



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2013/03.04.20.07-TDI

MODELAGEM DE DADOS ESPECTRAIS E AGROMETEOROLÓGICOS PARA ESTIMATIVA DA PRODUTIVIDADE DE CAFÉ

Tiago Bernardes

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Maurício Alves Moreira, aprovada em 18 de março de 2013.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3DLLLQ8>>

INPE
São José dos Campos
2013

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):

Presidente:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Membros:

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

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

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

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

EDITORAÇÃO ELETRÔNICA:

Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)

Luciana Manacero - Serviço de Informação e Documentação (SID)



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2013/03.04.20.07-TDI

MODELAGEM DE DADOS ESPECTRAIS E AGROMETEOROLÓGICOS PARA ESTIMATIVA DA PRODUTIVIDADE DE CAFÉ

Tiago Bernardes

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Maurício Alves Moreira, aprovada em 18 de março de 2013.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3DLLLQ8>>

INPE
São José dos Campos
2013

Dados Internacionais de Catalogação na Publicação (CIP)

Bernardes, Tiago.

B456m Modelagem de dados espectrais e agrometeorológicos para estimativa da produtividade de café / Tiago Bernardes. – São José dos Campos : INPE, 2013.

xxvi + 127 p. ; (sid.inpe.br/mtc-m19/2013/03.04.20.07-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

Orientador : Dr. Maurício Alves Moreira.

1. produtividade 2. café 3. bienalidade 4. modelo agrometeorológico 5. Landsat. I.Título.

CDU 528.88:631.165

Copyright © 2013 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, reprográfico, de microfilmagem ou outros, sem a permissão escrita do INPE, com exceção de qualquer material fornecido especificamente com o propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2013 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, microfilming, or otherwise, without written permission from INPE, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

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

Dr. Antonio Roberto Formaggio



Presidente / INPE / SJCampos - SP

Dr. Maurício Alves Moreira



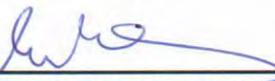
Orientador(a) / INPE / SJCampos - SP

Dr. Flávio Jorge Ponzoni



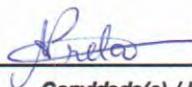
Membro da Banca / INPE / SJCampos - SP

Dra. Margarete Marin Lordelo Volpato



Convidado(a) / EPAMIG / Belo Horizonte - MG

Dra. Angélica Praelo Pantano



Convidado(a) / IAC / Campinas - SP

Este trabalho foi aprovado por:

() maioria simples

(x) unanimidade

Aluno (a): **Tiago Bernardes**

São José dos Campos, 18 de Março de 2013

“Se não houver frutos, valeu a beleza das flores; se não houver flores, valeu a sombra das folhas; se não houver folhas, valeu a intenção da semente”.

Henfil

*A meus queridos pais Antônio (in memoriam)
e Maria Imaculada e a meus irmãos Sandra,
Mateus e Juliana,
dedico.*

AGRADECIMENTOS

A Deus, por me permitir chegar até aqui cercado de tantas bênçãos.

Ao Dr. Maurício Alves Moreira, pela confiança em mim depositada, pela liberdade de atuação, pela amizade e valiosos ensinamentos passados durante todo este período.

Aos professores do INPE, pelo conhecimento repassado e inspiração no desenvolvimento de pesquisas e trabalhos científicos.

Aos demais pesquisadores e técnicos do INPE que, de uma forma ou de outra, colaboraram para que minhas atividades de aprendizado transcorressem de uma maneira tranquila e agradável.

Ao amigo Dr. Alfredo José Barreto Luiz, pesquisador da Empresa Brasileira de Pesquisa Agropecuária, EMBRAPA Meio Ambiente, pela valiosa ajuda e discussões sobre importantes aspectos tratados neste trabalho.

Aos colegas de doutorado e mestrado, pelos agradáveis momentos de convivência durante o curso de disciplinas e desenvolvimento acadêmico.

Aos colegas de república Flávio Fortes Camargo, Marco Aurélio Barros, Wagner Fernando Silva, Ariana Guimarães e Lilian Castro, pela convivência durante o período em São José dos Campos.

Ao grande amigo Marcos Adami, pela incansável disposição em ajudar, pelas tantas horas oferecidas para discussões, análises, processamentos ou simples momentos para risadas.

À amiga Luciana Miura Sugawara, pela grande ajuda no processamento de dados meteorológicos e valiosas dicas para implementação do modelo desenvolvido.

Aos amigos do doutorado, em especial André Lima, Samuel Coura, Júlio César de Oliveira, Kléber Trabaquini, Juliana Silveira dos Santos, Márcio Pupin, pelo companheirismo tornando o nosso local de trabalho mais alegre e descontraído.

