrais, a segunda incluindo atributos texturais e a terceira, considerando também classes de iluminação do relevo, extraídas por meio do fator de iluminação. Foram utilizadas seis imagens multiespectrais OLI/*Landsat-8*, de datas distintas, referentes a três diferentes estádios fenológicos da cultura: frutificação, granação e repouso. Além das imagens multiespectrais, foram também utilizados dados da missão SRTM, para determinar as variáveis topográficas como declividade, orientação e o fator de iluminação do terreno. Após correção atmosférica das imagens utilizando o método *Flaash*, aplicou-se o algoritmo de segmentação multirresolução parametrizado em fator de escala 30, forma 0,6 e compacidade 0,5. Posteriormente fez-se um processo de mineração de dados por meio do algoritmo C4.5, o qual gerou árvores de decisão para classificar as imagens. A validação das classificações foi feita por meio do Método de Monte Carlo utilizando como referência mapas obtidos por interpretação visual. Nas classificações feitas utilizando somente atributos espectrais, obteve-se exatidão média para a classe café de 53%. Quando repetiu-se as classificações, inserindo também atributos texturais e classes de iluminação do terreno, a exatidão da classe café foi incrementada para 67%. Em escala municipal a metodologia apresentou melhores resultados, concedendo exatidão para a classe café de 73,83% no município de Machado, que apresenta relevo acidentado e 82,83% no município de Alfenas, que trata-se de uma área mais plana. Não houve estágio fenológico que proporcionasse maior exatidão à classe café na classificação automática das imagens OLI/*Landsat-8*.

Palavras-chave: Café. Classificação baseada em objetos. Mineração de dados.



# **INFLUENCE OF SHADED RELIEF, SPECTRAL AND TEXTURAL ATTRIBUTES IN AUTOMATIC OBJECT BASED CLASSIFICATION OF COFFEE AREAS**

## **ABSTRACT**

Coffee, for being an important product in Brazilian exportations, needs constant monitoring and research, so that crop monitoring systems can be sound and reliable. This research evaluated the performance of an object based classification associated with data mining techniques applied in OLI/Landsat-8 images, with the purpose of mapping of coffee crops in the region of Alfenas, state of Minas Gerais in Brazil. Three analyzes were made, the first one using only the spectral attributes; the second including textural attributes and the third considering also the shaded relief classes. Six multispectral images from OLI/Landsat-8 were used, each one of a different date, relating to three different phenology stages: frutification, grain formation and rest. In addition to multispectral images, SRTM data were also used to determine the topographic variables such as slope, aspect and shaded relief. After atmospheric correction, the multiresolution segmentation algorithm were applied, and later its segments became entry to a data mining process by C4.5 algorithm, which generated decision trees to classify the images. The accuracy of the classifications was assessed by the Monte Carlo method using as reference the images obtained by visual interpretation. In the classification made using only spectral attributes was obtained an accuracy of 53% for coffee class. When was inserted textural attributes in the classification, the accuracy of the coffee class was increased to 67%. At the municipal level the methodology presented better results, providing accuracy of 73.83% to coffee class in the municipality of Machado and 82.83% in Alfenas. There were no preferential phenology stage that provided greater accuracy to the coffee class in the automatic classification of OLI/Landsat-8 images.

Keywords: Coffee. Object based classification. Data mining.



## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Esquematização das fases fenológicas do cafeeiro arábica nas condições climáticas tropicais do Brasil. ....	7
Figura 2.2 – Fusão de imagem IHS.....	13
Figura 2.3 – Exemplo de calculo de declividade de terreno. ....	16
Figura 2.4 - Geometria de iluminação/sombreamento de um elemento de terreno.....	17
Figura 2.5 - Ângulo zenital e ângulo azimutal.....	18
Figura 2.6 - As radiâncias $L_t$ das trajetórias 1, 3 e 5 contêm informação espectral intrínseca importante sobre o alvo de interesse. Por outro lado, a radiância de trajetória $L_p$ das trajetórias 2 e 4 incluem irradiância solar difusa ou radiância de áreas vizinhas no terreno. Esta radiância de trajetória geralmente introduz ruído radiométrico indesejável nos dados de sensoriamento remoto e complica o processo de interpretação de imagens. ...	19
Figura 2.7 – Conjunto de dados e árvore de decisão (parcial) de classificação do conjunto.....	27
Figura 3.1–Localização da microrregião de Alfenas no estado de Minas Gerais, Brasil. ....	31
Figura 3.2 - Fluxograma de atividades desenvolvidas no trabalho, composto por quatro etapas: 1-Preparação dos dados; 2-Estratificação das classes de iluminação; 3-Classificação baseada em objetos; e 4-Validação. ....	33
Figura 3.3 – Imagem SRTM, declividade e orientação de vertente da microrregião de Alfenas, Minas Gerais. ....	36
Figura 4.1 – Comportamento espectral das áreas cafeeiras em imagens <i>OLI/Landsat-8</i> com correções atmosféricas CDR (curvas vermelhas) e <i>Flaash</i> (curvas azuis) nos estádios fenológicos da frutificação (gráficos da primeira linha), granação (gráficos da segunda linha) e repouso (gráficos da terceira linha). Gráficos à esquerda referentes ao primeiro ano fenológico enquanto gráficos à direita referentes ao segundo ano fenológico. ....	42
Figura 4.2 - Mapa temático resultante da interpretação visual de imagem <i>Oli/Lansat-8</i> para a Microrregião de Alfenas em 20/11/2013. ....	44
Figura 4.3 – Percentagem da área plantada de café dos municípios da microrregião de Alfenas, Minas Gerais em relação á área total de café da microrregião. ....	46
Figura 4.4 - Mapa temático resultante do fatiamento em classes de orientação de face de vertente das áreas cafeeiras da Microrregião de Alfenas.....	47

Figura 4.5 – Distribuição percentual da orientação de face de vertente das áreas plantadas de café dos municípios da microrregião de Alfenas, Minas Gerais.....	48
Figura 4.6 - Microrregião de Alfenas, Minas Gerais representada em: Imagem Fator de iluminação (FI), FI estratificada em 5 classes de iluminação e FI estratificada em 2 classes de iluminação. ....	49
Figura 4.7 – Exemplo de imagem fator de iluminação (A) e imagem fator de iluminação estratificada em classes de iluminação (B). ....	49
Figura 4.8 - Segmentação multirresolução de imagem <i>OLI/Landsat-8</i> em falsa cor (5,4,3), em com parâmetros escala 30, forma 0,6 e compacidade 0, 5.....	52

## LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Bandas multiespectrais do sensor OLI/ <i>Landsat-8</i> .....	11
Tabela 2.2 - Exemplo de matriz de confusão com as estimativas de exatidão total, do usuário e do produtor.....	29
Tabela 3.1 - Imagens OLI/ <i>Landsat-8</i> (219 075) utilizadas.....	32
Tabela 3.2 - Estratificação das imagens fator de iluminação em cinco classes. ....	37
Tabela 3.3 – Tabela de atributos extraídos dos segmentos da imagem, para posteriores classificações.....	38
Tabela 4.1 – Distribuição das áreas cafeeiras na microrregião de Alfenas, Minas Gerais, obtida por interpretação visual de imagens OLI/ <i>Landsat-8</i> . ....	45
Tabela 4.2-Distribuição das classes de iluminação na microrregião de Alfenas em relação aos períodos de frutificação, granação e repouso no período entre 20/11/2013 e 21/07/2015. ....	50
Tabela 4.3-Distribuição dos cafezais da microrregião de alfenas em classes de iluminação no período entre 20/11/2013 e 21/07/2015. ....	51
Tabela 4.4 - Índice global e exatidão das classificações baseadas em objetos em imagens OLI/ <i>Landsat-8</i> para a microrregião de Alfenas, Minas Gerais, estratificada em cinco classes de iluminação.....	54
Tabela 4.5 - Índice global e exatidão da classe café das classificações baseadas em objetos em imagens OLI/ <i>Landsat-8</i> para o município de Alfenas, estratificada em duas classes de iluminação. ....	56
Tabela 4.6 - Índice global e exatidão da classe das classificações baseadas em objetos em imagens OLI/ <i>Landsat-8</i> para o município de Machado, estratificada em cinco classes de iluminação. ....	57



## LISTA DE SIGLAS E ABREVIATURAS

6S	Second simulation of a satellite signal in the solar spectrum
ASI	Agenzia spaziale italiana
CDR	Climate data record
CONAB	Companhia nacional de abastecimento
FLAASH	Fast line-of-sight atmospheric analysis of spectral hypercube
Geobia	Geographic object-based image analysis
IBGE	Instituto brasileiro de geografia e estatística
IG	Índice global
INPE	Instituto nacional de pesquisas espaciais
Landsat	Land remote sensing satellite
Maxver	Maximum likelihood
MD	Mineração de dados
MDE	Modelo digital de elevação
MMC	Método monte carlo
MODTRAN	Moderate resolution atmospheric transmission
NASA	National aeronautics and space administration
ND	Número digital
NGA	National geospatial-intelligence agency
OLI	Operacional land imager
RNA	Redes neurais artificiais
SRTM	Shuttle radar topography mission
SVM	Support vector machine

TIRS      Thermal infrared sensor

## SUMÁRIO

	<b><u>Pág.</u></b>
1	INTRODUÇÃO ..... 1
1.1.	Objetivo Geral ..... 3
1.2.	Objetivos específicos ..... 3
2	FUNDAMENTAÇÃO TEÓRICA..... 5
2.1.	Cultura cafeeira ..... 5
2.1.1.	Fenologia da cultura..... 6
2.2.	Mapeamento da cafeicultura ..... 8
2.3.	Programa <i>Landsat</i> ..... 10
2.3.1.	<i>Landsat-8</i> ..... 10
2.4.	Fusão de imagens..... 12
2.4.1.	Fusão Gram-Schmidt ..... 12
2.5.	Índices de vegetação ..... 14
2.5.1.	NDVI..... 14
2.6.	Dados de elevação..... 15
2.7.	Correção atmosférica ..... 18
2.8.	Segmentação de imagens..... 21
2.8.1.	Segmentação multirresolução ..... 22
2.9.	Classificação de imagens..... 23
2.9.1.	Classificação multiespectral ..... 24
2.9.2.	Classificação baseada em objetos ..... 24
2.10.	Mineração de dados..... 26
2.10.1.	Árvore de decisão e atributos..... 27
2.10.2.	O algoritmo C4.5 ..... 28
2.11.	Confiabilidade do mapeamento..... 28
3	MATERIAIS e MÉTODOS ..... 31
3.1.	Área de estudo ..... 31
3.2.	Dados orbitais ..... 32

3.3.	Metodologia.....	32
3.3.1.	Primeira Etapa: Preparação dos dados.....	34
3.3.2.	Segunda etapa: Estratificação de relevo em classes de Iluminação .....	35
3.3.3.	Terceira Etapa: Classificação.....	37
3.3.4.	Quarta etapa: Análise da exatidão do mapeamento da classificação .....	39
4	RESULTADOS e DISCUSSÕES.....	41
4.1.	Resultados Primeira Etapa.....	41
4.1.1.	Correção atmosférica .....	41
4.1.2.	Interpretação Visual .....	43
4.2.	Resultados Segunda Etapa.....	46
4.2.1.	Fatiamento da orientação de vertente.....	46
4.2.2.	Estratificação do relevo em classes de iluminação .....	48
4.3.	Resultados Terceira Etapa.....	51
4.3.1.	Classificação automática supervisionada.....	51
4.3.2.	Mineração de dados e classificação.....	52
4.4.	Resultados Quarta Etapa .....	53
4.4.1.	Validação dos mapas temáticos de café .....	53
4.4.2.	Análise dos resultados da classificação para os municípios de Alfenas e Machado .....	55
5	CONSIDERAÇÕES FINAIS .....	59
5.1.	Conclusões.....	59
5.2.	Recomendações .....	59
5.3.	Sugestão de trabalhos futuros.....	60
	REFERÊNCIAS BIBLIOGRÁFICAS.....	55

## 1 INTRODUÇÃO

O Brasil responde por 33% da produção mundial de café, o que gera diretamente cinco milhões de empregos e indiretamente dez milhões de empregos (EMBRAPA CAFÉ, 2004). Assim, a cafeicultura é uma importante fonte de renda para a economia nacional. Aproximadamente 50% da produção do café está concentrada no estado de Minas Gerais (CONAB, 2015). Apesar de sua importância, os métodos utilizados para o acompanhamento da área plantada, da produtividade e produção, diferem entre instituições governamentais e de iniciativa privadas, como as cooperativas (SOUZA et al., 2012). Em outras palavras, o monitoramento do agroecossistema cafeeiro, bem como o acompanhamento das safras de café no Brasil carecem de metodologias concisas e padronizadas. Imagens de satélites e técnicas de geoprocessamento são ferramentas indicadas para padronizar uma metodologia confiável que possa satisfazer tanto o monitoramento do agroecossistema, como o acompanhamento das safras do café (TARDIN et al., 1992; MOREIRA et al., 2004 e MOREIRA et al., 2007).

O café pode ser cultivado em áreas montanhosas, o que propicia sombreamento dificultado sua identificação (VIEIRA et al., 2006). Somando-se o fato de o comportamento espectral do café ser semelhante ao de florestas e algumas fisionomias do cerrado (VIEIRA et al., 2006), e que a heterogeneidade do comportamento espectral cafeeiro, varia em função de fatores da planta (sanidade, estado nutritivo e variedade), dos tratos culturais e do manejo da cultura (ADAMI et al., 2009), classificações automáticas de lavouras cafeeiras, quando feitas exclusivamente com base no comportamento espectral observado em imagens de satélites apresentam resultados com baixa exatidão e muitos erros de inclusão e omissão (MOREIRA et al., 2007).

Conhecer a distribuição espacial das lavouras cafeeiras é vital para prever e planejar ações em escala municipal, estadual e federal (MOREIRA et al., 2008). Imagens de satélite com média resolução espacial são ferramentas com

grande potencial para serem utilizadas no mapeamento das lavouras cafeeiras devido a suas características multiespectrais e multitemporais (MOREIRA et al., 2008; MOURA et al., 2009; MACHADO et al., 2010). Devido às dificuldades em classificar automaticamente áreas de café, o que resulta em baixos índices de exatidão (CORDERO-SANCHO; SADER, 2007; ANDRADE et al., 2013; GIROLAMO NETO et al., 2015), os mapeamentos atualmente são boa parte feitos por meio de abordagem visual (GUHL, 2004; MOREIRA et al., 2004). Tal interpretação visual é um processo trabalhoso que resulta em um mapa dependente do conhecimento do intérprete (MOREIRA et al., 2008).

Apesar dos muitos esforços para se alcançar uma boa classificação automática de áreas cafeeiras, a literatura ainda carece de metodologias com boa exatidão, especialmente em áreas de relevo acentuado. Alguns trabalhos demonstram que o uso de dados topográficos pode amenizar os efeitos do sombreamento na identificação automática de áreas cafeeiras (VIEIRA et al., 2006; CORDERO-SANCHO; SADER, 2007; LAMPARELLI et al., 2011). Fica evidente que, em áreas montanhosas, quando somente a informação espectral é considerada (valor digital contido nos pixels das imagens), dados de declividade, orientação de vertente e fator de iluminação incrementam as taxas de exatidão de mapeamento obtidas por classificações automáticas.

Além de atributos multiespectrais, utilizados em classificações baseadas em pixels e por regiões, alguns autores sugerem o uso de atributos texturais para identificar e mapear áreas cafeeiras (ANDRADE et al., 2013; GIROLAMO NETO et al., 2015). Nesse intuito, a análise baseada em objetos (da sigla em inglês, GEOBIA: *Geographic object-based image analysis*) tem ganhado atenção por possibilitar o uso de atributos relacionais de forma e de textura (ADDINK et al., 2012), mostrando-se promissora na identificação de outras culturas (LUZ et al., 2010; VIEIRA et al., 2012; SILVA JUNIOR et al., 2014), entretanto ainda pouco explorada no contexto do café (SANTOS et al., 2012; MARUJO, 2013; SARMIENTO et al., 2014).

Devido aos desafios existentes no mapeamento automático de áreas cafeeiras. Neste trabalho, visando incrementar a exatidão obtida em mapeamentos automáticos, propôs-se localizar e quantificar as áreas cafeeiras em imagens *OLI/Landsat-8*, por meio de classificação baseada em objetos com atributos texturais e classes de iluminação de terreno.

### **1.1. Objetivo Geral**

- Testar e avaliar o desempenho da classificação baseada em objetos com atributos texturais e classes de iluminação do terreno, associada a técnicas de mineração de dados, em imagens *OLI/Landsat-8*, para identificar áreas cafeeiras.

### **1.2. Objetivos específicos**

- Obter mapas base, contendo a distribuição espacial das lavouras de café na microrregião de Alfenas no período entre 20/11/2013 e 21/07/2015, para três estádios fenológicos: frutificação, granação e repouso, por meio de interpretação visual das imagens *OLI/Landsat-8*.
- Testar os modelos de correção atmosférica *CDR* e *Flaash* em áreas cafeeiras em imagens *OLI/Landsat-8*.
- Verificar se os atributos texturais e classes de iluminação do terreno incrementam a exatidão das classificações automáticas de áreas cafeeiras.
- Verificar se há estágio fenológico que proporciona melhor identificação automática das áreas cafeeiras.



## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1. Cultura cafeeira

Reconhecido como uma das bebidas mais populares do mundo, o café está entre as *commodities* de maior importância mundial devido ao volume financeiro movimentado em sua comercialização (TEIXEIRA e MILHOMEN, 2001). Cultivado em aproximadamente 80 países (RAMALHO et al., 2013), o café (*Coffea ssp*) foi introduzido no Brasil por volta do século XVIII e continua sendo uma importante cultura até hoje. O Brasil se destaca por ser o maior produtor e exportador de café no mundo (SAES, 2004; CONAB, 2015).

O café é uma cultura arbustiva de crescimento contínuo, que atinge 2 a 4 m de altura, conforme as condições climáticas da região. Das espécies de café existentes as mais importantes são a *Coffea arábica* e a *Coffea canefora* (robusta ou conilon). A variedade *C. arabica* é a espécie de café mais popular em todo o mundo, sendo que no Brasil representa aproximadamente 79% do café produzido (CONAB, 2015). Minas Gerais é o maior produtor do café arábica (aproximadamente 50% da produção nacional) e o estado do Espírito Santo é o maior produtor do café robusta, participando com 80% do café robusta produzido no Brasil (CONAB, 2015).

Os talhões cafeeiros são bastante heterogêneos, embora o café seja uma cultura perene. As práticas de manejo e tratamentos da cultura varia de acordo com o sistema de cultivo predominante, a espécie, a variedade, a disponibilidade tecnológica do produtor, a possibilidade de mecanização, a topografia, as condições climáticas ao longo do ano, se a área possui irrigação, a fertilidade do solo e as adubações (CARVALHO et al., 2004; MOREIRA et al., 2004). Acrescenta-se também a heterogeneidade dos talhões cafeeiros o fato de a utilização de poda nas lavouras de café, ser eficiente para renovação dos cafezais. Tal procedimento é comum porque após determinado número de colheitas, os ramos de um cafeeiro tornam-se envelhecidos e poucos

produtivos, chegando à morte, necessitando então de interferência (VERDIN FILHO, 2011).

### **2.1.1. Fenologia da cultura**

A maioria das plantas emite inflorescências na primavera e frutificam no mesmo ano (CAMARGO; CAMARGO, 2001). O café apresenta ciclo fenológico bianual, ou seja, completa seu ciclo fenológico em dois anos. Os cultivos cafeeiros apresentam um período vegetativo na época de seca e outro reprodutivo, na estação chuvosa, no qual crescem os ramos, folhas, flores e frutos (GOUVEIA, 1984). Assim, devido à bienalidade, a produção dos cafezais de um ano é proporcional à quantidade de gemas formadas na estação vegetativa anterior, proporcionando baixa e alta produtividade no período de dois anos (CAMARGO; CAMARGO, 2001). Portanto, ao avaliar a produção da atividade cafeeira, faz-se necessário que a série de dados de produtividade tenha temporalidade maior ou igual ao ciclo fenológico da cultura.

De acordo com as condições climáticas brasileiras, o ciclo fenológico do café arábica é dividido em seis fases como pode ser observado na Figura 2.1. As duas primeiras fases correspondem à fase vegetativa e ocorrem durante o primeiro ano fenológico. As fases três, quatro e cinco correspondem à etapa reprodutiva do café e estão no segundo ano fenológico, juntamente com a fase seis, período em que ocorre a auto-poda (CAMARGO; CAMARGO, 2001).

Período vegetativo											
Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago
Vegetação e formação das gemas florais							Indução e maturação das gemas florais				
											Repouso

Período reprodutivo											
Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago
Florada, chumbinho e expansão dos frutos				Granação dos frutos			Maturação dos frutos			Repouso, senescência ramos 3° e 4°	
Período reprodutivo (novo período vegetativo)										Autopoda	

Figura 2.1 - Esquematisação das fases fenológicas do cafeeiro arábica nas condições climáticas tropicais do Brasil.

Fonte: Rosa (2007).

A primeira fase fenológica do café ocorre de setembro a março, quando ocorre a formação das gemas (CAMARGO, 1985). Nesse período a iluminação solar tem maior duração no hemisfério Sul, possibilitando maior tempo fotoativo da vegetação. A segunda fase acontece entre abril e agosto (dias mais curtos). Nessa fase ocorre a indução das gemas foliares formadas na primeira fase para gemas florais. No fim da fase as plantas entram em repouso, o que define o primeiro ano fenológico. A terceira fase marca o início do segundo ano fenológico (setembro a dezembro), nessa fase ocorre a florada e a frutificação. A quarta fase (janeiro a março) corresponde à solidificação dos líquidos internos dos frutos, dando formação aos grãos, denominada de granação. A quinta fase (abril a junho) indica a maturação dos frutos, caracterizada pelo decréscimo da evapotranspiração potencial da planta. A sexta fase (julho a agosto) corresponde à senescência dos ramos produtivos não primários, que secam e morrem, também chamada auto-poda do cafeeiro (CAMARGO; CAMARGO, 2001).

A separação em estádios fenológicos possibilita, em um mapeamento automático, verificar se uma determinada época do ano é favorável à identificação de talões cafeeiros, devido aos eventos ocorridos em tal estádio.

