



RAFAEL CARLOS BISPO

**“UTILIZAÇÃO DE DADOS DO SENSOR MODIS NO
MONITORAMENTO E MAPEAMENTO DA CULTURA DE CAFÉ”**

CAMPINAS

2013



UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA AGRÍCOLA

RAFAEL CARLOS BISPO

**“UTILIZAÇÃO DE DADOS DO SENSOR MODIS NO
MONITORAMENTO E MAPEAMENTO DA CULTURA DE CAFÉ”**

Orientador: Prof. Dr. Rubens Augusto Camargo Lamparelli

Co-orientador: Prof. Dr. Jansle Vieira Rocha

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas para obtenção do título de Mestre em Engenharia Agrícola, na área de concentração de Planejamento e Desenvolvimento Rural Sustentável.

**ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA
DISSERTAÇÃO DEFENDIDA PELO ALUNO RAFAEL CARLOS
BISPO E ORIENTADA PELO PROF. DR. RUBENS AUGUSTO
CAMARGO LAMPARELLI.**

Assinatura do orientador

A handwritten signature in blue ink, appearing to be "R. Camargo", is written over a horizontal line.

CAMPINAS

2013

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE -
UNICAMP

B542u Bispo, Rafael Carlos
Utilização de dados do sensor Modis no
monitoramento e mapeamento da cultura de café / Rafael
Carlos Bispo. --Campinas, SP: [s.n.], 2013.

Orientador: Rubens Augusto Camargo Lamparelli
Coorientador: Jansle Vieira Rocha.
Dissertação de Mestrado - Universidade Estadual de
Campinas, Faculdade de Engenharia Agrícola.

1. Café - Sensoriamento remoto. 2.
Geoprocessamento. 3. Sensoriamento remoto -
Classificação. 4. Vegetação - Mapeamento. I.
Lamparelli, Rubens Augusto Camargo. II. Rocha, Jansle
Vieira. III. Universidade Estadual de Campinas.
Faculdade de Engenharia Agrícola. IV. Título.

Título em Inglês: Using Modis data to monitoring and mapping of coffee
crops

Palavras-chave em Inglês: Coffee - Remote sensing, Geoprocessing, Remote
sensing - Classification, Vegetation - Mapping

Área de concentração: Planejamento e Desenvolvimento Rural Sustentável

Titulação: Mestre em Engenharia Agrícola

Banca examinadora: Flávio Jorge Ponzoni, Glauco de Souza Rolim

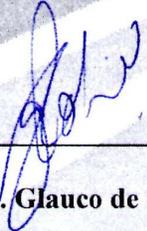
Data da defesa: 28-02-2013

Programa de Pós Graduação: Engenharia Agrícola

Este exemplar corresponde à redação final da **Dissertação de Mestrado** defendida por **Rafael Carlos Bispo**, aprovada pela Comissão Julgadora em 28 de fevereiro de 2013, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.



Prof. Dr. Rubens Augusto Camargo Lamparelli – Presidente e Orientador
Feagri/Unicamp



Prof. Dr. Glauco de Souza Rolim - Membro Titular
FCAV/Unesp



Prof. Dr. Flávio Jorge Ponzoni – Membro Titular
INPE

AGRADECIMENTOS

À Faculdade de Engenharia Agrícola da UNICAMP, pela oportunidade de realizar mais uma etapa de meus estudos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela bolsa de Mestrado concedida.

Ao meu orientador Prof. Dr. Rubens Augusto Camargo Lamparelli e co-orientador Prof. Dr. Jansle Vieira Rocha, por me aceitarem na equipe do Laboratório de Geoprocessamento, pelo apoio e conhecimentos compartilhados.

Ao Sr. Éder Ribeiro dos Santos, Coordenador de Geoprocessamento da Cooxupé, pela atenção e ajuda no trabalho de campo, pelas discussões e informações prestadas e pelos dados disponibilizados, sem os quais esta pesquisa não poderia ser realizada.

Ao Prof. Dr. Flavio Jorge Ponzoni e à Profa. Dra. Mara de Andrade Marinho Weill, participantes do exame de qualificação, pelas contribuições ao meu projeto de pesquisa.

Ao Agmon Moreira Rocha, técnico do Laboratório de Geoprocessamento da Feagri, pela amizade e suporte no dia-a-dia de estudos.

Aos colegas do Labgeo: Ariadiny M. Silva, Christiano L. Arraes, Daniel Duft, Daniela F. Silva, Diego Rocha, Gleyce K. D. Araújo, Henrique Ordones, Michelle C. A. Picoli, Rafael A. Moraes, Victor D. Manabe.

Aos meus amigos e geógrafos por toda vida: Antonio, Ricardo, Thiago.

À Maria Angélica Petrini, pelo companheirismo em todo trajeto. Agradeço-a especialmente, pois chegou na hora certa e sabe o bem que me fez.

Aos meus pais Maria e Aparecido, e ao meu irmão Diego, pelo amor, carinho, compreensão, apoio e incentivo.

Obrigado!

RESUMO

A produção de café esteve intimamente ligada ao desenvolvimento econômico do Brasil e ainda hoje o café é um importante produto da agricultura nacional. O Estado de Minas Gerais responde atualmente por 52% de toda a área de café do Brasil. Dessa forma, dada a importância da cafeicultura para a economia brasileira, é necessário desenvolver e melhorar as metodologias para seu monitoramento. Dados de sensoriamento remoto podem fornecer informações para o monitoramento e o mapeamento de café de maneira mais rápida e menos onerosa do que os métodos convencionais. Nesse contexto, os objetivos desta pesquisa foram identificar a bienalidade da cultura de café por meio de dados do sensor MODIS, juntamente com dados de estações meteorológicas, entre os anos de 2004 a 2012, e avaliar a eficácia das imagens-fração derivadas do sensor MODIS no mapeamento automático das áreas de café do município de Monte Santo de Minas/MG. Foi utilizada uma série temporal com 163 imagens da banda NIR do MODIS, produto MOD13Q1, para se extrair os valores de refletância dos *pixels* com pelo menos 80% de café. Dados diários de temperatura e precipitação foram agrupados de acordo com a resolução temporal das imagens (16 dias) para o cálculo do balanço hídrico. Para o mapeamento das áreas de café, foram utilizadas imagens do MODIS, bandas MIR, NIR e RED, dos períodos seco e chuvoso. Através do Modelo Linear de Mistura Espectral foram derivadas imagens-fração de solo, café e água/sombra. Estas imagens-fração serviram como dados de entrada para a classificação automática supervisionada com o método SVM – *Support Vector Machine*. Os resultados mostraram que para o monitoramento do café os dados de refletância dos períodos de colheita apresentaram maior correlação com a alternância da quantidade da produção. A partir da matriz de erro montada entre as classificações e as máscaras de referência, observou-se que os melhores resultados de Exatidão Global e Índice Kappa foram obtidos na classificação do período seco, sendo 67% e 0,41, respectivamente. Análises estatísticas de correlação e coeficiente de variação aplicadas sobre as imagens-fração de café permitiram melhor compreensão da complexidade do mapeamento do café.

Palavras-chave: modelo linear de mistura espectral, *support vector machine*, análise estatística, bienalidade.

ABSTRACT

Coffee production was closely linked to the economic development of Brazil and even today coffee is an important product of national agriculture. The State of Minas Gerais currently accounts for 52% of the whole area of coffee in Brazil. Thus, given the importance of the coffee crops to Brazilian economy, it is necessary to develop and improve methodologies for its monitoring. Then, remote sensing data can provide information for monitoring and mapping of coffee crops faster and cheaper than conventional methods. In this context, the objectives of this study were to identify the biennial yield of the coffee crop using data from MODIS and meteorological stations, over the period between 2004 and 2012, and assess the effectiveness of the fraction-images derived from MODIS in the automatic mapping of the areas of coffee in Monte Santo de Minas/MG. Were used a time series of 163 images of NIR band from MODIS, MOD13Q1 product, to extract the values of reflectance of pixels with at least 80% of coffee. Daily data of air temperature and precipitation were compiled to 16-day intervals to match the temporal resolution of MODIS imagery and to calculate the water balance. For coffee mapping, we used MODIS imagery, MIR, NIR and RED bands, of dry and rainy seasons. Through the Spectral Linear Mixing Model were derived fraction images of soil, coffee and water/shadow. These fraction images served as input data for supervised classification with SVM – Support Vector Machine approach. The results showed that for coffee monitoring the reflectance data of harvest period presented higher correlation with the alternation of coffee production. From the error matrix between the classifications and reference masks, it was observed that the best results of Overall Accuracy and Kappa Index were obtained in the classification of the dry season, with 67% and 0.41, respectively. Statistical analyses of correlation and coefficient of variation applied over images fraction of coffee allowed a better understanding about the complexity of mapping coffee.

Keywords: spectral linear mixing model, support vector machine, statistical analyses, biennial yield.

LISTA DE FIGURAS

Figura 1. Evolução do consumo interno de café no Brasil.....	5
Figura 2. (A) Cafeeiro em florada; (B) Folhas e frutos do cafeeiro.	7
Figura 3. Esquemática das seis fases fenológicas do cafeeiro arábica, durante 24 meses, nas condições climáticas tropicais do Brasil	8
Figura 4. Influência da atmosfera na trajetória da radiação eletromagnética entre a fonte e o sensor.....	11
Figura 5. Diferentes elementos contidos em um pixel	14
Figura 6. (A) Campo de visada instantânea cobrindo os limites entre dois ou mais objetos. (B) Objetos menores que o tamanho do pixel.....	15
Figura 7. Exemplos de classificação SVM, que separou as duas classes (círculos e quadrados)	21
Figura 8. Exemplos de classificação SVM, mostrando as margens e vetores de suporte	21
Figura 9. Varredura do MODIS, mostrando o aumento no tamanho dos pixels com a variação do ângulo de visada	23
Figura 10. Representação do <i>tile</i> h (v) de 1200 x 1200 km.....	24
Figura 11. Localização da área de estudo.....	26
Figura 12. Distribuição espacial do café em Monte Santo de Minas.	27
Figura 13. Mapa de altimetria do município de Monte Santo de Minas.	28
Figura 14. Histograma de altimetria das áreas de café de Monte Santo de Minas.....	29
Figura 15. Mapa de declividade do município de Monte Santo de Minas.	30
Figura 16. Mapa de orientação da vertente no município de Monte Santo de Minas	31
Figura 17. Exemplos de <i>pixels</i> MODIS transformados em polígonos sobrepostos à máscara de café da Cooxupé.	34
Figura 18. Fluxograma da metodologia para o monitoramento do café.....	35
Figura 19. Curvas espectrais dos endmembers de solo, café e água/sombra	36
Figura 20. Máscaras de referência para avaliar a acurácia das classificações.....	38
Figura 21. Correlação entre os dados de proporção de café dos sensores e Coeficiente de Variação do LISS III.....	41
Figura 22. Fluxograma da metodologia para o mapeamento do café.....	42

Figura 23. Refletância média dos pixels de café na banda NIR do MODIS.	43
Figura 24. Refletância média dos pixels de café na banda NIR distribuídos de acordo com os períodos da bienalidade.	45
Figura 25. Gráfico de refletância com balanço hídrico da produção de café (bienalidade de 2005 e 2006).	46
Figura 26. Gráfico de refletância com balanço hídrico da produção de café (bienalidade de 2009 e 2010).	48
Figura 27. Gráfico de refletância com balanço hídrico da produção de café (bienalidade de 2011 e 2012).	49
Figura 28. Quadro dos valores de refletância de acordo com os períodos da bienalidade. Erro! Indicador não definido.	
Figura 29. Gráfico do Desvio Padrão sobre refletância média da bienalidade.	50
Figura 30. Refletância média do café durante os períodos de colheita em conjunto com as quantias de sacas produzidas.	51
Figura 31. Imagens-fração de solo, café e água/sombra do período chuvoso (02 a 17/09/2012).	52
Figura 32. Imagens-fração de solo, café e água/sombra do período de estiagem (28/08 a 12/09/2012).....	53
Figura 33. Composição RGB das imagens-fração.	53
Figura 34. Classificação do período chuvoso.....	55
Figura 35. Classificação do período de estiagem	56
Figura 36. Gráfico de dispersão dos valores de proporção de café das imagens-fração café do MODIS e LISS III.	58
Figura 37. Distribuição espacial da classificação de café de acordo com as proporções de cobertura.	59
Figura 38. Distribuição espacial de toda a área de café de acordo com as proporções de cobertura.	60
Figura 39. Esquematização qualitativa da classificação de café.	62

LISTA DE TABELAS

Tabela 1. Características do produto MOD13Q1.....	25
Tabela 2. Níveis de desempenho da classificação para a interpretação de valores de Kappa obtidos.....	39
Tabela 3. Interpretação dos valores do coeficiente de correlação.....	40
Tabela 4. Matriz de erro para a classificação período chuvoso.....	55
Tabela 5. Matriz de erro para a classificação do período de estiagem.....	57

SUMÁRIO

1. INTRODUÇÃO.....	1
1.2. Justificativa	1
1.3. Hipótese	2
2. OBJETIVOS.....	3
3. REVISÃO BIBLIOGRÁFICA.....	4
3.1. Aspectos históricos e econômicos do café no Brasil	4
3.1.1. A cultura do café no Brasil.....	4
3.1.2. Panorama atual da cafeicultura no Brasil.....	4
3.1.3. Destaque para a cafeicultura no Sul de Minas Gerais	5
3.2. A cultura do café.....	6
3.2.1. A fenologia e a bienalidade do café	6
3.2.2. Condições geográficas para o cultivo de café	8
3.3. Sensoriamento Remoto aplicado ao monitoramento da cultura de café.....	10
3.3.1. Modelo Linear de Mistura Espectral.....	14
3.3.2. Métodos de classificação automática	18
3.3.3. Classificador SVM	20
3.4. Sistema MODIS	22
3.4.1. O sensor MODIS e suas principais características.....	22
3.4.2. O produto MOD13Q1	24
4. MATERIAIS E MÉTODOS.....	26
4.1. Área de Estudo.....	26
4.1.1. Distribuição geográfica do café no município	27
4.2. Materiais	31
4.3. Procedimentos Metodológicos.....	32
4.3.1. Monitoramento	33
4.3.2. Mapeamento	35
5. RESULTADOS E DISCUSSÕES.....	43
5.1. Monitoramento.....	43
5.1.1. A identificação da bienalidade	43

5.2. Mapeamento.....	51
5.2.1. Geração das imagens-fração para os períodos de chuva e estiagem.....	51
5.2.2. Classificações.....	54
5.2.3. Análises estatísticas da classificação do período de estiagem.....	57
6. CONCLUSÕES.....	63
REFERÊNCIAS BIBLIOGRÁFICAS.....	64

1. INTRODUÇÃO

A produção de café está intimamente ligada ao desenvolvimento econômico do país, sobretudo à Região Sudeste (São Paulo e Minas Gerais). Historicamente, o processo de industrialização do Brasil esteve relacionado ao capital acumulado das exportações de café. Após a crise econômica da década de 1930, parte da burguesia cafeeira viu-se na necessidade de investir seu capital no setor industrial, como alternativa frente à queda das exportações de café para os países europeus e para os Estados Unidos.

É certo que a participação das exportações de café há tempos deixou de ser o carro-chefe da economia brasileira, entretanto constitui-se ainda como um importante produto do setor do agronegócio.

Pesquisas indicam aumento no consumo de café, tanto na escala nacional, quanto na escala global. Paralelamente a esse aumento na demanda, ocorre a expansão da área destinada à produção de café, com projeção de crescimento de 3,21% da área plantada para a safra 2012/13 de acordo com os dados divulgados pela Companhia Nacional de Abastecimento - CONAB.

O Estado de Minas Gerais se destaca ao participar com pouco mais da metade da produção nacional de café, predominantemente com a espécie Arábica. Neste contexto, as regiões sul e centro-oeste do Estado se sobressaem por representarem cerca de 50% da área destinada à cafeicultura. O município de Monte Santo de Minas, localizado na Região Sul de Minas Gerais, é um bom exemplo deste cenário, pois a entrada da maior parte dos recursos financeiros no município provém do setor cafeeiro.

Dada a importância da atividade cafeeira para a economia do país, há que se melhorar o monitoramento agrícola da cafeicultura para planejar a comercialização com vistas a proteger o setor da especulação interna e externa.

1.2. Justificativa

Apesar da importância econômica e social, a atividade cafeeira em Minas Gerais necessita de informações complementares para o desenvolvimento de seu sistema produtivo, sobretudo no âmbito da especialização destas informações. Esta deficiência de informações

limita o planejamento econômico, bem como o planejamento ambiental, intrinsecamente ligado às práticas de manejo e o controle da erosão.

Todas essas informações são importantes para o planejamento. No entanto, realizar levantamento de todo o complexo cafeeiro por meio de métodos convencionais, como levantamento de campo com produtores, cooperativas e órgãos oficiais do governo, torna-se uma atividade que demanda tempo, custo e muita mão de obra.

Dessa forma, o Sensoriamento Remoto vem somar às técnicas já existentes de monitoramento, uma vez que há a possibilidade de obter informações objetivas em curto prazo, através de imagens de satélites disponibilizadas, muitas vezes, gratuitamente como é o caso do sensor MODIS.

1.3. Hipótese

A hipótese norteadora deste estudo é que a utilização de dados do sensor MODIS, juntamente com dados de estações meteorológicas, é capaz de fornecer informações para o monitoramento do café no município de Monte Santo de Minas/MG através de um acompanhamento, ao longo dos anos de 2004 a 2012, identificando assim seu ciclo bienal de produção.

A segunda hipótese diz respeito à possibilidade de mapeamento das áreas de café por meio da aplicação do classificador *Support Vector Machine* sobre as imagens-fração do MODIS obtidas do Modelo Linear de Mistura Espectral.

2. OBJETIVOS

Os objetivos gerais desta pesquisa são: (i) identificar a bienalidade da cultura de café através de dados do sensor MODIS, em conjunto com dados de estações meteorológicas, entre os anos de 2004 a 2012, no município de Monte Santo de Minas/MG e; (ii) avaliar a eficácia das imagens-fração derivadas do sensor MODIS no mapeamento automático das áreas de café do município de Monte Santo de Minas/MG.

Para tanto, faz-se necessário alcançar alguns objetivos específicos:

- Identificar os *pixels* de MODIS com pelo menos 80% de cobertura de café;
- Gerar gráficos do comportamento espectral do café entre os anos de 2004 a 2012;
- Gerar imagens-fração (fração-solo, fração-café e fração-sombra/água) para os períodos de estiagens e chuvosos em imagens MODIS;
- Gerar máscaras da cultura do café no município de Monte Santo de Minas/MG dos períodos de estiagem e de chuva para o ano de 2012;
- Validar as máscaras por meio de índices de Exatidão Global e Kappa.

3. REVISÃO BIBLIOGRÁFICA

3.1. Aspectos históricos e econômicos do café no Brasil

3.1.1. A cultura do café no Brasil

Planta nativa da África e trazida das Guianas por Francisco de Melo Palheta ao Brasil em 1927, o cafeeiro (*Coffea sp*) é pertencente à família das rubiáceas, gênero *Coffea*.

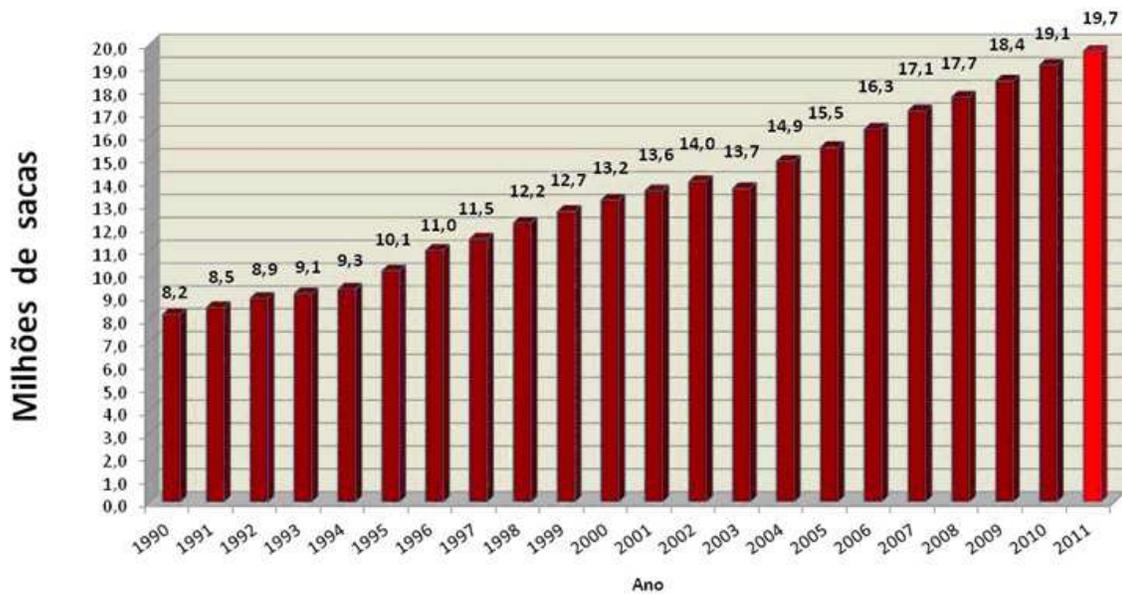
Cultivado inicialmente em Belém do Pará, em pouco tempo o café passou a ser produto de exportação em 1732. A partir daí, de acordo com MELLO (2001) e PONCIANO (1995), historicamente a cafeicultura esteve atrelada ao desenvolvimento do país. Ainda que as técnicas de cultivo estejam se desenvolvendo, o trabalho braçal consiste em um importante fator social para a fixação da mão-de-obra no meio rural por gerar empregos diretos.

3.1.2. Panorama atual da cafeicultura no Brasil

Atualmente o consumo de café vem aumentando. No período compreendido entre Novembro/2010 e Outubro/2011, a Associação Brasileira da Indústria de Café - ABIC¹ registrou o consumo de 19,72 milhões de sacas, o que representa um acréscimo de 3,11% em relação ao período anterior correspondente (Novembro/09 a Outubro/10), que havia sido de 19,13 milhões de sacas (Figura 1). Isso vai ao encontro da pesquisa realizada pelo Instituto Brasileiro de Geografia e Estatística – IBGE, de que o café é o alimento mais consumido diariamente por 78% da população brasileira acima de 10 anos, totalizando 255 ml/dia ou 93 litros/habitante.ano.

Seguindo esse ritmo de consumo interno, as estimativas de safra de café feitas pela Companhia Nacional de Abastecimento – CONAB (2012) mostram que a cafeicultura vem apresentando crescimento. Para a safra do biênio 2012/2013 totalizam 2.351,3 mil hectares (ha), com predomínio das espécies *Arábica e Conillon*. O resultado mostra um crescimento de 3,21% sobre a área de 2.278,1 ha, existentes na safra 2011, ou seja, foram acrescentados 73.148,2 ha da cultura.

¹ Informações obtidas diretamente do site < <http://www.abic.com.br>>



Ano-período: novembro - outubro

Figura 1. Evolução do consumo interno de café no Brasil.

Fonte: Disponível em <<http://www.abic.com.br>> Acesso em: 15 jan. 2012.

Paralelo a esse aumento na demanda interna, o mercado externo vem apresentando crescimento. De acordo com a Cecafé - Conselho dos Exportadores de Café do Brasil, as exportações de café verde do Brasil encerraram 2011 com alta de 1,2% na comparação com 2010, para um recorde de 30,09 milhões de sacas. Além do aumento nas exportações, outro fator favorável foi a alta dos preços no mercado internacional, sendo que a receita com as exportações de café somou um recorde de US\$ 8,7 bilhões em 2011, alta de 53,6% ante 2010. Com esses resultados, o café apresentou participação de 3,4% sobre a pauta das exportações brasileiras, e de 9,2% sobre as exportações totais do agronegócio.

3.1.3. Destaque para a cafeicultura no Sul de Minas Gerais

Região de destaque nacional na produção de café, a introdução da cafeicultura no Sul de Minas Gerais ocorreu nos municípios de Aiuruoca, Jacuí e Baependi no Vale do Sapucaí, em fins do século XVIII, por intermédio dos tropeiros. A produção inicial era destinada ao consumo próprio. A partir do final do século XIX, houve uma nova expansão visando atender a demanda local, e, então, a cafeicultura se expandiu por praticamente toda a região sul

mineira chegando a constituir um verdadeiro complexo agroindustrial na década de 1970 (FILETTO & ALENCAR, 2001).

De acordo com PÁDUA (1998) e SILVA (1998), a região do Sul de Minas Gerais apresenta condições que lhe favorece: fácil acesso aos grandes centros consumidores, infraestrutura adequada e condições climáticas excelentes para o cultivo do café, além de importantes cooperativas de café, como a Cooxupé², Cocatrel³, Cooparaíso⁴ e Minas Sul⁵ e expressivas instituições de pesquisa e ensino que garantem uma cafeicultura de referência.

Segundo os trabalhos realizados entre novembro e dezembro de 2011 pela CONAB relativos à área de cafeicultura, o Estado de Minas Gerais concentra a maior área com 1.208,8 mil ha, predominando a espécie arábica com 97,7%. A área total estadual representa 51,4% da área cultivada com café no País. Deste total produzido em Minas Gerais, somente as regiões Sul e Centro-Oeste do estado são responsáveis por 51,5% da área cultivada, o que vem a ressaltar a importância econômica da atividade na região.

Como se pode observar, tanto na escala nacional quanto na regional, a cafeicultura vem se mostrando como uma cultura em expansão, tornando-se cada vez mais necessário estabelecer um sistema de monitoramento eficiente e objetivo a fim de atender às necessidades de planejamento e de comercialização.

Nesse sentido, o uso das imagens de sensoriamento remoto constitui um instrumento fundamental para o mapeamento e monitoramento da cultura do café, pois como afirmou JENSEN (2005), a aquisição de imagens de sensoriamento remoto de forma sistemática e repetitiva em diferentes faixas do espectro eletromagnético permite diferenciar os alvos da superfície terrestre em razão de suas distintas respostas espectrais.

3.2. A cultura do café

3.2.1. A fenologia e a bienalidade do café

Segundo ALZUGARAY e ALZUGARAY (1984), as características comuns do cafeeiro são o porte de até cinco metros de altura, caule retilíneo de casca cinzenta e rugosa.

² Cooperativa Regional de Cafeicultores de Guaxupé

³ Cooperativa dos Cafeicultores da Zona de Três Pontas

⁴ Cooperativa dos cafeicultores de São Sebastião do Paraíso

⁵ Cooperativa dos Cafeicultores de Varginha

Suas folhas verde-escuras são curtopeciouladas e curto estipuladas, ovado-lanceoladas, agudas, glabras e ondulada nas margens e produzem inflorescências em panículas racemosas com flores viçosas, bracteadas brancas. Com relação aos frutos, estes são do tipo cápsula, contendo sementes duras, globosas, brilhantes e pretas (Figura 2).