A todos os meus familiares pelo amor e apoio incondicionais em todos os momentos da minha vida.

À Jane Verona, pelos momentos tão especiais e por despertar em mim o sentimento mais belo.

Ao Instituto Nacional de Pesquisas Espaciais - INPE, pelo inestimável conhecimento oferecido e oportunidade de desenvolvimento desta tese e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, pela concessão da bolsa de estudos.

À Cooperativa Regional de Cafeicultores em Guaxupé - COOXUPÉ, por intermédio do Senhor Éder Ribeiro dos Santos; ao Grupo Ipanema Coffees, por intermédio do Senhor Antônio Michelotto; e aos produtores de café da região Sul de Minas Gerais, pelo valioso apoio e cessão dos dados de campo essenciais para o desenvolvimento deste trabalho.

RESUMO

A produtividade da cultura cafeeira no Brasil tem sido estimada experimentalmente por meio de modelos agrometeorológicos que consideram o efeito da disponibilidade hídrica. No entanto, além da disponibilidade hídrica, vários outros fatores se somam para compor a produtividade, dentre eles o efeito conhecido como bienalidade, no qual a cultura apresenta produções altas e baixas, alternadamente, a cada 2 anos em função de um ciclo de desenvolvimento bianual, o que torna a produtividade do ano anterior importante na estimativa da produtividade de um determinado ano. No presente trabalho, este efeito foi considerado a partir de correlações entre dados de produtividade de lavouras obtidos em campo e a área foliar das mesmas lavouras. A área foliar foi estimada a partir dos índices de vegetação EVI e NDVI derivados de imagens Landsat. Foram obtidos modelos de regressão para estimar a produtividade do ano anterior a partir das imagens. O modelo final proposto penaliza a produtividade potencial da cultura em função das Evapotranspirações relativas, obtidas a partir de dados meteorológicos do modelo regional ETA, e da produtividade do ano anterior, obtida das regressões com os índices de vegetação. As Evapotranspirações relativas foram calculadas em 4 diferentes combinações de períodos representativos das fases fenológicas do cafeeiro e parametrizadas juntamente com a produtividade do ano anterior para determinação de coeficientes que representam o peso (ky) destas variáveis na penalização da produtividade potencial. O coeficiente de penalização pela produtividade do ano anterior (ky_0) apresentou os maiores valores, o que indica a importância desta variável na produtividade do cafeeiro. Com relação às variáveis de penalização hídrica os coeficientes referentes à fase entre os meses de Abril a Setembro (ky_1), que corresponde à indução e maturação das gemas florais, foram maiores. O coeficiente referente à fase entre os meses de Setembro a Dezembro (ky_2), correspondente ao florescimento e início da formação dos frutos, mostrou-se o segundo mais importante. O modelo final foi avaliado ao nível de produtividade por lavouras e ao nível de produção total por município. O modelo utilizando coeficientes de penalização parametrizados com as Evapotranspirações relativas agrupadas nos períodos Jun/Jul/Ago, Set/Out/Nov e Dez/Jan/Fev (combinação A) apresentou os melhores resultados em relação aos modelos C e D. O desempenho geral dos modelos ao nível de lavouras foi considerado ruim, com erros variando entre 13,73 a 21,43 sc/ha (EMA) e 18,51 a 28,66 sc/ha (EMQ), valores de R^2 variando entre 0,20 a 0,69, índices d_1 0,38 a 0,53 e índice d_2 entre 0,41 a 0,70. Ao nível de produção total por municípios os desempenhos foram melhores com erros variando entre 1.600 a 3.900 kg (EMA) e 2.490 a 6.904 kg (EMQ), valores de R^2 variando entre 0,67 a 0,93, índices d_1 0,65 a 0,83 e índice d_2 entre 0,77 a 0,90.