## **2.2. Mapeamento da cafeicultura**

Conhecer a distribuição espacial das lavouras cafeeiras é vital para prever e planejar ações em escala municipal, estadual e federal (MOREIRA et al., 2008). O desafio de se mapear áreas cafeeiras consiste em obter as estatísticas das áreas cafeeiras por um método objetivo, ou seja, um mapeamento confiável contendo a distribuição espacial das lavouras cafeeiras. Tal mapeamento, além de útil para o acompanhamento do parque cafeeiro, é também útil para monitorar o impacto desta cultura no meio ambiente. Até o presente momento as informações sobre área plantada e colhida tem grande participação de métodos subjetivos. Nesta linha de pesquisa vários esforços têm sido feitos para desenvolver uma metodologia robusta para estimar a área (MOREIRA et al., 2004 e 2008; ANDRADE et al., 2013; SARMIENTO et al., 2014) e, consecutivamente, produtividade (ROSA, 2007; BERNARDES, 2013).

As dificuldades em estabelecer uma metodologia confiável para mapear áreas cafeeiras, estão relacionadas à complexidade ocasionada pela diversidade dos fatores ambientais, culturais e econômicos, como manejo, tamanho das lavouras, variedade cultivada, espaçamento por unidade de área, entre outros, que variam muito na cultura cafeeira (CARVALHO et al., 2004; MOREIRA et al., 2004). Além disso, o relevo influi negativamente nos resultados dos mapeamentos, uma vez que o café é cultivado em áreas montanhosas e a identificação das áreas cafeeiras pode ser comprometida pela sombra do relevo (VIEIRA et al., 2006; CORDERO-SANCHO; SADER, 2007; MOREIRA et al., 2008).

Observa-se na literatura que os métodos objetivos de classificação aplicados ao mapeamento de café, em quase sua totalidade, fundamentam-se na análise puramente espectral de imagens de satélite. Sob esta ótica, pode-se dizer que os valores de níveis de cinza ou de reflectância representam as condições de um alvo em uma determinada data, podendo a resposta do mesmo ser diferente conforme as condições climáticas. Isso faz com que os resultados de

uma classificação por meio dessa abordagem apresentem uma exatidão baixa e com expressivos erros de inclusão e omissão (MOREIRA et al., 2004). Tais resultados ocorrem porque os cafezais são heterogêneos e a cultura apresenta resposta espectral complexa e semelhante à de outras fisionomias (VIEIRA et al., 2006). Para melhorar os resultados de classificação de lavouras de café, faz-se necessário uma intervenção do intérprete nos resultados da classificação, por meio da abordagem visual (GUHL, 2004; MOREIRA et al., 2004), o que faz com que a exatidão final do mapa dependa do conhecimento do intérprete, além de o processo ser trabalhoso (MOREIRA et al., 2008).

Uma grande evolução no processamento digital de dados de sensoriamento remoto vem ocorrendo principalmente devido à melhora nas resoluções espaciais e radiométricas dos sensores (BLASCHKE; KUX, 2007). Com tal advento, ao invés de classificar os pixels individualmente quanto às suas características espectrais, novos procedimentos têm sido utilizados por considerarem a delimitação de objetos com características espectrais e radiométricas homogêneas como base para o processamento posterior. A classificação passa a ser influenciada não apenas pelas características dos objetos como na abordagem pixel a pixel, mas também pelo contexto, uma vez que a análise isolada dos pixels geraria muito ruído (RIBEIRO; KUX, 2009). Aplicada a áreas cafeeiras, a classificação automática baseada em objetos apresenta maior exatidão do que a classificação automática pixel a pixel (MARUJO, 2013).

Mesmo com tais dificuldades, imagens de satélite com média resolução espacial são ferramentas com grande potencial para serem utilizadas no mapeamento das lavouras devido a suas características multiespectrais e multitemporais (MOREIRA et al., 2008; MOURA et al., 2009; MACHADO et al., 2010).

### **2.3. Programa *Landsat***

O programa *Landsat* (*Land Remote Sensing Satellite*) foi desenvolvido pela NASA (*National Aeronautics and Space Administration*) no final da década de 60, objetivando coletar dados sobre os recursos naturais renováveis e não renováveis da superfície terrestre (USGS, 2015b). O programa *Landsat* já conta com o lançamento de 8 satélites. Atualmente, encontra-se em operação o *Landsat-7* (em condições precárias) e o *Landsat-8*.

#### **2.3.1. *Landsat-8***

O Satélite *Landsat-8* é o mais moderno da família *Landsat*. Lançado em fevereiro de 2013, o satélite orbita a Terra em órbita quase polar, posicionando-se de maneira heliossíncrona a uma altitude de aproximadamente 705 km. Existem dois sensores a bordo do satélite *Landsat-8*, o sensor OLI (*Operacional Land Imager*) e o sensor TIRS (*Thermal Infrared Sensor*) (USGS, 2015a). Conforme é apresentado na Tabela 2.1, os sensores a bordo do satélite *Landsat-8* possuem faixa de imageamento de 185 km leste-oeste, resolução temporal de aproximadamente 16 dias, resolução espacial de 30m para as bandas do visível, 15m para banda pancromática e 100m para as bandas termais (TIRS).

As imagens provenientes dos sensores instalados no satélite *Landsat-8* trazem inovações importantes para usuários que demandam mapeamentos em mesoescala. O sensor espectral OLI e o sensor termal TIRS apresentam resolução espectral melhor que seus antecessores. Além disso, foram adicionadas duas bandas espectrais: a *new coastal* (banda 1), projetada especificamente para estudos dos recursos hídricos e investigação da zona costeira e um novo canal de infravermelho (banda 9) para a detecção de nuvens. Há também o acréscimo de uma banda de garantia de qualidade (BQA), que apresenta informações sobre a presença de nuvens, água e neve (USGS, 2015a). A partir do sensor termal TIRS, foram criadas duas bandas espectrais para o comprimento de onda antes coberto por uma única banda

nos sensores TM e ETM (USGS, 2015a). Tais adições provocaram mudanças nos intervalos dentro do espectro dos canais de todas as bandas.

Tabela 2.1 - Bandas multiespectrais do sensor OLI/*Landsat-8*.

<b>Bandas</b>	<b>Comprimento de onda (micrometros)</b>	<b>Resolução (metros)</b>
Banda 1 - Coastal aerosol	0,43 - 0,45	30
Banda 2 - Blue	0,45 - 0,51	30
Banda 3 - Green	0,53 - 0,59	30
Banda 4 - Red	0,64 - 0,67	30
Banda 5 - Near Infrared (NIR)	0,85 - 0,88	30
Banda 6 - SWIR 1	1,57 - 1,65	30
Banda 7 SWIR 2	2,11 - 2,29	30
Banda 8 Panchromatic	0,50 - 0,68	15
Banda 9 - Cirrus	1,36 - 1,38	30
Banda 10 - Thermal Infrared (TIRS) 1	10,60 - 11,19	100
Banda 11 - Thermal Infrared (TIRS) 2	11,50 - 12,51	100

Fonte: Adaptada de USGS (2015).

Outra alteração de destaque é a resolução radiométrica, uma vez que as imagens dos satélites anteriores possuíam 8 *bits*. Segundo USGS (2015b) os sensores OLI e TIRS proporcionam um melhor desempenho radiométrico (16 bits), possibilitando uma maior caracterização de alvos da imagem e também contribuindo para a diminuição do efeito de sombras. Em relação à exatidão geométrica das imagens oriundas do *Landsat-8*, outra inovação importante é a utilização de sensores *Pushbroom* em vez dos sensores *Whiskbroom*, utilizados anteriormente. Os sensores *Whiskbroom* são constituídos internamente de um espelho oscilante que se movimenta perpendicularmente à linha de vôo, “varrendo” a superfície terrestre. Os sensores *Pushbroom* dispensam o uso do espelho e apresentam seus detectores dispostos através de um arranjo linear, o que faz um menor basculamento do satélite, devido à organização dos detectores característicos desse tipo de sensor (MENESES e ALMEIDA, 2012). Este menor basculamento possibilitou uma diminuição no erro de posicionamento, que anteriormente era da ordem de 60 a 80 metros, e

passou para valores próximos a 12 metros para o sensor OLI (USGS, 2015a). Contudo, a NASA, juntamente com a USGS, realizam alguns processamentos padrões para a disponibilização das cenas, fato que dispensa o trabalho de correção geométrica para os usuários. As imagens do satélite *Landsat-8* são disponibilizadas aos usuários já ortorretificadas de acordo com a disponibilidade de dados para a área. De acordo com USGS (2015a), o processo de correção geométrica aplicado consiste na aquisição de Pontos de Controle a partir das bases de dados disponibilizados pelo projeto *Global Land Surveys 2000* (USGS 2015a; 2015b).

Já um procedimento bastante realizado por usuários, principalmente quando necessária intervenção manual de um intérprete, é a fusão de imagens. Tal procedimento possibilita associar a banda pancromática às demais bandas para incrementar a capacidade de distinção de alvos.

## **2.4. Fusão de imagens**

A fusão de imagens é um procedimento que permite integrar uma banda de maior resolução espacial (geralmente uma banda pancromática) a uma banda com resolução espectral menor, produzindo uma imagem colorida com ambas as características (ADAMI et al., 2007). Tal procedimento pode ser utilizado para incrementar a capacidade discriminatória de um intérprete ao observar diferentes alvos em uma imagem. Existem diferentes métodos de fusão de imagens. Os mais comuns são por transformações IHS, componentes principais, *Wavelet* e *Gram-Schmidt* (CHAVEZ et al., 1991; NUNEZ et al., 1999; KOUTSIAS et al., 2000).

### **2.4.1. Fusão Gram-Schmidt**

Devido à fusão *Gram-Schmidt* utilizar a resposta do sensor para estimar como a resposta do sensor deve parecer, torna-se possível obter mais detalhes da imagem (PINHO et al., 2005). A fusão *Gram-Schmidt* tem bom desempenho computacional e considera a heterogeneidade e representatividade dos

diferentes tipos de elementos da paisagem (LUCAS et al., 2014; SOARES et al., 2015). O procedimento de fusão *Gram-Schmidt* tem início com a simulação de uma banda pancromática a partir das bandas multiespectrais de menor resolução espacial. Na sequência, uma transformação de *Gram-Schmidt* é aplicada às imagens multiespectrais e à banda pancromática simulada. Posteriormente, a banda pancromática simulada é substituída pela banda pancromática original da imagem de melhor resolução espacial e é feito então uma transformação inversa, resultando assim na imagem pancromática de saída, a qual será utilizada em um procedimento de fusão IHS conforme Figura 2.2 (ENVI, 2004; AIAZZI et al., 2007; AL-WASSAI et al., 2011).

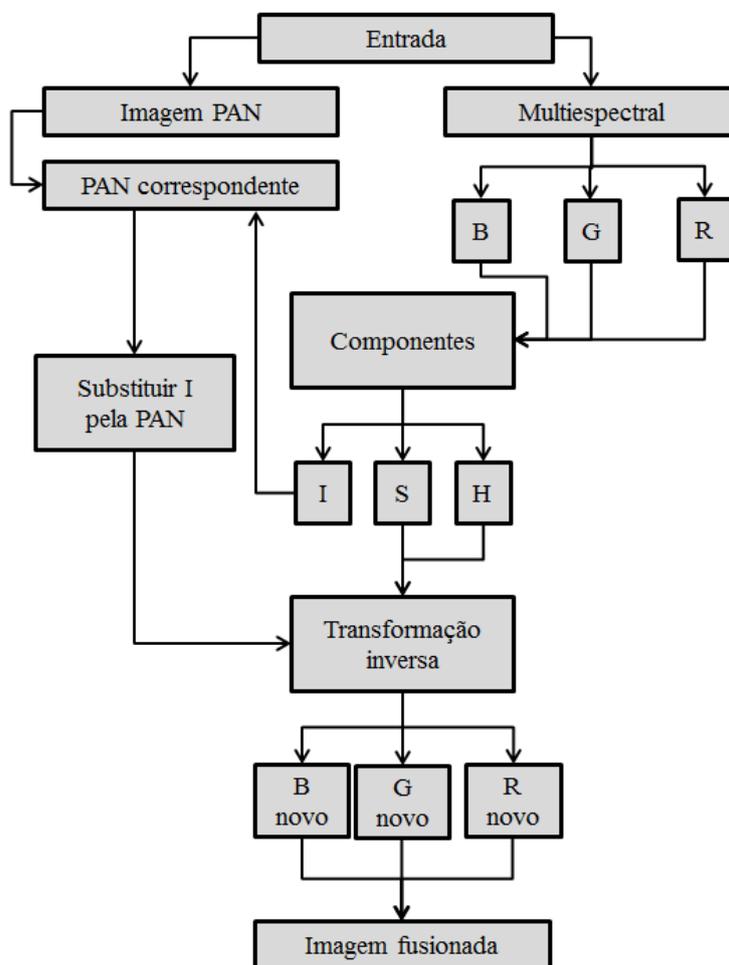


Figura 2.2 – Fusão de imagem IHS.

Fonte: Adaptada de Al-Wassai et al. (2011).

Além da fusão de imagens, outras operações também podem ser realizadas sobre as imagens de modo a obter-se produtos úteis. Operações matemáticas entre bandas podem destacar características em tais imagens, no caso da vegetação, tais operações são chamados índices de vegetação.

## 2.5. Índices de vegetação

Um índice de vegetação consiste no resultado da combinação de duas respostas espectrais obtidas com diferentes comprimentos de onda de modo a relacionar e quantizar a vegetação de uma área e a superfície de solo que esta ocupa (JENSEN, 2009).

Os índices de vegetação, em sua maioria, utilizam as bandas espectrais do infravermelho próximo e do vermelho para identificar e quantificar a concentração e vigor da vegetação (VIGANÓ et al., 2011). Isso é feito porque quanto mais sadia e verde a vegetação em uma área imageada, maior é a diferença da resposta espectral desta em tais comprimentos de onda (MOREIRA, 2014).

### 2.5.1. NDVI

Um dos índices de vegetação mais utilizados no sensoriamento remoto orbital é o Índice de Vegetação por Diferença Normalizada (NDVI, do inglês, *Normalized Difference Vegetation Index*) de ROUSE et al., 1973 (JACKSON; HUETE, 1991; MASKOVÁ et al., 2008). Tal índice é obtido por meio das operações aritméticas da Equação 2.1.

$$NDVI = \frac{Nir-R}{Nir+R}, \quad (2.1)$$

em que *Nir* representa a energia refletida na região do infravermelho próximo e *R*, a energia refletida na região do vermelho do espectro eletromagnético. Uma imagem NDVI tende a apresentar as regiões de vegetação vigorosa em pixels claros (pixels com valores altos), e regiões com menor vigor vegetativo em pixels escuro (pixels com valores baixos).

Embora os índices de vegetação tenham a intenção de minimizar as interferências provenientes de outras fontes além de vegetação, a resposta espectral do solo pode ser bastante presente em caso de vegetação esparsa ou jovem, deste modo existem índices específicos para minimizar este elemento, como é o caso do índice SAVI (ROSA, 2007). Entretanto para minimizar efeitos indesejados referentes ao solo, também podem ser utilizados dados específicos, assim como para diminuir a influência causada pela diferente iluminação dos alvos, pode-se utilizar um produto de iluminação, que pode ser extraído de produtos de elevação.

## **2.6. Dados de elevação**

Dados topográficos podem ser empregados para auxiliar na identificação de áreas cafeeiras em regiões montanhosas (VIEIRA et al., 2006). Cordero-Sancho e Sader (2007) corroboraram essa afirmação, pois segundo os autores, a exatidão global foi significativamente melhor no mapeamento de café no município de Guaxupé-MG, quando consideraram as variáveis topográficas e de iluminação em associação às informações espectrais contidas nas imagens ETM+/Landsat-7.

De uso gratuito e abrangendo praticamente toda a Terra, uma opção de dados de topografia são os dados da missão *Shuttle Radar Topography Mission* (SRTM) (FARR et al., 2007). Essa missão gerou um Modelo Digital de Elevação (MDE) para o globo terrestre, que atualmente é disponibilizado, já processado e gratuitamente no sítio *Earth Explorer* ([www.earthexplorer.usgs.gov](http://www.earthexplorer.usgs.gov)), com as opções de 90 ou 30 metros de resolução espacial.

Um dos produtos que podem ser extraídos do MDE é a declividade, que expressa a inclinação da superfície do terreno em relação ao plano horizontal. A declividade é definida pela razão da diferença da altitude dos pontos pela distância horizontal entre os mesmos, conforme Equação 2.2, em que o

resultado é expresso em porcentagem, podendo este ser convertida para graus (ENVI, 2004).

$$D = \frac{\Delta h}{\Delta s}, \quad (2.2)$$

em que  $\Delta h$  é a variação de altura entre dois pontos e  $\Delta s$  a distância entre eles, como pode ser observado na Figura 2.3.

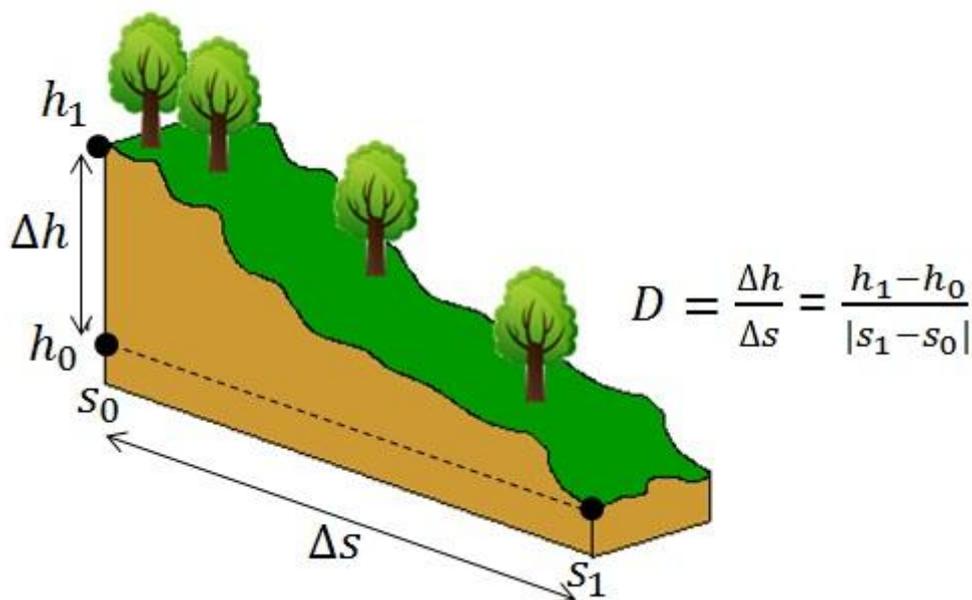


Figura 2.3 – Exemplo de cálculo de declividade de terreno.

Outro produto que pode ser extraído da topografia é a orientação da face do relevo, também chamada orientação de vertente. Utilizando a informação de declividade de um ponto e seus vizinhos, torna-se possível verificar a orientação do relevo. Por convenção adota-se que um terreno com face para norte está a  $0^\circ$  e em sentido horário esse ângulo aumenta (ENVI, 2004), conforme pode ser observado na Figura 2.4.

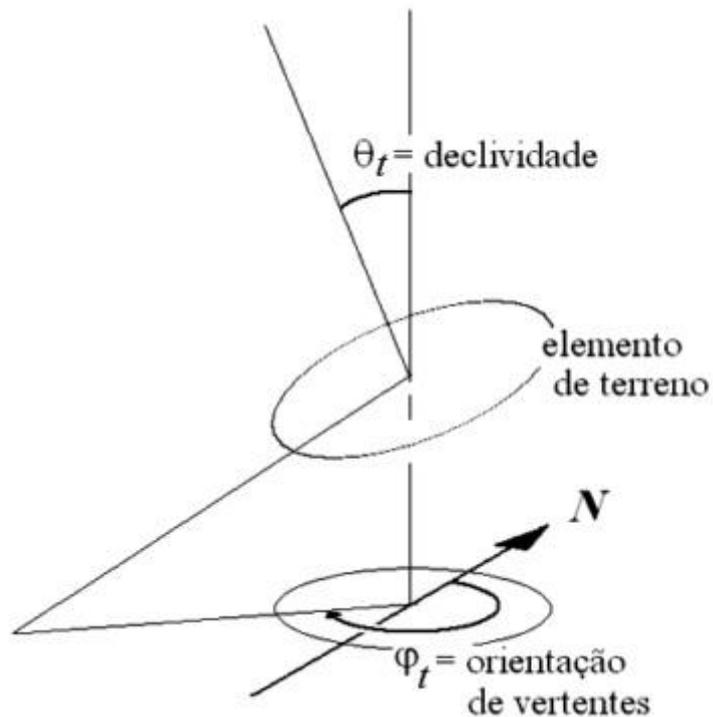


Figura 2.4 - Geometria de iluminação/sombreamento de um elemento de terreno.

Fonte: Adaptada de Valeriano (2011).

Além das características do terreno, para representar fielmente as variações naturais da geometria solar, deve-se considerar as alterações anuais e diárias da geometria de iluminação e as condições vigentes do período de interesse (VALERIANO, 2011). Desta maneira, uma imagem de fator de iluminação (FI) tende a expressar as variações de iluminação ao longo de um terreno. A equação para cômputo do FI, apresentada na equação 2.3, faz uso dos dados de elevação e orientação do relevo, bem como dos metadados das imagens multiespectrais, no caso o ângulo zenital solar e ângulo azimutal solar.

$$Fi = \cos(\theta_s) \cos(\theta_t) + \cos(\theta_s) \cos(\varphi_s - \varphi_t)), \quad (2.3)$$

em que,  $\cos(\theta_o)$  é o fator cosseno,  $\theta_s$  é o ângulo zenital solar,  $\theta_t$  é o ângulo zenital da normal à superfície do terreno (que corresponde à declividade),  $\varphi_s$  é o ângulo azimutal solar e  $\varphi_t$  é o ângulo azimutal da normal à superfície (que

corresponde à orientação de vertente). O ângulo azimutal de iluminação ( $\phi_0$ ) é a diferença entre  $\phi_s$  e  $\phi_t$  (VALERIANO, 2011). Por vezes na literatura a imagem fator de iluminação também é chamada imagem  $\cos(i)$ . Uma melhor visualização sobre o ângulo azimutal e o ângulo zenital pode ser observada na Figura 2.5.