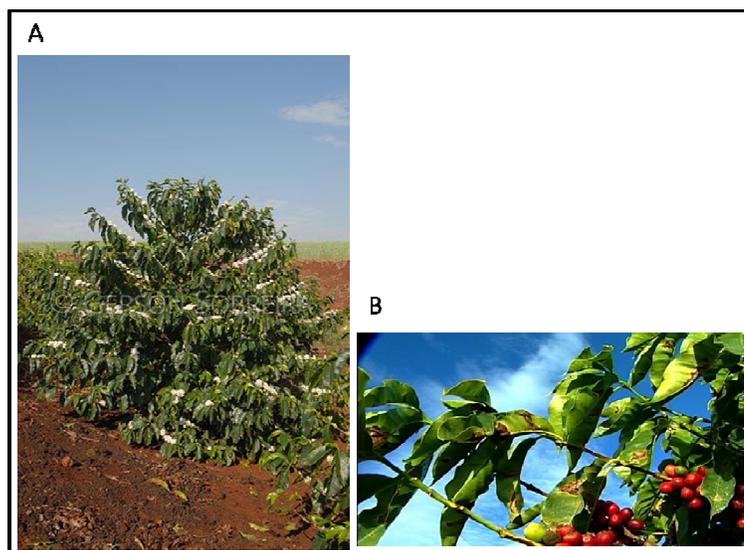


Figura 2. (A) Cafeeiro em florada; (B) Folhas e frutos do cafeeiro.

Fonte: Disponível em <<http://www.abic.com.br>> Acesso em: 15 jan. 2012.

Ainda segundo ALZUGARAY e ALZUGARAY (1984), as espécies de café mais cultivadas no Brasil são *Coffea arábica*, café-arábico como é comumente chamada, e *Coffea canephora*, conhecida como *Coffea robusta* ou Conillon. As variedades do café-arábico mais conhecidas são Caturra, Mundo Novo e Bourbon. Já o Conillon, embora produza uma bebida pouco saborosa e aromática, seu cultivo garante resistência à ferrugem das folhas, doença muito prejudicial à cafeicultura comercial.

De acordo com a esquematização feita por CAMARGO e CAMARGO (2001), é possível dividir o ciclo fenológico do café arábica em seis fases, no período de 24 meses, de acordo com as condições climáticas do Brasil (Figura 3).

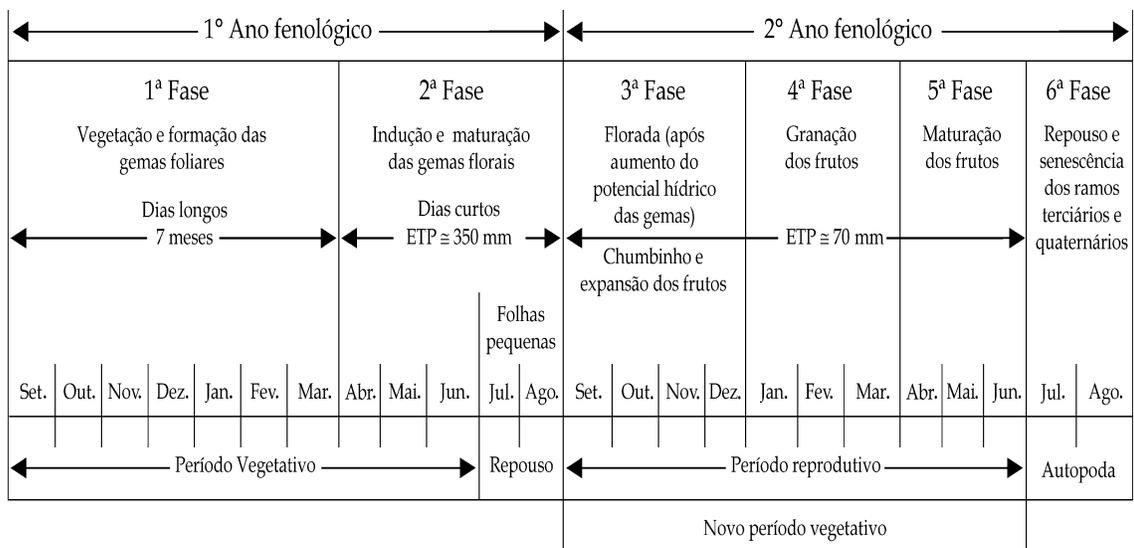


Figura 3. Esquemática das seis fases fenológicas do cafeeiro arábica, durante 24 meses, nas condições climáticas tropicais do Brasil. Fonte: CAMARGO e CAMARGO (2001).

A bienalidade é outra característica marcante na produção do café, isto é, devido às peculiaridades das funções vegetativas e reprodutivas existem anos de grande produção, pois o crescimento dos frutos absorve maior parte do fotoassimilado produzido pela planta durante a fotossíntese, diminuindo o desenvolvimento vegetativo. No ano seguinte, entretanto, o fruto se desenvolve nas partes novas dos ramos, sendo o crescimento desses novos ramos dependente da quantidade de frutos desenvolvidos nos ramos do ano anterior (CAMARGO e FAHL, 2001).

Vale ressaltar que o clima é outro fator fundamental na interferência da bienalidade produtiva e, portanto, na qualidade do produto, uma vez que o déficit hídrico é capaz de alterar o metabolismo da planta (PICINI et al. 1999).

3.2.2. Condições geográficas para o cultivo de café

As oscilações e frustrações da produção de café no Brasil são causadas, na maioria das vezes, pela variabilidade climática. As relações entre os parâmetros climáticos e a produção agrícola são bastante complexas, uma vez que fatores ambientais afetam o

crescimento e o desenvolvimento das plantas sob diferentes formas durante as fases de crescimento da cultura do café (CAMARGO e CAMARGO, 2001).

Dada essa dependência da atividade agrícola às condições de tempo e clima, SEDIYAMA et al. (2001) realizaram o zoneamento agroclimático do cafeeiro para o Estado de Minas Gerais, que os autores consideram de extrema importância para a implantação e o planejamento de atividades agrícolas, pois a delimitação de regiões climaticamente homogêneas significa não só estabelecer os indicadores do potencial do meio físico e biológico para a região em estudo, mas também registrar e delimitar as áreas de padrões homogêneos de atividades agrícolas e dos recursos naturais nela existentes.

Na delimitação da aptidão climática para a cafeicultura comercial, SEDIYAMA et al. (2001) consideraram as seguintes faixas com as limitações e possibilidades climáticas:

- *Aptas*: regiões com temperatura média anual superior a 18,0°C e inferior a 23,5°C e deficiência hídrica anual abaixo de 150 mm significam as regiões que apresentam condições térmicas e hídricas favoráveis à cafeicultura, correspondendo a 48,7% da área total do Estado de Minas Gerais, localizadas nas regiões Sul, Centro e Leste;

- *Aptas em áreas irrigadas*: regiões com temperatura média anual entre 23,5 a 24,0°C, quando associadas com práticas de irrigações suplementares, correspondem a 36,2% da área estadual;

- *Inaptas*: regiões com temperatura média anual inferior a 18,0°C e temperatura média anual superior a 24,0°C e deficiência hídrica anual superior a 150 mm. São regiões que apresentam temperaturas muito baixas ou muito elevadas e, além disso, deficiências hídricas elevadas, inaptas para recomendação de plantios de cafeeiros comerciais de alta sustentabilidade. Localizam-se na região Nordeste e parte do Norte do Estado, totalizando 15,1% da área estadual.

Além de Minas Gerais, as principais regiões produtoras de café no Brasil concentram-se nos Estados de São Paulo, Paraná, Rio de Janeiro e Espírito Santo, onde ocorre mais de 150 mm de chuva por mês durante o período de florescimento, formação e maturação dos frutos, nos meses de setembro a março, que correspondem ao período de renovação de ramos e folhas. Nos meses de colheita e repouso, de junho a agosto, a exigência é menor. Dessa forma, a estiagem deste período não ocasiona grandes prejuízos à planta (SEDIYAMA et al., 2001).

A declividade também é outro elemento que deve ser observado no plantio de café, pois a atuação deste refere-se à distribuição de processos hidrológicos e erosivos no solo (VALERIANO, 2000). A declividade ainda se torna crucial na definição da possibilidade do uso mecanização agrícola ou mão de obra manual (ZAMBOLIM, 2002). Como afirmou SEDIYAMA et al. (2001), no Estado de Minas gerais não é recomendável o plantio de café arábica em altitude inferior a 500 m e superior a 1.200 m devido às condições de temperaturas desfavoráveis.

A orientação da vertente é uma importante variável sobre a evapotranspiração e o decorrente balanço hídrico (VALERIANO, 2003). DIODATO et al. (2010) encontraram valores de evapotranspiração expressivamente menores em vertentes com orientação para Norte se comparadas às vertentes Sul em estudo realizado no hemisfério Norte. No entanto, no hemisfério Sul, ocorre o inverso e com mais intensidade em maiores latitudes. ALZUGARAY e ALZUGARAY (1984) recomendam que o plantio de café seja realizado em áreas com vertentes orientadas com face voltada para o Norte, Noroeste ou Nordeste. Segundo os autores, as lavouras nestas condições recebem maior quantidade de energia solar em relação àquelas voltadas para outras direções. Por conta dos ventos frios durante o inverno e da maior umidade, não é recomendável o plantio voltado para a face sul.

Em relação às características pedológicas, SEDIYAMA et al. (2001) dizem que os solos mais adequados ao cultivo do cafeeiro são os profundos, porosos e bem drenados, que possuem estrutura granular de tamanho médio e moderadamente desenvolvida. A textura média é a mais favorável, não sendo recomendados solos com teor de argila menor que 20% e, se muito argilosa, devem apresentar estrutura e porosidade favoráveis à cultura.

3.3. Sensoriamento Remoto aplicado ao monitoramento da cultura de café

O Sensoriamento Remoto pode ser definido como a arte e a ciência de se obter informações acerca de objetos presentes na superfície terrestre sem contato físico com os mesmos (JENSEN, 2009).

Em linhas gerais, a radiação solar ao incidir sobre o topo da atmosfera tem parte espalhada e/ou refletida pelas partículas atmosféricas e outra parte atravessa a atmosfera até interagir com os alvos terrestres (Figura 4). Nesta interação com os objetos, a radiação solar

pode sofrer um fracionamento em três partes: absorvida, transmitida e refletida, sendo esta última detectada por um sensor que pode estar posicionada a poucos metros do objeto ou dentro de plataformas áreas e orbitais. Sendo assim, cada objeto apresenta um comportamento diferente frente à radiação que nele incide, por conta das suas propriedades físico-químicas, denominado comportamento ou resposta espectral. Além das propriedades físico-químicas, outras características como comprimentos de onda, ângulo de incidência e polarização, interferem no comportamento espectral dos alvos (PONZONI, 2001).

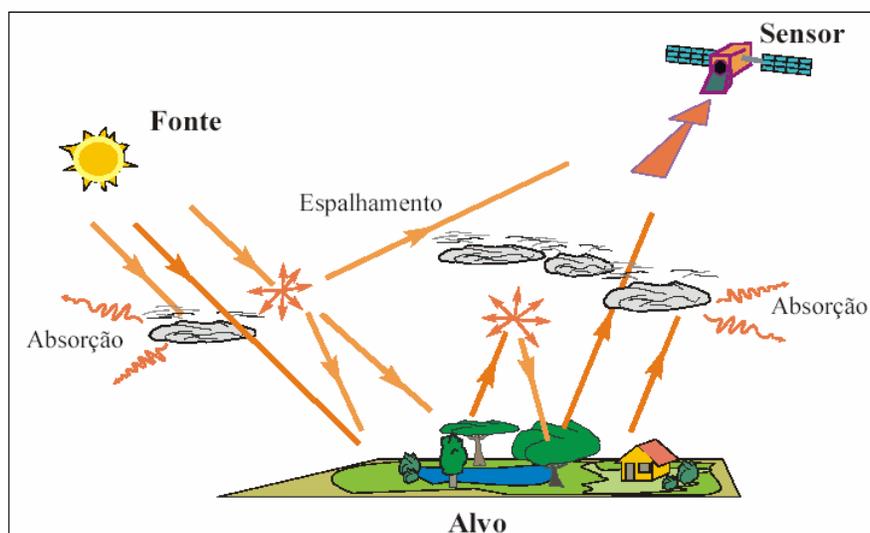


Figura 4. Influência da atmosfera na trajetória da radiação eletromagnética entre a fonte e o sensor. Fonte: MOREIRA (2002).

Segundo PONZONI & SHIMABUKURO (2007):

“a “aparência” da cobertura vegetal em um determinado produto de sensoriamento remoto é fruto de um processo complexo que envolve muitos parâmetros e fatores ambientais. O que é medido efetivamente por um sensor remotamente situado, oriundo de um dossel vegetal, não pode ser explicado somente pelas características intrínsecas deste dossel.” (p.35)

Ainda de acordo com PONZONI & SHIMABUKURO (2007), o fluxo radiante solar sobre um dossel é constituído por duas partes: o fluxo direto e o fluxo difuso. O fluxo direto é a fração da radiação que não é absorvida ou espalhada pela atmosfera. O fluxo difuso é a parte que é espalhada pela atmosfera na direção descendente, incidindo sobre o dossel de forma difusa.

Nota-se, portanto, que a radiação solar incidente sobre um dossel é espalhada e refletida, tendo sua direção e composição espectral alteradas de maneira bastante complexa. Essa alteração é causada tanto por parâmetros inerentes ao próprio dossel, quanto por fatores ambientais (GOEL, 1988).

Exemplos de trabalhos de Sensoriamento Remoto em áreas agrícolas, especificamente em cafeicultura com resultados satisfatórios pode-se citar o de TARDIN et al. (1992) realizado em uma área de testes em Alfenas, no Sul de Minas Gerais. Nesse estudo de mapeamento da cultura de café, foram utilizadas imagens do sensor TM do Landsat aplicando a técnica do algoritmo Máxima Verossimilhança.

Outro estudo dessa natureza ocorreu também no Sul de Minas Gerais, na região entre os municípios de Alfenas e Campo do Meio. Tal estudo realizado por EIPHANIO et al. (1994) utilizou-se de imagens do Landsat TM para avaliar as relações entre parâmetros culturais e a resposta espectral de cafezais.

Vale ressaltar que trabalhos anteriores ao lançamento do sensor TM Landsat não obtiveram êxitos devido à resolução espacial do sensor MSS/Landsat não ser adequada, bem como a heterogeneidade dos parâmetros culturais do café (EIPHANIO et al. 1994) .

Visando avaliar a qualidade dos diferentes métodos de classificação automática para geração de um mapa de uso do solo, BERNARDES et al. (2007) aplicou as classificações automáticas Máxima Verossimilhança, Ioseg e Battacharya sobre uma composição R(4)G(5)B(3) em imagens Landsat TM do município de Patrocínio/MG, importante região produtora de café. De acordo como os resultados, a melhor classificação obtida foi pelo algoritmo Battacharya, com 73% de acerto, seguido do classificador Máxima Verossimilhança com 57% e ISOSEG com 47% de acerto em relação à interpretação visual, considerada na análise como referência. Segundo o estudo, as áreas de relevo acidentado e lavouras fragmentadas e contíguas a remanescentes de vegetação nativa causaram maior confusão espectral.

No âmbito de superar as limitações da resolução espacial, HIRANO & BAMBANG (2007) mapearam as áreas de café da região da Província de Lampung, na Indonésia com imagens do satélite ALOS (*Advanced Land Observing Satellite*). Tal estudo buscou melhorar o mapeamento através da classificação supervisionada Máxima Verossimilhança em imagens ALOS/AVINIR-2 (*Advanced Visible and Near Infrared Radiometer-type 2*) com 10 metros de

resolução espacial e ALOS/PRISM (*Panchromatic Remote-Sensing Instrument for Stereo Mapping*) com 2,5 metros de resolução espacial, sendo esta última a banda pancromática. Apesar da boa resolução espacial, ideal para mapeamento com escala de 1:50.000 ou 1:25.000, os autores constataram que a resolução temporal foi crítica, uma vez que a alta nebulosidade impediu a aquisição de imagens livres de nuvens.

Com o objetivo de avaliar o potencial das imagens da série Landsat (TM e ETM+), MOREIRA et al. (2004) analisaram as respostas espectral e temporal das lavouras de café em produção e formação na região centro-sul do Estado de Minas Gerais. Segundo a classificação visual feita através do processo de vetorização e utilizando as bandas 3, 4 e 5 dos sensores TM e ETM+, verificou-se que a banda 4, correspondente à região do infravermelho próximo do espectro, foi a ideal para distinguir as lavouras de café em formação e em produção dos alvos pastagem e mata. Em contrapartida, a separação das classes de café em formação e pastagem nas bandas 3 e 5 não foi possível, dada à similaridade da resposta espectral. Outra constatação deste estudo foi de que o sistema convencional de plantio de café com 3 metros entre as linhas e 1,5 metros entre as covas, acaba por gerar a resposta espectral muito influenciada pelo solo. Ou seja, lavouras com maiores espaçamentos apresentaram maiores valores de refletância na banda 3 e menores valores na banda 4, por causa da maior influência do solo na resposta espectral.

Portanto, uma das dificuldades de se obter a resposta espectral do café reside na mistura espectral com outros alvos e, entre estes, o solo. O solo deve ser levado em consideração na análise espectral, pois dependendo de como foi feito o manejo, os espaçamentos entre os pés de café pode ou não expor mais o solo, o que influencia uma maior mistura espectral dos pixels (MOREIRA et al. 2004; TRABAQUINI et al. 2009).

SANTOS et al. (2012) lembram que outra dificuldade na identificação de áreas de café está no fato que essa cultura geralmente cresce em regiões montanhosas e isto causa sombras e distorções na resposta espectral, que tornam difícil a classificação e a interpretação de alvos sombreados na imagem, pois a resposta espectral é reduzida ou totalmente perdida. Além disso, o crescimento do café não é uma atividade sazonal e, portanto, em uma mesma região pode haver plantações de café com diferentes idades, o que também afeta os padrões espectrais observados.

Nesse sentido, estudos para minimizar o problema da confusão de mistura espectral nas áreas de café têm sido desenvolvidos. SOUZA & MOREIRA (2001) aplicaram diversas técnicas de pré-processamento com o objetivo de melhorar a classificação e a segmentação. Segundo esta pesquisa, a aplicação do MLME (Modelo Linear de Mistura Espectral) foi a que apresentou os melhores resultados. De acordo com os autores, as imagens-fração solo, vegetação e sombra, obtidas dos dados originais do Landsat/TM podem aperfeiçoar de forma significativa a classificação da área de café antes da aplicação da classificação supervisionada.

Observa-se assim, que desde o início da década de 1990 o uso do sensoriamento remoto vem contribuindo para o mapeamento e monitoramento da cultura do café e a escolha dos sensores e das técnicas deve se adequar às peculiaridades do objeto de estudo. Dentre as diversas técnicas, o MLME vem se mostrando fundamental sobre como resolver e/ou minimizar a questão da mistura espectral de diferentes alvos dentro de um mesmo *pixel*.

3.3.1. Modelo Linear de Mistura Espectral

Um dos problemas de se trabalhar com imagens de sensoriamento remoto diz respeito à chamada mistura espectral, devido ao tamanho do pixel ao incluir diferentes objetos ou elementos (Figura 5). A essa resposta espectral de um pixel resultante da combinação dos componentes dá-se o nome de mistura espectral (PONZONI & SHIMABUKURO, 2007).

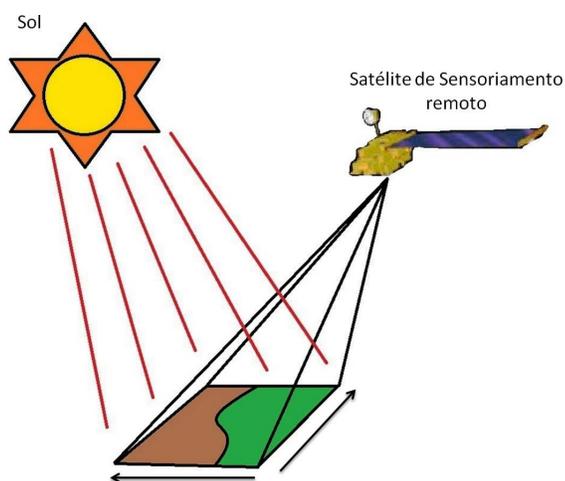


Figura 5. Diferentes elementos contidos em um pixel. Fonte: Elaboração do autor.

Segundo PONZONI & SHIMABUKURO (2007, p. 91), “a mistura espectral pode se dar de duas maneiras: a) quando o campo de visada instantânea cobre os limites entre dois ou

mais objetos; e b) quando os objetos são muito menores do que o *pixel*”; como ilustra a Figura 6.

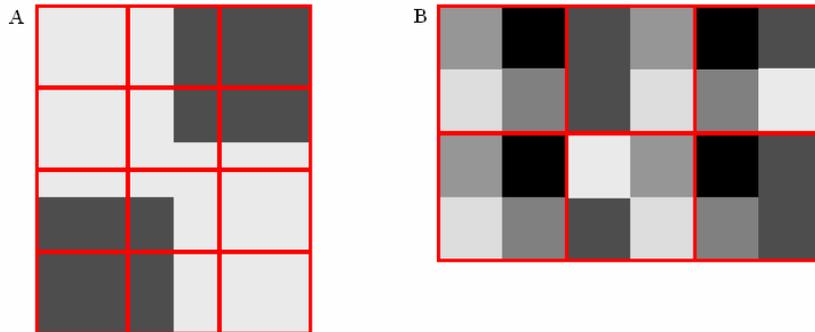


Figura 6. (A) Campo de visada instantânea cobrindo os limites entre dois ou mais objetos. (B) Objetos menores que o tamanho do pixel. Fonte: FERREIRA, 2003.

Partindo do princípio de que um *pixel* é uma combinação linear da refletância de diferentes alvos, contendo informação sobre a proporção e a resposta espectral de cada componente dentro do elemento de resolução espacial do sensor, será possível, então, estimar a proporção de cada componente na mistura.

Nesse sentido, a técnica do Modelo Linear de Mistura Espectral – MLME tem por escala de análise o *sub-pixel*, isto é, visa isolar a contribuição espectral de cada alvo presente no pixel.

O Modelo Linear de Mistura Espectral pode ser escrito da seguinte forma:

$$r_1 = a_{11} x_1 + a_{12} x_2 + \dots + a_{1n} x_n + e_1$$

$$r_2 = a_{21} x_1 + a_{22} x_2 + \dots + a_{2n} x_n + e_2$$

$$\begin{matrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{matrix}$$

$$r_m = a_{m1} x_1 + a_{m2} x_2 + \dots + a_{mn} x_n + e_m$$

isto é

$$r_i = \sum (a_{ij} x_j) + e_i$$

Equação (1)

Onde: r_i = refletância espectral média para i-ésima banda espectral;

a_{ij} = reflectância espectral da j -ésima componente no pixel para a i -ésima banda espectral;

x_j = valor de proporção da j -ésima componente no pixel;

e_i = erro para a i -ésima banda espectral;

$j = 1, 2, \dots, n$ (n = número de componentes assumidos para o problema);

$i = 1, 2, \dots, m$ (m = número de bandas espectrais para o sistema sensor).

Como se pode observar, o MLME é um típico exemplo de inversão (medidas indiretas) em sensoriamento remoto e sua solução matemática baseia-se no método dos mínimos quadrados (PONZONI & SHIMABUKURO, 2007). Tais métodos são:

a) Mínimos Quadrados com Restrição (*Constrained Least Squares – CLS*): o método mais simples e aplicável quando o número de componentes é igual a três, podendo ser para 4 ou mais, mas apresentando maior complexidade. Os valores de proporção devem ser não negativos e devem somar 1.

b) Mínimos Quadrados Ponderados (*Weighted Least Squares – WLS*): é o método mais geral e pode ser aplicado a uma ampla variedade de problemas de ajuste de curvas envolvendo formas lineares com constantes indeterminadas. Sua utilização é recomendada para os casos em que o número de componentes na mistura espectral for maior do que três.

c) Principais Componentes: é o método que reduz a dimensionalidade do conjunto de dados aplicando uma análise de componentes principais. Sua aplicação é recomendável quando o número de componentes for maior do que três.

Após a escolha dos algoritmos descritos acima, o MLME gera as chamadas imagens-fração. As imagens-fração representam as proporções dos componentes na mistura espectral, realçando os componentes para cada imagem. Por exemplo: a imagem-fração solo realça as áreas de solo exposto; a imagem-fração vegetação realça as áreas de cobertura vegetal; e a imagem-fração sombra realça as áreas sombreadas. Nota-se que o MLME não gera classes de elementos, e sim *pixels* com maiores ou menores proporções dos alvos terrestres.

Para a geração das imagens-fração é necessária uma seleção de “*pixels* puros”, também conhecidos como *endmembers*, pois estes trarão novas informações a partir das respostas espectrais originais.

O MLME funciona, portanto, como um modelador de espectros misturados através de uma combinação linear dos *endmembers* (ROBERTS et al. 1998) e sua aplicação em estudos com imagens de baixa e média resolução espacial tem sido utilizada com êxito.

A aplicação do MLME tem sido amplamente difundida entre os estudos voltados para observações das mudanças de uso do solo, tanto relacionados às pesquisas de caráter ambiental, como o desmatamento, quanto de caráter agrícola, como identificação de culturas.

FERREIRA (2003) ao investigar o potencial do MLME em imagens do sensor ETM+ para o mapeamento das principais fitofisionomias de Cerrado no Parque Nacional de Brasília obteve bons resultados no realce dos componentes herbáceo, arbustivo e arbóreo. Sua metodologia consistiu em processar o MLME em duas partes, uma sendo adquiridos os *endmembers* diretamente na imagem e outra através de espectrorradiometria. Em ambos os casos utilizou-se Mínimos Quadrados Ponderados como algoritmo. Segundo o autor, em ambos os processamentos, o MLME foi mais eficaz até mesmo que o NDVI na discriminação dos alvos.

ANDERSON (2004), ao classificar e monitorar a cobertura vegetal do Estado do Mato Grosso a partir de dados multitemporais do sensor MODIS, destacou os bons resultados apresentados pelo modelo linear de mistura espectral devido à robustez para a detecção de novos desmatamentos e eficácia na identificação de áreas queimadas.

Com o objetivo de identificar os estágios de sucessão secundária da Floresta Amazônica na região leste-nordeste do Estado de Rondônia, LU et al. (2003) e LU et al. (2004) aplicaram o MLME em imagens do sensor TM. Dentre os resultados obtidos das imagens-fração foi possível obter um subproduto, isto é, identificou-se a cultura do café. De acordo com os estudos, o MLME se mostrou promissor se comparado à classificação supervisionada Máxima Verossimilhança, sobretudo, à medida que a vegetação entra em seu estágio maduro, por conta do aumento da participação da fração sombra.

VASCONCELOS & NOVO (2004), em um estudo voltado para melhorar o mapeamento do uso do solo na região Amazônica nas proximidades dos municípios de Tucuruí, Jacundá e Novo Repartimento, obtiveram bons resultados com a classificação supervisionada por regiões (distância Battacharrya). As técnicas de pré-processamento das imagens classificadas consistiram em gerar imagens-fração a partir do MLME em imagens Landsat TM (bandas 3, 4 e 5) e em seguida a execução da segmentação, o que permitiu uma

boa separação entre regeneração e a classe agrossilvopastoril. Segundo os autores, as imagens-frações solo e sombra foram importantes para o classificador Battacharrya diferenciar as classes vegetação nativa, regeneração e agrossilvopastoril.

Inúmeros são os exemplos de aplicação do MLME nos estudos em culturas agrícolas como, por exemplo, o trabalho de ALVES (2009) ao mostrar a possibilidade de mapear a cultura de arroz irrigado no Estado do Rio Grande do Sul utilizando técnicas de segmentação e classificação sobre as imagens-fração derivadas da aplicação do MLME em imagens MODIS, produto MOD13Q1. A autora concluiu que o uso das imagens-fração é viável no mapeamento, uma vez que estas permitem identificar adequadamente as áreas de solo, vegetação e água.