MODELLING SPECTRAL AND AGROMETEOROLOGICAL DATA TO ESTIMATE COFFEE YIELD

ABSTRACT

Coffee yield has been estimated in Brazil through agrometeorological models which consider the effect of water availability. However besides the water availability several factors must be taken into account in yield forecasting, as the well known biennial bearing effect. This effect results in alternated high and low yield due to the biannual growth cycle of coffee crop and makes yield the previous year important. In this study this effect was considered using correlations between observed yield of coffee plots and foliar area of the same plots. The foliar area was estimated through Landsat derived vegetation indices (EVI and NDVI). We have used regression models to estimate yield the previous year. The final model penalizes the potential yield according the Relative evapotranspiration, obtained from meteorological data of ETA regional model, and yield the previous year, obtained from regression models with vegetation indices. The Relative evapotranspiration were calculated in four different combinations of periods representative of phenological phases of coffee crop and parameterized jointly to yield the previous year in order to determine the weight coefficients (ky) for these variables in the penalization of potential yield. The penalization coefficient for yield the previous year (ky_0) presented higher values, indicating the importance of this variable for coffee yield. In relation to the water penalization variables, the coefficients for the phase from April to September (ky_1), which match to flower bud induction, were higher. The coefficient for the phase from September to December (ky_2), which match to flowering and early fruit development, was the second most important. The final model was evaluated in plot yield level and total production of the municipality level. The models using weigh coefficients parameterized for Relative evapotranspiration gathered in periods of Jun/Jul/Aug, Sept/Oct/Nov and Dec/Jan/Feb (combination A) presented better results compared to the models C and D. The general accuracy of models in the plot level was considered bad, with errors ranging from 13,73 to 21,43 sc/ha (RE) and 18,51 a 28,66 sc/ha (MSE), values of R^2 ranging from 0,20 to 0,69, d_1 index ranging from 0,38 a 0,53 and d_2 index ranging from 0,41 a 0,70. In the municipality level the accuracy was better with errors ranging from 1600 to 3900 to kg (RE) and 2490 to 6904 kg (MSE) values of R^2 ranging from 0,67 to 0,93, d_1 index ranging from 0,65 a 0,83 and d_2 index ranging from 0,77 a 0,90.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Esquematização das fases fenológicas do cafeeiro arábica	6
Figura 2.2 - Representação pictórica do efeito de aumento do tamanho dos pixels do Modis em função do distanciamento do zênite.	23
Figura 2.3 - Distribuição dos tiles Modis (18 x 36) em projeção sinusoidal.	24
Figura 2.4 - Detalhe do tile H13V11, referente à área de estudo, entre as cenas disponíveis para o território brasileiro.	25
Figura 3.1 - Distribuição dos dados de campo nas áreas piloto selecionadas.	42
Figura 3.2 - Mapa base de áreas cafeeiras do Sul/Sudoeste de Minas Gerais.	44
Figura 3.3 - Fluxograma das etapas de trabalho.	49
Figura 3.4 - Sobreposição dos limites de pixels Modis em áreas cafeeiras; (A) grade da imagem Modis sobreposta ao mapa de café para individualizar pixels totalmente ocupados por café, cor verde; (B) Variabilidade de lavouras, dentro de um pixel, realçada nas imagens TM/Landsat-5, composição de bandas 4R, 5R, 3B	51
Figura 3.5 - Processamento realizado para seleção de pixels e avaliação das correlações entre dados Modis e dados de produtividade	52
Figura 3.6 - Amplitude de variação anual dos IV para os pixels selecionados (A); Padrão de lavoura em seu máximo índice de vegetação no mês de março (B) e mínimo índice de vegetação no mês de agosto (C);	54
Figura 3.7 - Segmentação das imagens Landsat para individualizar os talhões de café e converter de valores de índices de vegetação - média e moda - para cada talhão homogêneo de café.	59
Figura 3.8 - Etapas de coleta de dados, processamento e análise para obtenção de modelos de correlação com dados espectrais, biofísicos e produtividade dos talhões de café.	60

Figura 4.1 - Séries temporais dos valores de NDVI e EVI para a cultura do café no período de 2000 a 2010 – dados originais e filtrados.	73
Figura 4.2 - Correlação entre variações na produtividade e variações nos valores mínimos de índices de vegetação no mesmo ano.	77
Figura 4.3 - Correlação entre variações nos valores mínimos de IV (minEVI e minNDVI) e variações na produtividade do café no ano seguinte.	80
Figura 4.4 - Balanço hídrico para o município de Guaxupé e coeficientes de correlação de Pearson entre os anos de 2002 a 2009.	82
Figura 4.5 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo A.	98
Figura 4.6 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo B.	99
Figura 4.7 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo C.	99
Figura 4.8 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo D.	99
Figura 4.9 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo A.	104
Figura 4.10 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo B.	104
Figura 4.11 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo B.	105

Figura 4.12 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo C. 105

Figura 4.13 - Diagramas boxplot com os intervalos de confiança de índices Willmott (d) e coeficientes de determinação (R^2) ano a ano para cada modelo obtido – análise ao nível de município. 107