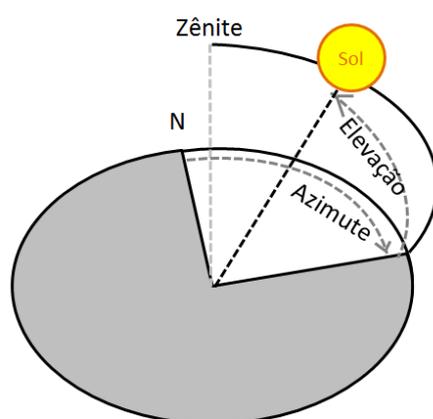


Figura 2.5 - Ângulo zenital e ângulo azimutal.

Além dos efeitos intrusivos causados pelo relevo na resposta espectral dos alvos, diversos fatores atmosféricos também interferem na resposta obtida pelo sensor. Com a finalidade de reduzir estes fatores, foram desenvolvidos os métodos de correção atmosférica.

## 2.7. Correção atmosférica

Imagens orbitais, como as originadas de dados coletados pelo sensor OLI, medem radiância, uma grandeza radiométrica que mensura a distribuição da radiação no espaço e resulta de efeitos aditivo e multiplicativo de interações da energia eletromagnética com a superfície e com a atmosfera, conforme Equação 2.4 (SILVA; VALERIANO, 2005; JENSEN, 2009).

$$L_s = L_t + L_p, \quad (2.4)$$

em que,  $L_s$  é a radiância total registrada pelo sensor,  $L_p$  é um componente intrusivo (mau) oriundo de outras fontes diferentes do alvo de estudo e,  $L_t$  a radiância do alvo de estudo, que podem ser também observados na Figura 2.6 (JENSEN, 2009).

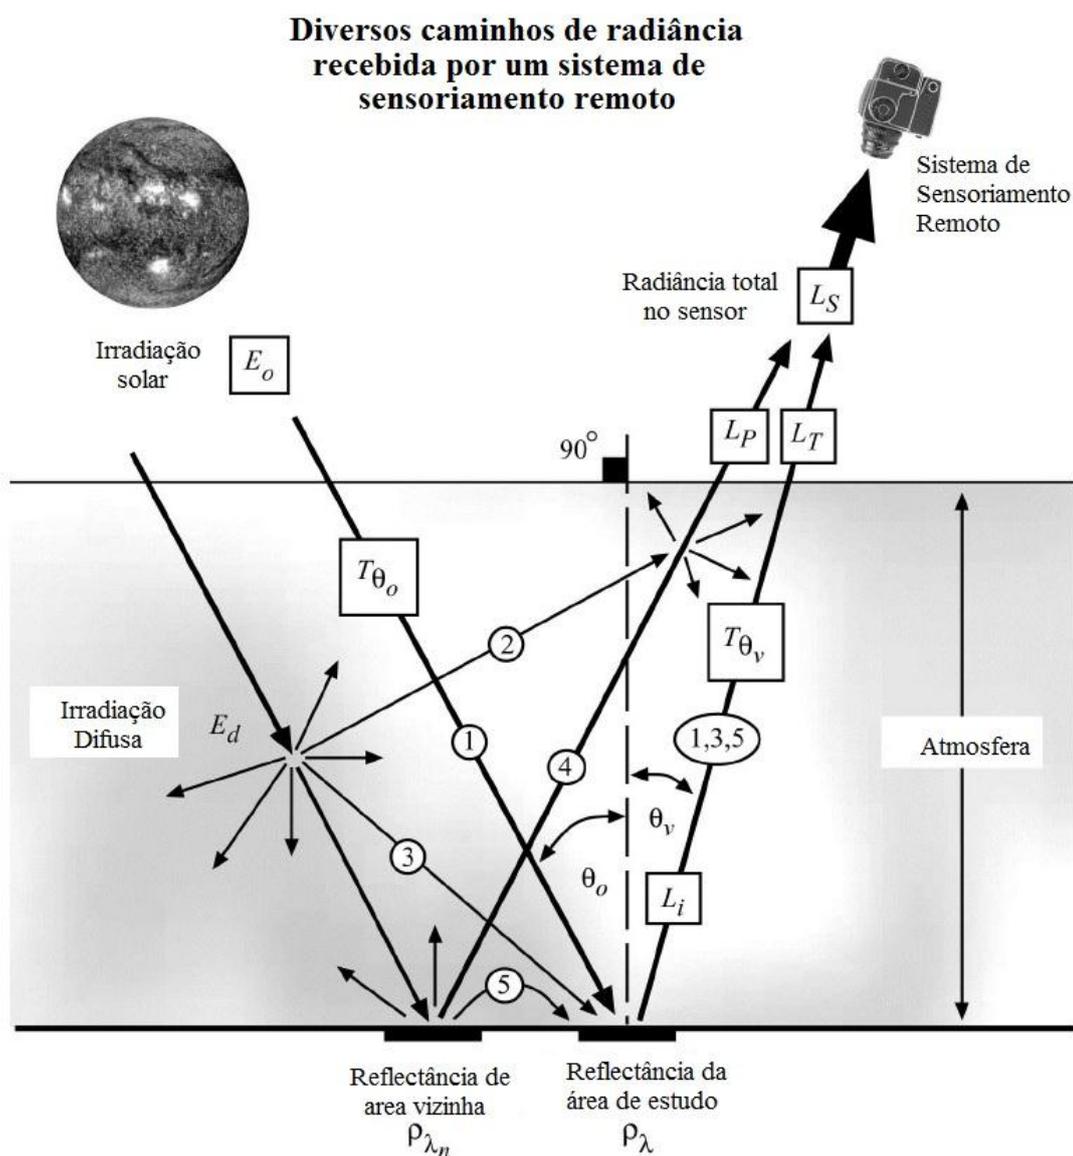


Figura 2.6 - As radiâncias  $L_t$  das trajetórias 1, 3 e 5 contêm informação espectral intrínseca importante sobre o alvo de interesse. Por outro lado, a radiância de trajetória  $L_p$  das trajetórias 2 e 4

incluem irradiância solar difusa ou radiância de áreas vizinhas no terreno. Esta radiância de trajetória geralmente introduz ruído radiométrico indesejável nos dados de sensoriamento remoto e complica o processo de interpretação de imagens.

Fonte: Adaptada de Jensen (2009).

Quando imagens são obtidas em datas diferentes, a resposta espectral, de um determinado ponto com as mesmas coordenadas geográficas está sujeita a variações e incertezas em cada aquisição. Tais variações podem ser efeitos atmosféricos, efeitos de iluminação, modificação de relevo, dentre outros (SMITH et al., 1980; SLATER; JACKSON, 1982).

A correção dos efeitos atmosféricos é feita em imagens de satélite com o intuito de minimizar os efeitos intrusivos na medição da radiância captada por um sensor. Tais efeitos ocorrem principalmente por causa dos fenômenos de espalhamento, absorção e refração da energia eletromagnética, sendo esse pré-processamento imprescindível para normalizar os dados multitemporais em uma mesma escala radiométrica (SONG et al., 2001). Tal correção transforma a informação de radiância obtida pelo sensor em informação de reflectância de superfície.

Dos modelos de propagação radiativa mais utilizados para correção atmosférica de imagens de satélite destacam-se o *Second Simulation of a Satellite Signal in the Solar Spectrum* o chamado 6S, e *Moderate resolution atmospheric Transmission* abreviado MODTRAN (CALLIECO; DELL'ACQUA, 2011).

Uma das vantagens do sensor *OLI/Landsat-8* é a disponibilização, por parte da USGS, do produto *Climate Data Record* (CDR), que utiliza o modelo 6S para obter a reflectância de superfície. Já com o modelo de propagação radiativa MODTRAN, um dos algoritmos de correção atmosférica mais utilizados é o *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) (COUTO JUNIOR et al., 2011). Existe uma implementação do módulo FLAASH

em modo de *plugin* para o *software* ENVI. Esta implementação requer que o usuário informe os metadados da imagem (localização geográfica, tamanho de pixel, data e horário de aquisição da imagem), informações do sensor (altitude) e características da região (elevação média do terreno). Além de arbitrar sobre uma variável de visibilidade que depende da intensidade das nuvens sobre a cena, sendo o interprete o estipulador deste valor.

Feito os ajustes iniciais sobre as imagens de modo a padronizar e normalizá-las, as mesmas estão preparadas para serem processadas para classificação automática. Em um processo de classificação baseada em objetos, é necessário primeiramente estabelecer os objetos, os também chamados segmentos.

## **2.8. Segmentação de imagens**

A segmentação de imagem consiste no agrupamento de pixels em regiões mediante um critério de semelhança (MEINEL et al., 2004). Sendo assim o processo no qual uma imagem é subdividida em partes constituintes e semelhantes, o que possibilita a imagem ser trabalhada em regiões ao invés de isoladamente por pixels (GONZALEZ; WOODS, 2006).

Uma vez que os resultados de uma classificação baseada em objetos são diretamente afetados pela qualidade da segmentação (MEINEL et al., 2004), torna-se importante obter segmentação que representem bem os alvos da imagem. Isso ocorre porque a segmentação é o primeiro processo a ser feito para uma posterior classificação baseada em objetos (BLASCHKE et al., 2014).

Os métodos de segmentação são divididos principalmente em três abordagens: divisão e fusão, detecção de bordas e crescimento de regiões. A abordagem de segmentação por divisão e fusão divide a imagem em blocos e verifica se tais blocos são homogêneos. Se os blocos divididos atenderem a um critério de homogeneidade, o segmento analisado permanece inalterado, do contrário é dividido em blocos menores e repete-se o processo nos blocos menores

(GONZALEZ; WOODS, 2006). A abordagem por detecção de bordas tem como estratégia encontrar o término de cada segmento e utilizar seu contorno para separar os objetos da imagem. Uma das técnicas empregadas com sucesso nessa abordagem é a segmentação de imagens após a aplicação de filtros passa alta, processamento que permite que as regiões de alta frequência (transição entre objetos) sejam destacadas na imagem (GONZALEZ; WOODS, 2006). A abordagem por crescimento de regiões inicia-se com um único pixel, chamado semente. Os vizinhos deste são analisados e caso atendam a um critério de similaridade são agrupados em um segmento. O processo se repete com a imagem inteira (GONZALEZ; WOODS, 2006).

A maior parte dos algoritmos de segmentação por crescimento de região necessita de parametrização adequada para que os segmentos resultantes sejam condizentes aos alvos de uma imagem, o que é o caso da segmentação multirresolução (ESPINDOLA, 2006). Embora, existam tentativas de parametrização automática dos métodos de segmentação (FEITOSA et al., 2006a, 2006b; ESPINDOLA; CÂMARA, 2007; DLUGOSZ et al., 2008; WANG et al., 2010), geralmente o intérprete realiza manualmente uma série de tentativas até encontrar um padrão que seja visualmente satisfatório e reproduzível (BLASCHKE et al., 2000; FEITOSA et al., 2006b;).

Na literatura diversos trabalhos fazem comparações entre diferentes algoritmos de segmentação (BÉNIÉ et al., 1989; MEINEL et al., 2004; MARUJO, 2013). Em sensoriamento remoto a abordagem de segmentação mais utilizada é a por crescimento de regiões (TILTON; LAWRENCE, 2000), sendo um dos algoritmos de segmentação mais utilizados desta abordagem, o algoritmo de segmentação multirresolução de Baatz e Schäpe (2000) (BENZ et al., 2004; HAPP et al., 2013, ZHANG et al., 2015).

### **2.8.1. Segmentação multirresolução**

A segmentação multirresolução funde regiões de uma imagem em sentido *bottom-up* (debaixo para cima, ou múltiplas pequenas regiões em regiões

maiores). Inicialmente cada pixel é um segmento da imagem, e, por meio dos critérios de homogeneidade definidos para o algoritmo (cor, forma, compacidade, suavidade e escala), os segmentos semelhantes são fundidos formando um segmento maior com as características dos menores, ocorrendo em pares (BAATZ; SCHÄPE, 2000). O critério de homogeneidade entre dois segmentos para união em um novo segmento é dado pela Equação 2.5 (BAATZ; SCHÄPE, 2000).

$$h = \sqrt{\sum_D \left( \frac{f_1d - f_2d}{\sigma} \right)^2}, \quad (2.5)$$

em que,  $h$  é a similaridade,  $d$  são as dimensões também chamadas de bandas espectrais da imagem,  $f_1d$  e  $f_2d$  são os atributos dos segmentos em comparação na dimensão  $d$  e,  $\sigma$  o desvio padrão.

Uma vez que os segmentos são agrupamentos de pixels semelhantes, tais objetos não possuem uma classe definida, sendo para isso necessário um processo de rotulação, a também chamada classificação.

## 2.9. Classificação de imagens

A classificação de imagens é o processo no qual se atribuem classes temáticas aos *pixels* ou regiões de uma imagem (MOREIRA, 2014). O processo de classificação automática de imagens pode ser supervisionado ou não supervisionado. Na abordagem supervisionada, o treinamento consiste no reconhecimento de padrões especificados por um intérprete, por exemplo, uma amostragem. A fase de amostragem consiste no treinamento do classificador. Nesse processo são fornecidas, pelo intérprete, amostras representativas de cada alvo de ocupação do solo, na imagem a ser classificada (MOREIRA, 2014). Na abordagem não supervisionada, o próprio algoritmo encontra os padrões de separação das classes (MOREIRA, 2014).

### **2.9.1. Classificação multiespectral**

A classificação *multiespectral* é o processo de classificação de imagens que utiliza apenas o domínio espectral, ou seja, somente a intensidade representada em cada número digital de pixel. Isso é realizado tanto para amostragem quanto para classificação. Desse modo, um classificador associa cada pixel ou região da imagem a uma classe predefinida (MOREIRA, 2014).

A maior parte desses classificadores baseiam-se puramente no número digital dos pixels. Dentre estes destacam-se como um dos mais tradicionais o maxver (MOREIRA, 2011). Primordialmente eram feitas classificações utilizando apenas os valores de número digital contido nos pixels das imagens, as chamadas classificações pixel a pixel. Posteriormente começou-se a utilizar segmentação de imagens para se trabalhar com agrupamentos de pixels semelhantes, entretanto ainda com base apenas nos valores de número digital dos pixels, neste caso uma média dos valores dos pixels do segmento. Nesta abordagem destaca-se o algoritmo isoseg (OLIVEIRA e MATALEVI, 2013).

Com a melhora da resolução espacial e radiométrica das imagens de satélite no decorrer dos anos, os métodos de classificação multiespectrais não mais forneciam resultados suficientemente exatos (BLASCHKE et al., 2014). Em um esforço para se obter melhores resultados de classificação, buscou-se utilizar atributos de textura, forma e contexto e não somente a informação espectral isolada (ADDINK et al., 2012), dando origem à metodologia atualmente chamada Geobia (*Geographic Object-Based Image Analysis*) (BLASCHKE et al., 2014).

### **2.9.2. Classificação baseada em objetos**

Na literatura também se encontram outras nomenclaturas para a classificação baseada em objetos: classificação orientada a objetos, segmentos, ou regiões (SOEDIONO, 1989; WEIH; RIGGAN, 2008; FRIEDRICH et al., 2009; RESENDE, 2012; CASTRO FILHO; CASTRO, 2007). A nomenclatura

classificação baseada em objetos foi adotada neste trabalho para evitar ambiguidades com paradigmas de programação.

A abordagem de classificação baseada em objetos é bastante utilizada para identificar culturas agrícolas (LUZ et al., 2010; VIEIRA et al., 2012; SILVA JUNIOR et al., 2014). Entretanto, especificamente para a cafeicultura, há poucos relatos (SANTOS et al., 2012; MARUJO, 2013; SARMIENTO et al., 2014).

A classificação baseada em objetos simula o comportamento de um intérprete ao reconhecer áreas em uma imagem, analisando não somente o *pixel*, mas também seus vizinhos (MOREIRA, 2014). Tal classificação pressupõe a existência de uma imagem segmentada. No caso de uma abordagem de classificação automática supervisionada, esses segmentos são amostrados para reconhecimento de padrões das classes. A busca por padrões de classificação é feita utilizando atributos extraídos dos segmentos amostrais, tais como a média espectral de cada banda, atributos de forma e textura. Por fim, o modelo gerado é utilizado por um algoritmo classificador para classificar toda a imagem.

Dentre os atributos que podem ser extraídos dos segmentos de uma imagem, destacam-se a média espectral, o desvio padrão médio da resposta espectral, o brilho, a diferença máxima, a compacidade, a retangularidade, a elipsidade, as texturas, entre outros (DEFINIENS, 2007). A média espectral de um segmento consiste na média dos valores digitais dos pixels presentes em um mesmo segmento, para uma determinada banda espectral. Semelhantemente, o desvio padrão médio de um segmento consiste na média dos desvios-padrão dos valores digitais dos pixels de um segmento em relação a média do mesmo. O brilho é um atributo calculado utilizando todas as bandas da imagem e mede a variação dos valores digitais mínimos e máximos dos pixels de um segmento. A diferença máxima é uma característica que usa o brilho para avaliar a variação máxima de um pixel. A compacidade avalia o quão compacto é um

segmento. A retangularidade avalia quão próximo da forma de um retângulo é um segmento. A elipsidade avalia quão próximo da forma de uma elipse é um segmento (DEFINIENS, 2007).

As texturas são métricas estatísticas que avaliam a propagação da variação dos valores digitais dos pixels em um segmento (HARALICK et al., 1973). Há diversas métricas de textura, dentre elas têm-se a homogeneidade, a entropia, e a dissimilaridade. Comparadas aos demais atributos, as texturas são mais complexas, pois requerem maior tempo computacional para seu cálculo. Para computo de um atributo de textura, dado um segmento, cada pixel torna-se uma referência local e é feita uma verificação (de acordo com o tipo de textura) com seus vizinhos através de uma matriz de co-ocorrência (o que caracteriza os atributos de textura de Haralick) (HARALICK et al., 1973).

## **2.10. Mineração de dados**

A mineração de dados é o processo de exploração de dados que visa encontrar padrões, sequências e correlações. Os métodos de mineração de dados usualmente utilizam análises matemáticas para derivar padrões e dar suporte à tomada de decisões (WITTEN et al., 2011).

Com base em um conjunto de amostras, um algoritmo de mineração de dados busca um padrão capaz de criar regras de classificação. Um conceito importante no quesito amostragem é a validação cruzada (do inglês, *cross validation*). A validação cruzada, particiona os dados de entrada e iterativamente utiliza as partições para aprimorar as regras de classificação (WITTEN et al., 2011).

Diversas técnicas de mineração de dados têm-se mostrado promissoras na identificação de padrões quando aplicadas aos dados de sensoriamento remoto (KORTING et al., 2009; ANDRADE et al., 2011; GIROLAMO NETO et al., 2015). Em tal contexto, imagens multiespectrais podem ser assumidas como fonte de dados, sendo o valor do número digital de seus pixels e as

feições dos segmentos que estes compõem os atributos. Uma das abordagens mais utilizadas para descoberta de padrões, têm sido os algoritmos por árvore de decisão (WITTEN et al., 2011), que são computacionalmente eficientes e apresentam bom desempenho quando aplicados à classificações de uso e cobertura da terra (YANG et al., 2003; WEN et al., 2008; SATO et al., 2013).

### 2.10.1. Árvore de decisão e atributos

Algoritmos de classificação por árvores de decisão são considerados algoritmos supervisionados, uma vez que é necessário saber quais são as classes de cada amostra do conjunto de treinamento (HALL et al., 2009). Com base nos atributos das amostras de treinamento fornecidas, o algoritmo de mineração constrói uma estrutura de árvore, em que os nós são intervalos de atributos e as folhas são classes. A partir dessa árvore, classificam-se as amostras desconhecidas sem necessariamente testar todos os valores dos seus atributos. A classificação de uma nova amostra é feita percorrendo os ramos e nós da árvore, de acordo com os valores dos atributos da amostra desconhecida. Percorrendo-se a árvore com os atributos da amostra desconhecida, tal amostra é classificada com a classe que se encontra o nó folha da árvore, conforme pode ser observado na Figura 2.7 (WITTEN et al., 2011).

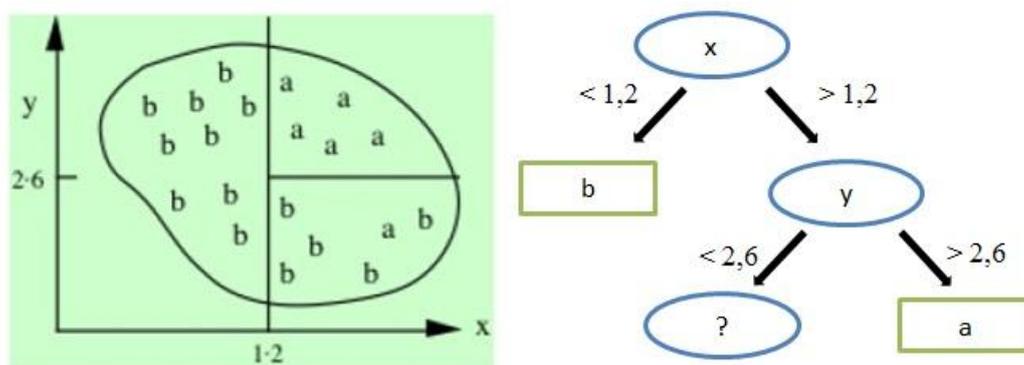


Figura 2.7 – Conjunto de dados e árvore de decisão (parcial) de classificação do conjunto.

Fonte: Adaptado de WITTEN et al. (2011).

Diversos são os algoritmos classificadores baseados em árvore de decisão, sendo um dos mais utilizados o C4.5 (QUINLAN, 1993).

### **2.10.2. O algoritmo C4.5**

O algoritmo C4.5 (QUINLAN, 1993) é um classificador por árvores de decisão. Semelhantemente a seu predecessor ID3, o C4.5 utiliza um conceito chamado ganho de informação normalizado que é calculado com base nos valores de entropia, equação 2.6, para decidir se um nó da árvore leva a um nó folha (classe) ou a outra verificação de atributo.

$$Entropia(p_1, p_2, \dots, p_n) = -p_1 \log p_1 - p_2 \log p_2 \dots - p_n \log p_n, \quad (2.6)$$

O algoritmo funciona em cinco etapas, descritas a seguir (QUINLAN, 1993). Na primeira etapa, procura-se por casos-base. Os casos-base do C4.5 podem ser valores de atributos nos quais sempre tenderão a uma mesma classe. Nesse caso, cria-se um nó folha com a classe visada. Na segunda etapa, todos os atributos são analisados, de modo a selecionar qual apresentar maior ganho de informação normalizado. Na terceira etapa, cria-se um nó com o atributo selecionado na segunda etapa. Na quarta etapa, as amostras são particionadas sem o atributo da terceira etapa. Por fim, repete-se o algoritmo como o nó filho até acabarem os atributos ou até que não haja mais ganho de informação (QUINLAN, 1993). No software WEKA (HALL et al., 2009), existe uma implementação *open source* em *Java* do algoritmo C4.5, denominada J48.