Outro exemplo com êxito foi o de AGUIAR (2007) ao empregar o MLME sobre imagens diárias de refletância do sensor MODIS/Terra para identificar o modo de colheita de cana-de-açúcar, com a prática da queima e mecanizada. Neste estudo, foram escolhidos três *endmembers* com base nos valores de refletância das bandas 1, 2, 5 e 6 do sensor MODIS/Terra, produto MOD09GHK: cana (para áreas com cana em pé), palha (para áreas colhidas sem uso do fogo) e queima (para áreas colhidas com uso do fogo). Fez-se necessário reamostrar para 250 m os *pixels* das bandas 5 e 6, com o uso do aplicativo MODIS *Reprojection Tools* (MRT).

Em um estudo similar, mas com imagens do sensor TM Landsat, MELLO et al. (2009) obteve bons resultados no mapeamento de áreas de colheita de cana-de-açúcar com e sem a queima da palha ao comparar com outros métodos de classificação automática.

Utilizando imagens do sensor ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) para identificar e monitorar áreas de cultivo de feijão sob pivô central na região do Distrito Federal, PAPA et al. (2011) alcançou resultados relevantes ao aplicar o MLME. A metodologia consistiu em coletar os *endmembers* através de leituras das assinaturas espectrais do feijão, do solo e da palha por meio do sensor laboratorial hiperespectral FieldSpec@3 , com leitura da radiação eletromagnética refletida no intervalo de comprimento de onda 0,350 a 2,500 μm , compreendido nas faixas do visível, infravermelho próximo e infravermelho de ondas curtas do espectro.

3.3.2. Métodos de classificação automática

Dentre as técnicas utilizadas em Sensoriamento Remoto, às de classificação automática têm sido amplamente difundida por facilitar o mapeamento, bem como pela rapidez no processo. De acordo com CROSTA (2002), a classificação automática de imagens visa à categorização da cobertura do solo distinguindo as composições de diferentes materiais superficiais.

Nesse sentido, a classificação de imagens consiste em um processo de reconhecimento de classes ou grupos, os quais os elementos exibem características comuns. Os métodos de classificação automática podem ser divididos em dois grandes grupos: não-supervisionado e supervisionado.

No primeiro grupo as classes são definidas automaticamente pelo próprio algoritmo da classificação. Segundo CROSTA (2002) a classificação não-supervisionada baseia-se no princípio de que o aplicativo é capaz de identificar por si só as classes dentro de um conjunto de dados, e para melhor entender esse conceito faz-se necessário olhar para o espaço de atributos de todos os pixels que compõe uma imagem, e não apenas para os pixels que constituem as áreas de treinamento.

RICHARDS (1986) ressalta que a classificação não supervisionada é realizada na maioria das vezes através de métodos de agrupamento, ou seja, o algoritmo identifica as classes e separa os pixels pertencentes a cada uma delas sem a interferência do analista. De acordo com o autor, a classificação não supervisionada é útil para determinar a composição das classes espectrais dos dados antes de uma análise mais detalhada que poderá ser feita com os métodos de classificação supervisionada. Entre os exemplos desta classificação estão os algoritmos K-Médias e IsoSeg (ou IsoData).

No segundo grupo as informações para definir as classes temáticas são independentes, seja através de amostras ou assinaturas espectrais. O método de classificação supervisionada exige do usuário um breve conhecimento da área a ser classificada antes de iniciar o processo. Ideal seria haver locais específicos dentro da área a ser classificada onde observações de campo tivessem sido efetuadas durante a passagem do satélite para adquirir as imagens (CROSTA, 2002). Nesse grupo estão, por exemplo, os algoritmos Máxima Verossimilhança, Paralelepípedo, Mínima Distância e Distância de Mahalanobis.

Ainda que a classificação tenha como objetivo distinguir e identificar os diferentes alvos em uma imagem, existem as limitações no que se refere à simplificação das informações

contidas em uma imagem, pois na verdade há grande complexidade em uma cena de satélite (CROSTA, 2002).

Nesse sentido, existem outros métodos de classificação automática mais complexos, como é o caso *Support Vector Machine* (SVM). No caso da cafeicultura, o SVM apresenta-se como promissor devido ao seu potencial em classificar áreas heterogêneas com poucas amostras de treinamento (MELGANI e BRUZZONE, 2004).

3.3.3. Classificador SVM

O *Support Vector Machine* (SVM) faz parte da nova geração de sistemas de aprendizado supervisionados baseados na teoria de aprendizagem estatística. Vapnik e colaboradores foram os pioneiros neste novo método e obtiveram sucesso em muitos problemas de classificação (GONÇALVES et al., 2006).

MELGANI e BRUZZONE (2004) colocam que recentemente o SVM tem recebido particular atenção para a classificação de imagens multiespectrais de sensoriamento remoto. Este método frequentemente tem encontrado acurácias elevadas na classificação quando comparado a outras técnicas de reconhecimento de padrão amplamente utilizadas, tais como máxima verossimilhança e rede neurais. Além disso, os autores destacam que o SVM se mostra especialmente vantajoso na presença de classes heterogêneas para as quais há somente poucas amostras de treinamento disponíveis.

O SVM é um método de classificação supervisionada desenvolvido especialmente para obter bons resultados de classificação sobre imagens complexas e ruidosas. Baseia-se na separação das classes através de uma superfície de decisão que maximiza a margem de separação entre tais classes. Essa superfície também é conhecida como hiperplano ideal (*optimal hyperplane*) e os pontos que estão próximos a margem do hiperplano ideal chamam-se vetores de suporte (*support vectors*). Ainda que o SVM seja um classificador binário na sua forma mais simples, ele pode funcionar como um classificador multiclases, através da combinação de vários classificadores binários SVM (ENVI, 2008 e BROWN et al. 2000).

A Figura 7 ilustra dois possíveis separadores de classes que estão distribuídas linearmente. Entre as várias possibilidades para obtenção do hiperplano ideal, deve-se avaliar qual delas faz a melhor distinção entre as duas categorias.

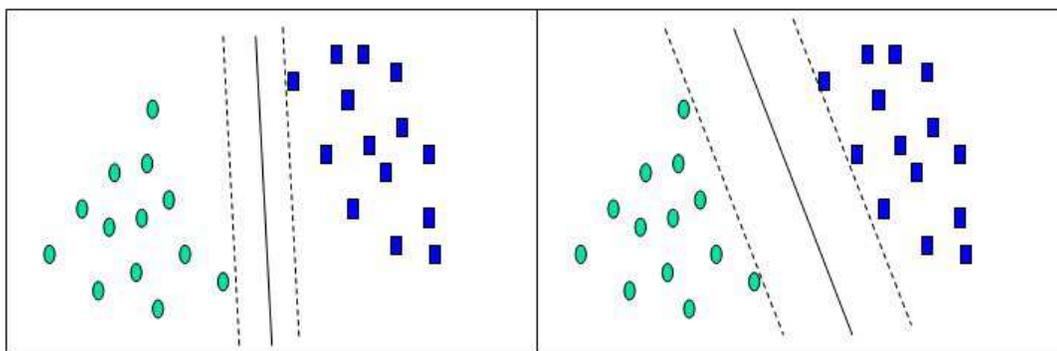


Figura 7. Exemplos de classificação SVM, que separou as duas classes (círculos e quadrados). Fonte: DTREG <<http://www.dtreg.com/svm.htm>> Acesso em: 04 dez. 2012.

Os vetores de suporte são elementos críticos do sistema de treinamento, pois o algoritmo faz uso destes dados para gerar a classificação (ENVI, 2008). A Figura 8 recupera a figura anterior, agora evidenciando as margens e os vetores de suporte de cada classe. Neste exemplo, observa-se que o classificador da direita é o mais adequado, uma vez que segue a premissa básica do SVM, ou seja, o hiperplano ideal deve apresentar a maior margem possível entre a função de separação e os vetores de suporte. Segundo DODONOV e MELLO (2008), é assumido que quanto maior for a margem de distância entre os planos, menor é o erro de generalização do classificador.

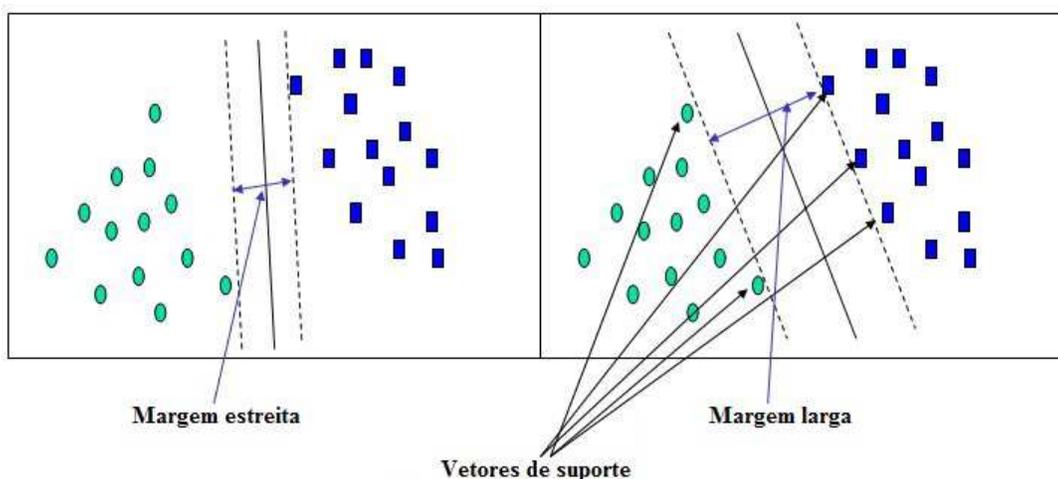


Figura 8. Exemplos de classificação SVM, mostrando as margens e vetores de suporte. Fonte: Adaptado de DTREG <<http://www.dtreg.com/svm.htm>> Acesso em: 04 dez. 2012.

O SVM possui quatro funções: linear, quadrática, polinomial e função de base radial (FBR). SALLABA (2011) testou o potencial do SVM para classificar os dados de sazonalidade de séries temporais do sensor MODIS, a fim de distinguir as classes de uso e cobertura da terra em uma área localizada no sul da Suécia. Com objetivo de encontrar o melhor resultado considerando o tempo de processamento computacional, a complexidade e a acurácia da classificação, o autor aplicou três parâmetros do SVM comumente utilizados (linear, polinomial e FBR) e validou os resultados tendo como referência o CORINE Land Cover 2006, para determinar qual deles obteve melhor desempenho. O parâmetro FBR apresentou performance ligeiramente melhor que o polinomial. O autor, porém, sugere o uso do parâmetro linear, pois este exigiu menos tempo computacional durante o treinamento do SVM e, além disso, a diferença nos valores de acurácia não foi significativa.

SHAO e LUNETTA (2012) classificaram a cobertura da terra do Sistema Estuarino Albemarle-Pamlico, localizado nos Estados Unidos, utilizando séries temporais de dados MODIS. Os autores compararam a performance do SVM com dois métodos convencionais: redes neurais e árvore de decisão, considerando a quantidade, variabilidade e pureza das amostras de treinamento. O SVM apresentou acurácia mais elevada e melhora significativa do coeficiente Kappa para toda a faixa de amostras de treinamento comparado aos outros algoritmos. Os resultados indicam que o SVM obteve maior capacidade de generalização, especialmente quando se utilizou menos amostras de treinamento.

Também utilizando séries temporais do MODIS, SENTHILNATH et al. (2012) combinaram classificação e segmentação de imagens para mapear o rio Krishna, no sul da Índia, e avaliar as regiões inundadas pelo rio. Para separar as classes água e não-água, foram aplicados os classificadores SVM e Redes Neurais Artificiais. Comparando estatisticamente ambos os classificadores, o SVM apresentou melhor desempenho tanto em imagens antes e depois da inundação quanto durante a inundação.

3.4. Sistema MODIS

3.4.1. O sensor MODIS e suas principais características

Abordo das plataformas Terra e Aqua, o sensor MODIS (*Moderate-resolution Imaging Spectroradiometer*) foi desenvolvido pela NASA (*National Aeronautics and Space Administration*) dentro de um contexto de consciência das mudanças causadas no clima global pós-convenção de Estocolmo de 1972.

Com passagem às 10h30min no Equador com órbita descendente, o MODIS Terra dispõe de 36 bandas contidas no intervalo de 0,4 a 14,4 μm do espectro eletromagnético. Sua resolução espacial está dividida em: 250 m (2 bandas), 500 m (5 bandas), 1000 m (29 bandas) em nadir. Já a sua cobertura de repetição é diária, a norte da latitude 30° e a cada dois dias, para latitudes inferiores a 30°.

Sua varredura de 55° para cada lado na órbita de 705 km de altura proporciona uma faixa imageada de 2.330 km. Os *pixels* crescem com um fator de duas vezes na direção ao longo da linha de imageamento (*long-track*) e de um fator de cinco vezes na direção através da linha de imageamento, denominado *cross-track* (Figura 9).

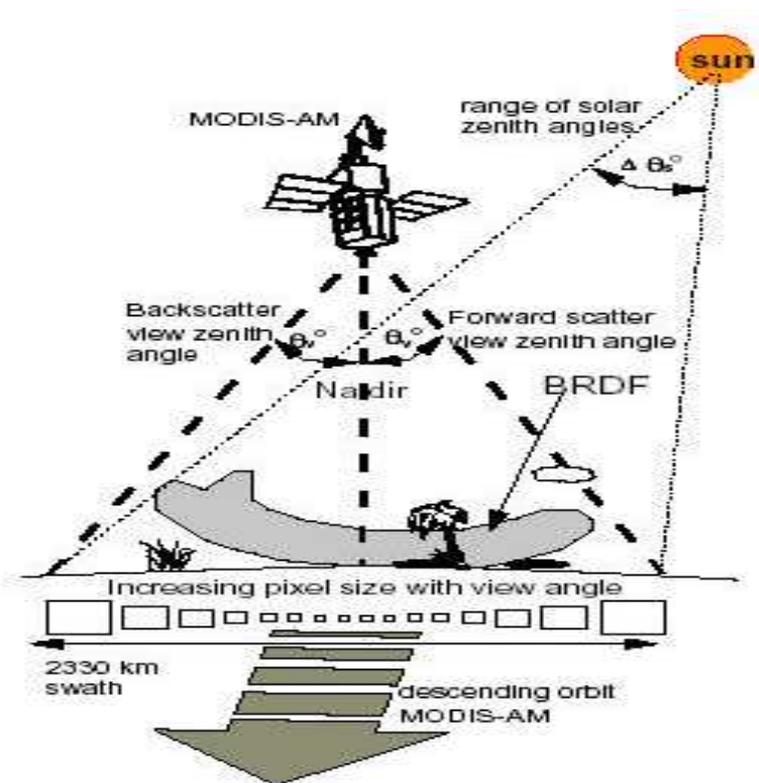


Figura 9. Varredura do MODIS, mostrando o aumento no tamanho dos pixels com a variação do ângulo de visada. Fonte: VAN LEEUWEN et al. (1999).

Outra característica do sistema MODIS é a sua disposição dos dados de forma hierárquica, isto é, de acordo com o grau de processamento dos dados. Estão distribuídos em 5 níveis de 0 a 4 (SOARES et al. 2007).

Distribuídos entre os níveis acima citados, o MODIS disponibiliza um total de 44 produtos, todos disponíveis gratuitamente pela NASA no formato HDF (*Hierarchy Data Format*), com projeção sinusoidal e dividido em quadrantes (*tiles*) de 10x10 graus, equivalente a 1200x1200 km (Figura 10).

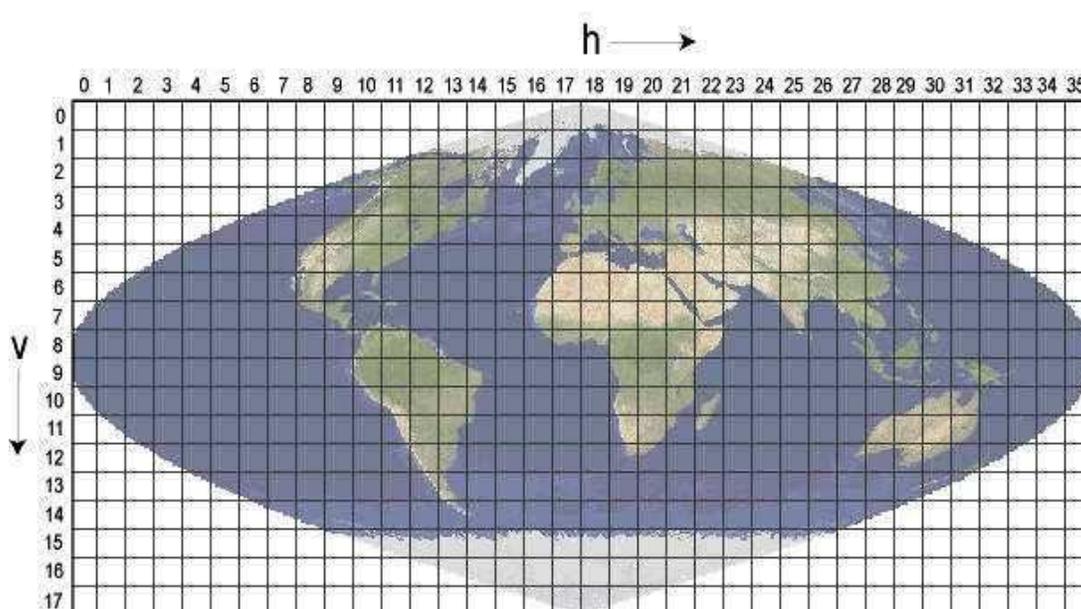


Figura 10. Representação do *tile* h (v) de 1200 x 1200 km. Fonte: <modis.gsfc.nasa.gov>. Acesso em: 14 dez. 2011.

Além destes produtos, é disponibilizado também o ATBD (*Algorithm Theoretical Basis Document*), um manual contendo todas as informações sobre os algoritmos utilizados para a geração dos produtos (SOARES et al. 2007).

3.4.2. O produto MOD13Q1

Os produtos MODIS relacionados ao estudo da vegetação são basicamente três: MOD15 – Leaf Área Index / fPAR e MOD17 - Net Primary Production /Net Photosynthesis e

MOD13 – Vegetation Índices (VI). Por sua vez, o produto MOD13 VI subdivide-se em MOD13A1, MOD13A2, MOD13A3, MOD13C1, MOD13C2 e o MOD13Q1, sendo este último fonte dos dados utilizados no presente estudo.

Todos os dados disponíveis do MOD13Q1 estão dispostos na Tabela 1.

Tabela 1. Características do produto MOD13Q1.

Conjunto de Dados	Unidade	Tipo de dado	Valor Nulo	Varição válida	Fator de Escala
NDVI	NDVI	16-bit	-3000	-2000 a 10000	0.0001
EVI	EVI	16-bit	-3000	-2000 a 10000	0.0001
Qualidade dos Índices de Vegetação	Bits	16-bit	65535	0 a 65534	-
Vermelho (Banda 1)	Refletância	16-bit	-1000	0 a 10000	0.0001
NIR (Banda 2)	Refletância	16-bit	-1000	0 a 10000	0.0001
Azul (Banda 3)	Refletância	16-bit	-1000	0 a 10000	0.0001
MIR (Banda 7)	Refletância	16-bit	-1000	0 a 10000	0.0001
Ângulo zenital de visada	Graus	16-bit	-10000	-9000 a 9000	0.01
Ângulo zenital solar	Graus	16-bit	-10000	-9000 a 9000	0.01
Ângulo azimute	Graus	16-bit	-4000	-3600 a 3600	0.01
Dia da composição	Dias Julianos	16-bit	-1	1 a 366	-
Qualidade do pixel	-	8-bit	-1	0 a 3	-

As bandas do MOD13Q1 utilizadas neste estudo são: o vermelho (620-670nm), o infravermelho próximo (841-876nm) e infravermelho médio (2105 - 2155nm).

4. MATERIAIS E MÉTODOS

4.1. Área de Estudo

Localizado na região Sul de Minas Gerais (Figura 11) e com uma área total de 592,5 km², o município de Monte Santo de Minas apresenta relevo bastante ondulado com serras e planaltos elevados, característico da região da Serra da Mantiqueira. A vegetação é marcada pela transição entre Mata Atlântica e Cerrado. O clima é subtropical de altitude (classificação climática de Köppen-Geiger: Cwa), com inverno ameno, podendo ocorrer geadas durante o inverno e verão quente e úmido. A temperatura média anual é de 20,6 C° e precipitação média anual de 1690 mm, concentrada entre os meses de dezembro e fevereiro. As principais classes de solo presentes no município são Latossolo, Neossolo, Luvisolo e Argissolo.

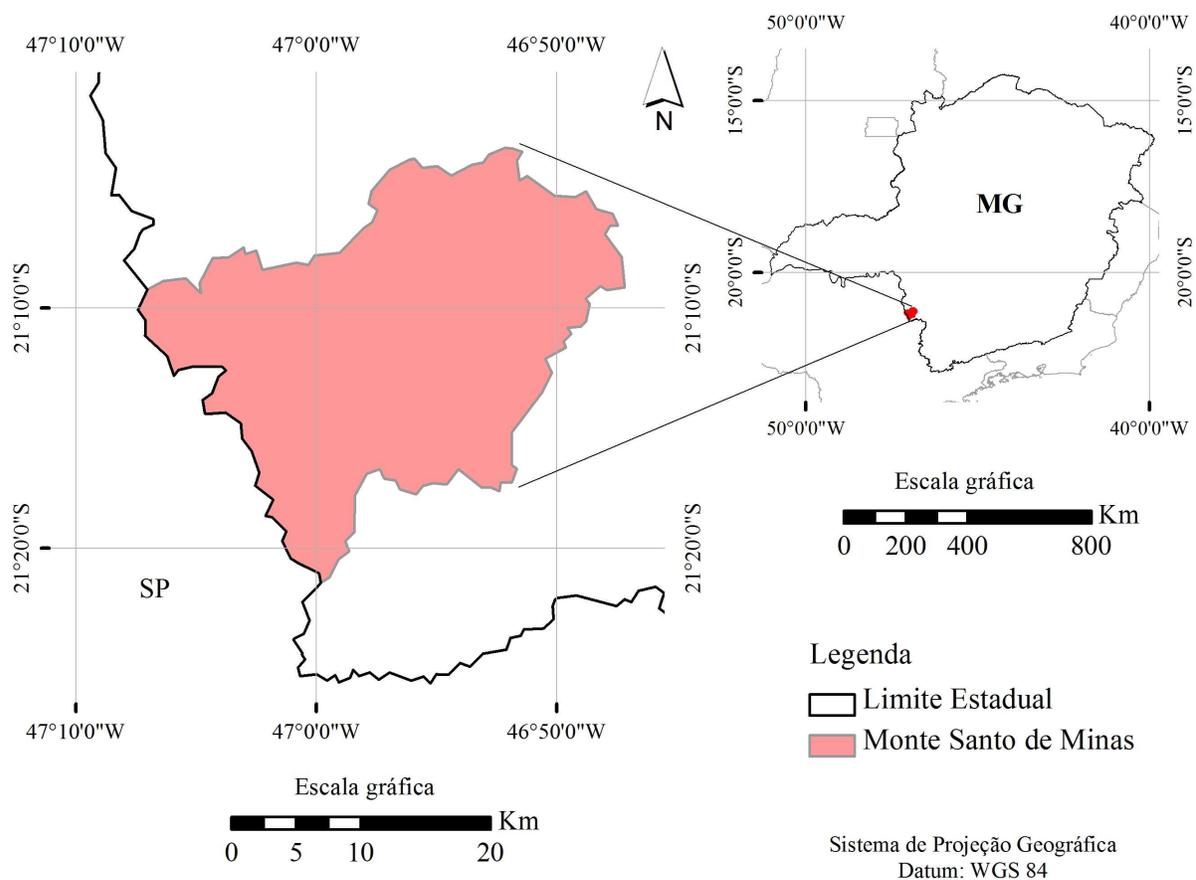


Figura 11. Localização da área de estudo.

Estas condições físicas contribuíram para fixação da atividade agrícola cafeeira, desenvolvida principalmente por pequenos produtores, sendo atualmente a maior responsável pela entrada de recursos financeiros no município.

4.1.1. Distribuição geográfica do café no município

Como se pode observar na Figura 12, a cafeicultura encontra-se bem espalhada no município de Monte Santo de Minas.

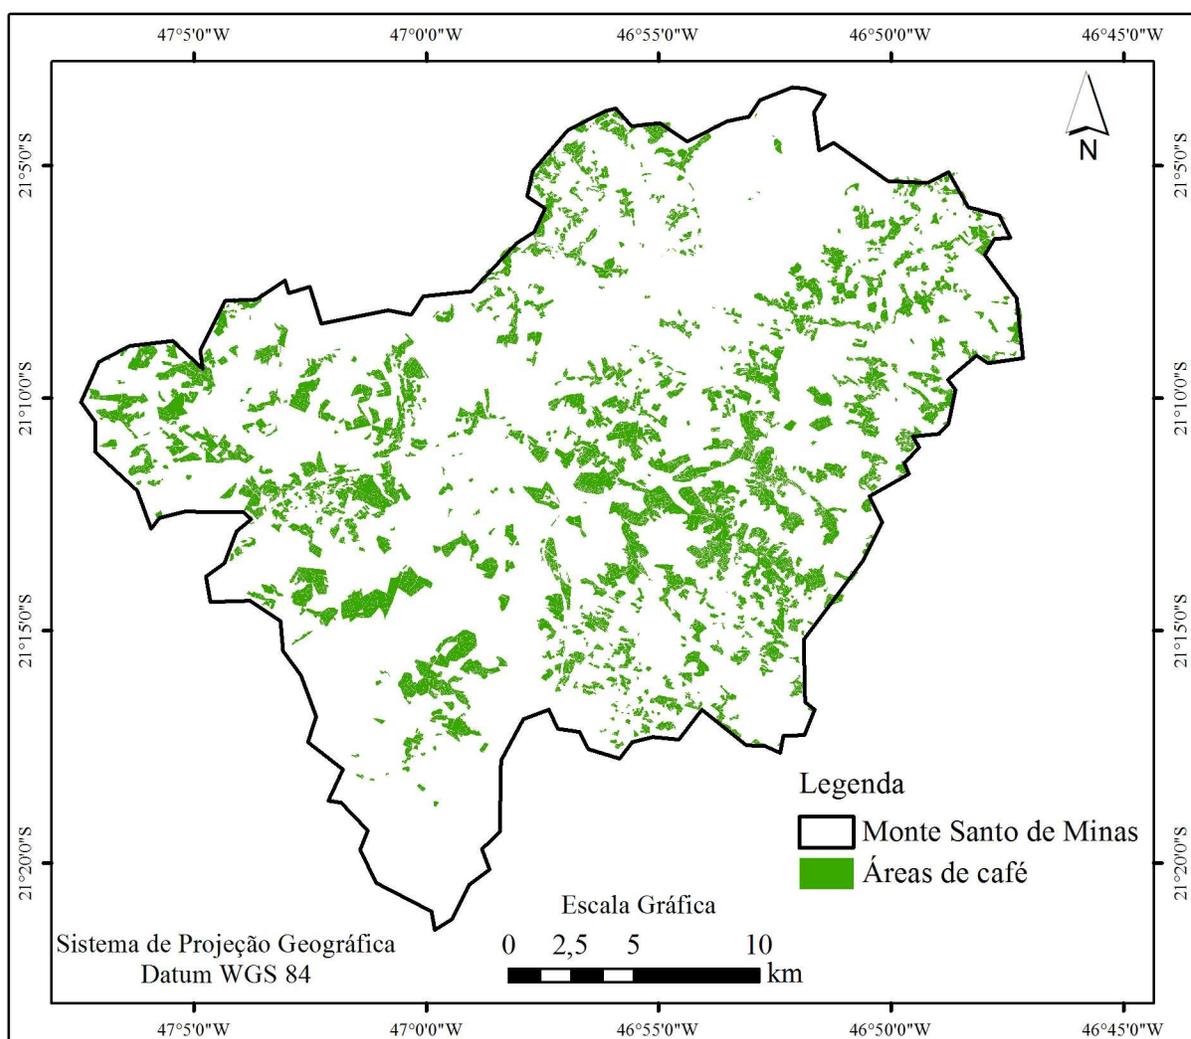


Figura 12. Distribuição espacial do café em Monte Santo de Minas. Fonte: Cooxupé, 2012.