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Resumo de alguns Índices de vegetação, formulação e Autores.	31
Tabela 3.1 - Número de dados de produtividade amostrados para cada ano (n_i) e número válido de unidade amostrais quando calculada a diferença (variação) entre dois anos ($n_i - n_{i-1}$).	56
Tabela 3.2 - Diferentes combinações das durações dos períodos considerados nas análises dos efeitos das evapotranspirações relativas utilizadas na parametrização e teste do modelo agrometeorológico.	65
Tabela 3.3 - Fator W em função da temperatura média do ar ($T_{\text{média}}$ em °C) e altitude (metros).	67
Tabela 3.4 - Pressão de saturação do vapor (p_v) em função da temperatura média do ar ($T_{\text{méd}}$).	68
Tabela 3.5 - Fração de esgotamento de água no solo (p).	69
Tabela 3.6 - Evapotranspiração real (ET_r) em mm.dia^{-1} em função do índice de água disponível no solo (IADS), Evapotranspiração máxima (ET_m) e água remanescente no solo (ARS).	70
Tabela 4.1 - Coeficientes de correlação de Pearson (r), coeficientes de determinação (R^2) e valor-p (p) para as variações na produtividade do café e nas métricas de Índices de Vegetação no mesmo ano, para o período de 2002 a 2009.	75

Tabela 4.2 - Coeficientes de correlação de Pearson (r), coeficientes de determinação (R^2) e valor-p (p) para as variações nas métricas de índices de vegetação e variações na produtividade do ano seguinte.	79
Tabela 4.3 - Variáveis e os resultados do teste estatístico (Parâmetro estimados, Erro padrão, valor F e valor p) obtidos a partir do modelo aplicado quando combinou-se idade da lavoura e densidade de plantio com os índices de vegetação NDVI e EVI (r=0,71)	85
Tabela 4.4 - Variáveis e os resultados do teste estatístico (Parâmetro estimados, Erro padrão, valor F e valor p) obtidos para os resultados do modelo 2, aplicado somente com a densidade de plantio (r=0,67).....	86
Tabela 4.5 - Variáveis e os resultados do teste estatístico (Parâmetro estimados, Erro padrão, valor F e valor p) obtidos para os resultados do modelo 3, aplicado somente com a densidade de plantio (r=0,64).....	87
Tabela 4.6 - Tamanho das amostras, numero de variáveis por modelo, valor F, valor p, coeficiente de correlação (r) e coeficiente de determinação (R^2) obtidos para os 3 modelos gerais que apresentaram as melhores correlações.	88
Tabela 4.7 – Tamanho da amostra, Número de variáveis, valor F, valor p, r e R^2 , obtidos para as cultivares Catuaí e Mundo Novo.	89

Tabela 4.8 – Variáveis utilizadas no modelo, valor dos parâmetros estimados, Erro padrão, valor F e valor p, obtidos para o cultivar Catuaí (r=0,85).	89
Tabela 4.9 - Variáveis utilizadas no modelo, valor dos parâmetros estimados, Erro padrão, valor F e valor p, obtidos para o cultivar Catuaí (r=0,64).	89
Tabela 4.10 - Parâmetros estatísticos obtidos para os melhores modelos utilizando dados das cultivares Catuaí e Mundo Novo e dados agregados de ambas as variedades (Catuaí e Mundo Novo)	90
Tabela 4.11 – Variáveis, valores das estimativas dos parâmetros, Erro padrão, valor t e valor p obtidos a partir do modelo aplicado para o cultivar Catuaí (r=0,84).....	91
Tabela 4.12 - Variáveis, valores das estimativas dos parâmetros, Erro padrão, valor t e valor p obtidos a partir do modelo aplicado para o cultivar Mundo Novo (r=0,53)	91
Tabela 4.13 - Variáveis, valores das estimativas dos parâmetros, Erro padrão, valor t e valor p obtidos a partir do modelo aplicado para as duas variedades juntas (r=0,52)	92
Tabela 4.14 - Valores de coeficientes de resposta da cultura à produtividade do ano anterior (ky_0) e à disponibilidade hídrica (ky_i) considerando as diferentes sequências de durações dos períodos da variável hídrica (Evapotranspiração relativa - ER/EP) e parâmetros estatísticos dos modelos.....	95

Tabela 4.15 - Valores de coeficiente de determinação (R^2), Erro Médio Absoluto (EMA), Erro Médio Quadrático (EMQ), e índices de Willmott d_1 e d_2 , resultantes da regressão linear entre os dados de produtividade observados em campo e os dados estimados pelo modelo. (^a Limites do intervalo de confiança ($\alpha=0,01$) com valores estimados pelo *Bootstrap*)..... 98