Uma vez com um mapa classificado automaticamente, é necessário que o mesmo seja validado, para demonstrar que a classificação não consiste em um arranjo aleatório das classes.

### **2.11. Confiabilidade do mapeamento**

Os mapas obtidos por meio das classificações automáticas apresentam erros que necessitam ser mensurados. A maneira mais indicada de se avaliar um mapa consiste em adotar um sistema de amostragem de área e, a partir dos

dados coletados na amostra, determinar a exatidão do mapa (ADAMI et al., 2011). As amostras utilizadas para validação devem ser suficientemente grandes para garantir confiabilidade aos resultados, porém devem considerar o ponto de vista econômico, de modo a não impossibilitar a coleta em campo (ADAMI et al., 2011). Em outras palavras, a validação é feita de modo a comparar a informação contida no mapa gerado e os dados de referência. A partir daí gera-se uma matriz de confusão (também chamada matriz de erros). Essa matriz apresenta a distribuição de *pixels* (ou regiões) classificados corretamente e erroneamente (CONGALTON, 1991). Um exemplo de matriz de confusão pode ser observado na Tabela 2.2.

Tabela 2.2 - Exemplo de matriz de confusão com as estimativas de exatidão total, do usuário e do produtor.

	Estrato 2			
	Dados de referência			Exatidão usuário (%)
	Café	Não café	Pontos classificados	
Café	<b>47</b>	8	55	85,4
Não café	2	<b>47</b>	49	95,9
Total de referência	49	55	<b>104</b>	
Exatidão do produtor (%)	<b>95,9</b>	<b>85,4</b>		
Exatidão Geral (%)	<b>90,4</b>			

Fonte: Adaptada de ADAMI et al. (2011).

Nota-se na matriz de confusão da Tabela 2.2 os elementos corretamente classificados na diagonal principal destacados em negrito. Partindo destes pontos é possível extrair o índice global (também chamado exatidão geral) por meio da equação 2.7 (IPPOLITI-RAMILO, 1999).

$$IG = \frac{\sum_{i=j}^m N_{ij}}{N}, \quad (2.7)$$

em que, N é o número total de unidades amostrais;  $N_{ij}$  sempre que i for igual a j, os elementos da diagonal principal (elementos corretamente classificados);

m, o número de classes presentes na matriz de erro; e i e j, as linhas e colunas, respectivamente. Tal índice reflete a probabilidade de um ponto sorteado na imagem estar corretamente classificado. Uma vez que a distribuição das classes temáticas de uma imagem não é igual em um terreno, o IG pode mascarar a exatidão de outra determinada classe. Para isso, outra avaliação de resultados consiste na análise dos erros de comissão e omissão de cada classe isolada, complemento das acurácias de usuário e produtor (CONGALTON, 1991), que podem ser obtidas pelas equações 2.8 e 2.9, respectivamente.

$$ec = \frac{\sum_{i=j} N_{ij}}{N_{+j}}, \quad (2.8)$$

$$eo = \frac{\sum_{i=j} N_{ij}}{N_{i+}}, \quad (2.9)$$

em que,  $N_{+j}$  é o somatório dos elementos da coluna e  $N_{i+}$ , o somatório dos elementos da linha. A acurácia de usuário de uma determinada classe está relacionada à probabilidade de dado um ponto aleatório daquela classe estar corretamente classificado segundo a referência. Enquanto que, a acurácia de produtor representa quanto de uma classe determinada está corretamente classificada, com base nos erros de omissão (ADAMI et al., 2011).

Um modo eficiente de validar uma classificação é por meio da aplicação do Método Monte Carlo (MMC), pois minimiza a chance de ser uma avaliação arbitrária. O MMC é um método estocástico em que se utiliza um gerador de números aleatórios para obter, pela repetição do cálculo diversas vezes, parâmetros de uma função (LANDAU; BINDER, 2009; RAMOS, 2011; PINTO et al., 2013). De maneira simplificada, o MMC consiste na média de muitas validações, com vários pontos de verificação. Ao assumir um número alto de sorteios, busca-se minimizar a chance da validação ter sido um *outlier*.

### 3 MATERIAIS e MÉTODOS

#### 3.1. Área de estudo

O desenvolvimento deste trabalho teve como área de estudo a microrregião de Alfenas. Os procedimentos também foram aplicados em escala municipal aos municípios de Alfenas, Machado e Serrania, todos contidos na microrregião de Alfenas e importantes produtores cafeeiros.

A microrregião de Alfenas, situada no sul do estado de Minas Gerais, representada na Figura 3.1, é uma das regiões mais importantes para a produção cafeeira brasileira (DAHER, 2011). Localizada entre as coordenadas geográficas 21° 25' 46''S e 45° 56' 50''O, e área de 4.991,6 km<sup>2</sup> (IBGE, 2014), a microrregião de Alfenas abrange os municípios de Alfenas, Alterosa, Areado, Carmo do Rio Claro, Carvalhópolis, Conceição da Aparecida, Divisa Nova, Fama, Machado, Paraguaçu, Poço Fundo e Serrania (IBGE, 1990).

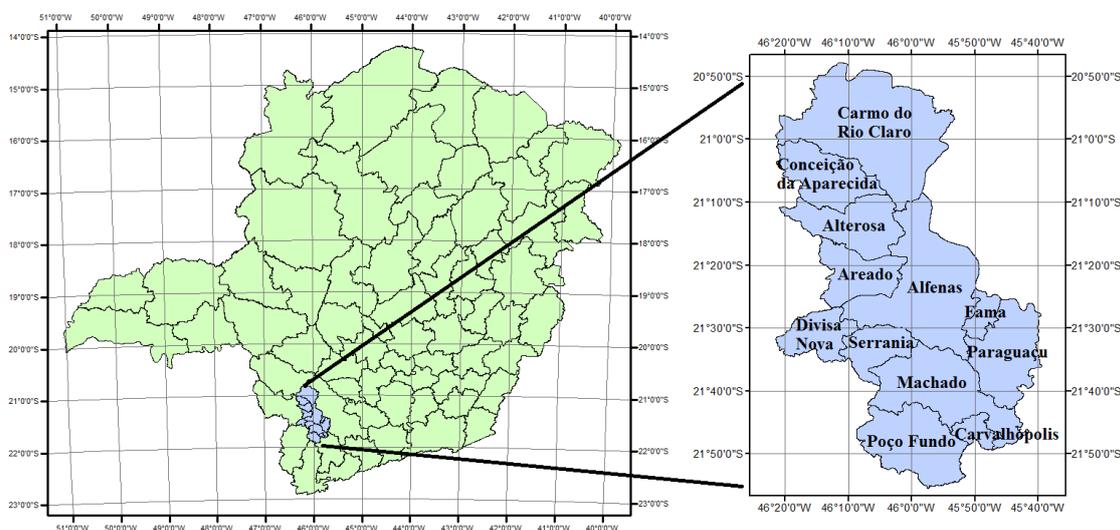


Figura 3.1—Localização da microrregião de Alfenas no estado de Minas Gerais, Brasil.

### 3.2. Dados orbitais

A área de estudo encontra-se inteiramente inserida na imagem da órbita 219/075 do OLI/Landsat-8. Neste estudo foram utilizadas imagens de seis datas distintas, conforme Tabela 3.1. Para seleção das imagens, além da menor percentagem de nuvens possível, também se buscou estabelecer um intervalo equidistante entre as datas de aquisição. Desse modo, foi possível representar os estádios fenológicos da cultura: frutificação, granação e repouso em cada ano considerado.

Tabela 3.1 - Imagens *OLI/Landsat-8* (219|075) utilizadas.

<b>Imagem</b>	<b>Data (dd/mm/aa)</b>	<b>Estádio fenológico</b>	<b>Horário de aquisição (GMT) (hh:mm:ss)</b>	<b>Ângulo solar Azimutal (°)</b>	<b>Ângulo solar Zenital (°)</b>
1	20/11/2013	Frutificação	13:05:34	90,68	65,47
2	08/02/2014	Granação	13:04:54	83,93	57,59
3	02/07/2014	Repouso	13:03:44	36,18	36,04
4	07/11/2014	Frutificação	13:04:11	82,58	64,86
5	10/01/2015	Granação	13:04:00	96,83	60,32
6	21/07/2015	Repouso	13:03:32	38,66	37,59

Informações sobre a topografia foram obtidas da missão SRTM. A microrregião de Alfenas encontra-se entre quatro cenas SRTM. Assim, foi necessário mosaicar as imagens antes de utilizá-las. As imagens SRTM são dados de elevação do terreno e foram utilizadas para gerar imagens de declividade e orientação do relevo no software *ENVI*.

Tanto as imagens *OLI/Landsat-8* quanto as imagens SRTM, apresentavam 30 metros de resolução espacial e foram obtidas gratuitamente no sítio *Earth Explorer* ([www.earthexplorer.usgs.gov](http://www.earthexplorer.usgs.gov)).

### 3.3. Metodologia

A metodologia adotada nesta pesquisa apresenta quatro etapas conforme Figura 3.2.

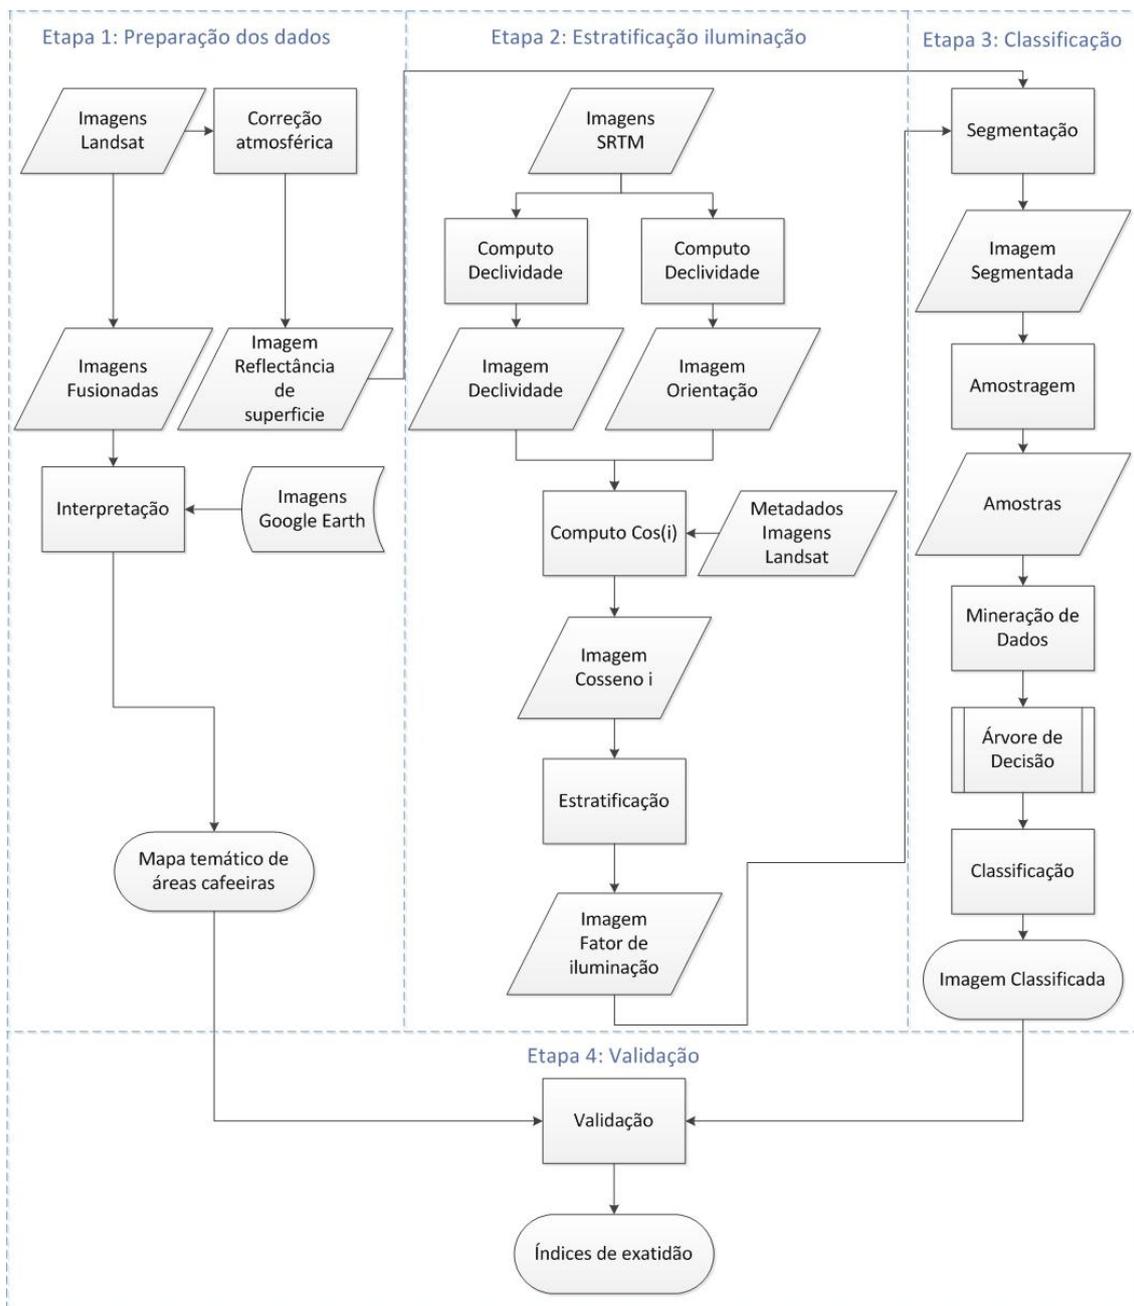


Figura 3.2 - Fluxograma de atividades desenvolvidas no trabalho, composto por quatro etapas: 1-Preparação dos dados; 2-Estratificação das classes de iluminação; 3-Classificação baseada em objetos; e 4-Validação.

### 3.3.1. Primeira Etapa: Preparação dos dados

Para deixar os dados multitemporais na mesma escala radiométrica (SONG et al., 2001), o primeiro procedimento feito nas imagens foi a correção dos efeitos atmosféricos. Testou-se para isso, dois tipos de correção atmosférica dentre os mais citados na literatura, a correção pelo método *FLAASH* e o produto *Reflectance climate data record landsat surfasse* (CDR) (COUTO JUNIOR et al., 2011; FRANÇA et al., 2015).

O produto CDR pode ser obtido já processado e gratuitamente no sítio *Earth Explorer* ([www.earthexplorer.usgs.gov](http://www.earthexplorer.usgs.gov)). O produto CDR inicialmente apresentava valores de pixels entre -2.000 e 16.000. USGS (2015b) informa que os valores válidos da imagem do produto CDR são os entre 0 e 10.000, necessitando apenas normalizá-los. Para representar a reflectância dos alvos, a imagem foi normalizada entre 0 e 1.

A correção atmosférica pelo método *FLAASH* foi realizada por meio de um *plugin* no software *ENVI 5.1*. Inicialmente, as bandas *OLI/Landsat-8* foram convertidas de número digital (ND) para radiância, utilizando os ganhos e *offsets* específicos do *OLI/Landsat-8*, já inclusos no *plugin*. Em seguida, os valores de radiância foram convertidos em valores de reflectância de superfície. A altitude do sensor (*OLI*) foi ajustada em 705 km, que corresponde à altitude operante do sensor, e adotou-se como elevação média do terreno 1 km, informação extraída dos dados topográficos para a microrregião de Alfenas. Além dos metadados das imagens *OLI/Landsat-8*, também é necessário que o usuário insira um valor arbitrado sobre as condições de visibilidade da cena sendo 100 uma imagem totalmente visível (ENVI, 2009). Após o procedimento, as imagens corrigidas pelo método *FLAASH* também foram normalizadas entre 0 e 1.

Uma vez realizadas as correções atmosféricas feitas, comparou-se a resposta espectral de ambas. Para cada pixel interpretado como café na imagem de referência, coletaram-se os valores espectrais (referente à reflectância de

superfície) em cada uma das bandas multiespectrais das imagens com correção atmosférica. Com os valores médios de cada banda foram gerados gráficos comparativos entre as respostas espectrais obtidas com o produto CDR e a correção atmosférica *FLAASH*.

Com o intuito de interpretar visualmente as áreas cafeeiras contidas nas imagens, após a correção atmosférica, foi feito o procedimento de fusão de imagens por meio do método *Gram-Schmidt*. Tal procedimento teve a finalidade de reduzir o tamanho do pixel de 30 m para 15 m, sendo o mesmo aplicado às bandas 4, 5 e 6 (vermelho, infravermelho próximo e infravermelho médio, respectivamente) utilizando a banda 8 (pancromática).

A interpretação visual das imagens foi feita conforme recomendações de Moreira et al. (2008), analisado os talhões de café nas imagens *OLI/Landsat-8* e conferindo, em caso de dúvida, nas imagens de alta resolução espacial do *Google Earth*. Se houvesse uma lavoura cafeeira na então era desenhado um polígono naquela feição e esta era associada à classe café. Embora as imagens do *Google Earth* datassem 04/08/14, (as imagens *OLI/Landsat-8* utilizadas datavam entre 20/11/2013 e 21/07/2015) a comparação com as imagens do estudo pôde ser feita porque o café é uma cultura perene, ou seja, permanecendo no local de plantio por bastante tempo (ROSA, 2007). Deste modo, como não houve trabalho de campo para coleta de dados *in situ*, os dados do *Google Earth* foram utilizados como verdade terrestre para interpretar as lavouras de café nas imagens *OLI/Landsat-8*.

### **3.3.2. Segunda etapa: Estratificação de relevo em classes de Iluminação**

Visando estratificar as imagens em classes de iluminação do terreno para amenizar a influência do relevo acidentado na identificação das áreas cafeeiras, utilizaram-se os dados de elevação (imagens SRTM), para calcular a imagem declividade e a imagem orientação de vertente, conforme Figura 3.3.

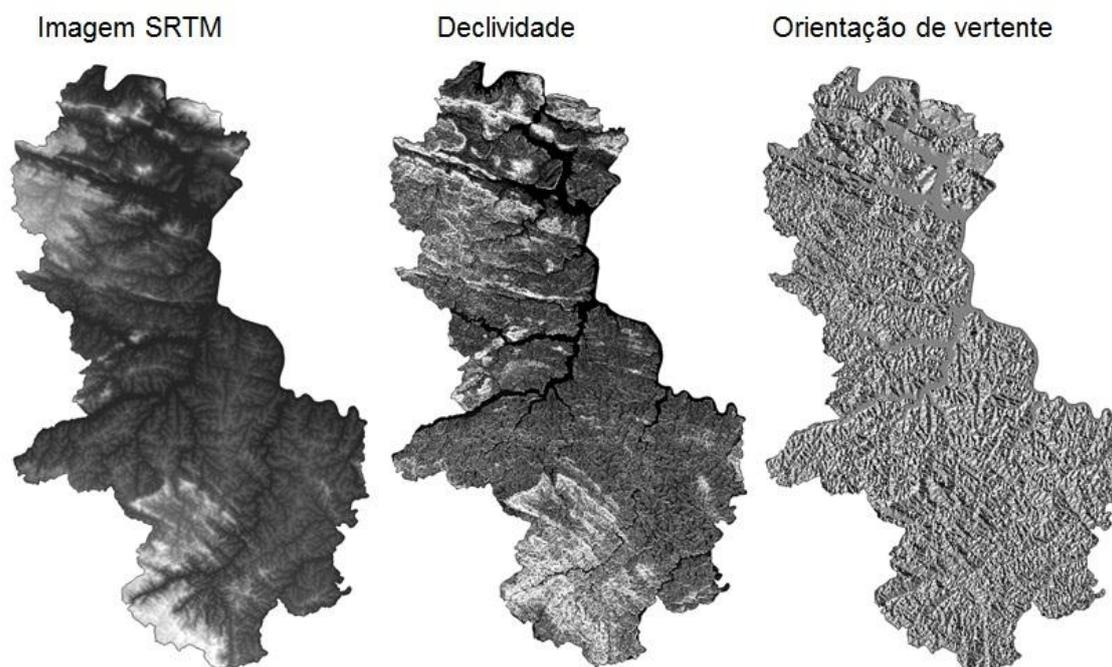


Figura 3.3 – Imagem SRTM, declividade e orientação de vertente da microrregião de Alfenas, Minas Gerais.

A orientação de vertentes foi fatiada nas direções  $0^{\circ}$  a  $45^{\circ}$  (N-NE),  $45^{\circ}$  a  $90^{\circ}$  (NE-E),  $90^{\circ}$  a  $135^{\circ}$  (E-SE),  $135^{\circ}$  a  $180^{\circ}$  (SE-S),  $180^{\circ}$  a  $225^{\circ}$  (S-SW),  $225^{\circ}$  a  $270^{\circ}$  (SW-W),  $270^{\circ}$  a  $315^{\circ}$  (W-NW),  $315^{\circ}$  a  $360^{\circ}$  (NW-N) conforme Souza et al.(2004), Vieira et al. (2004) e Alves et al. (2005).

Posteriormente os dados de declividade e orientação de vertente foram associados aos metadados das imagens *OLI/Landsat-8* (ângulo solar azimutal e ângulo solar zenital), e calculou-se a imagem fator de iluminação para cada imagem (MEYER et al., 1993; CANAVESI, 2008; LAMPARELLI et al., 2011; MOREIRA; VALERIANO, 2014).

As imagens fator de iluminação obtidas foram então estratificadas em cinco classes de iluminação, adotando intervalos equidistantes e dispostos na Tabela 3.2 (MEYER et al., 1993).

Tabela 3.2 - Estratificação das imagens fator de iluminação em cinco classes.

Classe de iluminação	Intervalo do fator de iluminação	Nome da classe
1	0,0 - 0,2	muito sombreado
2	0,2 - 0,4	sombreado
3	0,4 - 0,6	pouco iluminado
4	0,6 - 0,8	iluminado
5	0,8 - 1,0	muito iluminado

Para fins de testes, também optou-se por estratificar as imagens em apenas duas classes de iluminação: sombreado (de 0,0 a 0,5) e iluminado (de 0,5 até 1,0).