Sabendo da importância do fator altitude na definição dos processos de alteração das temperaturas do ar (FILHO et al., 2006), Monte Santo de Minas oferece condições de altitude ideais para o cultivo do café. O mapa de altimetria do município (Figura 13) mostra que as áreas mais baixas encontram-se na região Sul e as mais elevadas estão nas regiões Norte e Oeste. Já na Figura 14, observa-se que praticamente a totalidade do café (98,9 %) no município situa-se entre 600 m e 1200 m de altitude, sendo que 68,9% estão entre 900 m a 1.100 m de altitude.

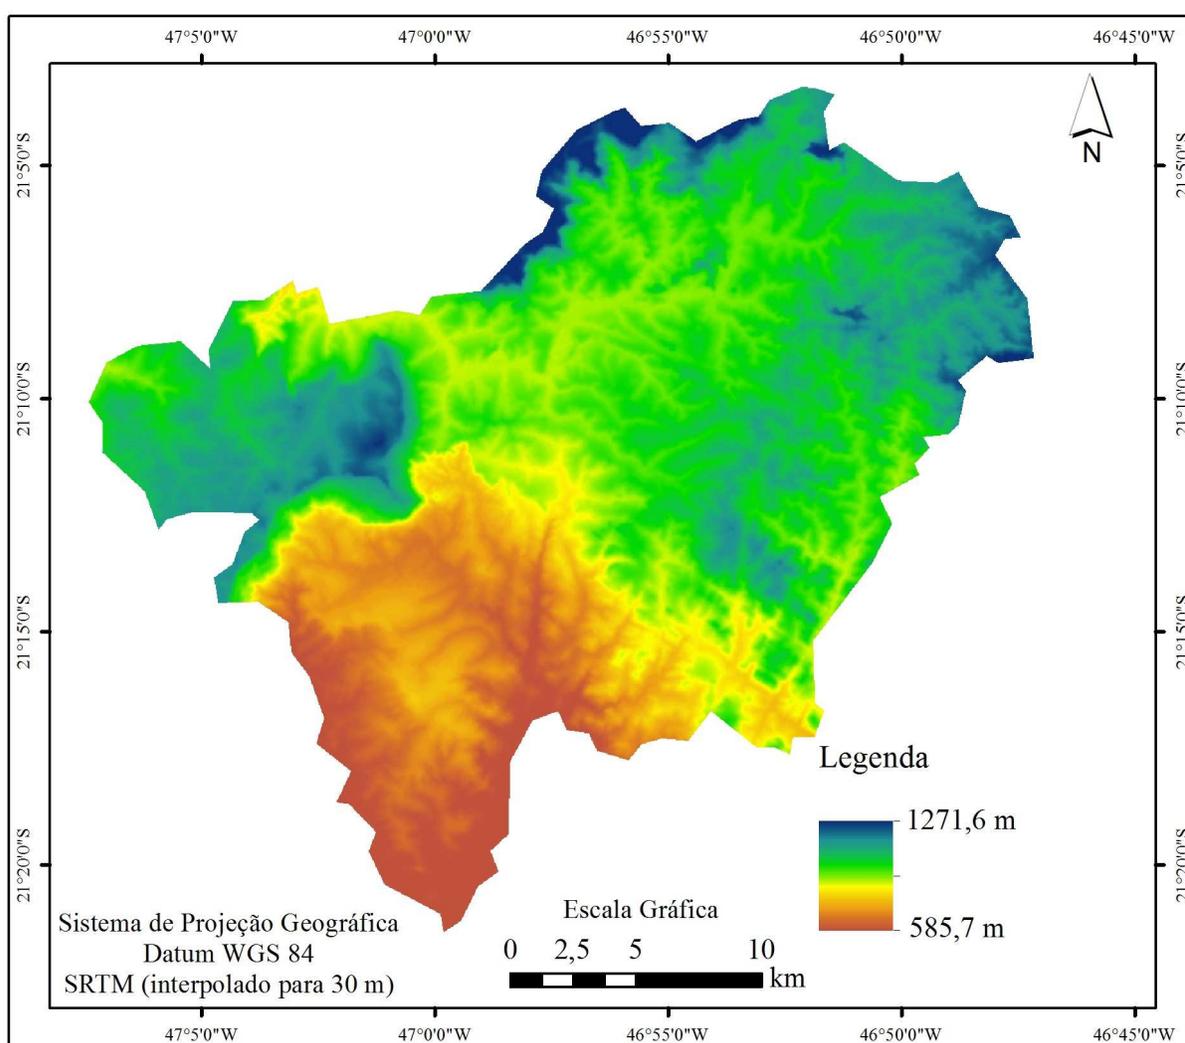


Figura 13. Mapa de altimetria do município de Monte Santo de Minas.

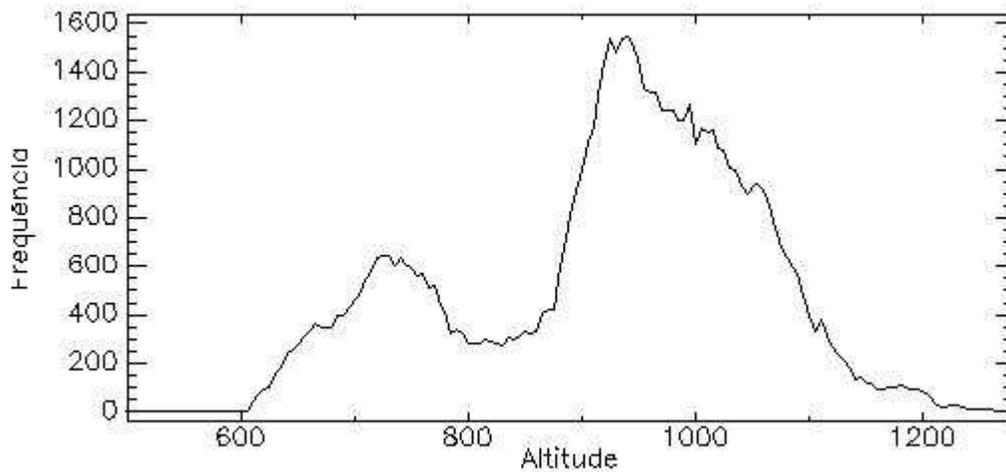


Figura 14. Histograma de altimetria das áreas de café de Monte Santo de Minas.

A Figura 15 ilustra as classes de declividade presentes no município de Monte Santo de Minas. Ao cruzar os polígonos das áreas de café com a declividade observou-se que: 18,3% do café estão em áreas com 0 a 5% de declividade; 44,5% estão em áreas com 5 a 10% de declividade; 24,1% estão em áreas com 10 a 15% de declividade; 7,5% em áreas com 15 a 20% de declividade; 4,4% em áreas com 20 a 30% de declividade; 0,9% em áreas com 30 a 40% de declividade; e por fim 0,3% do café está em áreas com 40 a 80% de declividade. Ou seja, mais de 90% do café está situado em condições propícias à mecanização, o que potencializa a redução de custos na produção.

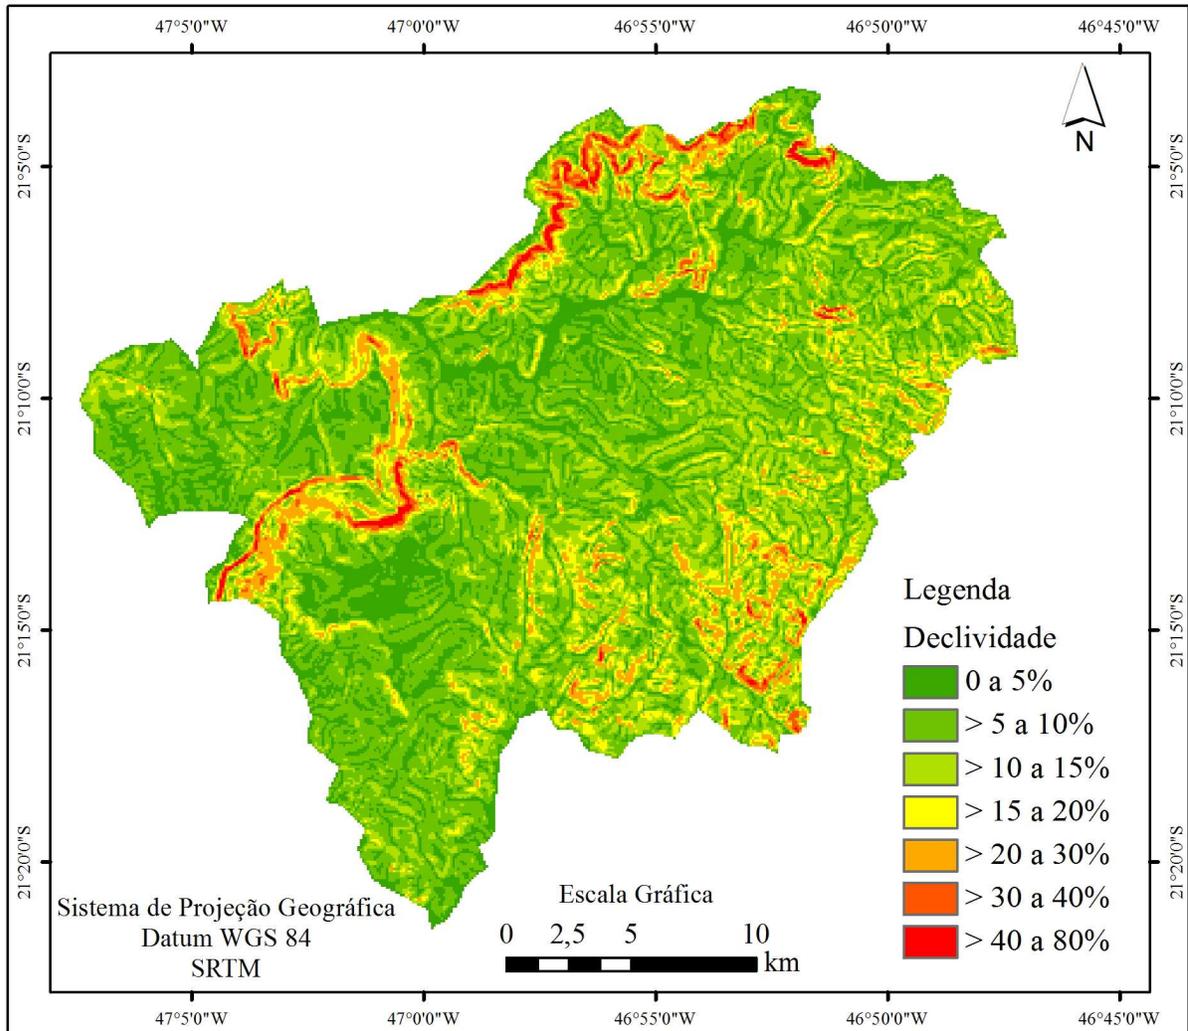


Figura 15. Mapa de declividade do município de Monte Santo de Minas.

Em Monte Santo de Minas, as áreas de café sobrepostas no mapa de orientação da vertente (Figura 16) encontram-se distribuídas de maneira praticamente equitativa: Norte= 12,8%; Nordeste = 13,4%; Noroeste = 11,1%; Leste = 13,4%; Sudeste = 13,0%; Sul = 13,7%; Sudoeste = 12,4%; Oeste = 10,2%. Isto é, 37,3 % do café estão nas condições ideais de recebimento de energia solar, nas faces Norte, Nordeste e Noroeste.

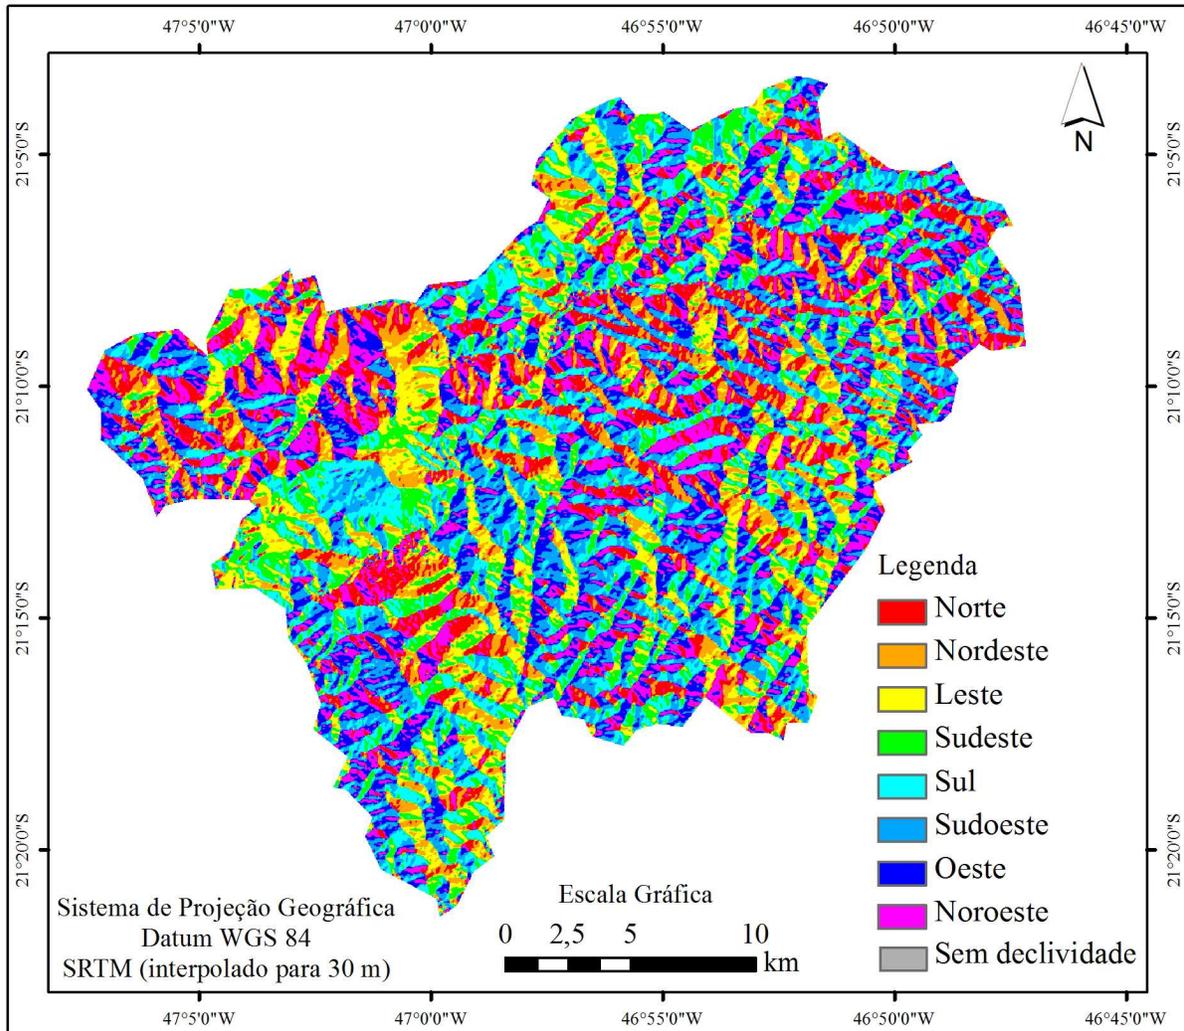


Figura 16. Mapa de orientação da vertente no município de Monte Santo de Minas.

4.2. Materiais

Para realização deste estudo foram utilizadas imagens do sensor MODIS a bordo da plataforma Terra, produto MOD13Q1, bandas vermelho (RED), infravermelho próximo (NIR) e infravermelho médio (MIR), do *tile* h13v11. Todas com resolução espacial de aproximadamente 250 metros (239,9 m x 249 m), temporal de 16 dias e projeção Sinusoidal.

Estas imagens foram convertidas do formato hdf para o formato tif e reprojetaadas para o Sistema de Projeção Geográfica e *Datum* WGS 84 através do aplicativo *Modis Reprojection Tools* (MRT), disponibilizado gratuitamente pela NASA, através do *site* <https://lpdaac.usgs.gov/tools/modis_reprojection_tool>.

Vale ressaltar que as imagens do produto MODIS não necessitam de qualquer tipo de correção, pois já passaram previamente por correções atmosférica, geométrica e radiométrica (SOARES et al. 2007).

Além das imagens MODIS, foram usadas imagens do sensor LISS III. A opção por esse sensor fez-se necessária pela melhor resolução espacial, de 23,5 metros, para fins estatísticos de correlação e de coeficiente de variação com os dados MODIS, de moderada resolução espacial.

Das imagens do sensor LISS III, satélite indiano IRS-P6 ResourceSat-1, foram adquiridas as bandas (B3) vermelho 0,62-0,68 μm ; (B4) infravermelho próximo 0,77-0,86 μm ; e (B5) infravermelho médio 1,55-1,70 μm . O sensor LISS III dispõe de resolução temporal de 24 dias e radiométrica de 7 bits. Estes dados estão disponibilizados gratuitamente pelo Instituto Nacional de Pesquisas Espaciais (INPE), através do *site* <<http://www.dgi.inpe.br/CDSR>>.

Paralelamente aos dados de sensoriamento remoto, utilizaram-se também dados diários de precipitação e de temperatura máxima e mínima da estação meteorológica localizada no município de Monte Santo de Minas, 21°11'53" S e 46°57'58" O, 908 m de altitude. Estes dados foram disponibilizados pela Cooxupé⁶.

Como apoio na identificação das áreas de plantio de café foi utilizada uma máscara feita através de classificação visual de uma imagem do satélite SPOT 5, com resolução espacial de 5 metros. Esta máscara data do segundo semestre de 2006 e também foi disponibilizada pela Cooxupé.

Os aplicativos usados para o processamento das imagens e confecção dos mapas finais foram o ENVI 4.5 e o ArcGis 9.3.

4.3. Procedimentos Metodológicos

Os procedimentos metodológicos estão divididos em dois núcleos: monitoramento e mapeamento. Estes por sua vez, estão subdivididos em etapas de execução.

⁶ A fundação da Cooxupé data do ano de 1932 como uma cooperativa de crédito agrícola e posteriormente, em 1957, transformada em Cooperativa de Cafeicultores. Atualmente conta com aproximadamente 12.000 cooperados e 1.900 colaboradores, recebendo a produção de café de mais de 200 municípios das regiões Sul de Minas, Alto Parnaíba, ambas de Minas Gerais e da região do Vale do Rio Pardo, no estado de São Paulo.

4.3.1. Monitoramento

A primeira etapa diz respeito à coleta e a organização dos dados de sensoriamento remoto e estação meteorológica.

Para fins de monitoramento do café, utilizou-se apenas a banda NIR do MODIS, produto MOD13Q1, entre o período de 28 de agosto de 2004 a 27 de agosto de 2012. Na sequência, foi feita uma série temporal, totalizando 163 cenas da banda NIR. A escolha pela banda NIR para o monitoramento se dá em razão da alta refletância do café nesta região espectral, pois como afirmam ZHAN et al. (2002) os intervalos de comprimentos de onda vermelho e infravermelho próximo estão entre as mais importantes regiões espectrais para o sensoriamento remoto da vegetação.

Os dados meteorológicos de temperatura do ar (°C) e precipitação (mm), medidos pela estação meteorológica em Monte Santo de Minas/MG foram organizados de maneira correspondente aos dados do MODIS, a cada 16 dias. Dessa forma, a cada 16 dias tem-se o valor médio de temperatura do ar e um valor do acumulado de precipitação.

A segunda etapa consistiu em utilizar os dados acima em conjunto para o monitoramento.

Para gerar os gráficos de refletância de café em toda série temporal, fez-se necessário selecionar o maior número de *pixels* do MODIS com pelo menos 80% de café em sua composição. Esta opção por 80% de café contido nos *pixels* de Modis foi adotada pelo critério de boa distribuição espacial dos *pixels* no município. A técnica empregada nesta etapa foi transformar os *pixels* do MODIS em polígonos e assim cruzar com a máscara de café da Cooxupé (Figura 17). Observa-se que, devido ao arruamento entre os cafezais, não foi possível ter um único polígono de *pixel* MODIS com 100% de café, sendo o valor máximo de 97,64%.

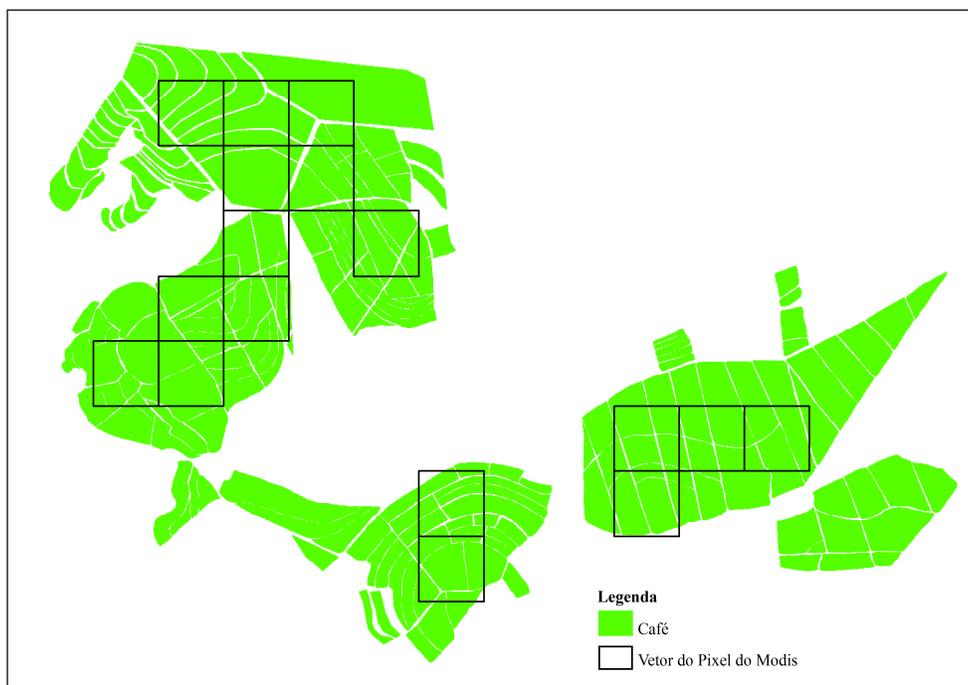


Figura 17. Exemplos de *pixels* MODIS transformados em polígonos sobrepostos à máscara de café da Cooxupé.

De posse de todos os polígonos dos *pixels* do MODIS com pelo menos 80% de café, um total de 414 *pixels*, efetuou-se a extração dos valores dos *pixels* das imagens NIR agrupadas na série temporal de 2004 a 2012, para geração dos gráficos de refletância de café.

Os dados da estação meteorológica foram utilizados para geração do balanço hídrico climatológico. O balanço hídrico foi calculado em planilha “EXCEL_MICROSOFT” conforme ROLIM et al. (1998), adotando-se o método de THORNTHWAITE & MATHER (1955), considerando uma capacidade de água disponível (CAD) de 100 mm, capaz de atender uma grande variedade de culturas e diversas aplicações hidrológicas. Nota-se que os dados de entrada (temperatura média do ar e precipitação) para o cálculo foram ajustados para corresponderem aos 16 dias de composição do MODIS.

Após realizar o cruzamento das informações de refletância e do balanço hídrico climatológico, o passo seguinte foi separá-los por ciclo bienal do café, isto é, de acordo com a esquematização das seis fases fenológicas do cafeeiro arábica, durante 24 meses, nas condições climáticas tropicais do Brasil, proposto por CAMARGO e CAMARGO (2001). Esta separação das informações conforme a bienalidade do café resultou em quatro ciclos de

produção: 28/08/2004 a 28/08/2006; 29/08/2006 a 27/08/2008; 28/08/2008 a 28/08/2010; 29/08/2010 a 27/08/2012.

A Figura 18 resume os procedimentos empregados para o monitoramento do café.

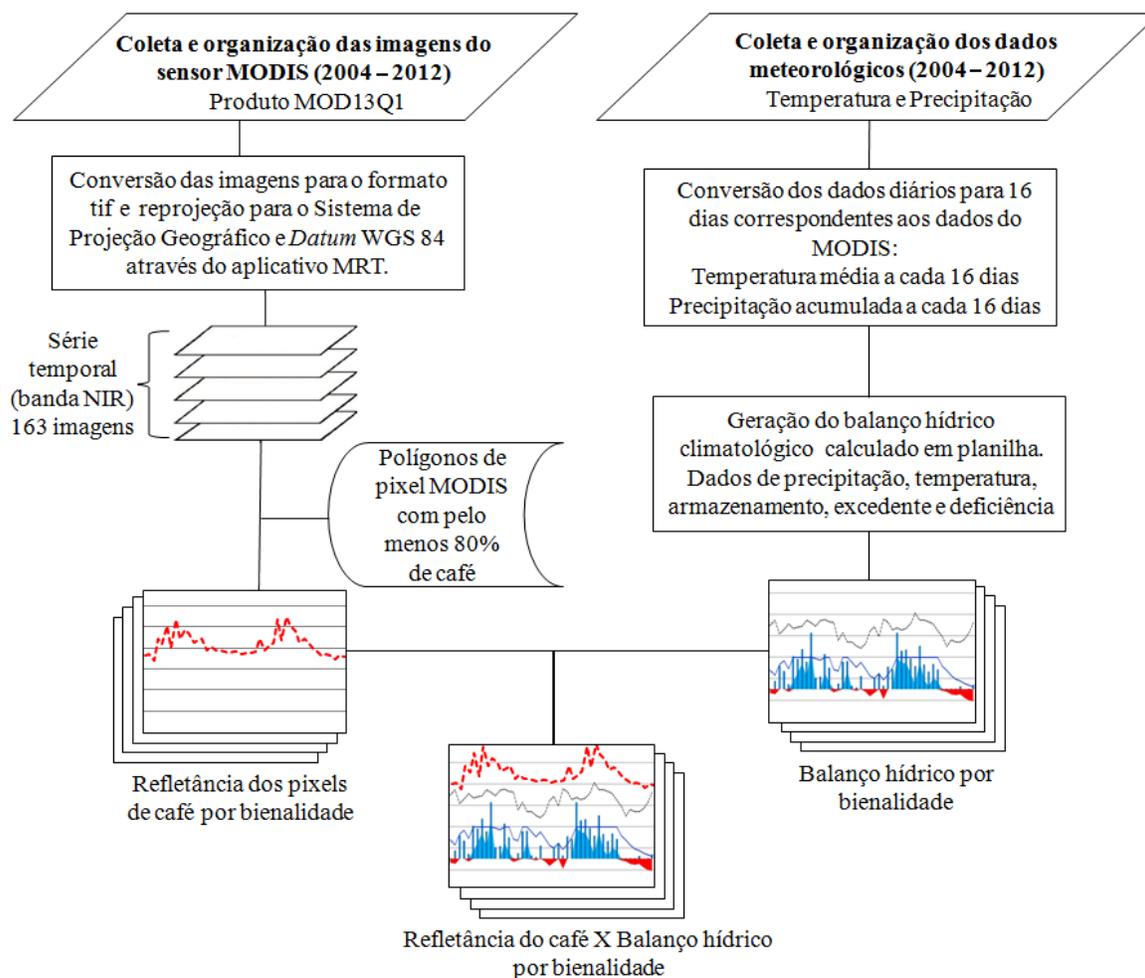


Figura 18. Fluxograma da metodologia para o monitoramento do café.