### 3.3.3. Terceira Etapa: Classificação

Individualmente, buscou-se retirar das imagens todos os pixels que apresentavam nuvens. Para isso, utilizou-se a banda *Quality Assessment Band* (BQA) (USGS, 2015b). Diferentemente das outras imagens obtidas pelo sensor OLI, a BQA é dividida em 16 bits, sendo cada bit referente a um determinado tipo de produto (USGS, 2015b). Neste trabalho utilizou-se apenas os bits de 12 a 15, referentes à ocorrência de nuvens. Os bits 12 e 13 são indicadores de nuvens cirrostratus enquanto que os bits 14 e 15 de nuvens mais densas (USGS, 2015b). Assim, quando um pixel da imagem apresentava valores BQA prováveis de nuvens, este era automaticamente classificado como nuvem e não participava dos demais processamentos. Identificou-se que as nuvens da imagem apresentavam valores maiores que 28.000 na BQA. Deste modo, uma nuvem era identificada quando o bit 15 estava ativo, valendo o pixel 32.768, ou quando os demais bits BQA (12,13 e 14) estivessem ativos, valendo 28.672.

Para classificar a imagem, primeiramente era necessário que a mesma fosse segmentada. Foram feitos diversos testes empíricos, visando obter segmentos que representassem as feições dos objetos contidos nas imagens, de modo a não exceder os contornos e não unir dois alvos distintos (ANTUNES, 2003; ESPINDOLA, 2006). Por fim, para o algoritmo de segmentação multirresolução

(BAATZ; SCHAPE, 2000) estabeleceu-se como padrão, fator de similaridade (no *Ecognition* denominado escala) 30, parâmetro de forma 0,6 e compacidade 0,5 nas bandas: NDVI, pan, vermelho e infravermelho próximo (bandas em que a vegetação apresentou maior caracterização).

Após a segmentação, tornou-se possível a extração dos atributos dos segmentos. Foram feitas três extrações com diferentes atributos, para três posteriores classificações, conforme Tabela 3.3. Para a primeira classificação foram extraídos os atributos: média espectral de cada banda, desvio padrão médio em cada banda, brilho, diferença máxima, compacidade, retangularidade, elipsidade, assimetria e densidade. Para a segunda classificação além dos atributos citados foram extraídos atributos de textura (HARALICK, 1973): segundo momento angular, contraste, correlação, dissimilaridade, entropia, homogeneidade, média e desvio padrão. Por fim, para a terceira classificação, extraíram-se os mesmos atributos da segunda classificação e acrescentaram-se as classes de iluminação.

Tabela 3.3 – Tabela de atributos extraídos dos segmentos da imagem, para posteriores classificações.

<b>Atributos Classificação 1</b>	<b>Atributos Classificação 2</b>	<b>Atributos Classificação 3</b>
- Média espectral de cada banda (*)	- Atributos Classificação 1	- Atributos Classificação 1
- Desvio padrão médio em cada banda (*)	- Textura Segundo momento angular (**)	- Atributos Classificação 2
- Brilho	- Textura Contraste (**)	- Classes de iluminação
- Diferença máxima	- Textura Correlação (**)	
- Compacidade	- Textura Dissimilaridade (**)	
- Retangularidade	- Textura Entropia (**)	
- Elipsidade	- Textura Homogeneidade (**)	
- Assimetria	- Textura Média (**)	
- Densidade	- Textura Desvio Padrão (**)	

\* Para bandas do azul, verde, vermelho, infravermelho próximo, swir1, swir2 e ndvi

\*\* Para bandas do azul, verde, vermelho, infravermelho próximo, swir1, swir2, ndvi e pan

Para treinamento dos classificadores, coletaram-se de modo aleatório, a partir do mapa de referência, 10.000 amostras pertencentes às classes café e não

café, sendo a amostra descartada caso apresentasse nuvem. Neste trabalho utilizou-se o algoritmo C4.5 (denominado também J48) (QUINLAN, 1993) implementado no software WEKA 3.7 (HALL et al., 2009). Tal algoritmo foi utilizado, por ser um dos que mais se destaca dentre os geradores de árvore de decisão (YANG et al., 2003; SATO et al., 2013). Os modelos de classificação (árvores de decisão) foram obtidos pelo algoritmo C4.5 (QUINLAN, 1993) em sua implementação no software WEKA (HALL et al., 2009). Assim, para cada classificação, gerou-se uma árvore de decisão (DELGADO, 2012).

As árvores de decisão, contendo as regras de classificação, foram então aplicadas às imagens segmentadas, sendo o procedimento de treinamento e classificação replicado para todas as datas.

#### **3.3.4. Quarta etapa: Análise da exatidão do mapeamento da classificação**

Para validar os resultados das classificações empregou-se o Método de Monte Carlo (MMC), tendo como dados de referências os mapas obtidos por meio da interpretação visual. Esse procedimento foi avaliado através de 100 sorteios de 1.000 pontos. A cada sorteio de 1.000 pontos calculava-se uma matriz de confusão e após os 100 sorteios era calculada uma matriz de confusão média para cada classificação.

Com posse das matrizes de confusão foram calculados o Índice Global (IG) e a exatidão para a classe café. Ao analisar os resultados obtidos nos dois anos, buscou-se verificar qual estágio fenológico proporcionou maior exatidão nas classificações. Além de comparar os resultados das três abordagens de classificações.



## **4 RESULTADOS e DISCUSSÕES**

### **4.1. Resultados Primeira Etapa**

#### **4.1.1. Correção atmosférica**

Os espectros de reflectância das áreas cafeeiras, tanto na correção atmosférica CDR quanto na correção por Flaash, para as bandas 2 (azul), 3 (verde) 4 (vermelho), 5 (infravermelho próximo), 6 (swir1) e 7 (swir2) do sensor OLI, podem ser observados na Figura 4.1. Os gráficos do lado esquerdo são referentes às imagens do primeiro ano fenológico analisado, e os gráficos da direita são referentes às imagens do segundo ano. As curvas presentes nos gráficos representam os valores médios de reflectância, extraídos das áreas cafeeiras (686646 pixels), em azul, pertencentes à correção Flaash e, em vermelho, ao produto CDR.

Como pode ser observado, em todos os estádios fenológicos o comportamento espectral do café foi um típico espectro de vegetação, ou seja, observa-se um pico de absorção da reflectância nas faixas de comprimentos de onda do vermelho e um aumento no infravermelho próximo e médio (JENSEN, 2009)

Para o primeiro ano os gráficos do espectro de ambas as correções atmosféricas apresentaram maiores variações em comparação ao segundo ano. Nota-se que principalmente no estágio fenológico de frutificação do primeiro ano houve variação entre os dois espectros nos comprimentos de onda do visível (bandas 2, 3 e 4). Já na fase de granação observa que esta variação ocorreu também no infravermelho.

O espectro de reflectância resultante de ambas as correções testadas mostraram-se semelhantes, quase se sobrepondo. Por falta de um espectro de reflectância de dossel de café arábica que pudesse ser utilizado como referência, neste estudo optou-se por utilizar as correções do método Flaash por constar na literatura como uma boa aproximação da verdade terrestre

(FRANÇA et al., 2015) possibilitando, em relação ao produto CDR, maior controle do intérprete sobre as operações feitas nas imagens.

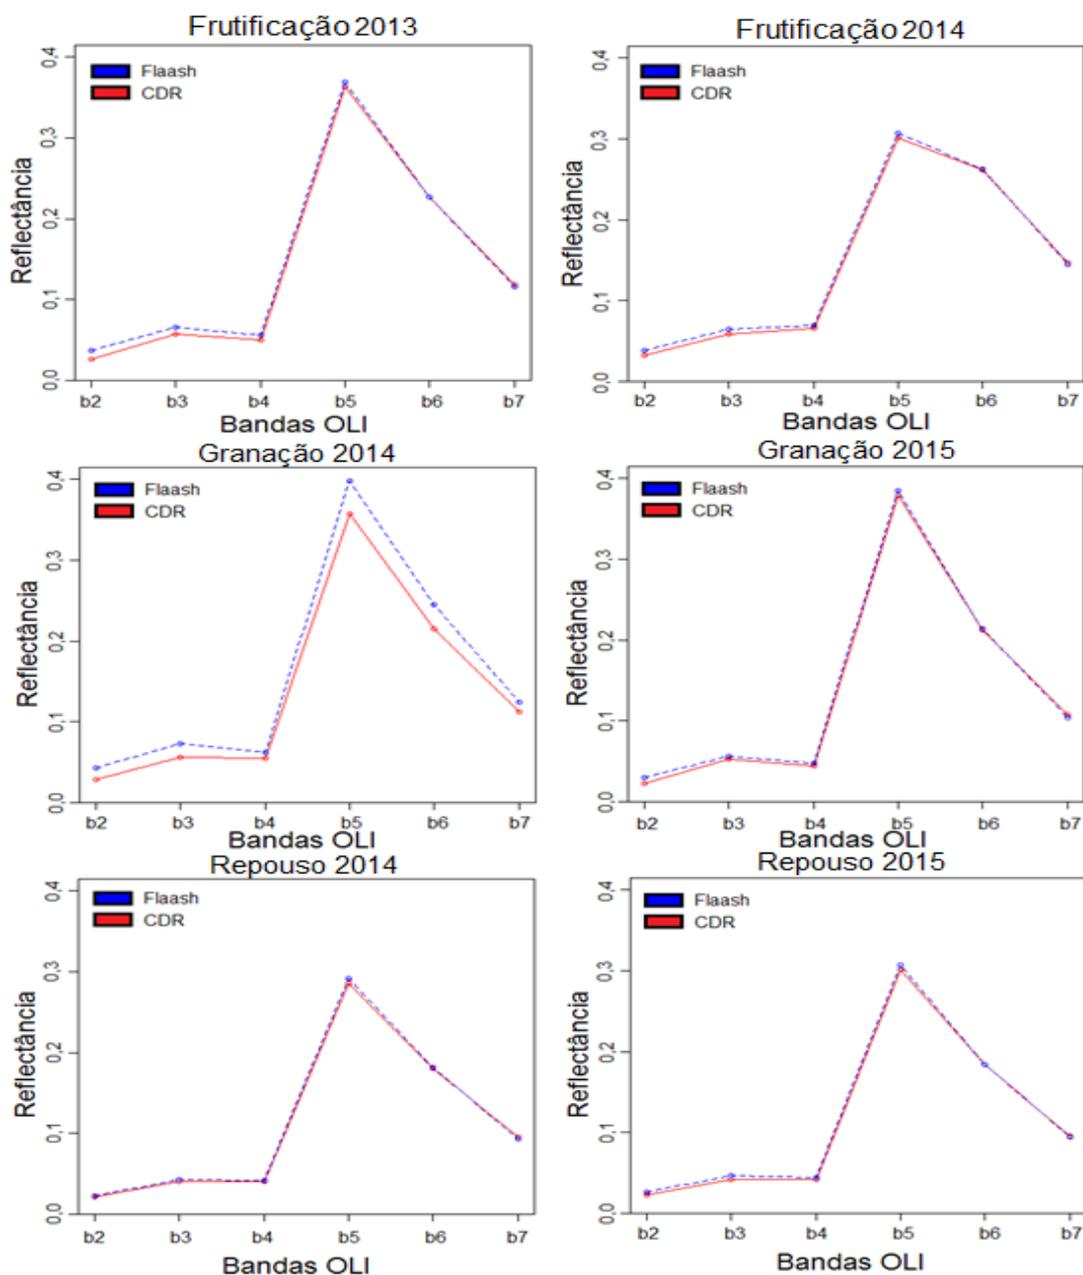


Figura 4.1 – Comportamento espectral das áreas cafeeiras em imagens OLI/Landsat-8 com correções atmosféricas CDR (curvas vermelhas) e Flaash (curvas azuis) nos estádios fenológicos da frutificação (gráficos da primeira linha), granação (gráficos da

segunda linha) e repouso (gráficos da terceira linha). Gráficos à esquerda referentes ao primeiro ano fenológico enquanto gráficos à direita referentes ao segundo ano fenológico.

#### **4.1.2. Interpretação Visual**

Na Figura 4.2 está contido o mapa temático com a distribuição espacial das lavouras de café, na microrregião de Alfenas para a data de 20/11/2013, resultante da interpretação das imagens fusionadas. Esse mapa serviu como referência para analisar os resultados das classificações posteriores e indicou que a cafeicultura está dispersa por toda a microrregião. Uma vez que o período abordado neste trabalho compreendeu dois anos, poucas foram as alterações nas imagens de referência entre as diferentes datas. Isso ocorreu, pois o café é uma cultura perene e a região tem plantio bem consolidado, embora ocorra poda e renovação dos cafezais com frequência (DANTAS, 2012; MINA e ALVES, 2013).

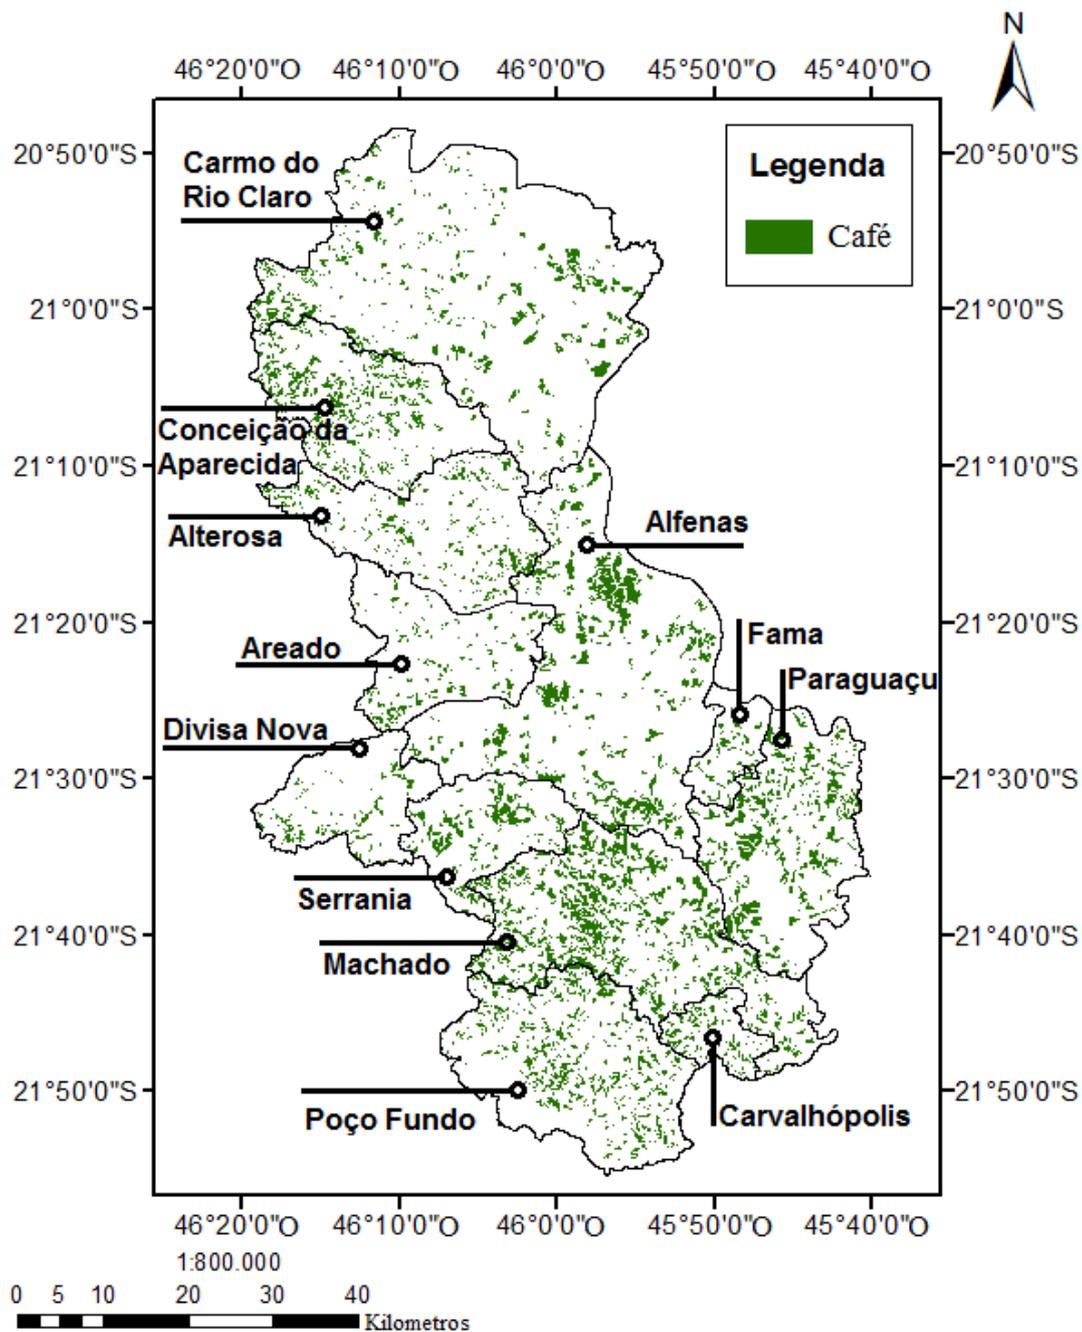


Figura 4.2 - Mapa temático resultante da interpretação visual de imagem *Oli/Lansat-8* para a Microrregião de Alfenas em 20/11/2013.

Foi observado que o cultivo do café ocupa aproximadamente 14% da microrregião, o que configura uma área aproximada de 61.800 hectares conforme mostra a Tabela 4.1. Dados de 2009 da CONAB indicam uma área

aproximada de 51.200 hectares de café na microrregião de Alfenas. Tal diferença pode ser justificada devido à defasagem entre os mapeamentos e como afirmado por SOUZA et al., (2012), há divergências entre dados de diferentes instituições.

Tabela 4.1 – Distribuição das áreas cafeeiras na microrregião de Alfenas, Minas Gerais, obtida por interpretação visual de imagens *OLI/Landsat-8*.

<b>Nome do Município</b>	<b>Área do município (ha)</b>	<b>Área de café (ha)</b>	<b>Área de café (ha) (CONAB, 2009)</b>
Alfenas	84.997,75	10.487,63	9.508,35
Alterosa	36.184,89	3.254,73	2.033,82
Areado	28.299,55	1.962,22	2.083,87
Carmo do Rio Claro	106.517,92	7.673,02	7.042,13
Carvalhópolis	8.105,06	1.218,34	248,17
Conceição da Aparecida	35.238,07	5.315,07	3.512,40
Divisa Nova	21.687,04	1.412,69	949,29
Fama	8.597,01	1.008,29	1.261,67
Machado	58.562,17	13.002,74	12.651,73
Paraguaçu	42.402,01	7.226,82	5.691,91
Poço Fundo	47.398,92	6.303,92	3.117,63
Serrania	20.916,86	2.930,73	3.097,13
<b>Total</b>	<b>498.907,25</b>	<b>61.796,20</b>	<b>51.198,10</b>

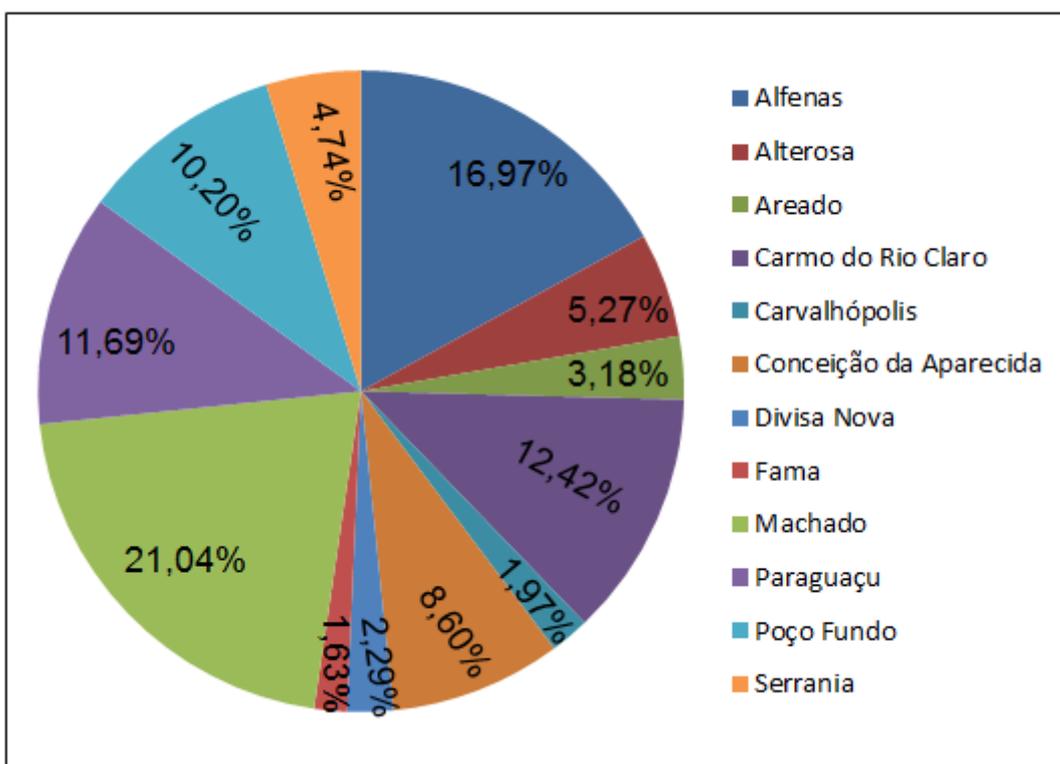


Figura 4.3 – Percentagem da área plantada de café dos municípios da microrregião de Alfenas, Minas Gerais em relação á área total de café da microrregião.

Nota-se que os municípios de Machado e Alfenas são os que apresentam maior área de produção, não sendo necessariamente os municípios de maiores áreas, correspondendo a 21,04% e 16,97% da produção de café da microrregião.

## 4.2. Resultados Segunda Etapa

### 4.2.1. Fatiamento da orientação de vertente

Observa-se nas Figura 4.4 e Figura 4.5 os resultados do cruzamento entre o mapa temático de áreas cafeeiras e o fatiamento em orientação de face de vertente.

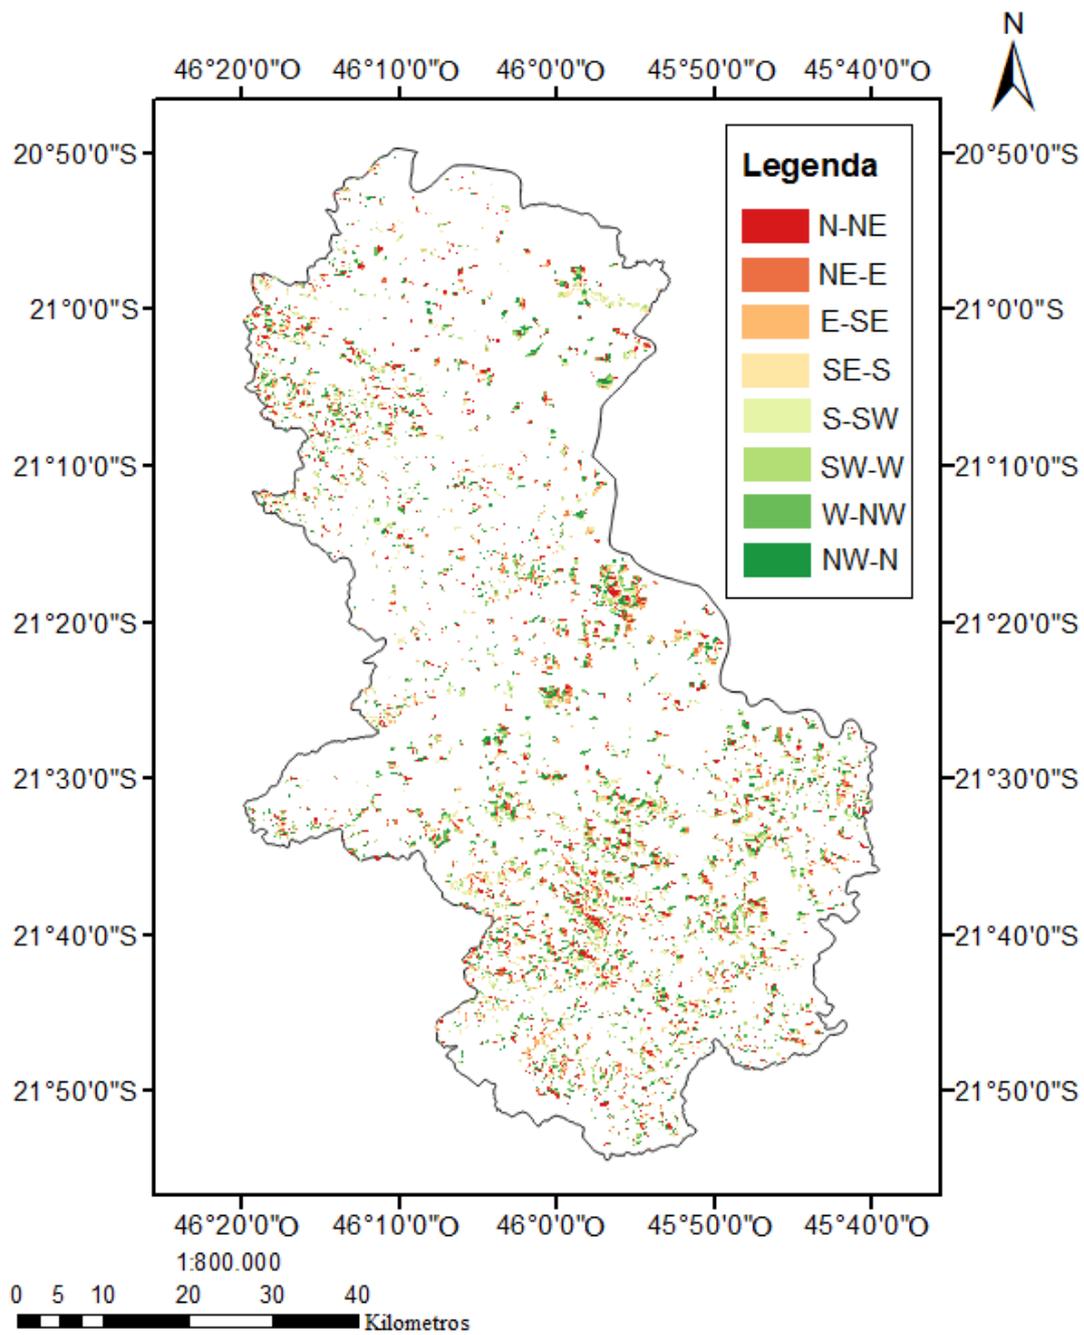


Figura 4.4 - Mapa temático resultante do fatiamento em classes de orientação de face de vertente das áreas cafeeiras da Microrregião de Alfenas.

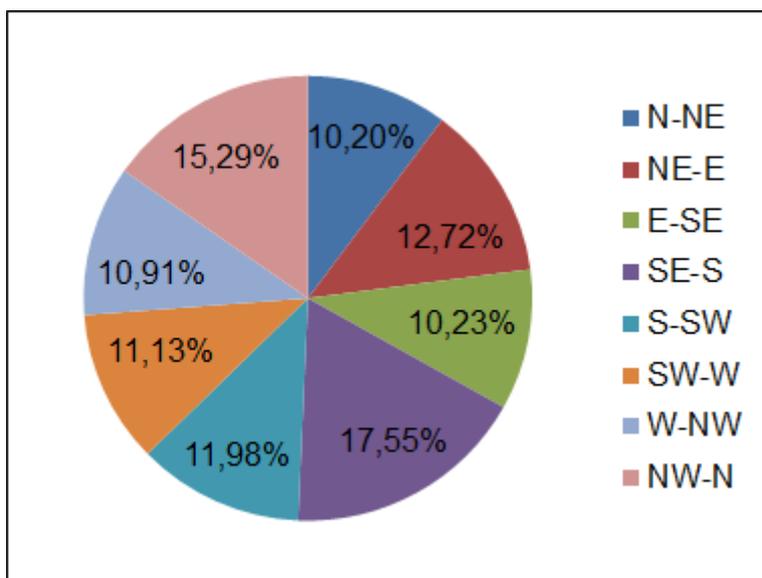


Figura 4.5 – Distribuição percentual da orientação de face de vertente das áreas plantadas de café dos municípios da microrregião de Alfenas, Minas Gerais.

Nota-se que na microrregião de Alfenas há maior ocorrência de plantio de café nas vertentes Sudeste-Sul (17,55%) e Noroeste-Norte (15,29%), entretanto nas demais vertentes as plantações de café também estão amplamente distribuídas, não indicando uma vertente preferencial ao plantio (ALVES et al., 2004; SOUZA et al., 2004; VIEIRA et al., 2004).

#### 4.2.2. Estratificação do relevo em classes de iluminação

A imagem fator de iluminação (FI), bem como suas estratificações em duas e cinco classes de iluminação podem ser observadas na Figura 4.6. Nota-se que o relevo da microrregião não é uniforme, sendo bastante acidentado em algumas áreas, como na porção norte da microrregião (Carmo do Rio Claro) e na região sul (Machado).

Imagem Fator de iluminação (FI)      FI estratificada em 5 classes      FI estratificada em 2 classes

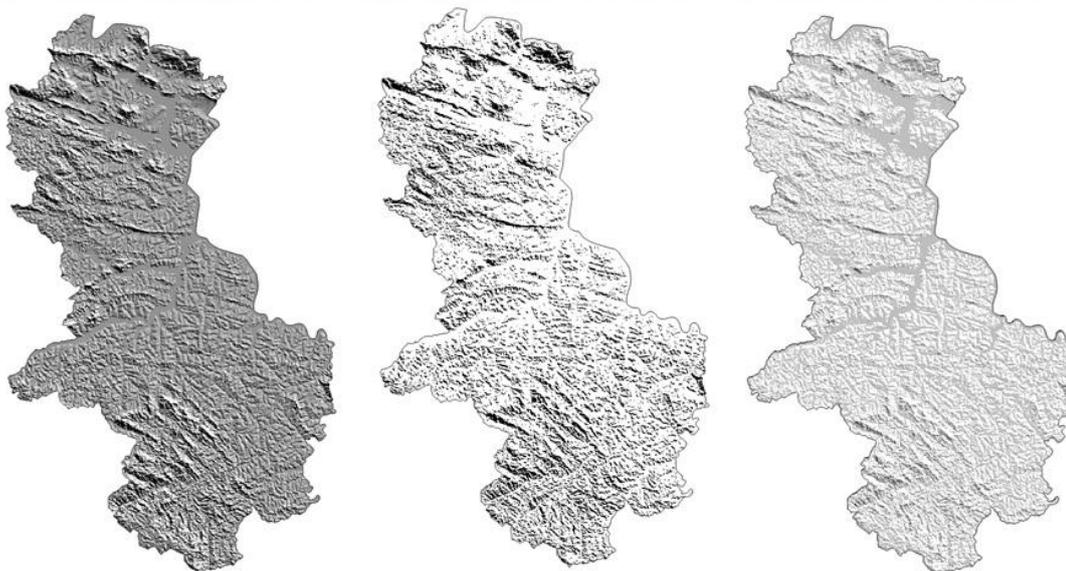


Figura 4.6 - Microrregião de Alfenas, Minas Gerais representada em: Imagem Fator de iluminação (FI), FI estratificada em 5 classes de iluminação e FI estratificada em 2 classes de iluminação.

Para uma melhor visualização, a Figura 4.7A ilustra uma parcela da imagem fator de iluminação calculada para a microrregião de Alfenas, e a Figura 4.7B a mesma imagem estratificada em classes de iluminação.

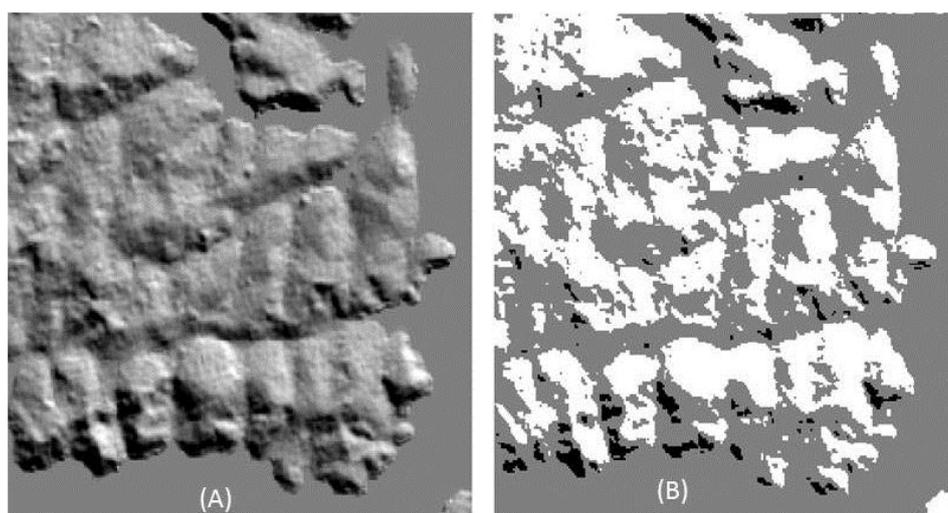


Figura 4.7 – Exemplo de imagem fator de iluminação (A) e imagem fator de iluminação estratificada em classes de iluminação (B).

Após a estratificação da área da microrregião em classes de iluminação, obtiveram-se os resultados apresentados na Tabela 4.2. Ao observar a Tabela 4.2, nota-se que no período de frutificação, a microrregião de Alfenas encontra-se bem iluminada, especificamente observa-se que quase em sua totalidade a microrregião encontra-se na classe muito iluminada (valores de FI maiores que 0,8). Nesse período ocorre a maior parte da atividade fotossintética da planta, justamente devido à maior iluminação diária (CAMARGO, 1985). No período da granação, embora haja uma redução das áreas na classe muito iluminado, não foi constatada grande transição para a classe sombreado. Já no período de repouso foi constatada a existência de áreas sob o efeito de sombreamento. No entanto, nesta fase, a atividade fotossintética é muito reduzida, pois está ocorrendo o processo de auto-poda (CAMARGO E CAMARGO, 2001) não sendo prejudicial à produção do café.

Tabela 4.2-Distribuição das classes de iluminação na microrregião de Alfenas em relação aos períodos de frutificação, granação e repouso no período entre 20/11/2013 e 21/07/2015.

Distribuição percentual do fator de iluminação na microrregião de Alfenas (MG)						
Data	Estádio Fenológico					
	Frutificação		Granação		Repouso	
	20/11/2013	07/11/2014	08/02/2014	10/01/2015	02/07/2014	21/07/2015
<b>Azimute</b>	90,68°	82,58°	83,93°	96,83°	36,18°	38,66°
<b>Elevação solar</b>	65,47°	64,86°	57,59°	60,32°	36,04°	37,59°
muito sombreado (0,0 - 0,2)	00%	00%	00%	00%	01%	00%
sombreado (0,2 - 0,4)	00%	00%	00%	00%	06%	05%
pouco iluminado (0,4 - 0,6)	00%	01%	01%	00%	49%	36%
iluminado (0,6 - 0,8)	05%	06%	26%	15%	43%	57%
muito iluminado (0,8 - 1)	95%	93%	73%	85%	01%	02%

Realizando um cruzamento entre as imagens estratificadas em classes de iluminação e os mapas temáticos de café (referência) pode-se observar o modo como os talhões cafeeiros estão distribuídos nas classes de iluminação determinadas, conforme pode ser observado na Tabela 4.3.

Tabela 4.3-Distribuição dos cafezais da microrregião de alfenas em classes de iluminação no período entre 20/11/2013 e 21/07/2015.

Distribuição percentual do fator de iluminação nas áreas cafeeiras da microrregião de Alfenas (MG)						
Data	Estádio Fenológico					
	Frutificação		Granação		Repouso	
	20/11/2013	07/11/2014	08/02/2014	10/01/2015	02/07/2014	21/07/2015
<b>Azimute</b>	90,68°	82,58°	83,93°	96,83°	36,18°	38,66°
<b>Elevação solar</b>	65,47°	64,86°	57,59°	60,32°	36,04°	37,59°
muito sombreado (0,0 - 0,2)	00%	00%	00%	00%	00%	00%
sombreado (0,2 - 0,4)	00%	00%	00%	00%	04%	03%
pouco iluminado (0,4 - 0,6)	00%	00%	00%	00%	26%	22%
iluminado (0,6 - 0,8)	04%	05%	23%	13%	63%	67%
muito iluminado (0,8 - 1)	96%	95%	77%	87%	07%	08%

Ao observar os resultados contidos na Tabela 4.3, nota-se que, nos estádios fenológicos de frutificação e granação, as fases mais importantes em termos de fotossíntese, as lavouras de café estão totalmente contidas nas classes iluminado e muito iluminado. Já no período de repouso nota-se que houve uma percentagem de lavouras de café (26% e 22%) situadas na classe pouco iluminada. Como dito anteriormente, neste período o café encontra na fase de auto-poda.

### 4.3. Resultados Terceira Etapa

#### 4.3.1. Classificação automática supervisionada

##### 4.3.1.1. Segmentação

Após diversos testes empíricos a segmentação multirresolução (BAATZ; SCHÄPE, 2000) mostrou-se adequada aos talhões cafeeiros em imagens *OLI/Landsat-8* quando os parâmetros foram ajustados em: escala 30, forma 0,6 e compacidade 0,5. Tais parâmetros resultaram em um total de 104232 segmentos para cobrir a microrregião inteira, de modo que uma parcela destes pode ser observada na Figura 4.8.

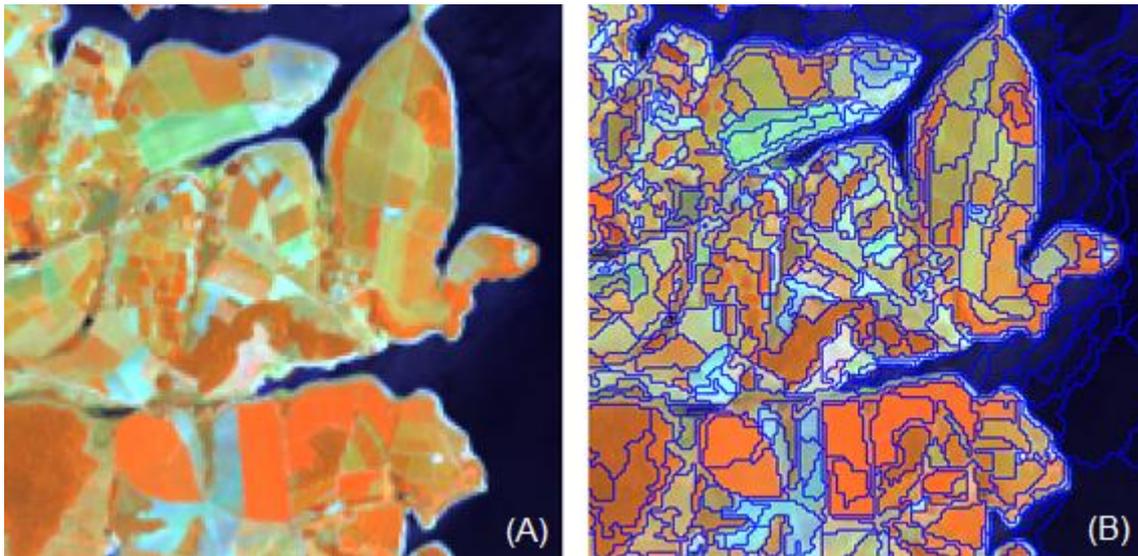


Figura 4.8 - Segmentação multirresolução de imagem *OLI/Landsat-8* em falsa cor (5,4,3), em com parâmetros escala 30, forma 0,6 e compacidade 0, 5.

Nota-se que os segmentos ficaram bem ajustados aos contornos dos elementos da imagem, conseguindo distinguir alvos de floresta, de solo exposto, talhões cafeeiros, corpos d'água e áreas urbanas. Os segmentos gerados não tinham área grande a ponto de englobar diferentes alvos em uma mesma região e não *hyper* segmentou a imagem de modo a impossibilitar a extração de atributos de forma e textura.

#### 4.3.2. Mineração de dados e classificação

Os modelos de classificação utilizando apenas atributos espectrais apresentaram árvores de tamanho médio com 1.700 regras, e os modelos utilizando textura o tamanho médio foi de 3.500 regras. Devido à dimensão do tamanho das árvores, as mesmas estão armazenadas no sítio <<https://mega.nz/#F!25Rw3bbR!jX7j21jTytyqSdg9EQX9cw>>. As árvores resultaram nestes tamanhos, pois não houve a intenção de minimizar o tamanho delas, o foco do trabalho manteve-se em obter a melhor taxa de exatidão possível na classificação, independente do desempenho ou tempo de classificação.

Os atributos com maior ganho de informação variavam de acordo com o modelo gerado. Dentre todos os atributos dos modelos, em geral destacaram-se como nós iniciais frequentes, os valores espectrais das bandas verde, vermelho, infravermelho próximo, swir1 e as texturas GLCM desvio padrão, GLCM média, GLCM dissimilaridade e GLCM homogeneidade, que indicam grande ganho de informação nas verificações iniciais do classificador C4.5. Condizente com as sugestões de Andrade et al. (2013) e Girolamo Neto et al. (2015), os atributos de texturas mostraram-se importantes na detecção da classe café.

#### **4.4. Resultados Quarta Etapa**

##### **4.4.1. Validação dos mapas temáticos de café**

Os resultados da validação indicam altos valores de índice global, valores acima de 90% conforme Tabela 4.4. Tal valor supera os obtidos por Andrade et al. (2013) com redes neurais artificiais (RNA) (73%) e por Girolamo et al. (2015) com SVM (84%) e assemelha-se aos obtidos por Sarmiento et al. (2014), que obtiveram 91%, 90% e 94% com as técnicas K Nearest Neighbor (KNN) Support vector machine (SVM) Maximum likelihood (Maxver), respectivamente. Entretanto, uma vez que, aproximadamente 14% da área da microrregião eram talhões cafeeiros e 86% não, os altos valores do índice global observados nas matrizes de confusão estão mascarados devido a maior proporção desta classe na cena. Assim, o acerto da classe café deve ser analisado por meio da exatidão da classe café.

Os valores de exatidão da classe café obtidos sem utilização dos atributos texturais apresentaram uma média de 53% ao passo que com textura (e também considerando as classes de iluminação) de 67,33% de exatidão para a classe café conforme disposto na Tabela 4.4. As exatidões sem uso de textura apresentaram valores semelhantes aos obtidos por Andrade et al. (2013) (53%), porém quando acrescentou-se os atributos texturais, houve melhora nos índices obtidos. Já Sarmiento et al. (2014) obtiveram exatidão de 94,9% para a

classe café, também no sul de Minas Gerais, entretanto utilizando classificação pixel a pixel (maxver), com duas classes de uso (café e não café) em imagem *quickbird*, resultado bastante superior aos obtidos neste estudo. Tal diferença se deu provavelmente devido à diferença na resolução espacial dos sensores utilizados que foi colossal, uma vez que os autores utilizaram imagens com 2,44 metros expandida a 0,6 metros por meio da banda pancromática e neste estudo utilizou-se as imagens *OLI/Landsat-8* com 30 metros de resolução espacial.

Tabela 4.4 - Índice global e exatidão das classificações baseadas em objetos em imagens *OLI/Landsat-8* para a microrregião de Alfenas, Minas Gerais, estratificada em cinco classes de iluminação.

Imagens	Validação dos mapas temáticos de café da microrregião de Alfenas							
	Classificação com atributos espectral		Classificação com atributos espectrais e texturais		Classificação com atributos espectrais, texturais e 2 classes de iluminação		Classificação com atributos espectrais, texturais e 5 classes de iluminação	
	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)
Imagem 1 (20/11/2013)	88	48	93	67	93	67	93	68
Imagem 2 (08/02/2014)	89	61	93	68	94	68	94	69
Imagem 3 (02/07/2014)	90	50	95	73	95	72	94	68
Imagem 4 (07/11/2014)	89	57	94	67	94	68	94	68
Imagem 5 (10/01/2015)	89	50	93	62	93	62	93	63
Imagem 6 (21/07/2015)	89	52	94	67	94	67	94	66
<b>Média</b>	<b>89</b>	<b>53</b>	<b>93,667</b>	<b>67,3333</b>	<b>93,833</b>	<b>67,3333</b>	<b>93,667</b>	<b>67</b>

Por meio do método de Monte Carlo e concordante com Girolamo Neto et al. (2015); técnicas de mineração de dados por árvore de decisão mostraram-se aptas para identificar e classificar áreas cafeeiras, com 67,33% de exatidão para a classe café em imagens *OLI/Landsat-8*. Observa-se que a inclusão do

atributo textura melhorou o desempenho dos classificadores, comparado aos resultados obtidos quando considerou-se apenas atributos espectrais. De modo geral houve uma melhora de 14,33% na exatidão da classe café. Seguindo a mesma análise, o índice global e a exatidão do café, obtidos com a estratificação da área em duas (sombreado e iluminado) ou cinco classes (muito iluminado, iluminado, pouco iluminado, sombreado e muito sombreado) de iluminação, foi bastante próximo. Isto indica que em termos práticos, ao se fazer uso dos atributos texturais e espectrais conjuntamente, pode-se utilizar apenas duas classes de iluminação, ao invés de múltiplas classes, conforme recomendação de MEYER et al. (1993) e Lamparelli et al. (2011).