4.3.2. Mapeamento

O núcleo metodológico de mapeamento teve como ponto de partida a escolha das datas das imagens MODIS, tanto do período anterior à colheita (chuvoso), quanto do período posterior à colheita (estiagem). A primeira data corresponde ao período chuvoso, sendo a composição de 02 a 17 de fevereiro de 2012. A imagem de estiagem data do dia 28 de agosto a

12 de setembro de 2012. Ambas as imagens estavam livres de nuvens. Para cada data foi feita a composição R(MIR) G(NIR) B(RED) para aplicação do MLME e geração das imagens-fração (solo, café e água/sombra).

Além das composições das imagens, as informações dos *endmembers* de solo, café e água/sombra são necessárias para a aplicação do MLME. Os *endmembers* de solo e água/sombra foram escolhidos nas próprias imagens, estando os *pixels* de solo com maior resposta espectral na banda MIR e os *pixels* de água/sombra na banda RED, isto é, na faixa espectral onde estes alvos têm melhor resposta.

Entretanto, para a escolha do *endmember* de café, fez-se necessário buscar o valor mais alto de refletância na banda NIR em uma imagem de outra data, pois a imagem-fração de café obtida a partir do *endmember* selecionado na própria imagem de aplicação do MLME não apresentou valores de proporção contidos entre 0 a 1, prejudicando assim a estimativa de proporção de café.

O *pixel* MODIS de café com maior refletância no NIR foi selecionado na imagem de 01 a 16 de janeiro de 2008. Tal região onde se encontra esse *endmember* foi indicada previamente pelo Coordenador de Geoprocessamento da Cooxupé, Sr. Éder Ribeiro dos Santos, e depois conferida na série temporal de imagens NIR.

Na Figura 19 têm-se as curvas espectrais dos *endmembers* selecionados utilizados no MLME.

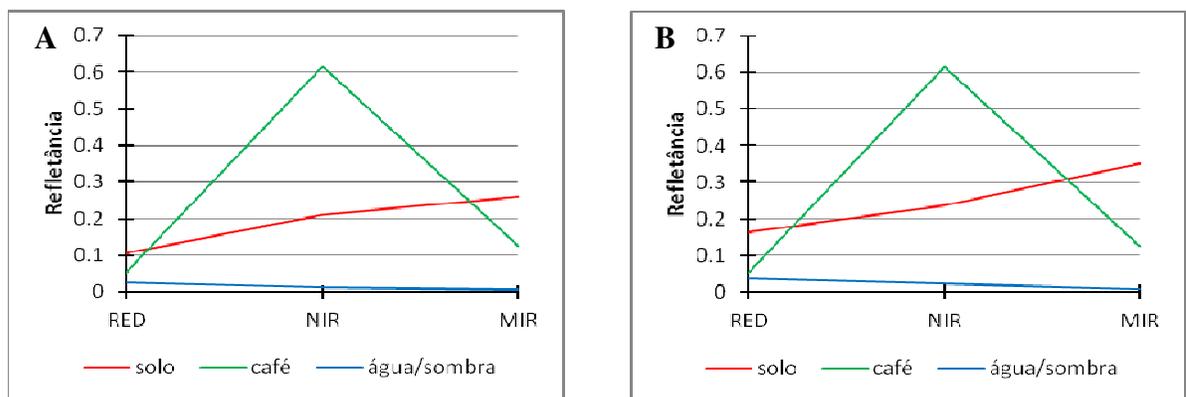


Figura 19. Curvas espectrais dos *endmembers* de solo, café e água/sombra. **A.** período chuvoso; **B.** período de estiagem.

Após a geração das imagens-fração para cada período, foi feita a composição RGB com as mesmas, sendo R(fração solo) G(fração café) B(fração sombra). Nessas composições foram feitos os testes de classificação utilizando o classificador automático supervisionado SVM com diversos parâmetros. Optou-se em utilizar a Função de Base Radial (FBR), testando diversos valores de parâmetro de penalidade para definir a probabilidade requerida ao classificador para classificar um determinado *pixel*. De acordo com os testes feitos, tanto para a imagem do período chuvoso quanto para a da estiagem, o melhor nível de probabilidade foi de 0,30, numa escala de 0 a 1, em que quanto mais próximo de 1, maior número de *pixels* não classificados.

Na etapa seguinte tratou-se da avaliação da acurácia da classificação por meio da Matriz de Erro, Exatidão Global e Índice Kappa. Foi gerada a Matriz de Erro, para cada período, a partir do cruzamento entre a classificação obtida (com as classes Café, Mata e Outros Usos), em sua totalidade, e a referência. Como referência terrestre, foram utilizadas as máscaras de café e de mata, ambas mapeadas visualmente e disponibilizadas pela Cooxupé, sendo que para o mapeamento do café foi feita uma checagem com 5.000 pontos em campo e Índice Kappa de 0,979, considerado excelente. Ainda sobre a máscara de café, esta foi atualizada durante o trabalho de campo realizado em setembro de 2012, pois havia dúvidas sobre algumas áreas quanto à mudança do uso do solo, isto é, deixou de ser café para outras culturas como cana-de-açúcar e eucalipto. A máscara de Outros Usos é o polígono do município resultante da extração das máscaras de café e mata (Figura 20).

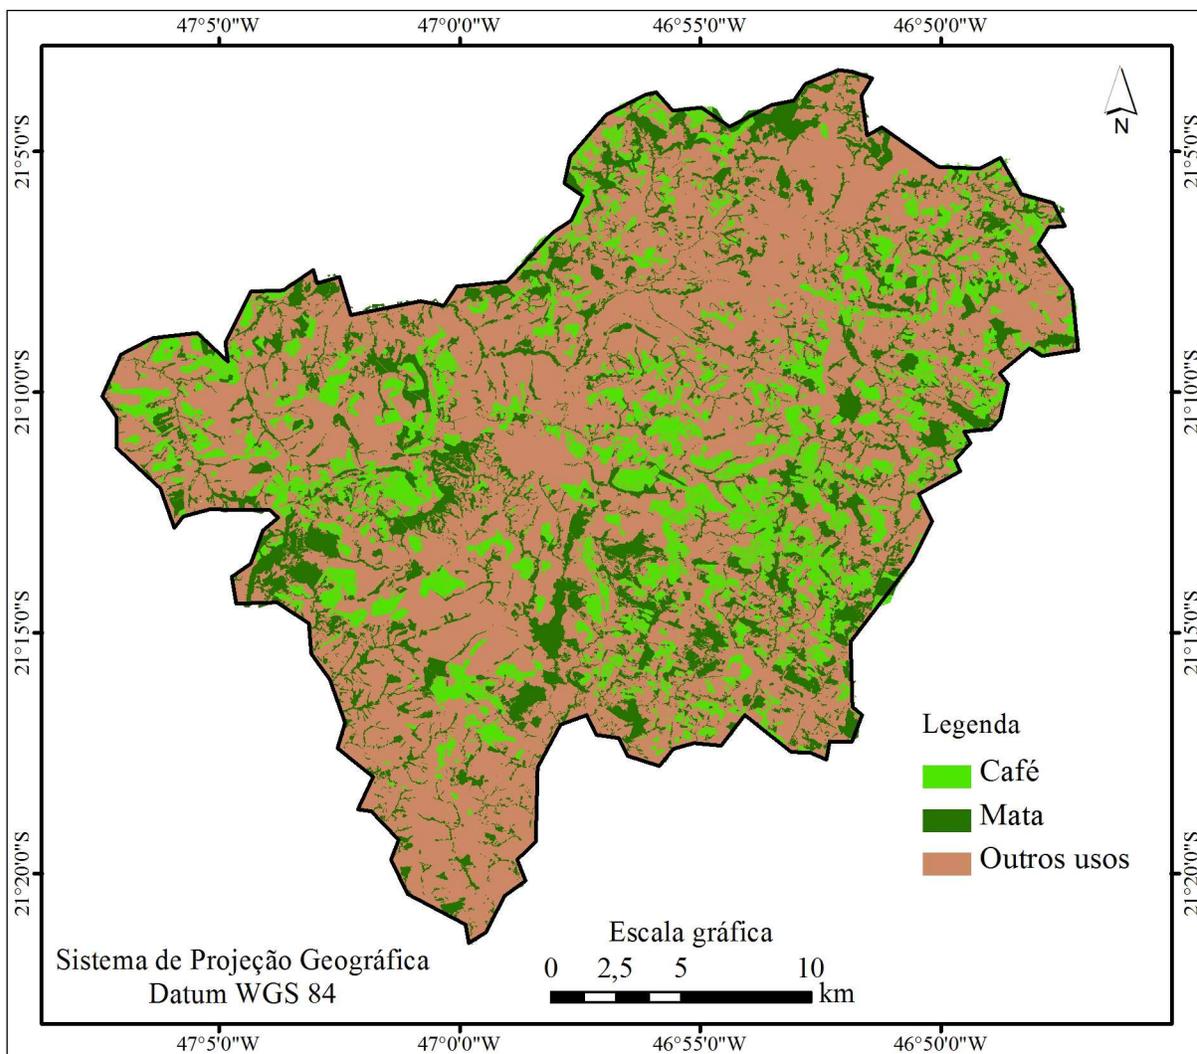


Figura 20. Máscaras de referência para avaliar a acurácia das classificações. Fonte: Cooxupé, 2012.

Com a Matriz de Erro foi possível identificar dois tipos de erros: erro de comissão, onde são *pixels* que pertencendo à outra classe o classificador colocou na classe de interesse, e erro de omissão em que os *pixels* pertencentes a uma determinada classe de interesse, o classificador atribuiu a outra(s) classe(s).

Além disso, a partir da Matriz de Erro foi calculada a Exatidão Global (Equação 2), que significa o total de acertos em relação ao total de amostras da máscara.

$$EG = \frac{A}{n} * 100$$

Equação (2)

em que:

EG = Exatidão Global;

A = Acerto geral (pontos amostrais com acertos);

n = Número de pontos amostrais.

Foi também determinado o Índice Kappa (Equação 3). Segundo CONGALTON (1991), esse índice deriva de uma técnica estatística para avaliação da concordância ou discordância em duas situações de interesse, cuja variação é de 0 a 1. Quanto mais próximo de 1, melhor é o resultado da classificação (Tabela 2).

$$K = \frac{\left[n * \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_{i.} * x_{.j}) \right]}{\left[n^2 - \sum_{i=1}^r (x_{i.} * x_{.j}) \right]} \quad \text{Equação (3)}$$

em que:

K = Índice Kappa de concordância;

n = Número de observações (pontos amostrais);

r = Número de linhas da matriz de erro;

x_{ij} = Observação na linha i e coluna i;

x_{i.} = Total marginal da linha i;

x_{.j} = Total marginal da coluna j;

Tabela 2. Níveis de desempenho da classificação para a interpretação de valores de Kappa obtidos.

Índice Kappa (K)	Qualidade
K = 0	Péssima
0,01 < K ≤ 0,20	Ruim
0,21 < K ≤ 0,40	Razoável
0,41 < K ≤ 0,60	Boa
0,61 < K ≤ 0,80	Muito Boa
0,81 < K ≤ 1,00	Excelente

Fonte: LANDIS E KOCH (1977).

Considerando os resultados de Índice Kappa e Exatidão Global, foi escolhida a melhor classificação para verificar de maneira qualitativa a classe de interesse mapeada, o café. Nesta etapa observou-se qual é a proporção média do café mapeado e qual proporção de café é predominante.

Além disso, foram analisadas, dentre as proporções de café, quais são as mais homogêneas e mais heterogêneas. Esta última análise foi possível devido à entrada de dados de imagens-fração de café obtidas a partir da aplicação do MLME sobre a composição R(5) G(4) B(3) do sensor LISS III com data de imageamento contida no intervalo da imagem MODIS melhor classificada. Visou-se com isso garantir que os alvos tivessem sofrido pouca transformação natural e assim obter um resultado de correlação significativo.

O coeficiente de correlação linear de Pearson (r) mede o grau de associação entre duas características a partir de uma série de observações. Sua variação é de +1 a -1. Quando $r = 1$, há correlação positiva perfeita entre as variáveis. Já quando $r = -1$, há correlação negativa perfeita entre as variáveis. Se $r = 0$, significa que as duas variáveis não são dependentes (SHIMAKURA, 2006). De acordo com a mesma autora, os valores de r podem ser interpretados conforme a Tabela 3.

Tabela 3. Interpretação dos valores do coeficiente de correlação.

Valor de r (+ ou -)	Correlação
0,00 a 0,19	Muito fraca
0,20 a 0,39	Fraca
0,40 a 0,69	Moderada
0,70 a 0,89	Forte
0,90 a 1,00	Muito forte

Fonte: SHIMAKURA, 2006.

Vale ressaltar que o sensor LISS III fornece dados das imagens em Números Digitais (ND) com níveis de cinza e o MODIS fornece dados físicos de refletância. Entretanto, quando as imagens são transformadas em imagens-fração, ambos apresentam dados de proporção, de 0 a 1, o que equivale dizer em porcentagem de 0 a 100%.

Dessa forma, cada *pixel* da imagem-fração de café do MODIS foi correlacionado com o valor médio dos *pixels* da imagem-fração de café do LISS III circunscritos no polígono do MODIS com o objetivo de verificar o grau de correlação.

Considerando-se o resultado da correlação significativo, calculou-se o Coeficiente de Variação (CV) da proporção de café nos *pixels* do LISS III circunscritos nos polígonos de *pixels* do MODIS. A opção por utilizar o CV reside no fato deste ser uma medida relativa de dispersão útil para a comparação em termos relativos do grau de concentração em torno da média, haja vista que foram utilizados para correlação os valores da média de proporção do LISS III com os valores absolutos do MODIS. Assim, foram associados os valores de Coeficiente de Variação dos *pixels* do LISS III aos respectivos *pixels* do MODIS para análise de heterogeneidade e homogeneidade da classificação do café (Figura 21).

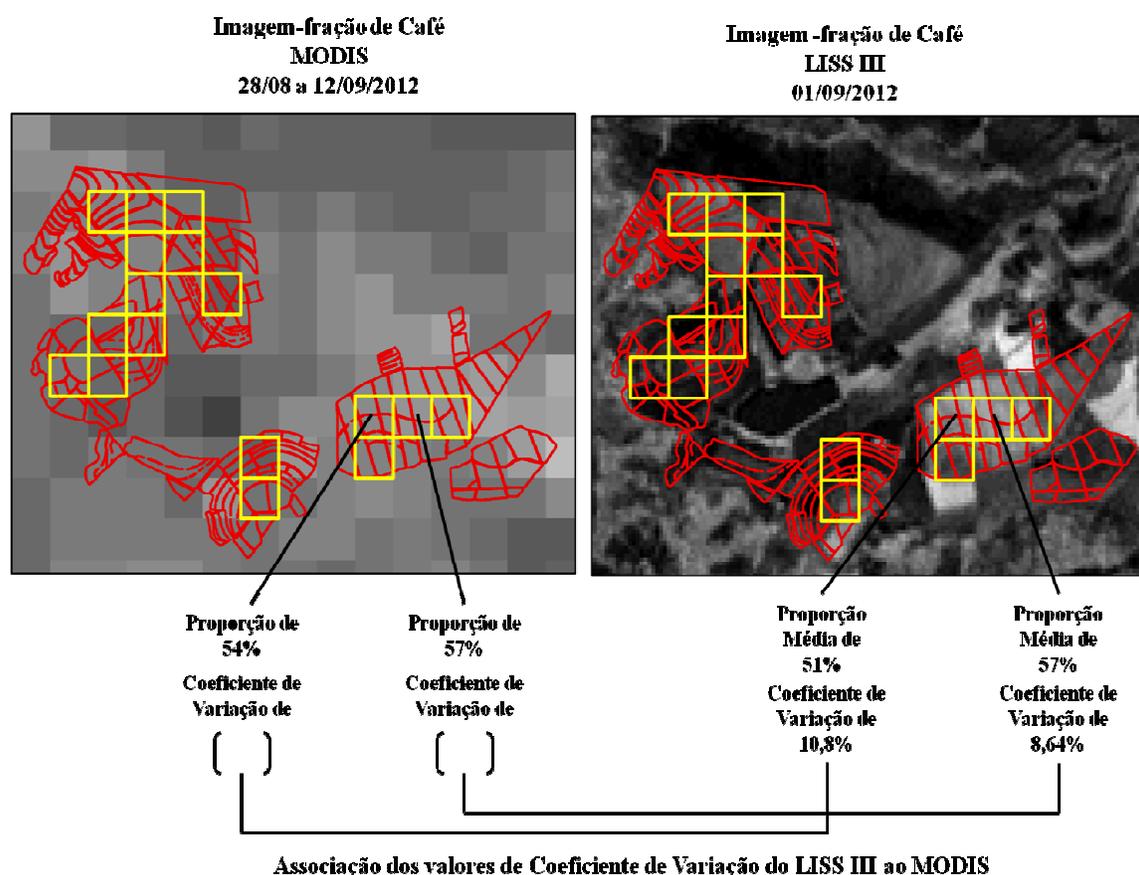


Figura 21. Correlação entre os dados de proporção de café dos sensores e Coeficiente de Variação do LISS III.

Esta verificação qualitativa com o apoio da análise estatística teve por objetivo fornecer mais informações no processo de entendimento das possibilidades e limitações do classificador através das semelhanças e diferenças do café com os demais alvos em uma determinada época do ano para aquelas condições dos cafezais de Monte Santo de Minas/MG.

A Figura 22 traz o fluxograma das etapas adotadas para o mapeamento das áreas de café.

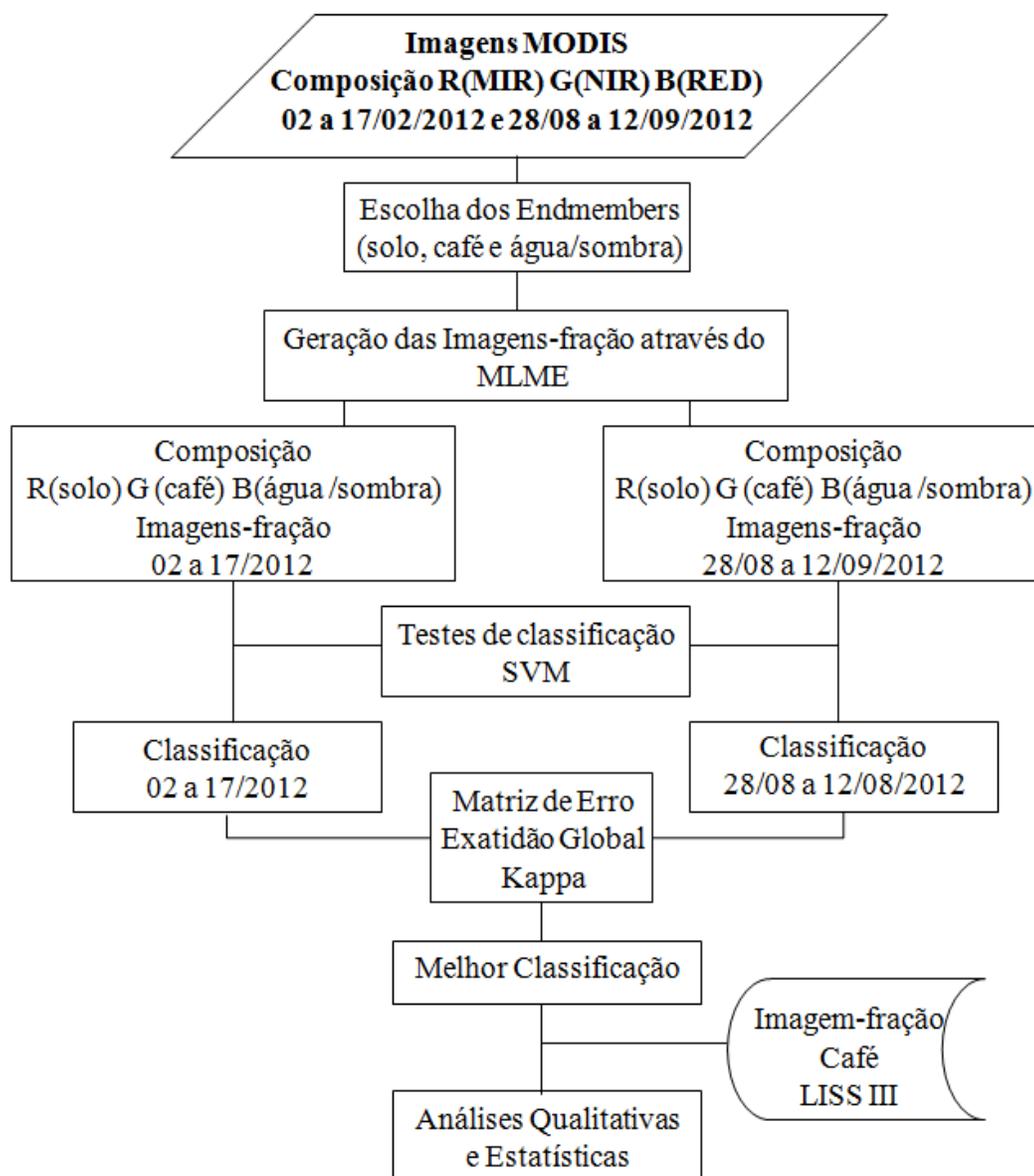


Figura 22. Fluxograma da metodologia para o mapeamento do café.

5. RESULTADOS E DISCUSSÕES

A apresentação dos resultados segue conforme subdivisão adotada na metodologia.

5.1. Monitoramento

5.1.1. A identificação da bienalidade

Na Figura 23 são apresentados, ao longo da série temporal, os valores médios de refletância dos 414 pixels do MODIS na banda NIR com pelo menos 80% de café. Juntamente com estes valores, está disposta a esquematização das seis fases fenológicas do cafeeiro arábica, durante 24 meses, nas condições climáticas tropicais do Brasil, proposta por CAMARGO e CAMARGO (2001).

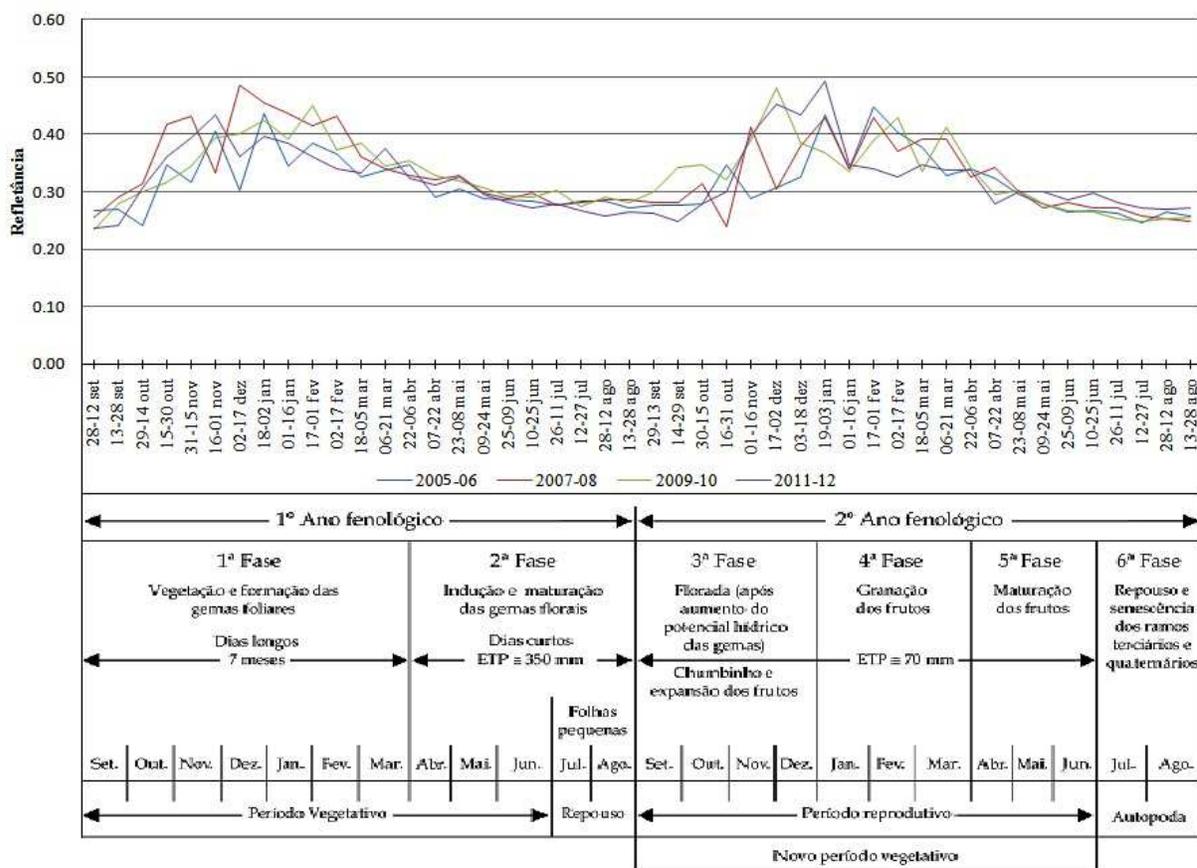


Figura 23. Refletância média dos pixels de café na banda NIR do Modis durante os ciclos produtivos de 2005 a 2012 e fases fenológicas do café (Camargo e Camargo, 2001).

De maneira geral, observa-se que a refletância dos pixels de café acompanha o ciclo produtivo da cultura, isto é, maiores valores de refletância média entre os meses de setembro e abril e menores valores de refletância entre os meses de maio e agosto. Para os meses de maior refletância, além do fato de ser o período de maiores precipitações, portanto, maior vigor vegetativo do cafeeiro, não ocorre a colheita, o que favorece a planta estar mais enfolhada e ter maior refletância na banda NIR. Para os meses de menor refletância, soma-se à estiagem que propicia menor vigor vegetativo, a ocorrência da colheita, agravando ainda mais o desfolhamento e assim, reduzindo a refletância.

Para fins de identificação da bienalidade do café, optou-se por apresentar os valores médios de refletância de acordo com os períodos aqui denominados de Vegetativo, Produção Baixa, Reprodutivo e Produção Alta ao longo de toda a série temporal analisada. Esta divisão levou em consideração os meses de colheita (de maio a agosto) e a época de retomada do desenvolvimento vegetativo da planta (setembro a abril), bem como a observação das alternâncias de refletância média nesse intervalo. Produção Baixa e Produção Alta referem-se ao período de colheita, enquanto que Vegetativo e Reprodutivo referem-se ao desenvolvimento vegetativo.

O conjunto desses quatro períodos configura uma bienalidade, em que os maiores valores de refletância são os períodos Vegetativo e Reprodutivo e os menores valores de refletância são os períodos de Produção Baixa e Produção Alta.

De acordo com a fenologia do cafeeiro, o período Vegetativo tem como característica maior atividade metabólica voltada às atividades vegetativas da planta, como a formação de novos galhos em detrimento das funções reprodutivas. Esta fase favorece o enfolhamento do cafeeiro e, conseqüentemente, apresenta maior refletância. Em decorrência da menor atividade metabólica voltada à reprodução de novos frutos nesse período, a fase seguinte de colheita é de baixa produção, ocorrendo, portanto, pouco desfolhamento dos galhos do cafeeiro. Assim, esta fase de Produção Baixa se caracteriza pelos baixos valores de refletância.

Em seguida, tem-se o período Reprodutivo, ou seja, agora as atividades metabólicas da planta se voltam mais para o processo reprodutivo em detrimento do processo vegetativo. Dessa forma, o café em geral desenvolve menos galhos e folhas. Em conseqüência disto, há menor refletância se comparado à primeira fase de retomada do vigor vegetativo (Vegetativo).

Adotado como último período da bienalidade neste trabalho tem-se a Produção Alta. Nesta fase o café apresenta mais frutos proporcionados pelo surgimento dos novos galhos ainda no primeiro período, o Vegetativo. Em termos de refletância, a Produção Alta apresenta menor valor dentre todos os supracitados em razão da colheita ser mais intensificada, pois o café com mais frutos do que na fase de Produção Baixa acaba por sofrer mais desfolhamento em seus galhos.

Na Figura 24, é possível observar essa alternância de refletância média entre os períodos, caracterizando a bienalidade em que os maiores valores de refletância são durante os períodos Vegetativo e Reprodutivo, correspondentes ao intervalo entre as colheitas, de Produção Baixa e Alta.

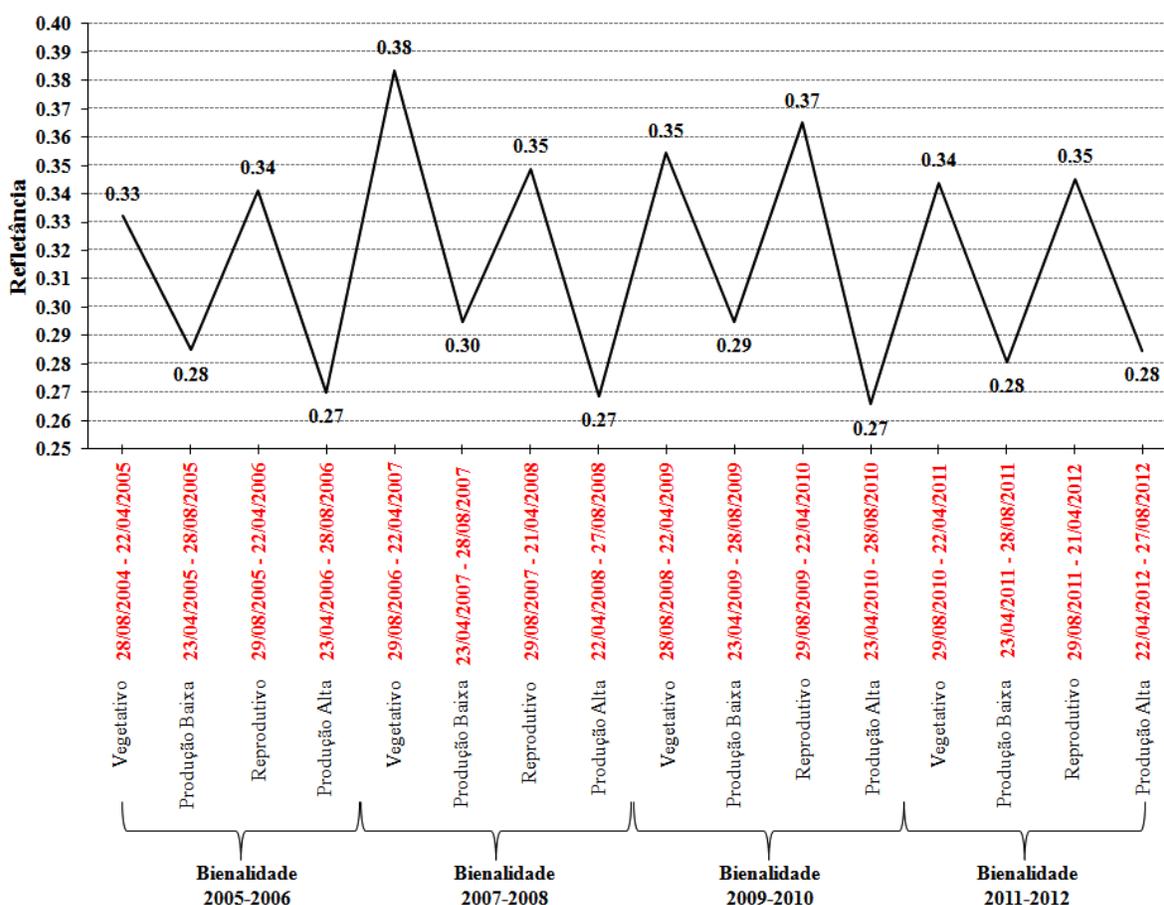


Figura 24. Refletância média dos pixels de café na banda NIR distribuídos de acordo com os períodos da bienalidade.

Observando o comportamento espectral de acordo com cada ano fenológico em conjunto com dados do balanço hídrico, é possível verificar com mais detalhes os períodos. A Figura 25 mostra como estão bem visíveis os períodos entre a recuperação do cafeeiro e os períodos de colheita. Nota-se que para a bialidade de 2005 e 2006, o período Reprodutivo teve maior média de refletância (0,34) do que o Vegetativo (0,33). Tal fato pode ser atribuído às condições climáticas, pois houve maior precipitação no Reprodutivo do que no Vegetativo, tendo acumulado 1224,4 mm contra 1012,2 mm, respectivamente. A Figura 25 ilustra os dados de refletância em conjunto com o balanço hídrico climatológico da bialidade de 2005 e 2006.

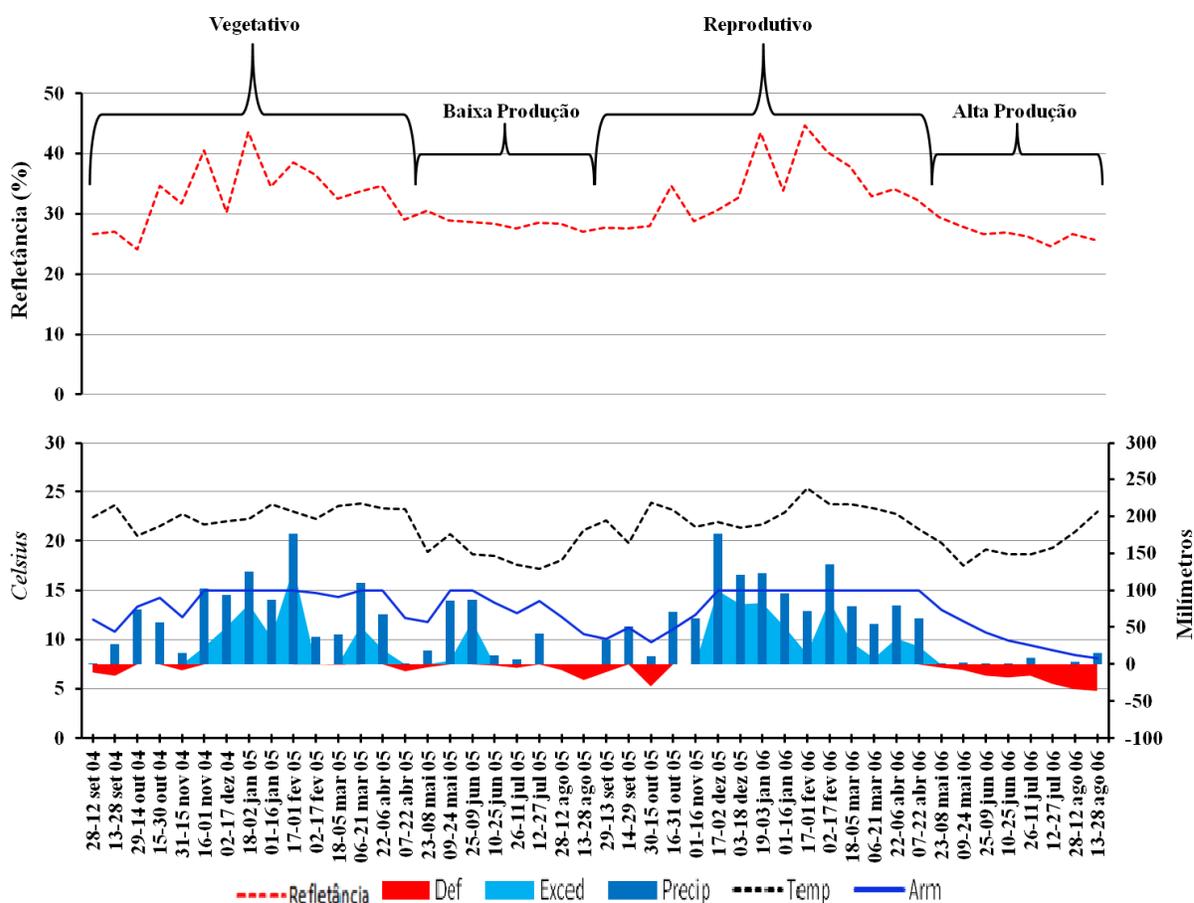


Figura 25. Gráfico de refletância com balanço hídrico da produção de café (bialidade de 2005 e 2006).

Outro fato que pode ter contribuído para a maior refletância no Reprodutivo é o aumento da produção de grãos nos pés de café, uma vez que este ano apresentou maior

produção de sacas dentre todo o período analisado (320 mil sacas de café). Assim, os pés de café, ainda que não muito enfolhados, podem apresentar maior refletância devido à presença de muitos frutos nos galhos. Com relação aos valores de refletância nos períodos de Produção Baixa e Alta, houve maior refletância em Baixa (0,28) do que em Alta (0,27).

Para a bienalidade de 2007 e 2008 (Figura 26), o período Vegetativo apresentou maior valor de refletância média em relação ao Reprodutivo e, maior refletância média do período de Baixa Produção em relação ao de Alta Produção. Entre os períodos de recuperação, sendo 1.446.2 mm acumulado durante o Vegetativo e 1.070.2 mm durante o Reprodutivo.

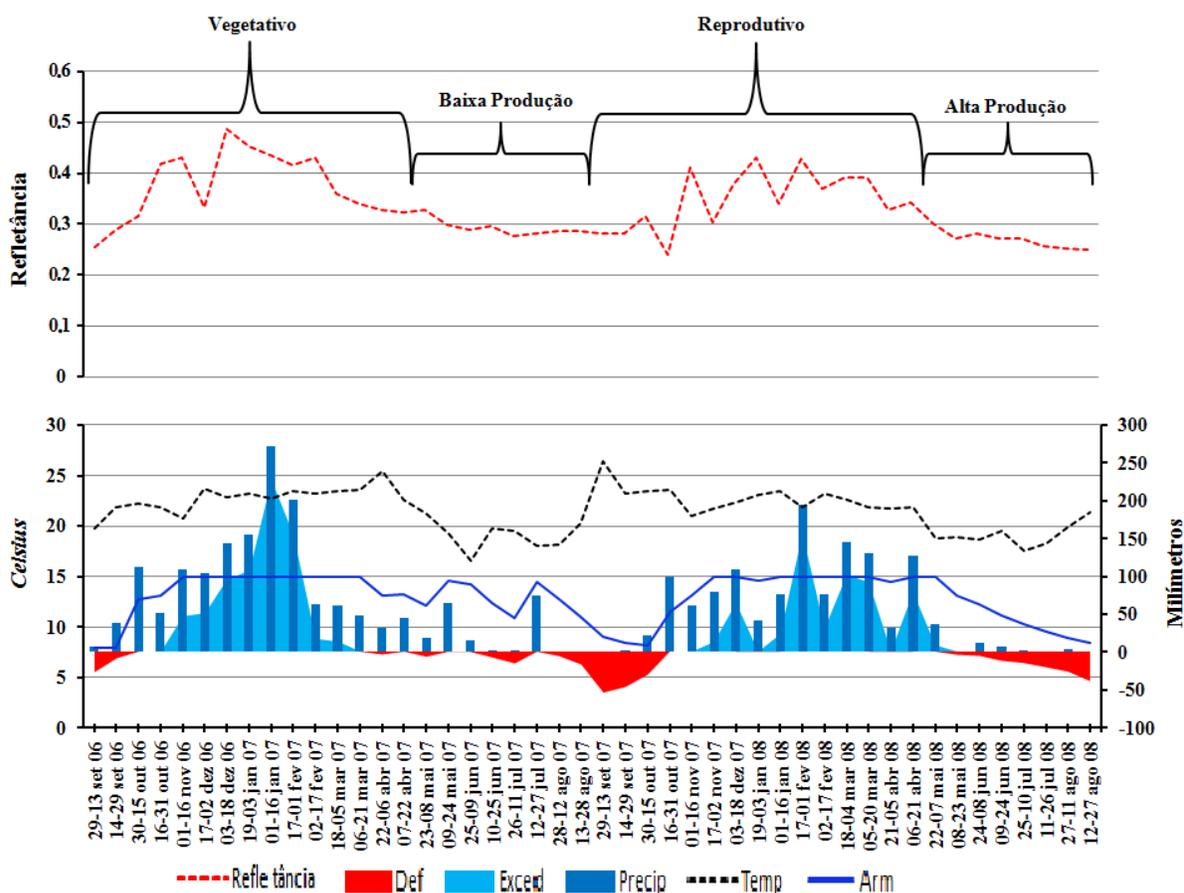


Figura 26. Gráfico de refletância com balanço hídrico da produção de café (bienalidade de 2007 e 2008).

Assim como na bialidade de 2005 e 2006, a de 2009 e 2010 (Figura 27) apresentou maior precipitação acumulada no Reprodutivo, com 1.364,5 mm, enquanto que no Vegetativo foi de 1.251 mm. Os valores de refletância durante as colheitas foram de 0,29 para Produção Baixa e, 0,27 para o de Alta Produção.

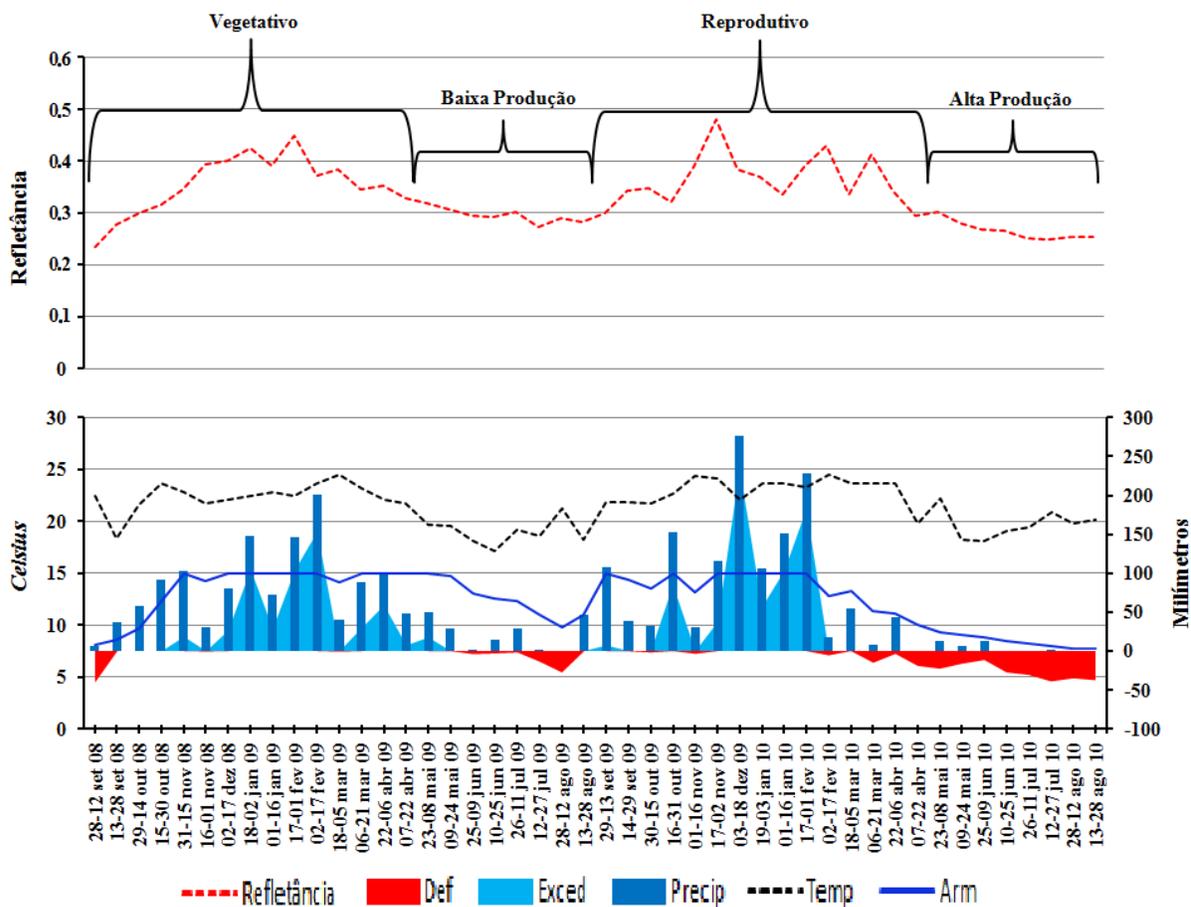


Figura 27. Gráfico de refletância com balanço hídrico da produção de café (bialidade de 2009 e 2010).

Para a bialidade de 2011 e 2012, observa-se que durante o processo de recuperação do café, o Vegetativo apresentou valor médio de refletância de 0,34 contra 0,35 do Reprodutivo. Neste caso, não foi o fato de ter ocorrido menor precipitação durante o período Vegetativo em relação ao Reprodutivo, pois o acumulado de precipitação foi de 1.580,2 mm para o primeiro e 1.481,8 mm para o segundo. O que pode ter colaborado é a ocorrência de uma estiagem mais acentuada no ano anterior (Figura 27), com deficiência hídrica desde o mês de fevereiro/março de 2010. Além disto, soma-se ao fato da colheita de 2010 ter sido mais

intensa devido à quantidade produzida de café no período analisado (315 mil sacas), configurando-se, portanto, em desfolhamento intenso em um ano de estiagem e déficit hídrico.

Com relação aos períodos de Produção Baixa e Alta, estes apresentaram o mesmo valor de refletância, 0,28. Como se pode observar, o valor de refletância da Produção Alta de 2012 ficou acima de todos os valores do mesmo período em outros anos de bialidade, que foram de 0,27. Para este caso, conforme mostra a Figura 27, a explicação pode estar no excesso de chuva para os padrões do período de colheita (Produção Alta), acumulando 289 mm, sobretudo de maio a junho. Esse fato dá indício de que a chuva possa ter estimulado o vigor vegetativo do café deixando-o mais enfolhado, além atrasar a colheita.

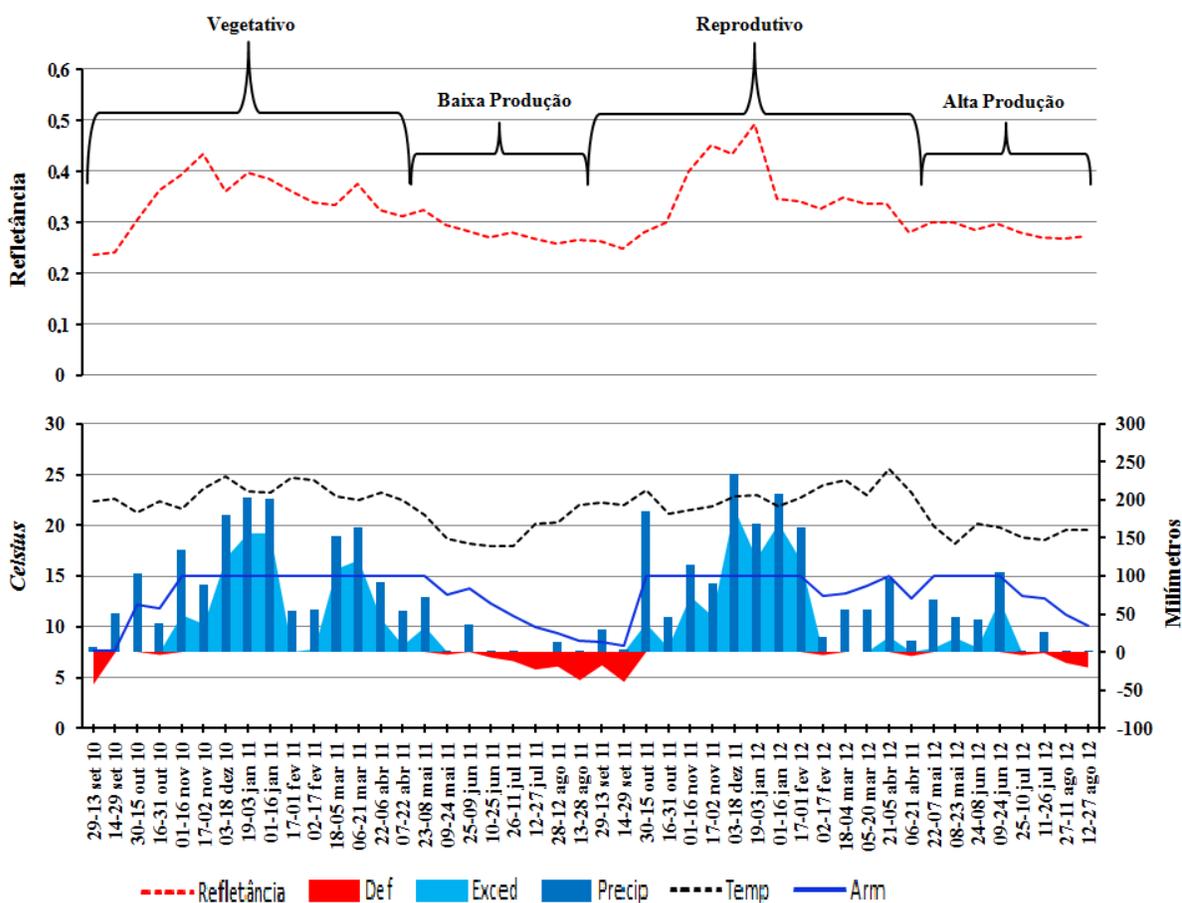


Figura 28. Gráfico de refletância com balanço hídrico da produção de café (bialidade de 2011 e 2012).

Como se pode verificar, as condições climáticas nos períodos de retomada do desenvolvimento vegetativo da planta (setembro a abril) são fatores que provocam heterogeneidade de refletância, enquanto que no período de colheita (maio a agosto) a refletância é mais homogênea. A utilização dos dados meteorológicos em sintonia com os valores de refletância para identificação e entendimento dos processos da bienalidade foi imprescindível.

A Figura 29 ilustra essa variação dos valores de refletância dos períodos através da medição do desvio padrão.

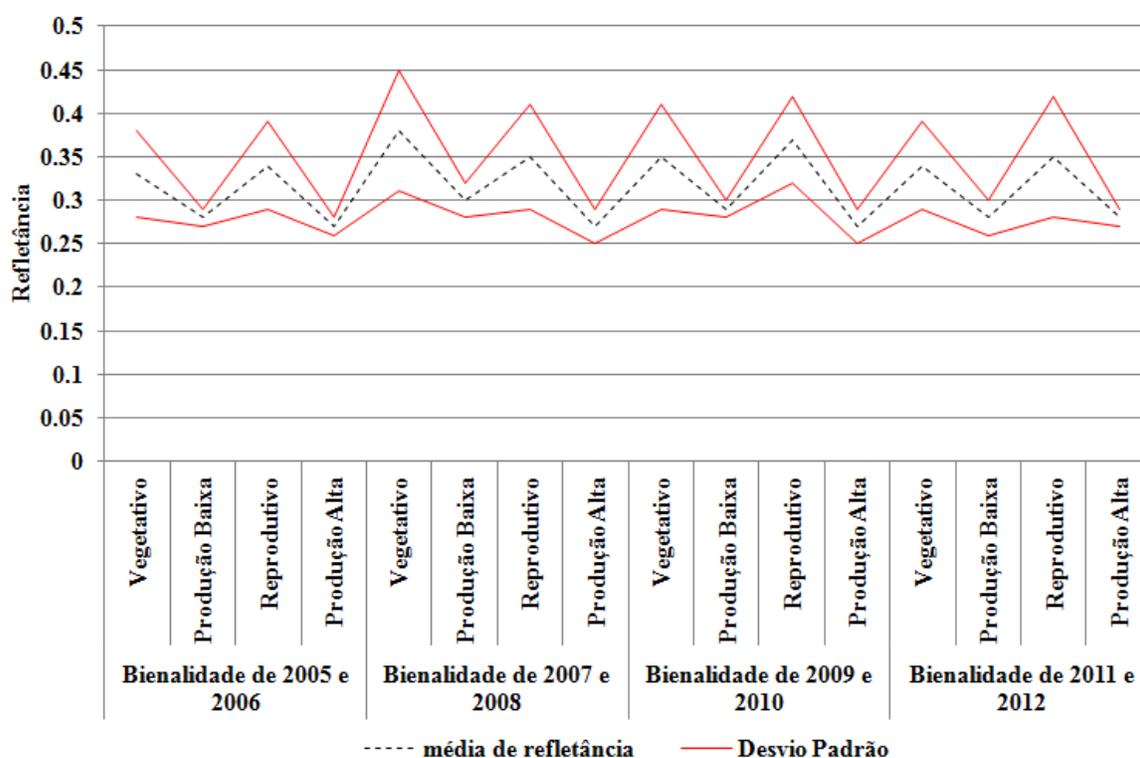


Figura 29. Desvio Padrão da refletância média dos pixels de café na banda do NIR.

Devido ao maior desvio padrão durante os períodos Vegetativo e Reprodutivo potencializados pelas condições meteorológicas, entende-se que a utilização dos dados de refletância durante os meses de colheita são mais adequados para a identificação da bienalidade do café.

BERNARDES et al. 2012, ao utilizar índices de vegetação (NDVI e EVI) do MODIS constataram também que há correlação inversa, indicando que os aumentos positivos na

produtividade resultaram em um decréscimo dos valores mínimos dos índices de vegetação do MODIS, o que sugere a maior perda de folhas após a colheita em anos de alta produtividade de café. De acordo com seus resultados, a correlação dos valores mínimos de EVI foram superiores aos valores mínimos de NDVI.

Na Figura 30 estão dispostos os valores médios de refletância referentes ao período de colheita para cada ano (NIR, EVI e NDVI) e os valores de produção para cada ano.

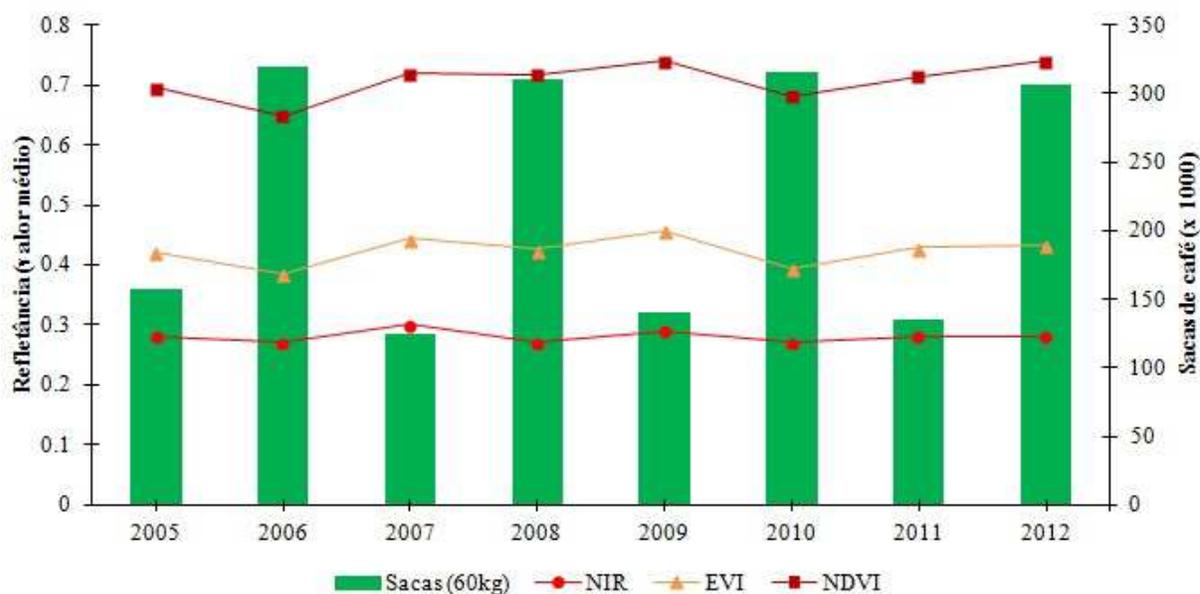


Figura 30. Refletância média do café durante os períodos de colheita em conjunto com as quantias de sacas produzidas.