Destaca-se que os resultados obtidos na Tabela 4.4 foram sem nenhuma intervenção por interpretação visual, todos os valores demonstrados são oriundos da classificação automática sem nenhuma correção. Nota-se que nos três estádios fenológicos, (granação, frutificação e repouso) a média de exatidão para a classe café foi de aproximadamente 62%. Deste modo, percebe-se que não houve um estágio fenológico em que a classificação apresentasse um melhor resultado. Com base nesta análise, pode-se dizer que, embora não havendo melhora significativa nos resultados da classificação recomenda-se utilizar imagens do período seco (Maio e Abril), pois assim a chance de obter imagens livres de cobertura de nuvem é grande. Além disso, corrobora com Moreira et. al (2004) ao comentar que nesta época do ano, nesta região não existe outra cultura que possa confundir com o comportamento espectral semelhante ao café.

#### **4.4.2. Análise dos resultados da classificação para os municípios de Alfenas e Machado**

A avaliação dos resultados das classificações feitas de modo isolado em escala municipal dos 2 municípios com maior área de café da microrregião de Alfenas, respectivamente os municípios de Machado e Alfenas são mostrados nas Tabelas 4.5 e 4.6, respectivamente.

Tabela 4.5 - Índice global e exatidão da classe café das classificações baseadas em objetos em imagens OLI/Landsat-8 para o município de Alfenas, estratificada em duas classes de iluminação.

Imagens	Validação dos mapas temáticos de café do município de Alfenas (MG)							
	Classificação com atributos espectral		Classificação com atributos espectrais e texturais		Classificação com atributos espectrais, texturais e 2 classes de iluminação		Classificação com atributos espectrais, texturais e 5 classes de iluminação	
	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)
Imagem 1 (20/11/2013)	91	63	96	82	96	83	96	84
Imagem 2 (08/02/2014)	92	70	96	81	96	81	96	82
Imagem 3 (02/07/2014)	92	48	97	84	97	84	97	85
Imagem 4 (07/11/2014)	93	58	97	83	97	83	96	82
Imagem 5 (10/01/2015)	94	75	96	80	96	80	96	82
Imagem 6 (21/07/2015)	92	50	96	81	96	84	96	82
<b>Média</b>	<b>92,333</b>	<b>60,6667</b>	<b>96,333</b>	<b>81,8333</b>	<b>96,333</b>	<b>82,5</b>	<b>96,167</b>	<b>82,8333</b>

Tabela 4.6 - Índice global e exatidão da classe das classificações baseadas em objetos em imagens *OLI/Landsat-8* para o município de Machado, estratificada em cinco classes de iluminação.

Imagens	Validação dos mapas temáticos de café do município de Machado (MG)							
	Classificação com atributos espectral		Classificação com atributos espectrais e texturais		Classificação com atributos espectrais, texturais e 2 classes de iluminação		Classificação com atributos espectrais, texturais e 5 classes de iluminação	
	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)	Índice global (%)	Exatidão café (%)
Imagem 1 (20/11/2013)	83	65	90	72	90	70	91	72
Imagem 2 (08/02/2014)	86	59	91	74	90	73	91	76
Imagem 3 (02/07/2014)	84	50	92	76	91	75	92	76
Imagem 4 (07/11/2014)	86	58	91	74	90	71	90	75
Imagem 5 (10/01/2015)	82	64	90	74	90	74	89	71
Imagem 6 (21/07/2015)	80	45	90	73	90	72	90	70
<b>Média</b>	<b>83,5</b>	<b>56,8333</b>	<b>90,667</b>	<b>73,8333</b>	<b>90,167</b>	<b>72,5</b>	<b>90,5</b>	<b>73,3333</b>

Percebe-se que as exatidões para classe café obtidas para o município de Alfenas, 60,67% com exclusivamente atributos espectrais e 82,83% foram relativamente maiores do que as obtidas com a mesma metodologia aplicada em Machado, 56,83% com exclusivamente atributos espectrais e 73,83%. Isso se deve principalmente ao relevo, Alfenas é uma região mais plana do que Machado, o que diminui a influência do sombreamento e torna os talhões cafeeiros mais uniformes.

Nota-se que para ambos os municípios, quando utilizados apenas atributos espectrais, o estágio fenológico de repouso (imagens 3 e 6) é onde ocorrem as menores taxas de acerto, 48% e 50% em Alfenas e 50% e 45% em Machado. Ao acrescentar os atributos de textura essa oscilação não mais ocorreu.

Comparando as exatidões para a classe café obtidas em escala municipal com as exatidões obtidas para a microrregião, nota-se que em escala municipal, houve maior acerto (6% melhor no município de Machado e 15% melhor no município de Alfenas). Isso ocorre, pois a microrregião é uma área grande e a heterogeneidade dos talhões e dos manejos se agrava conforme o tamanho da área observada (MOREIRA et al., 2004).

A classificação baseada em objetos, associada a técnicas de mineração de dados no município de Machado (MG) apresentou índice global e exatidão da classe café maior que as encontradas por Andrade et al. (2013) que também tiveram como área de estudo Machado (MG). (53%), sendo a média sem textura obtida neste estudo para o município de Machado 56,83%, sendo esta incrementada ao acrescentar os atributos de textura e as estratificações do terreno em classes de iluminação (73,33%).

## **5 CONSIDERAÇÕES FINAIS**

### **5.1. Conclusões**

A partir da metodologia proposta, fundamentada em dados coletados pelo *OLI/Landsat-8* e Classificação baseada em objetos e mineração de dados, para verificar a influência dos atributos espectrais, texturais e fator de iluminação pôde-se concluir:

- O espectro de reflectância resultante das correções atmosféricas pelo método Flaash quanto pelo produto CDR mostraram-se semelhantes.
- Por meio de análise da matriz de confusão gerada pelo método Monte Carlo, os resultados de exatidão da classe café e índices global da classificação com estratificação do relevo em duas ou cinco classes de iluminação, mostraram-se semelhantes.
- Atributos de textura auxiliaram na identificação de áreas cafeeiras em imagens *OLI/Landsat-8*, incrementando as taxas de exatidão de mapeamento.
- As lavouras de café da microrregião de Alfenas, em sua maioria, estão localizadas em áreas iluminadas durante todo o ano.
- Em imagens *OLI/Landsat-8*, por meio de classificação automática baseada em objetos, não houve diferença nos valores de índice global e exatidão da classe café que indicasse que um estágio fenológico (data) proporcionasse melhores resultados.

### **5.2. Recomendações**

A metodologia desenvolvida neste trabalho pode ser empregada para classificação automática de outras culturas além do café. Entretanto os resultados de exatidão obtidos mostram que ainda é necessário desenvolver metodologias com maior poder de detecção das áreas cafeeiras, uma vez que

os índices de exatidão obtidos ainda exigem que um intérprete humano faça correções no mapeamento, para que este possa ser utilizado como referência.

Para correção atmosférica de séries de imagens *OLI/Landsat-8* recomenda-se a utilização do modelo FLAASH, uma vez que o mesmo mostrou-se suficiente na caracterização da resposta espectral dos alvos. Para segmentação de imagens *OLI/Landsat-8* o algoritmo multirresolução mostrou-se satisfatório no delineamento de áreas cafeeiras, estabelecendo contornos nas regiões limites dos alvos e não incluindo múltiplos elementos em um mesmo segmento.

### **5.3. Sugestão de trabalhos futuros**

Com o propósito de melhorar ainda a exatidão da classe café obtida em classificações automáticas e conseqüentemente de modelos de produção de café, recomendam-se como trabalhos futuros:

- Avaliar o uso de segmentação multitemporal em séries *OLI/Landsat-8* para obtenção de uma segmentação mais precisa;
- Avaliar a influência da direção de plantios cafeeiros na resposta espectral da cultura, bem como nos atributos texturais;
- Relacionar orientação de vertente com atributos texturais;
- Testar a estratificação de classes de iluminação pelo histograma ao invés de intervalos equidistantes;
- Testar outros métodos de mineração de dados para encontrar padrões dos talhões cafeeiros.

## REFERÊNCIAS BIBLIOGRÁFICAS

ADAMI, M.; DEPPE, F.; RIZZI, R.; MOREIRA, M. A.; RUDORFF, B. F. T.; FONSECA, L. M. G.; FARIA, R. T. Fusão de imagens por IHS para melhorar a identificação de uso do solo em elementos amostrais. **Engenharia Agrícola**, v. 27, n. 2, p. 529–536, 2007. ISSN 0100-6916.

ADAMI, M.; MOREIRA, M. A.; BARROS, M. A.; Avaliação da exatidão do mapeamento da cultura do café no estado de Minas Gerais. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR)., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 1–8. CD-ROM; On-line. ISBN 978-85-17-00031-7. Disponível em: <<http://www.dsr.inpe.br/laf/cafesat/artigos/AvaliacaoExatidaoMapeamentoCafe.pdf>>. Acesso em: 18 fev. 2016.

ADAMI, M.; MOREIRA, M. A.; BARROS, M. A. Confiabilidade do mapeamento. cap. Apêndice A, p. 356–371. In: MOREIRA, M. A. (ed.). **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa: UFV, 2011. 422p. ISBN 978-85-7269-381-3. Disponível em: <[editora@ufv.br](mailto:editora@ufv.br)>. Acesso em: 07 abr. 2016.

ADDINK, E. A.; COILLIE, F. M. V.; JONG, S. M. D. Introduction to the {GEOBIA} 2010 special issue: from pixels to geographic objects in remote sensing image analysis. **International Journal of Applied Earth Observation and Geoinformation**, v. 15, p. 1 – 6, 2012. ISSN 0303-2434. Special Issue on Geographic Object-based Image Analysis: {GEOBIA}.

AIAZZI, B.; ALPARONE, L.; BARONTI, S.; SELVA, M.; PHYSICS, A.; CARRARA, N.; MADONNA, V.; FIORENTINO, S. MS + Pan Image Fusion by an Enhanced Gram-Schmidt Spectral Sharpening. In: EARSeL SYMP. NEW STRATEGIES FOR EUR. REMOTE SENS, 26., 2007, Rotterdam. **Proceedings...** Rotterdam: Millpress, 2007. p. 113–120. ISBN 9789059660533.

ALVES, H. M. R.; VIEIRA, T. G. C.; SOUZA, V. C. O.; BERTOLDO, M. A.; ANDRADE, H.; SANTOS, N. B. Análise da dinâmica de regiões cafeeiras em Minas Gerais em relação ao ambiente. In: Simpósio de Pesquisa dos Cafés do Brasil, 4. 2005, Londrina. **Anais...** Londrina; On-line. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/909437/analise-da-dinamica-de-regioes-cafeeiras-em-minas-gerais-em-relacao-ao-ambiente>>. Acesso em: 18 fev. 2016.

AL-WASSAI, F. A.; KALYANKAR, N. V.; AL-ZUKY, A. A. The IHS Transformations based image fusion. **Computer Vision and Pattern Recognition**, v. 2, n. 5, p. 1-10, 2011. Disponível em: <<http://arxiv.org/ftp/arxiv/papers/1107/1107.4396.pdf>> Acesso em: 18 fev. 2016.

ANDRADE, L. N.; VIEIRA, T. G. C.; LACERDA, W. S.; VOLPATO, M. M. L.; ALVES, H. M. R.; SILVA, A. C. O.; SOUZA, C. G. Redes Neurais Artificiais (RNA) aplicadas à classificação de áreas cafeeiras na região de Três Pontas-MG. In: SIMPÓSIO DE PESQUISAS DOS CAFÉS DO BRASIL, 7., 2011, Araxá-MG. **Anais...** [S.l.]: Consórcio Pesquisa Café, 2011.

ANDRADE, L. N. D.; VIEIRA, T. G. C.; LACERDA, W. S. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em Machado-MG. **Coffe Science**, v. 8, p. 78–90, 2013.

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 146p. 2003. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, 2003.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: **Angewandte geographische Informationsverarbeitung**. 2000. p. 6.

BÉNIÉ, G.; THOMSON, K.; GOLDBERG, M. A comparison of four segmentation algorithms in the context of agricultural remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 44, p. 1–13, 1989.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for gis-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, n. 34, p. 239 – 258, 2004. ISSN 0924-2716.

BERNARDES, T. **Modelagem de dados espectrais e agrometeorológicos para estimativa da produtividade de café**. 2013. 153 p. (sid.inpe.br/mtc-m19/2013/03.04.20.07-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3DLLLLQ8>>. Acesso em: 18 fev. 2016.

BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; QUEIROZ F. R.; MEER, VAN DER, F.; WERFF, H.; COILLIE, F.; TIEDE, D. Geographic Object-Based Image Analysis - Towards a new paradigm. **ISPRS**

**Journal of Photogrammetry and Remote Sensing**, v. 87, n. January, p. 180–191, 2014. ISSN 09242716.

BLASCHKE, T.; KUX, H. **Sensoriamento remoto e SIG avançados**: novos sistemas sensores, métodos inovadores. São Paulo: Oficina de Textos, 2007. ISBN 9788579750564.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object-Oriented Image Processing in an Integrated GIS / Remote Sensing Environment and Perspectives for Environmental Applications. **Umweltinformation für Planung, Politik und Öffentlichkeit** / Environmental Information for Planning, Politics and the Public, n. 1995, p. 555–570, 2000.

CALLIECO, F.; DELL'ACQUA, F. A comparison between two radiative transfer models for atmospheric correction over a wide range of wavelengths. **International Journal of Remote Sensing**, v. 32, n. 5, p. 1357–1370, 2011.

CAMARGO, A. Florescimento e frutificação de café arábica nas diferentes regiões (cafeeiras) do Brasil. **Pesquisa Agropecuária Brasileira**, v. 20, n. 7, p. 831–839, 1985.

CAMARGO, Â. P.; CAMARGO, M. B. P. Definição e Esquematização das Fases Fenológicas do Cafeeiro Arábica nas Condições Tropicais do Brasil. **Bragantia**, v. 60, n. 1, p. 65–68, 2001. ISSN 00068705. 5, 6, 7, 37

CANAVESI, V. **Aplicação de dados hyperion eo-1 no estudo de plantações de eucalyptus spp.** 2008. 124p. (INPE-15316-TDI/1360). Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m18@80/2008/07.01.14.06>>. Acesso em: 18 fev. 2016.

CARVALHO, L. M.; CLEVERS, J. G.; SKIDMORE, A. K.; JONG, S. M. Selection of imagery data and classifiers for mapping brazilian semideciduous atlantic forests. **International Journal of Applied Earth Observation and Geoinformation**, v. 5, n. 3, p. 173 – 186, 2004. ISSN 0303-2434.

CASTRO FILHO, C. A. P.; CASTRO, F. S. P. Automação de procedimentos fotointerpretativos através da classificação orientada a segmentos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 5651–5657. ISBN 978-85-17-00031-7. Disponível

em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2006/11.13.15.36>>. Acesso em: 07 abr. 2016.

CHAVEZ, P. S.; SIDES Jr., S. C.; ANDERSON, J. A. Comparison of Three Different Methods to Merge Multiresolution and Multispectral Data: Landsat TM and SPOT Panchromatic. **Photogrammetric Engineering & Remote Sensing**, v. 57, n. 3, p. 295–303, 1991.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Levantamento café safra 2015**. Brasília: CONAB, 2015. 43 p. ISSN 2318-7913. Disponível em:

<[http://www.conab.gov.br/OlalaCMS/uploads/arquivos/15\\_01\\_14\\_11\\_57\\_33\\_boletim\\_cafe\\_janeiro\\_2015.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/15_01_14_11_57_33_boletim_cafe_janeiro_2015.pdf)>. Acesso em 16 dez. 2015.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991. ISSN 00344257.

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**, Taylor & Francis, Inc., Bristol, PA, USA, v. 28, n. 7, p. 1577–1593, jan. 2007. ISSN 0143-1161.

COUTO JUNIOR, A. F.; MENESES, P. R.; SANO, E. E. Desempenho da correção atmosférica baseada no algoritmo flaash e sua avaliação para o processamento digital de imagens do sensor Landsat 7-ETM+ dentro do bioma cerrado. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 7317–7323.

CROOME, R. **The potential for satellite remote sensing to monitor coffee, tea, cocoa and coconut plantings in Papua New Guinea**: experimentation with Landsat MSS and TM data in the Madang and Goroka. 1. ed. Canberra: Australian National University, 1989. p. 19. ISBN 0646011294.

DAHER, L. **A cafeicultura no sul de minas gerais, estudo de caso: a fazenda conquista**. 34 p. Monografia (graduação em Geografia Licenciatura) — Universidade Federal de Alfenas, 2011.

DANTAS, M.F. **Impactos da modernização da agricultura na estrutura agrária sul mineira na microrregião de Alfenas** – MG. Trabalho de Conclusão de Curso – Universidade Federal de Alfenas, Alfenas, 2011.

DEFINIENS. **Definiens developer 7 reference book**. 2007. 195 p. Disponível em: < [www.ecognition.cc/download/ReferenceBook.pdf](http://www.ecognition.cc/download/ReferenceBook.pdf)>. Acesso: 16 dez. 2015.

DELGADO, R. C. et al. Evolução espaço-temporal do café no estado de Minas Gerais por meio do classificador de árvore de decisão. **Enciclopédia biosfera**, v.8, n.15, p. 904-913, 2012.

DLUGOSZ, F. L.; ROSOT, N. C.; ROSOT, M. A. D.; OLIVEIRA, Y. M. M. de. Índice para a avaliação de segmentação de imagens. **Floresta**, v. 39, n. 1, p. 131–143, 2008.

EMBRAPA CAFÉ. **Características das principais variedades de café cultivadas em Rondônia**. 2004. 26 p. Disponível em: < <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/54346/1/Doc93-cafe.pdf>>. Acesso: 17 Fevereiro 2016.

ENVI. **ENVI atmospheric correction module: QUAC and FLAASH user's guide**. 2009. 44 p. Disponível em: < [https://www.exelisvis.com/portals/0/pdfs/envi/Flaash\\_Module.pdf](https://www.exelisvis.com/portals/0/pdfs/envi/Flaash_Module.pdf)>. Acesso: 16 dez. 2015.

ENVI. **ENVI User's guide**. 2004. 1–1150 p. Disponível em: < [http://aviris.gl.fcen.uba.ar/Curso\\_SR/biblio\\_sr/ENVI\\_userguid.pdf](http://aviris.gl.fcen.uba.ar/Curso_SR/biblio_sr/ENVI_userguid.pdf)>. Acesso: 16 dez. 2015.

ESPINDOLA, G. M. D. **Ajustes de parâmetros em algoritmos de segmentação de imagens por crescimento de regiões**. 2007. 64 p. (INPE-14659-TDI/1215). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006. Disponível em:<<http://urlib.net/6qtX3pFwXQZGivnJSY/NwtLS>>. Acesso em: 18 fev. 2016.

ESPINDOLA, G. M. D.; CÂMARA, G. Ajuste de parâmetros no algoritmo de segmentação de imagens do software ecognition In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13. (SBSR)., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 5739-5744. CD-ROM; On-line. ISBN 978-85-17-00031-7. (INPE-16353-PRE/10931). Disponível em:<<http://urlib.net/dpi.inpe.br/sbsr@80/2006/11.15.22.12>>. Acesso em: 18 fev. 2016.

FARR, T. G.; ROSEN, P. a.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S.; KOBRICK, M.; PALLER, M.; RODRIGUEZ, E.; ROTH, L.; SEAL, D.;

SHAFFER, S.; SHIMADA, J.; UMLAND, J.; WERNER, M.; OSKIN, M.; BURBANK, D.; ALSDORF, D. E. The shuttle radar topography mission. **Reviews of Geophysics**, v. 45, n. 2, p. 1–43, 2007. ISSN 87551209.

5.3.1. FEITOSA, R. Q.; COSTA, G. A. O. P.; CAZES, T. B.; FEIJO, B. A. Genetic approach for the automatic adaptation of segmentation parameters. In: INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS (OBIA06), 1., 2006, Salzburg, Austria. **Proceedings...** Salzburg: ISPRS, 2006.

FRANÇA, D. G. M.; SIANI, S. M. O.; MORAES, E. C. Avaliação da correção atmosférica por FLAASH sobre cenas OLI Landsat-8. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 17., 2015, João Pessoa-PB, Brasil. **Anais...** São José dos Campos: INPE, 2015. v. 6526, n. 1, p. 6381–6388.

GIROLAMO NETO, C. D.; FONSECA, L. M. G.; KORTING, T. S.; SANCHES, I. D.; EBERHARDT, I. D. R.; BENDINI, H. d. N.; MARUJO, R. F. B.; TRANBAQUINI, K. Classificação automática de áreas cafeeiras utilizando imagens de sensoriamento remoto e técnicas de mineração de dados. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 1609-1616. Internet. ISBN 978-85-17-0076-8. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM495M>>. Acesso em: 18 fev. 2016.

GOLTZ, E.; PINHO, C. M. D.; RUDORFF, B. F. T.; FONSECA, L. M. G. Classificação orientada a objeto na identificação de áreas de reforma de cana-de-açúcar. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 199-206. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15887-PRE/10497). Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.15.40>>. Acesso em: 18 fev. 2016.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3. ed. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 013168728X.

GOUVEIA, N. M. **Estudo da diferenciação de crescimento de gemas florais de coffea arabica L.**: observações sobre antese e maturação dos frutos. 237 p. 1984. Dissertação (Mestrado em Biologia Vegetal) — Unicamp, Campinas, 1984.

GUHL, A. Café y cambio de paisaje en la zona cafetera colombiana entre 1970 y 1997. **Cenicafe**, v. 55, n. 1, p. 29–44, 2004.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software. **ACM SIGKDD Explorations Newsletter**, v. 11, n. 1, p. 10, 2009. ISSN 19310145.

HAPP, P. N.; FEITOSA, R. Q.; BENTES, C.; FARIAS, R. UM ALGORITMO DE SEGMENTAÇÃO POR CRESCIMENTO DE REGIÕES PARA GPUS. In: **Boletim de Ciências Geodésicas**. Curitiba: 2013. p. 208–226.

HARALICK, R.; SHANMUGAN, K.; DINSTEN, I. Textural features for image classification. **systems, man, and cybernetics, IEEE Transactions on**. N. 6. 1973. 610–621 p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Divisão Regional do Brasil em mesorregiões e microrregiões geográficas**. Rio de Janeiro: IBGE, 1990. 135 p. Cidades. Rio de Janeiro: IBGE, 2014. Disponível em:

<<http://www.cidades.ibge.gov.br/xtras/uf.php?lang=&coduf=31&search=minas-gerais>>. Acesso: 16 dez. 2015.

IPPOLITI-RAMILO, G. A. **Imagens TM/Landsat-5 da época de pré-plantio para a previsão da área de culturas de verão**. 1998. 185 p. (INPE-7116-TDI/668). Dissertação (mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São Jose dos Campos, 1998. Disponível em: <<http://urlib.net/6qtX3pFwXQZ3r59YD6/GNU2g>>. Acesso em: 18 fev. 2016.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. **Preventive veterinary medicine**. V.11. 1991. 185–200 p. 29.

JENSEN, J. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Parêntese Editora, 2009. ISBN 9788560507061.

KORTING, T. S.; FONSECA, L. M. G.; ESCADA, M. I. S.; CAMARA, G. GeoDMA – Um sistema para mineração de dados de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7813-7820. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15905-PRE/10515). Disponível em:<<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.21.17>>. Acesso em: 18 fev. 2016.

KOUTSIAS, N.; KARTERIS, M.; CHUVIECO, E. The Use of Intensity-Hue-Saturation Transformation of Landsat-5 Thematic Mapper Data for Burned Land Mapping. **Photogrammetric Engineering Remote Sensing**, v. 66, n. 7, p. 829–839, 2000. ISSN 00991112.

LAMPARELLI, R. A. C.; NERY, L.; ROCHA, J. V. Utilização de técnicas por componentes principais (ACP) e fator de iluminação, no mapeamento da cultura do café em relevo montanhoso. **Engenharia Agrícola**, v. 31, n. 3, p. 584–597, 2011.

LANDAU, D. P.; BINDER, K. **A guide to Monte-Carlo simulations in statistical physics**. 3. ed. Cambridge University Press, 2009. 500 p. ISBN 9780521768481.

LUCAS, E. A.; BRANCO, V. T. A.; RICHA, C. H. ; MOREIRA, D. M.; SCHAFER, A. G. Mapeamento do uso e ocupação do solo na bacia hidrográfica do rio Negro-RS utilizando imagens de satélite do sensor OLI/LANDSAT 8. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 26., 2014, Gramado-RS. **Anais...** Rio de Janeiro: Sociedade brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2014.

LUZ, N. B.; ANTUNES, A. F. B.; TAVARES JÚNIOR, J. B. Segmentação multirresolução e classificação orientada a objetos aplicados a imagens Spot-5 para o mapeamento do uso da terra. **Floresta**, v. 40, n. 2, p. 429–446, 2010. ISSN 1982-4688.

MACHADO, M. L.; ALVES, H. M. R.; VIEIRA, T. G. C.; FILHO, E. I. F.; LACERDA, M. P. C. Mapping of coffee lands (*Coffea arabica* L.) in the zona da mata region, Minas Gerais state, using remote sensing. **Coffee Science**, v. 5, n. 2, p. 113–122, 2010.

MARUJO, R. d. F. B. **Avaliação de métodos de segmentação de imagens aplicadas na classificação de culturas cafeeiras**. 50 p. Monografia (graduação em Ciência da Computação) — UFLA, 2013.

MAŠKOVÁ, Z.; ZEMEK, F.; KVET, J. Normalized difference vegetation index (NDVI) in the management of mountain meadows. **Boreal Environment Research**, v. 13, n. 5, p. 417–432, 2008. ISSN 12396095.

MEINEL, G.; NEUBERT, M.; SENSING, R.; CITY, L. A comparison of segmentation programs for high resolution remote sensing data. **International**

**Archives of Photogrammetry and Remote Sensing**, v. 35, n. 2, p.1097–1105, 2004.

MENESES, P.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. 1. ed. 2012. p. 266. Disponível em: <<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso: 16 dez. 2015.

MEYER, P.; ITTEN, K. I.; KELLENBERGER, T.; SANDMEIER, S.; SANDMEIER, R. Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 48, n. 4, p. 17–28, 1993. ISSN 09242716.

MOREIRA, E. P.; VALERIANO, M. M. Application and evaluation of topographic correction methods to improve land cover mapping using object-based classification. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier B.V., v. 32, n. 1, p. 208–217, 2014. ISSN 15698432.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Atual e ampliada – Viçosa, MG: UFV, 2011. 422p.

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

MOREIRA, M. A.; BARROS, M. A.; ROSA, V. G. C.; ADAMI, M. Tecnologia de informação: imagens de satélite para o mapeamento de áreas de café de Minas Gerais. **Informe Agropecuário**, v. 28, n. 241, p. 27-37, 2007.

MOREIRA, M. A.; BARROS, M. A.; RUDORFF, B. F. T. Geotecnologias no mapeamento da cultura do café em escala municipal. **Sociedade e natureza** (Online), v. 20, n. 1, p. 101–110, 2008. Disponível em: <<http://www.scielo.br/pdf/sn/v20n1/a07v20n1.pdf>>. Acesso: 16 dez. 2015.

MOURA, L. d. C. **A ocupação espaço-temporal dos cafezais no município de Machado, no sul de Minas**: a relação entre aptidão agrícola da terra e seu uso na atividade cafeeira. 2007.117 p. Tese (Doutorado em Agronomia) — Universidade Federal de Lavras, UFLA, Lavras, 2007.

MOURA, L. d. C.; ANDRADE, H.; ALVES, H. M. R.; BERNARDES, T. Levantamento e mapeamento espaço: temporal dos cafezais no município

mineiro de Machado. **Caminhos de Geografia**, v. 33, p. 3–8, 2009. ISSN 1098-6596.

NUNEZ, J.; OTAZU, X.; FORS, O.; PRADES, A.; PALA, V.; ARBIOL, R. Multiresolution-based image fusion with additive wavelet decomposition. **Geoscience and Remote Sensing, IEEE Transactions on**, v. 37, n. 3, p. 1204–1211, May 1999. ISSN 0196-2892.

OLIVEIRA, B. S.; MATALEVI, G. A. V. Avaliação do desempenho dos classificadores Ioseg e Bhattacharya para o mapeamento de áreas de cana-de-açúcar no município de Barretos-SP. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR), 2013, Foz do Iguaçu. **Anais...São José dos Campos: INPE, 2013. p. 89-96. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). Disponível em:**<<http://urlib.net/3ERPFQRTRW34M/3E7GGEM>>. Acesso em: 18 fev. 2016.

OTUKEI, J.; BLASCHKE, T. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. **International Journal of Applied Earth Observation and Geoinformation**, v. 12, p. S27–S31, 2010. ISSN 03032434.

PINHO, C. M. D.; RENNÓ, C. D.; KUX, H. J. H. Avaliação de técnicas de fusão aplicadas à imagens Quickbird. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. (SBSR), 2005, Goiânia. **Anais... São José dos Campos: INPE, 2005. p. 4225-4232. CD-ROM, On-line. ISBN 85-17-00018-8. (INPE-12768-PRE/8058). Disponível em:** <<http://urlib.net/ltid.inpe.br/sbsr/2004/11.22.20.14>>. Acesso em: 18 fev. 2016.

PINHO, C. M. D., SILVA, F. C., FONSECA, L. M. C.; MONTEIRO, A. M. V. Intra-urban land cover classification from high-resolution images using the C4.5 algorithm. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. vol. 37. Part B7. p. 695-699. 2008.

PINTO, C. T.; PONZONI, F. J.; FONSECA, L. M. G.; CASTRO, R. M. Simulação de Monte Carlo na avaliação das incertezas em parte do processo de calibração de sensores. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR)., 2013, Foz do Iguaçu. **Anais... São José dos Campos: INPE, 2013. p. 9131-9137. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). Disponível em:**<<http://urlib.net/3ERPFQRTRW34M/3E7GD3T>>. Acesso em: 18 fev. 2016.

POHL, C.; VAN GENDEREN, J. L. Review article Multisensor image fusion in remote sensing: Concepts, methods and applications. **International Journal of Remote Sensing**. 1998. p. 823-854, DOI: 10.1080/014311698215748.

PONTIUS, R. G.; MILLONES, M.; Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 2011. ISSN 0143-1161.

QUINLAN, J. **C4. 5: programs for machine learning**. San Mateo: Morgan Kaufmann, 1993. 302 p. ISSN 08856125.

RAMALHO, J. C.; RODRIGUES, A. P.; SEMEDO, J. N.; PAIS, I. P.; MARTINS, L. D.; SIMÕES-COSTA, M. C.; LEITÃO, A. E.; FORTUNATO, A. S.; BATISTA-SANTOS, P.; PALOS, I. M.; TOMAZ, M. a.; SCOTTI-CAMPOS, P.; LIDON, F. C.; DAMATTA, F. M. Sustained photosynthetic performance of *Coffea* spp. under long-term enhanced [CO<sub>2</sub>]. **PLoS ONE**, v. 8, n. 12, p. 1–19, 2013. ISSN 19326203.

RAMOS, A. L. O. **Validação de simulação por Monte Carlo da Interação de LASER vermelho e infravermelho com emulsão lipídica para estudos de dosimetria de luz em tecidos biológicos**. 2011. 88p. Dissertação (Mestrado em Física) — Universidade de São Paulo, São Paulo, 2011.

RENÓ, V. F.; NOVO, E. M. L. M.; ALMEIDA-FILHO, R.; SUEMITSU, C. Mapeamento da antiga cobertura vegetal de várzea do Baixo Amazonas a partir de imagens históricas (1975-1981) do Sensor MSS-Landsat. **Acta Amazônica**, v. 41, n. 1, p. 47–56, 2011. ISSN 0044-5967.

RESENDE, M. Classificação híbrida: pixel a pixel e baseada em objetos para o monitoramento da condição da superfície dos pavimentos. **Boletim de Ciências Geodésicas**, p. 397–420, 2012.

RIBEIRO, B. M. G.; KUX, H. J. H. Classificação orientada a objeto para mapeamento do uso do solo â métodos de análise de expansão urbana. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7893-7900. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15997-PRE/10606). Disponível em:<<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.18.00.02.47>>. Acesso em: 18 fev. 2016.

ROSA, V. G. C. **Modelo agrometeorológico-espectral para monitoramento e estimativa da produtividade do café na Região Sul / Sudoeste do Estado de Minas Gerais**. 2007. 145 p. (INPE-14791-TDI/1234). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2007/06.12.19.35>>. Acesso em: 18 fev. 2016.

ROUSE, J.; HAAS, R.; SCHELL, J.; DEERING, D. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE SYMPOSIUM, 3., 1973, Washington. **Proceedings...** Whashington: Nasa, 1973. p. 309–317.

ROVEDDER, J. **Validação da classificação orientada a objetos em imagens de satélite Ikonos e elaboração de indicadores ambientais georreferenciados no município de Torres, planície costeira do Rio Grande Do Sul**. 93 p. Tese (Doutorado em Sensoriamento Remoto) — Universidade Federal do Rio Grande do Sul, 2007.

SAES, M. S. M.; NAKAZONE, D. O Agronegócio café do Brasil no mercado internacional. **FAE BUSINESS**, n. 9, p. 40–42, 2004.

SANTOS, J. A. dos; GOSSELIN, P. H.; PHILIPP-FOLIGUET, S.; TORRES, R. da S.; FALCÃO, A. X. Multiscale classification of remote sensing images. **IEEE T. Geoscience and Remote Sensing**, v. 50, n. 10, p. 3764–3775, 2012.

SARMIENTO, C. M.; RAMIREZ, G. M.; COLTRI, P. P.; FELIPE, L.; AUGUSTO, O.; NASSUR, C.; SOARES, J. F. Comparação de classificadores supervisionados na discriminação de áreas cafeeiras em campos gerais – Minas Gerais. **Coffee Science**, v. 9, n. 4, p. 546–557, 2014.

SATO, L. Y.; SHIMABUKURO, Y. E.; KUPLICH, T. M.; GOMES, V. C. F. Análise comparativa de algoritmos de árvore de decisão do sistema WEKA para classificação do uso e cobertura da terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR)., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 2353-2360. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). Disponível em: <<http://urlib.net/3ERPFQRTRW34M/3E7GFLK>>. Acesso em: 18 fev. 2016.

SILVA, B. S. G.; VALERIANO, D. d. M. Correção atmosférica e topográfica de imagens de satélite em terrenos montanhosos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. (SBSR), 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p. 3587-3594. CD-ROM, On-line. ISBN 85-17-00018-

8. (INPE-12738-PRE/8028). Disponível em:

<<http://urlib.net/ltid.inpe.br/sbsr/2004/11.21.18.37.34>>. Acesso em: 18 fev. 2016.

Silva Junior, C.; FRANK, T.; RODRIGUES, T. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 44–53, 2014. ISSN 14154366.

SLATER, P. N.; JACKSON, R. D. Atmospheric effects on radiation reflected from soil and vegetation as measured by orbital sensors using various scanning directions. **Applied Optics**. v. 21, n. 21, p. 3923–3931, 1982.

SMITH, J.; LIN, T.; RANSON, K. The Lambertian assumption and Landsat data. **Photogrammetric engineering and remote sensing**, v. 46, n. 9, p. 1183–1189, 1980. ISSN 1098-6596.

SOARES, R. B.; SOARES, C. B. S. d. S.; COSTA, J. A. L. da; COSTA, S. d. S.; SOARES, R. B. Aplicação de técnica de fusão em imagens Landsat 8/OLI. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 4836-4843. Internet. ISBN 978-85-17-0076-8. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM4DB2>>. Acesso em: 18 fev. 2016.

SOEDIONO, B. Identificação de alvos urbanos em imagens Ikonos, aplicando classificação orientada a segmentos. **Journal of Chemical Information and Modeling**, v. 53, n. 2001, p. 160, 1989. ISSN 1098-6596.

SONG, C.; WOODCOCK, C.E.; SETO, K.C.; PAX-LENNEY, M.; MACOMBER, S.A. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects?. **Remote Sensing of Environment**, v. 75, p. 230-244, 2001.

SOUZA, V. C. O.; VIEIRA, T. G. C ; ALVES, H. M. R. ; BERTOLDO, M. A. ; BERNARDES, T. Uso do Sistema de Informação Geográfica para Avaliação Ambiental da propriedade a partir de dados regionais: Estudo de caso da Fazenda Diamantina, São Sebastião do Paraíso. In: CONGRESSO BRASILEIRO DE PESQUISAS CAFEEIRAS, 30, 2004, São Lourenço. **Anais...** São Lourenço: Ministério da Agricultura, Pecuária e Abastecimento. Epamig. Ufla, 2004. On-line. Disponível em: <<http://www.epamig.ufla.br/geosolos/publicacoes/2004/7.pdf>>. Acesso em: 18 fev. 2016.

SOUZA, S. A. S.; RESENDE, A. L. S.; STRIKIS, P. C.; COSTA, J. R.; RICCI, M. S. F.; AGUIAR-MENEZES, E. E. L. Infestação Natural de Moscas Frugívoras (Diptera: Tephritoidea) em Café Arábica, sob Cultivo Orgânico Arborizado e a Pleno Sol, em Valença, RJ. **Neotropical Entomology**, v.34, n. 4, p. 639-648, 2005.

SOUZA, V. C. O.; CUNHA, R. L.; ANDRADE, L. N. D.; VOLPATO, M. M. L.; CARVALHO, V. L. D.; ESMIN, A. A. A. Knowledge extraction techniques applied to blotch (*Cercospora coffeicola* Berkeley & Cooke) occurrence modeling trees in southern Minas Gerais. **Coffee Science**, v. 8, n. 1, p. 82–90, 2013.

SOUZA, V. C. O.; VIEIRA, T. G. C.; VOLPATO, M. M. L.; ALVES, H. M. R. Espacialização e dinâmica da cafeicultura mineira entre 1990 e 2008, utilizando técnicas de geoprocessamento. **Coffee Science**, v. 7, n. 2, p. 122–134, 2012.

STEHMAN, S. V. Estimating the Kappa Coefficient and its Variance under Stratified Random Sampling. **Photogrammetric Engineering & Remote Sensing**, v. 62, n. 4, p. 401–407, 1996. ISSN 0099-1112.

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**, v. 27, n. 9, p. 1355-61, 1992.

TEIXEIRA, S. M.; MILHOMEM, A. V. A competitividade e custos da cafeicultura brasileira. In: ZAMBOLIM, L. (ed.) **Tecnologias de produção de café com qualidade**. Viçosa, UFV, Departamento de Fitopatologia, 2001. cap. 2. p. 25-64.

TILTON, J.; LAWRENCE, W. Interactive analysis of hierarchical image segmentation. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2000), 2000, Honolulu Hawaii, USA. **Proceedings...** Honolulu: IEEE International, 2000. v. 2, p. 733–735.

USGS. **Landsat 8 (L8) data users handbook**. Earth Resources Observation and Science (EROS) Center, v. 8, n. June, p. 97, 2015. Disponível em: <<http://landsat.usgs.gov/documents/Landsat8DataUsersHandbook.pdf>>. Acesso: 16 dez 2015.

USGS. **Landsat 8 surface reflectance ( provisional ) product guide** : earthexplorer version. 2015. 2015 p. Product Guide, 2015. 27 p. Disponível em: <<http://www.researchgate.net/file.PostFileLoader.html?id=5588428f6225ff921d8>>

b45e7&assetKey=AS%3A273799973408789%401442290409851>. Acesso: 16 dez 2015.

VALERIANO, M. D. M. Cálculo do fator topográfico de iluminação solar para modelagem ecofisiológica a partir do processamento de Modelos Digitais de Elevação (MDE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR)., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 5933-5940. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). Disponível em:<<http://urlib.net/3ERPFQRTRW/39ULK4H>>. Acesso em: 18 fev. 2016.

VELICKOV, S.; SOLOMATINE, D.; YU, X.; PRICE, R. Application of data mining techniques for remote sensing image analysis. INT. CONFERENCE ON HYDROINFORMATICS, 4., 2000, Iowa, USA. **Proceedings...** Rotterdam: Balkema, 2000.

VERDIN FILHO, A. C. **Influência do espaçamento e densidade de hastes em café conilon conduzido com a poda programada de ciclo.** 2011. 68 p. Dissertação (Mestrado em Produção Vegetal) — Universidade Federal do Espírito Santo, 2011.

VIEIRA, M. A.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, series to map sugarcane over large areas. **Remote Sensing of Environment**, v. 123, p.553–562, 2012. ISSN0034 – 4257.

VIEIRA, T. G. C. ; ALVES, H. M. R. ; BERTOLDO, M. A. ; SOUZA, V. C. O. ; BERNARDES, T. Evolução de áreas cafeeiras na região de Patrocínio/MG em relação ao uso da terra e às classes de orientação de vertente, utilizando o sistema de informação geográfica SPRING. In: CONGRESSO BRASILEIRO DE PESQUISAS CAFEIRAS, 30., 2004, São Lourenço, MG. **Anais...** São Lourenço: Ministério da Agricultura, Pecuária e Abastecimento. Epamig. Ufla, 2004. On-line. Disponível em:<<http://www.epamig.ufla.br/geosolos/publicacoes/2004/8.pdf>>. Acesso em: 18 fev. 2016.

VIEIRA, T. G. C.; ALVES, H. M. R.; LACERDA, M. P. C.; VEIGA, R. D.; EPIPHANIO, J. C. N. Crop Parameters And spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, v. 1, n. 2, p. 111–118, 2006.

VIGANÓ, H. A.; BORGES, E. F.; FRANCA-ROCHA, W. J. S. A. Análise do desempenho dos Índices de Vegetação NDVI e SAVI a partir de imagem Aster.

In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR)., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 1828-1834. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). Disponível em:<<http://urlib.net/3ERPFQRTRW/3A49SGL>>. Acesso em: 18 fev. 2016.

WANG, Z.; JENSEN, J. R.; IM, J. An automatic region-based image segmentation algorithm for remote sensing applications. **Environmental Modelling Software**, v. 25, n. 10, p. 1149 – 1165, 2010. ISSN 1364-8152.

WEIH, R. C.; RIGGAN, N. D. Object-based classification vs. pixel-based classification: comparative importance of multi-resolution imagery. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, n.4/C7, 2008. ISSN 16821750.

WEN, X. W. X.; HU, G. H. G.; YANG, X. Y. X. CBERS-02 remote sensing data mining using decision tree algorithm. **First International Workshop on Knowledge Discovery and Data Mining (WKDD 2008)**. Adelaide, Australia: IEEE Computer Society, 2008. p. 86–89.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining: practical machine learning tools and techniques**. Morgan Kaufmann. 2011. 665 p. ISSN 14337851. ISBN 9780123748560.

YANG, C.-C.; PRASHER, S. O.; ENRIGHT, P.; MADRAMOOTOO, C.; BURGESS, M.; GOEL, P. K.; CALLUM, I. Application of decision tree technology for image classification using remote sensing data. **Agricultural Systems**, v. 76, n. 3, p. 1101–1117, 2003. ISSN 0308521X.

ZHANG, X.; FENG, X.; XIAO, P.; HE, G.; ZHU, L. Segmentation quality evaluation using region-based precision and recall measures for remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 73 – 84, 2015. ISSN 0924-2716.

ZHANG, Y.; HONG, G. An IHS and wavelet integrated approach to improve pansharpening visual quality of natural colour IKONOS and QuickBird images. **Information Fusion**, v. 6, n. 1, p. 225–234, 2004. ISSN 15662535.

## **PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE**

### **Teses e Dissertações (TDI)**

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

### **Manuais Técnicos (MAN)**

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

### **Notas Técnico-Científicas (NTC)**

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programa de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

### **Relatórios de Pesquisa (RPQ)**

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

### **Propostas e Relatórios de Projetos (PRP)**

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

### **Publicações Didáticas (PUD)**

Incluem apostilas, notas de aula e manuais didáticos.

### **Publicações Seriadas**

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

### **Programas de Computador (PDC)**

São as sequências de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. São aceitos tanto programas fonte quanto executáveis.

### **Pré-publicações (PRE)**

Todos os artigos publicados em periódicos, anais e como capítulos de livros.