Observa-se que tanto os índices de vegetação, quanto a banda do NIR acompanham de maneira inversa à quantidade de produção de café. Ao aplicar coeficiente de correlação linear de Pearson (r), verificou-se que o NIR apresentou melhor correlação (-0,80) em comparação ao EVI e NDVI, com 0,68 e 0,40, respectivamente.

5.2. Mapeamento

5.2.1. Geração das imagens-fração para os períodos de chuva e estiagem

A partir da composição R(MIR) G(NIR) B(RED) das bandas do sensor MODIS, produto MOD13Q1, foram introduzidas as informações do *endmembers* de solo, café e água/sombra para a geração das imagens-fração de cada período. A imagem-fração solo realça as áreas de solo exposto; a imagem-fração de café realça as áreas de café e a imagem-fração de água/sombra realça as áreas com presença de água e/ou sombra. Nessas imagens sintéticas, o valor do *pixel* varia de 0 a 1, sendo que quanto mais próximo de 1, maior é o valor estimado da proporção do alvo em sua respectiva imagem-fração. As Figuras 31 e 32 ilustram as imagens-fração dos períodos de chuva e de estiagem, respectivamente. As áreas mais claras indicam maior proporção, enquanto as escuras apresentam menor proporção.

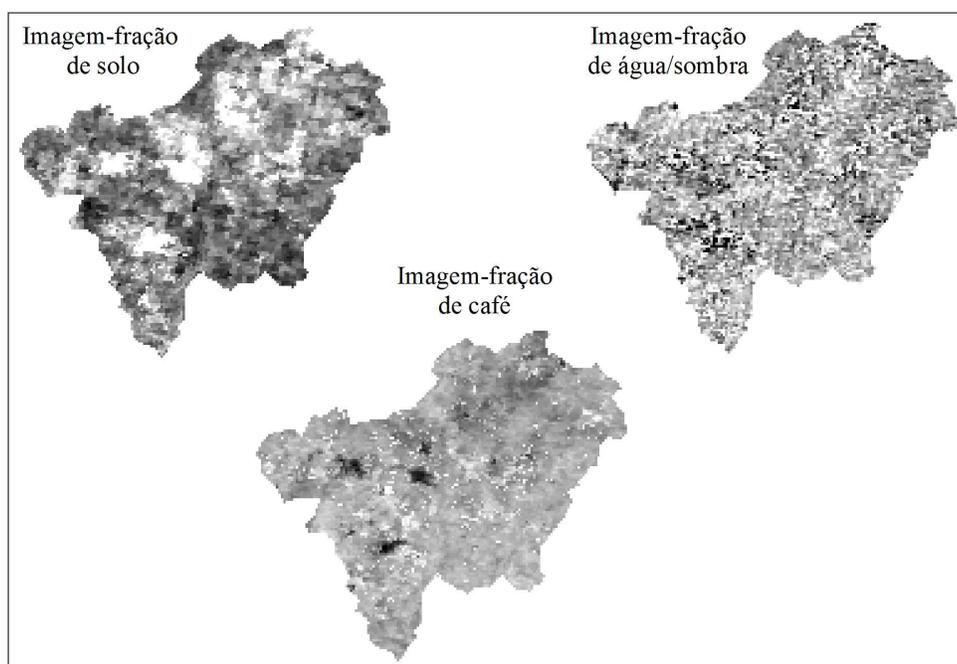


Figura 31. Imagens-fração de solo, café e água/sombra do período chuvoso (02 a 17/02/2012).

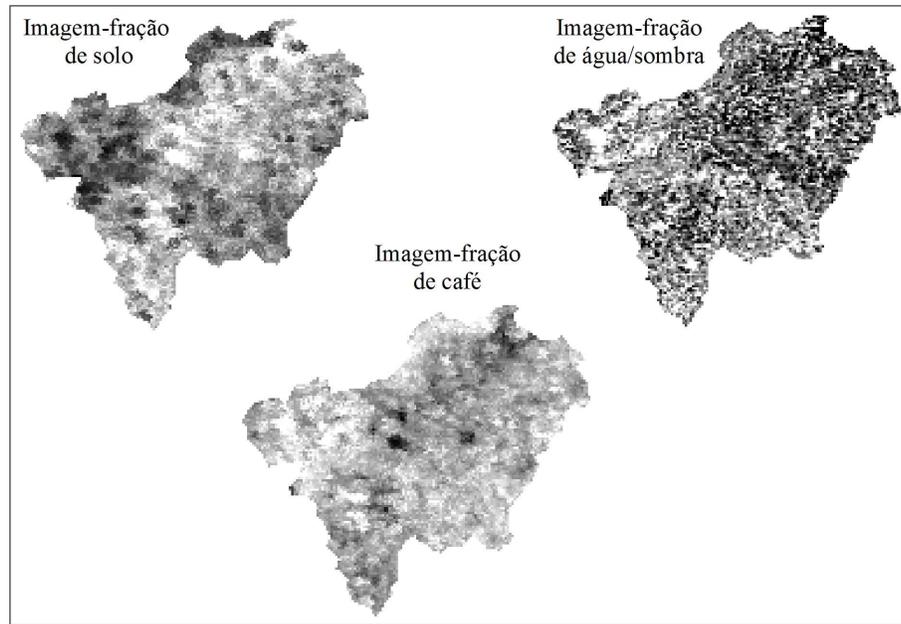


Figura 32. Imagens-fração de solo, café e água/sombra do período de estiagem (28/08 a 12/09/2012).

Na Figura 33, têm-se as imagens-fração na composição R(solo) G(café) B(água/sombra), sobre as quais foram aplicados os testes de classificação com o SVM.

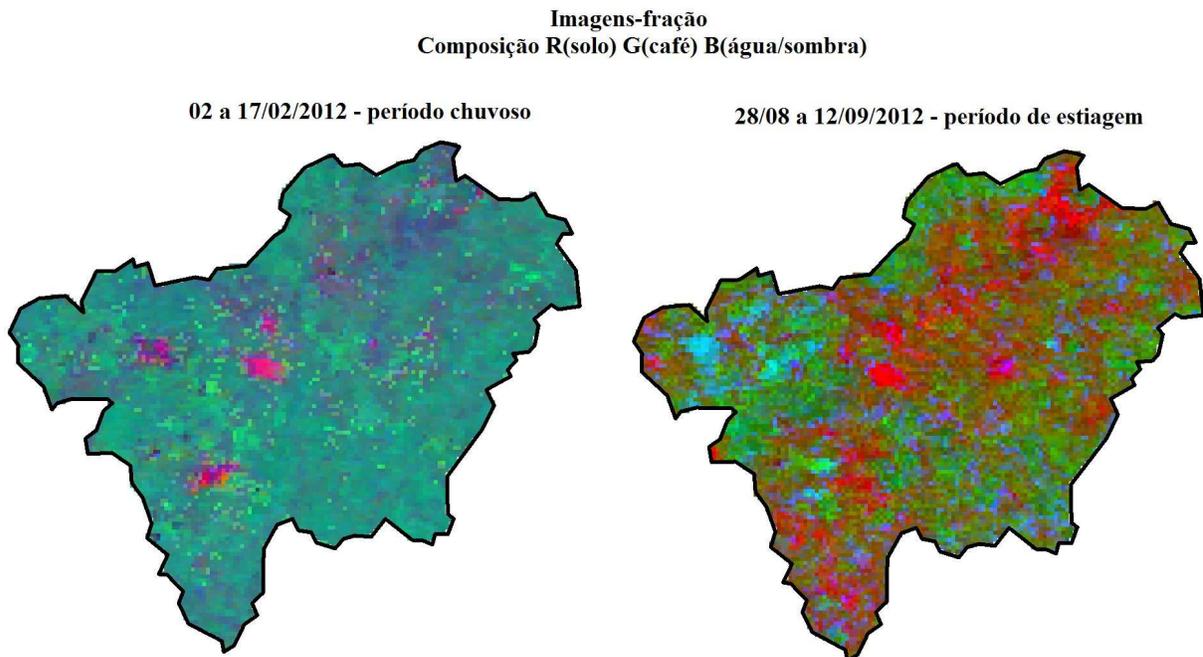


Figura 33. Composição RGB das imagens-fração.

5.2.2. Classificações

O resultado da classificação automática obtida para o período chuvoso é apresentado na Figura 34.

A avaliação da acurácia desta classificação está na matriz de erro da Tabela 4. A diagonal em destaque mostra o total de *pixels* classificados corretamente, do qual se obteve Exatidão Global de 65%. O Índice Kappa foi de 0,32, avaliado como razoável, segundo os intervalos de valores propostos por LANDIS e KOCH (1977) (Tabela2). Para a classe Café, que é o alvo de interesse, houve erro de omissão de 60,81% e acurácia do produtor de 39,19%, ou seja, 39,19% *pixels* de café foram corretamente classificados, enquanto que 60,81% foram atribuídos às outras classes de Mata e Outros usos. Já o erro de comissão foi de 54,25% e a acurácia do usuário de 45,75% para o Café, o que significa que 54,25% dos *pixels* classificados como café na verdade pertencem às classes de Mata e Outros usos e 45,75% dos *pixels* classificados como café foram acertados.

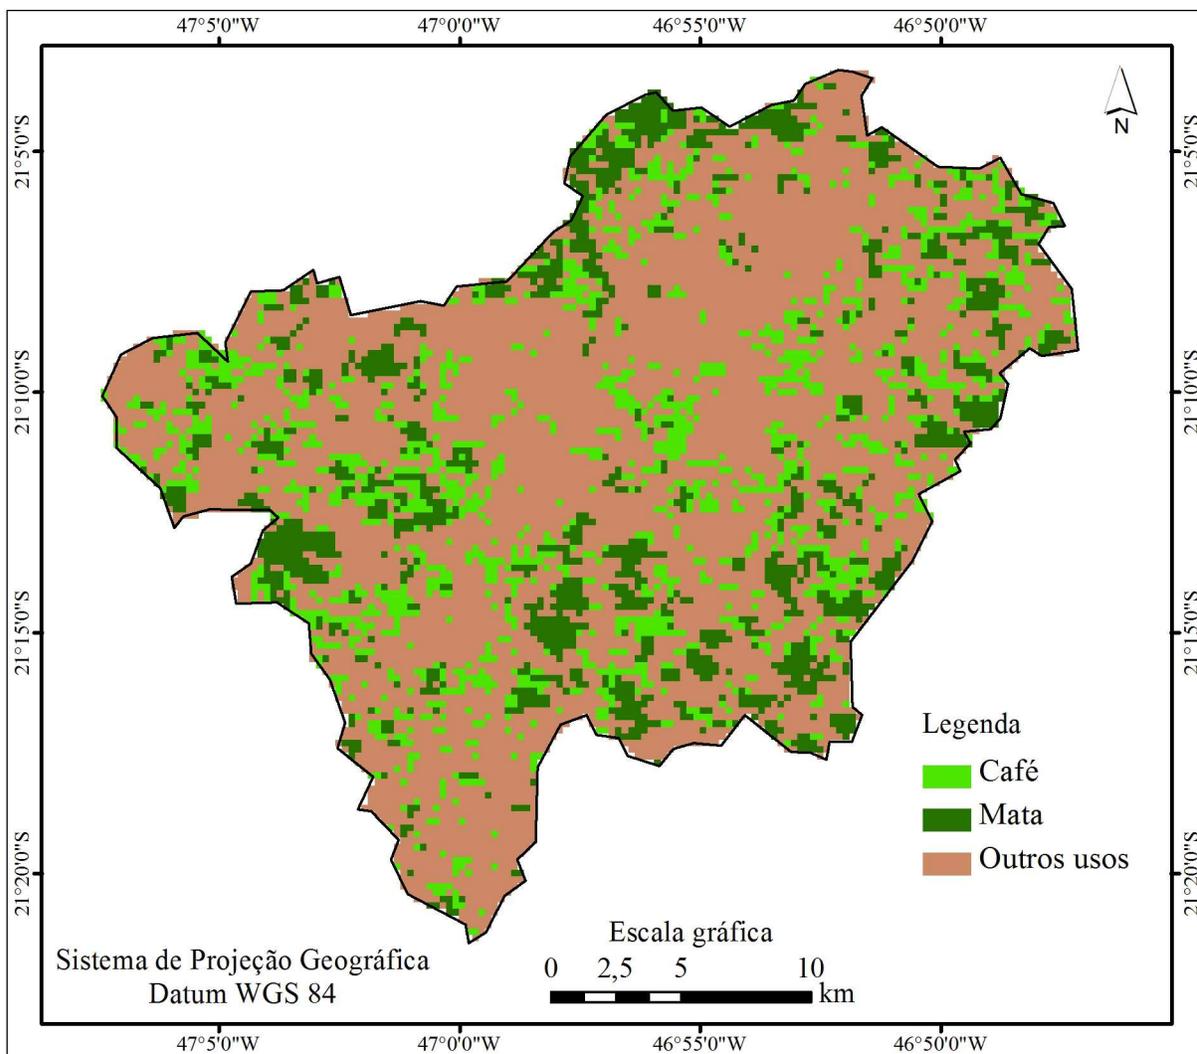


Figura 34. Classificação do período chuvoso.

Tabela 4. Matriz de erro para a classificação período chuvoso.

	Referência			Total	Erro de Comissão (%)	Acurácia Usuário (%)
	Café	Mata	Outros usos			
Café	754	270	624	1648	54,25	45,75
Mata	231	696	581	1508	53,85	46,15
Outros usos	939	874	5148	6961	26,05	73,95
Total	1924	1840	6353	10117		
Erro de Omissão (%)	60,81	62,17	18,97			
Acurácia Produtor (%)	39,19	37,83	81,03			
EG	65%					
Kappa	0,32					

Por sua vez, a Figura 35 refere-se à classificação automática do período de estiagem, com a respectiva acurácia apresentada na Tabela 5. Observa-se que os valores ficaram próximos daqueles do período chuvoso, exceto o Índice Kappa e o erro de omissão e acurácia do produtor para a classe Café, que foram melhores. A Exatidão Global foi de 67% e o erro de comissão e acurácia do usuário para o Café foram 52,06% e 47,94%, respectivamente. O erro de omissão para o Café foi menor, de 38,99%, resultando, então, em maior acurácia do produtor, de 61,01%, para o período de estiagem. O Índice Kappa foi de 0,41, indicando qualidade boa da classificação, conforme a Tabela 2.

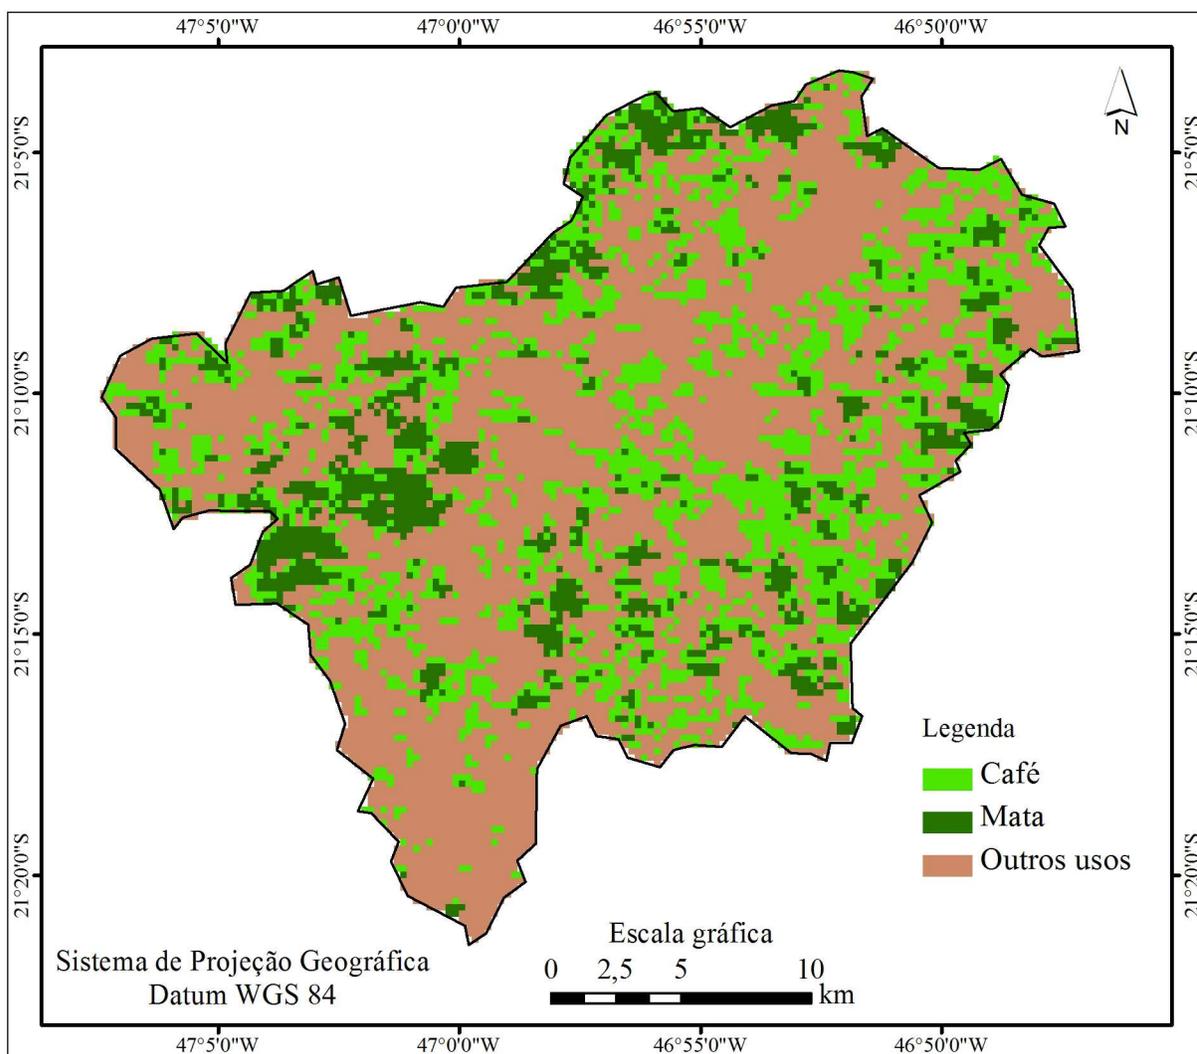


Figura 35. Classificação do período de estiagem.

Tabela 5. Matriz de erro para a classificação do período de estiagem.

		Referência				Erro de Comissão (%)	Acurácia Usuário (%)
		Café	Mata	Outros usos	Total		
Classificação	Café	1324	477	961	2762	52,06	47,94
	Mata	237	670	384	1291	48,10	51,90
	Outros usos	609	646	4804	6059	20,71	79,29
	Total	2170	1793	6149	10112		
	Erro de Omissão (%)	38,99	62,63	21,87			
	Acurácia Produtor (%)	61,01	37,37	78,13			
	EG	67%					
Kappa	0,41						

Como se pode observar, a melhor classificação, considerando os resultados da Matriz de Erro, foi a do período de estiagem, o que vai ao encontro dos resultados obtidos por MOREIRA et al. (2004) em que, apesar da perenidade da cultura do café, a melhor época para o mapeamento da lavoura de café em imagens multiespectrais de sensores orbitais é nos meses mais secos.

Dessa forma, as análises estatísticas para auxiliar a compreensão das possibilidades e limitações do classificador através das semelhanças e diferenças do café com os demais alvos, foram feitas sobre a classificação do período de estiagem.

5.2.3. Análises estatísticas da classificação do período de estiagem.

Para fins de análises estatísticas com mais detalhes do que o MODIS pode proporcionar, recorreu-se aos dados do sensor LISS III, pelo fato deste ter melhor resolução espacial (23,5 m). A fim de garantir a confiabilidade dos dados de imagem-fração de café obtidas a partir da aplicação do MLME sobre a composição R(5) G(4) B(3) do LISS, aplicou-se a técnica estatística de correlação juntamente com as imagens-fração de café do MODIS. O índice de correlação entre as imagens-fração de café foi de 0,7, indicando forte correlação (Figura 36).

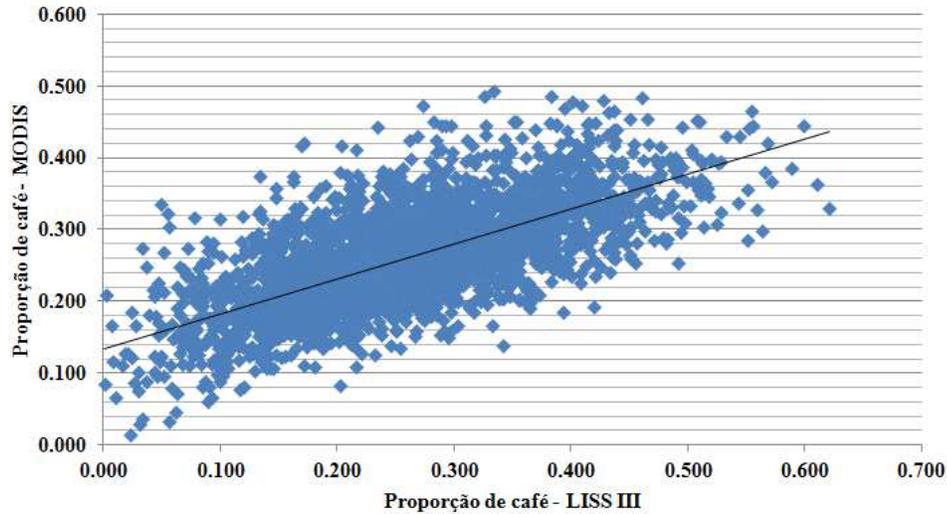


Figura 36. Gráfico de dispersão dos valores de proporção de café das imagens-fração café do MODIS e LISS III.

A primeira análise estatística diz respeito à distribuição espacial do café de acordo com as proporções (Figura 37).

Na Figura 37, estão as proporções de café corretamente classificado, representando 61,01% do total da área de café do município. Nota-se que a maioria do café mapeado corretamente (52%) apresenta uma proporção maior que 20% até 30% de cobertura do solo, sendo a proporção alta (maior que 40% até 50%) representando a minoria, 3%. Essa informação condiz com o período, pois a maioria dos pés de café na estiagem, sobretudo logo após a colheita, encontra-se com pouca folhagem, sendo mínimos os pés com mais folhagem.

Outra informação relevante reside na relação de proporção com o coeficiente de variação. À medida que os pixels da imagem-fração do MODIS apresentam maior proporção de café, ocorre queda no coeficiente de variação. Esta relação indica que *pixels* de MODIS com baixa proporção de café são mais heterogêneos e os com maiores proporção de café são mais homogêneos. Vale ressaltar que esta informação de coeficiente de variação advém dos valores de cada pixel das imagens-fração do LISS III circunscrito no *pixel* do MODIS e justificado a sua utilização pela forte correlação.

É possível observar que, tanto a distribuição espacial das proporções de café classificados corretamente, quanto a lógica entre proporção e coeficiente de variação, são compatíveis com toda a área de café do município contida nos *pixels* do MODIS (Figura 38).

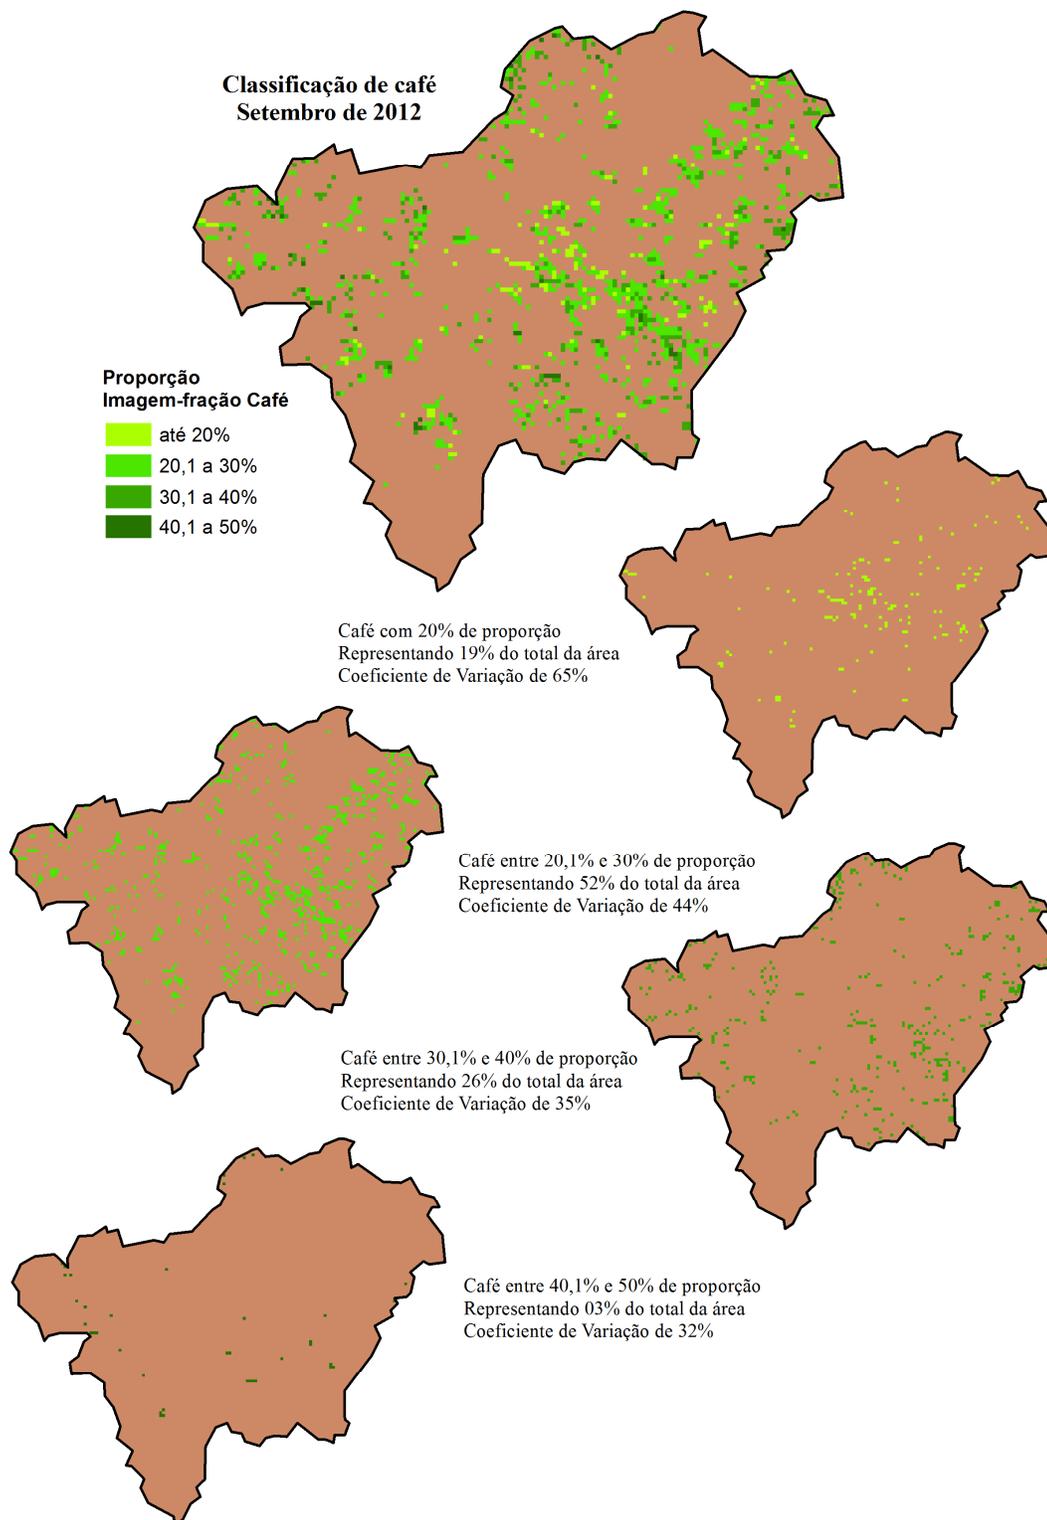


Figura 37. Distribuição espacial da classificação de café de acordo com as proporções de cobertura.

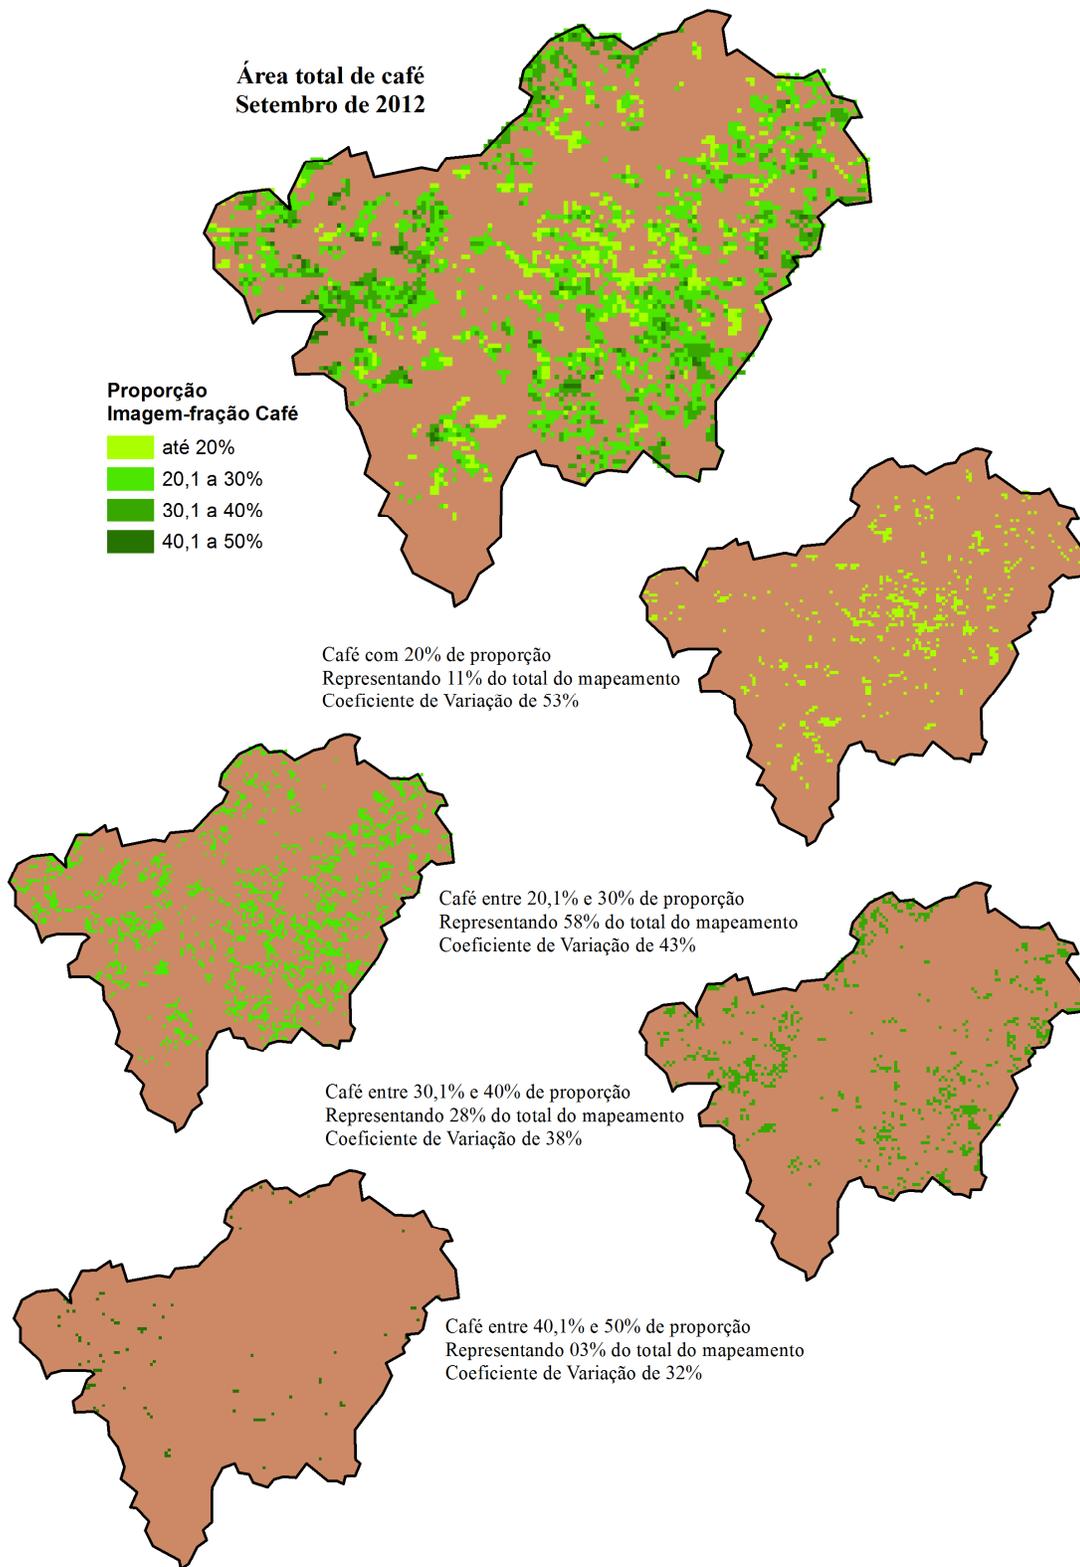


Figura 38. Distribuição espacial de toda a área de café de acordo com as proporções de cobertura.

Fazendo a junção dos resultados da matriz de erro com as proporções e os dados de coeficiente de variação (CV), é possível analisar a classificação de café com mais atenção às características do café confundido com as outras classes (Mata e Outros usos), bem como as características destas classes confundidas com café. Tem-se na Figura 39 a esquematização autoexplicativa dessa análise qualitativa.

Nesta esquematização (Figura 39), foram selecionadas para análise as proporções com maior porcentagem de representação sobre a classificação. Na análise horizontal: a Mata classificada como Café de proporção $>20\%$ e $\leq 30\%$, CV de 41% e com 59% de representatividade de sua classe; e os Outros usos classificado como Café de proporção $>20\%$ e $\leq 30\%$, CV de 48% e com 60% de representatividade de sua classe.

Na análise vertical: o Café classificado como Mata de proporção $>20\%$ e $\leq 40\%$, CV 29% e com 95% de representatividade de sua classe; e o Café classificado como Outros usos de proporção $\leq 30\%$, CV de 56% e com 83% de representatividade de sua classe. O Café classificado corretamente de proporção >20 e $\leq 30\%$, CV de 44% e com 52% de representatividade de sua área.

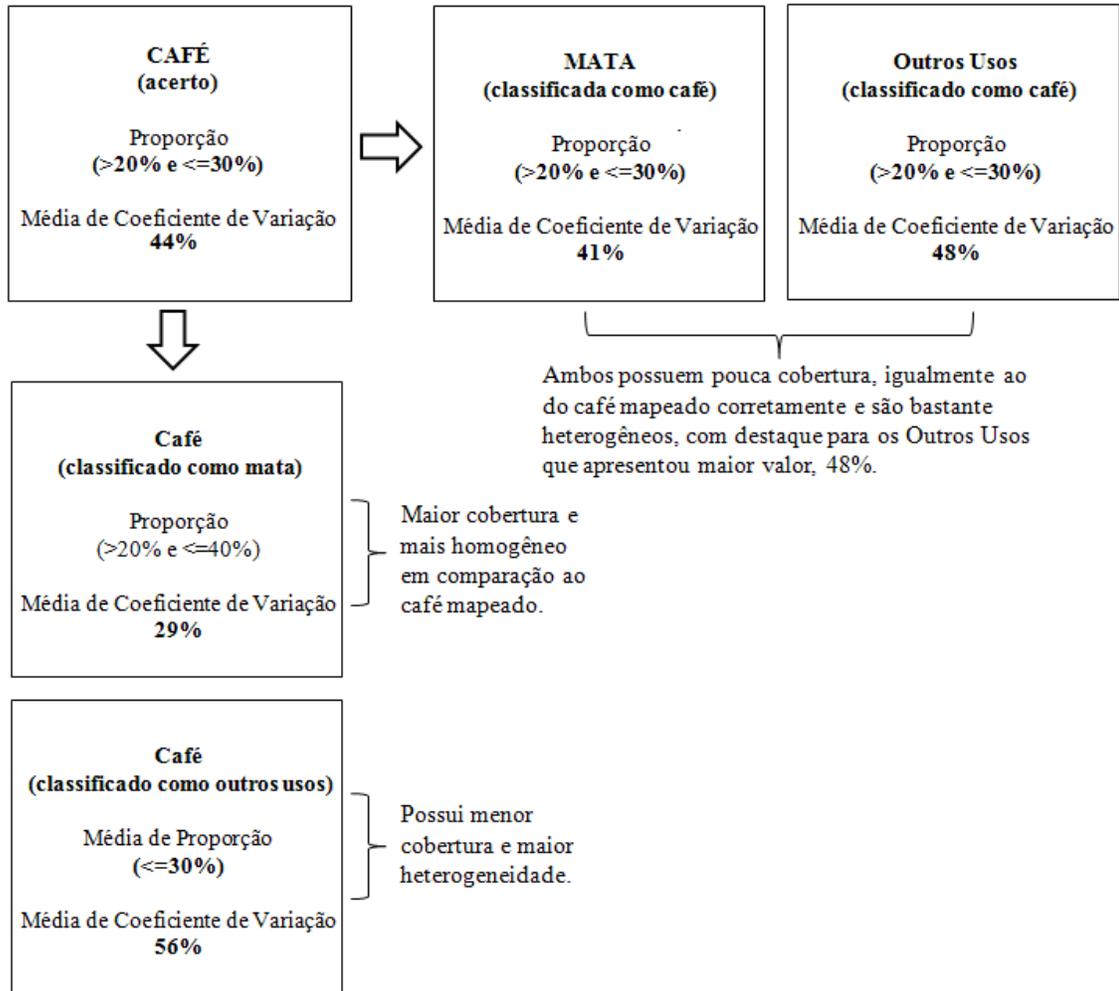


Figura 39. Esquematização qualitativa da classificação de café.

Como se pode observar, o classificador entendeu como Café a Mata de igual proporção de cobertura do solo e tão heterogênea quanto o café classificado corretamente. Similarmente, a classe Outros usos foi confundida pelo classificador como Café, devido às semelhanças de proporção e heterogeneidade.

Observando os erros de omissão, nota-se que o classificador entendeu como Mata um Café com pouco mais de proporção e também mais homogêneo. Por outro lado, a confusão do Café com Outros usos, o classificador afirmou como Café as áreas de Outros usos com menor proporção e mais heterogêneo.

6. CONCLUSÕES

Os resultados deste trabalho mostraram que, apesar da baixa resolução espacial do sensor MODIS, é possível a sua utilização para o monitoramento da cafeicultura utilizando apenas os dados da banda do Infravermelho Próximo. Este fato propõe a não necessidade de utilização de índices de vegetação para identificar e monitorar a bienalidade do café.

A utilização dos dados meteorológicos foi crucial para buscar maior compreensão a respeito das variações dos valores de refletância nos períodos de retomada do vigor vegetativo do cafeeiro. Nesse sentido, observou-se que os dados de refletância dos períodos de colheita apresentaram maior correlação com a alternância da quantidade da produção, isto é, a bienalidade do café.

Com relação ao mapeamento do café em Monte Santo de Minas, pode-se dizer que os dados MODIS não são o mais indicados para tal fim, tendo como ponto negativo a sua resolução espacial não adequada, uma vez que as áreas de café são pequenas, muitas vezes menores que um *pixel* do MODIS.

Entretanto, a utilização das imagens-fração mostrou-se promissora, sobretudo pelos desdobramentos ao fornecerem informações sobre o aspecto do café, classificado ou não corretamente. Estas informações de proporção do café, juntamente com a utilização de imagens-fração do sensor LISS III (de melhor resolução espacial em relação ao MODIS) proporcionaram melhor compreensão da complexidade do café a ser identificado pelo classificador SVM. Em suma, isto mostra que a classificação automática supervisionada de café em imagens-fração obtidas a partir de dados MODIS apresenta uma complexidade pertencente à própria cultura cafeeira, em que a heterogeneidade dos pés, tamanhos diferentes, sistemas de manejos distintos e espaçamentos variados, acabam por dificultar sua classificação automática.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, D. A. **Monitoramento da área colhida de cana-de-açúcar por meio de imagens do sensor Modis**. 99 p. Dissertação (Mestrado em Sensoriamento Remoto) - Inpe, São José Dos Campos/SP, 2007. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2007/05.11.18.56>> Acesso em: 23 ago 2010.

ALVES, G. M. **Análise do Modelo Linear de Mistura Espectral aplicado a imagens Modis para o mapeamento da cultura de arroz irrigado no estado do Rio Grande do Sul**. 69 p. Dissertação (Mestrado em Sensoriamento Remoto). Universidade Federal do Rio Grande do Sul, Porto Alegre/RS, 2009. Disponível em: <<http://hdl.handle.net/10183/23937>> Acesso em: 25 maio 2011.

ALZUGARAY, D.; ALZUGARAY, C. **Flora brasileira**. São Paulo/SP: Três Livros, 1984.

ANDERSON, L. O. **Classificação e monitoramento da cobertura vegetal do estado do Mato Grosso utilizando dados multitemporais do sensor Modis**. 247 p. Dissertação (Mestrado em Sensoriamento Remoto) – Inpe, São José dos Campos/SP, 2004. Disponível em: <<http://mtc-m12.sid.inpe.br/col/sid.inpe.br/jeferson/2004/08.31.13.56/doc/publicacao.pdf>> Acesso em: 06 fev. 2012.

BERNARDES, T.; ALVES, H. M. R.; VIEIRA, T. G. C. Classificação automática de imagens de satélites no mapeamento da região cafeeira de Patrocínio, MG. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 5, 2007, Águas de Lindóia/SP. **Anais...** Brasília/DF: Embrapa Café, 2007. Disponível em <<http://www.alice.cnptia.embrapa.br/handle/doc/906103>> Acesso em: 22 dez. 2011.

BERNARDES, T.; MOREIRA, M. A.; ADAMI, M.; GIAROLLA, A.; RUDORFF, B. F. T. Monitoring Biennial Bearing Effect on Coffee Yield Using MODIS Remote Sensing Imagery. **Remote Sensing**, Basel, v. 4, p. 2492-2509, 2012.

BROWN, M.; LEWIS, H. G.; GUNN, S. R. Linear Spectral Mixture Models and Support Vector Machines for Remote Sensing. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 38, n. 5, p. 2346 – 2360, 2000.

CAMARGO, A. P.; CAMARGO, M. B. P. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia**, Campinas/SP, v. 60, n.1, p. 65-68, 2001.

CAMARGO, M. B. P.; FAHL, J. I. Seca afeta produção de café deste ano e pode comprometer safra futura. **Folha Rural**, Guaxupé/MG, v. 278, p. 10-11, 2001.

CARGNELUTTI FILHO, A.; MALUF, J. R. T.; MATZENAUER, R.; STOLZ, A. P. Altitude e coordenadas geográficas na estimativa da temperatura mínima média decendial do ar no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v. 41, n. 6, p. 893-901, jun. 2006.

CONAB. Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: Café**, safra 2012. Primeira estimativa, janeiro/2012. Brasília/DF: Conab, 2012.

CONGALTON, R. G. A review of assessing the accuracy classifications of remotely sensed data. **Remote Sensing of Environment**, New York, v. 37, p.35-46, 1991.

CROSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Ed. rev. Campinas/SP: IG/UNICAMP, 2002.

DIODATO, N.; CECCARELLE, M.; BELLOCCHI, G. GISaided evaluation of evapotranspiration at multiple spatial and temporal climate patterns using geoindicators. **Ecological Indicators**, London, v. 10, p. 1009 - 1016, 2010.

DODONOV, E.; MELLO, R. F. **Estudo sobre abordagens de extração, classificação e predição de comportamento de processos**. Technical Report. ICM/USP: São Carlos, 2008. 100 p.

EIPHANIO, J. C. N.; LEONARDI, L.; FORMAGGIO, A. R. Relações entre parâmetros culturais e resposta espectral de cafezais. **Pesquisa Agropecuária Brasileira**, Brasília/DF, v. 29, n.3, p. 439-447, mar. 1994.

ENVI - Environment for Visualizing Images. Applying Support Vector Machine Classification. In: **ENVI User's Guide**. 2008.

FERREIRA, M. E. **Análise do Modelo Linear de Mistura Espectral na discriminação de fitofisionomias do Parque Nacional de Brasília (Bioma Cerrado)**. Dissertação (Mestrado em Geologia). Universidade de Brasília, Brasília/DF, 2003.

FILETTO, F.; ALENCAR, E. Introdução e expansão do café na região sul de Minas Gerais. **Organizações Rurais e Agroindustriais**: revista de administração da UFLA, Lavras/MG, v. 3, n. 1, jan/jul. 2001.

GOEL, N. S. Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. **Remote Sensing Reviews**, New York, v. 4, p. 1-21, 1988.

GONÇALVES, P.; CARRÃO, H.; PINHEIRO, A.; CAETANO, M. Land cover classification with Support Vector Machine applied to MODIS imagery. In: **EARSeL SYMPOSIUM**, 25, Porto, Portugal, 2005. **Proceedings...** Rotterdam: Millpress, 2006. p. 517 – 525.
Disponível em: < <http://www.earsel.org/symposia/2005-symposium-Porto/index.htm>> Acesso em: 09 dez. 2012.

HIRANO, A.; BAMBANG, H. Looking into smallholder coffee plantation with ALOS data in Lampung Province, Indonesia. In: **ASIAN CONFERENCE ON REMOTE SENSING**, 28, 2007, Kuala Lumpur. **Proceedings...** Kuala Lumpur: ACRS, 2007.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 3ª ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2005.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. Tradução da 2ª ed. por: EPHIPHANIO, J. C. et al. São José dos Campos/SP: Parênteses, 2009.

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

LU, D.; MORAN, E.; BATISTELLA, M. Linear mixture model applied to Amazonian vegetation classification. **Remote Sensing of Environment**, New York, v. 87, p. 456-469, 2003.

LU, D.; MORAN, E.; BATISTELLA, M.; MAUSEL, P. Application of spectral mixture analysis to Amazonian land-use and land-cover classification. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 23, p. 5354-5358, 2004.

MELGANI, F.; BRUZZONE, L. Classification of Hyperspectral Remote Sensing Images With Support Vector Machines. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 42, n. 8, p. 1778 – 1790, 2004.

MELLO, E. V. Cafeicultura no Brasil. In: ZAMBOLIM, L. **Tecnologias de produção de café com qualidade**. Viçosa/MG: UFV, 2001. p. 565-646.

MELLO, M. P.; VIEIRA, C. A. O.; AGUIAR, D. A de.; RUDORFF, B. F. T. Classificação da colheita da cana-de-açúcar por meio de imagens de satélite utilizando superfícies de resposta espectro-temporais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14, 2009, Natal/RN. **Anais...** . São José dos Campos: Inpe, 2009. p. 279-286. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.05.02.44/doc/279-286.pdf>> Acesso em: 23 ago 2010.

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

MOREIRA, R. C. **Espectroscopia por imageamento**. Material elaborado para o Centro Técnico Aeroespacial, Instituto de Estudos Avançados. São José dos Campos/SP: [s. n.], maio de 2002.

PÁDUA, T. S. **Espaçamento econômico na cultura do cafeeiro (*Coffea arabica* L.): um estudo no Sul de Minas Gerais**. 62 p. Dissertação (Mestrado em Administração Rural), Universidade Federal de Lavras, Lavras/MG, 1998.

PAPA, R. A.; LACERDA, M. P. C.; BILICH, M. R.; CAMPOS, P. M.; SILVA, R. A. B. Comportamento espectral da cultura do feijão, por meio de dados obtidos por espectralradiometria e imagem ASTER, no Distrito Federal. In: SIMPÓSIO BRASILEIRO DE

SENSORIAMENTO REMOTO, 15, 2011, Curitiba/PR. **Anais...** São José dos Campos: Inpe, 2011, p. 4696-4703. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0283.pdf>> Acesso em: 06 fev. 2012.

PICINI, A. G.; CAMARGO, M. B. P de.; ORTOLANI, A. A.; FAZUOLI, L.C.; GALLO, P. B. Desenvolvimento e teste de modelos agrometeorológicos para a estimativa de produtividade do cafeeiro. **Bragantia**, Campinas/SP, v. 58, n. 1, p. 157-170, 1999.

PONCIANO, N. J. **Segmento exportador da cadeia agroindustrial do café brasileiro**. 128p. Tese (Doutorado em Economia Rural). Universidade Federal de Viçosa, Viçosa/MG, 1995.

PONZONI, F. J. Comportamento espectral da vegetação. In: MENESES, P. R.; MADEIRA NETTO, J. S. (Orgs.). **Sensoriamento remoto: reflectância de alvos naturais**. 1º ed. Brasília/DF: Editora UNB, 2001, v. 1, p. 157-199.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos/SP: Parêntese, 2007.

RICHARDS, J. A. **Remote sensing digital image analysis: an introduction**. Berlin: Springer-Verlag, 1986.

ROBERTS, D. A.; GARDNER, M.; CHURCH, R.; USTIN, S.; SCHEER, G.; GREEN, R. O. Mapping Chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**, New York, v. 65, p. 267-279, 1998.

ROLIM, G. S.; SENTELHAS, P. C.; BARBIERI, V. Planilhas no ambiente EXCEL TM para os cálculos de balanços hídricos: normal, sequencial, de cultura e de produtividade real e potencial. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 6, n. 1, p.133-137, 1998.

SALLABA, F. **The potential of support vector machine classification of land use and land cover using seasonality from MODIS satellite data**. 95 p. Master degree thesis, Department of Earth and Ecosystem Sciences, Lund University, Lund, Sweden, 2011. Disponível em: <http://www.natgeo.lu.se/ex-jobb/exj_220.pdf> Acesso em: 09 dez. 2012.

SANTOS, J. A. dos; GOSSELIN, P-H; PHILLIP-FOLIGUET, S; TORRES, R. da S.; FALCÃO, A. X. Multiscale Classification of Remote Sensing Images. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 50, p. 3764 – 3775, 2012.

SEDIYAMA, G. C.; MELO JUNIOR, J. C. F. de.; SANTO, A. R. dos.; RIBEIRO, A.; COSTA, M. H.; HAMAKAWA, P. J.; COSTA, J. M. N. da.; COSTA, L. C. Zoneamento agroclimático do cafeeiro (*Coffea arabica* L.) para o estado de Minas Gerais. **Revista Brasileira de Agrometeorologia**, Passo Fundo/RS, v. 9, n. 3 (Edição especial: Zoneamento Agrícola), p. 501-509, 2001.

SENTHILNATH, J.; BAJPAI, S.; OMKAR, S. N.; DIWAKAR, P. G.; MANI, V. An approach to multi-temporal MODIS image analysis using image classification and segmentation. **Advances in Space Research**, Oxford, v. 50, p. 1274 – 1287, 2012.

SHAO, Y.; LUNETTA, R. S. Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 70, p. 78 – 87, 2012.

SHIMAKURA, S.E. **Interpretação do coeficiente de correlação**. Disponível em: <<http://leg.ufpr.br/~silvia/CE003/node74.html>> Acesso em: 02 nov. 2012.

SILVA, S. de M. **Competitividade do agronegócio do café na Região Sul de Minas Gerais**. 125 p. Dissertação (Mestrado em Administração Rural), Universidade Federal de Lavras, Lavras/MG, 1998.

SOARES, J. V.; BATISTA, G. T.; SHIMABUKURO, Y. E. Histórico e Descrição. *In*: RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; CEBALLOS, J. C. (Orgs.). **O Sensor MODIS e suas Aplicações Ambientais no Brasil**. São José dos Campos/SP: Parênteses, 2007. Cap. 1, p. 3-21.

SOUZA, I. de M.; MOREIRA, M. A. Análise de resultados de segmentação por crescimento de regiões em diferentes técnicas de processamento digital de dados do Landsat/TM para mapeamento de áreas cafeeiras. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10, 2001, Foz do Iguaçu/PR. **Anais...** . São José dos Campos: Inpe, 2001.

TARDIN, A. T. I.; ASSUNÇÃO, G. V.; SOARES, J. V. Análise preliminar de imagens TM visando a discriminação de café, citrus e cana-de-açúcar na região de Furnas - MG. **Pesquisa Agropecuária Brasileira**, Brasília/DF, v. 27, n. 9, p.1355-1361, 1992.

TRABAQUINI, K.; MIGLIORANZA, E.; FRANÇA, V.; PEREIRA NETO, O. C. Estudo do ambiente físico do cafeeiro utilizando técnicas de geoprocessamento e sensoriamento remoto no norte do Estado do Paraná. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14, 2009, Natal/RN. **Anais...** . São José dos Campos: Inpe, 2009. P. 515-522. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.02.12.48/doc/515-522.pdf>> Acesso em: 29 de fev 2012.

VALERIANO, M. M. Curvatura vertical de vertentes em microbacias pela análise de modelos digitais de elevação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 7, n. 3, p. 539 – 546, 2003.

VALERIANO, M. M.; GARCIA, G. J. The estimate of topographical variables for soil erosion modelling through geoprocessing. **International Archives of Photogrammetry & Remote Sensing**, Amsterdam, v. 33, p. 678 - 685, 2000.

VAN LEEUWEN, W. J. D.; HUETE, A. R.; LAING, T. W. MODIS vegetation index compositing approach: a prototype with AVHRR data. **Remote Sensing of Environment**, New York, v. 69, p. 264– 280, 1999.

VASCONCELOS, C. H.; NOVO, E. M. L. M. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens – fração solo, sombra e vegetação derivadas

do modelo linear de mistura aplicado a dados do sensor TM/Landsat5, na região do reservatório de Tucuruí – PA. **Acta Amazônica**, Manaus/AM, v. 34, n. 3, p. 487-493, 2004.

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

ZHAN, X.; SOHLBERG, R. A.; TOWNSHEND, J. R. G.; DIMICELI, C.; CARROLL, M. L.; EASTMAN, J. C.; HANSEN, M. C.; DEFRIES, R. S. Detection of land cover changes using MODIS 250 m data. **Remote Sensing of Environment**, New York, v. 83, p. 336 – 350, 2002.