Tabela 4.16 - Valores de coeficiente de determinação (R^2), Erro Médio Absoluto (EMA), Erro Médio Quadrático (EMQ), e índices de Willmott d_1 e d_2 , resultantes da regressão linear entre os dados de produção total por município e os dados estimados pelo modelo..... 102

SUMÁRIO

1. INTRODUÇÃO	1
1.1. Contextualização.....	1
1.2. Hipótese.....	3
1.3. Objetivo geral.....	3
1.4. Objetivos específicos.....	3
2. REFERENCIAL TEÓRICO	5
2.1. Cultura cafeeira	5
2.1.1. Fenologia da cultura.....	6
2.1.2. Exigências climáticas	7
2.1.3. Influência de fatores ambientais na produtividade.....	8
2.1.4. Influência da fitomassa foliar na produtividade.....	10
2.2. Estimativas de produtividade agrícola.....	11
2.2.1. Modelos de produtividade	12
2.2.2. Modelos agrometeorológicos.....	14
2.3. Dados de sensoriamento remoto	19
2.3.1. Dados landsat	19
2.3.1.1. Processamento de dados landsat	19
2.3.2. Dados modis.....	22

2.3.3. Processamento de séries temporais	25
2.3.3.1. Wavelets	26
2.4. Sensoriamento remoto na estimativa de produtividade de culturas agrícolas	27
2.4.1. Estimativas de variáveis biofísicas	28
2.4.2. Índice de área foliar – iaf	29
2.4.3. Índices de vegetação	30
2.4.3.1. Índices de vegetação para estimativa de iaf	31
2.4.4. Aplicações no brasil	33
2.4.5. Validação dos modelos	35
3. MATERIAL E MÉTODOS	41
3.1. Área de estudo	41
3.1.1. Áreas piloto	41
3.2. Dados	43
3.2.1. Imagens de satélite	43
3.2.2. Mapa de área cafeeira	43
3.2.3. Dados meteorológicos	45
3.2.4. Dados de campo	45
3.3. Metodologia	46
3.3.1. Descrição do modelo	46

3.3.2. Etapa 1 – processamento de imagens de satélite e correlações com dados de campo.....	49
3.3.2.1. Mapa de áreas cafeeiras.....	49
3.3.2.2. Dados modis	50
3.3.2.2.1. Seleção de pixels	50
3.3.2.2.2. Filtragem da série temporal.....	53
3.3.2.2.3. Métricas derivadas dos índices de vegetação modis.....	53
3.3.2.2.4. Dados de produtividade	54
3.3.2.2.5. Análise das correlações.....	55
3.3.2.3. Dados landsat	57
3.3.2.3.1. Processamento das imagens (correção radiométrica, atmosférica e normalização).....	57
3.3.2.3.2. Extração dos iv por talhões	58
3.3.2.3.3. Análise das correlações	59
3.3.3. Etapa 2 – processamento de dados meteorológicos e integração aos dados de sensoriamento remoto.....	61
3.3.3.1. Modelo agrometeorológico	61
3.3.3.2. Evapotranspiração potencial (et0).....	66
3.3.3.3. Evapotranspiração real (etr).....	68
3.3.4. Etapa 3 – geração da produtividade estimada e validação	71
4. RESULTADOS	73

4.1. Correlações entre produtividade e dados modis	73
4.1.1. Variação anual dos índices de vegetação	73
4.1.2. Análise das correlações entre variações nos dados de campo e nos índices de vegetação em cada par de anos.....	74
4.2. Correlações entre produtividade e dados obtidos de imagens do tm/landsat	83
4.2.1. Modelos fundamentados em variáveis espectrais e variáveis biofísicas (parâmetros culturais)	83
4.2.2. Modelos fundamentados em variáveis espectrais	89
4.3. Parametrização dos coeficientes de resposta.....	93
4.4. Estimativas de produtividade com o modelo final.....	96
4.4.1. Estimativa de produtividade por lavouras.....	97
4.4.2. Estimativa da produção total por município	101
4.4.3. Influência do mapa de áreas cafeeiras nas estimativas da produção através dos modelos para anos diferentes.....	105
5. CONCLUSÕES	109
REFERÊNCIAS BIBLIOGRÁFICAS	111

1. INTRODUÇÃO

1.1. Contextualização

O café é a segunda *commodity* mais comercializada no mundo, perdendo apenas para a cadeia produtiva do petróleo. O Brasil é responsável por cerca de um terço da produção mundial e, embora o café tenha diminuído sua participação nas exportações brasileiras ao longo do tempo devido à diversificação dos produtos, ainda é um importante gerador de divisas para o País (EMBRAPA Café, 2009).

De acordo com relatório da Organização Internacional do Café (ICO, 2009), o aumento dos custos de produção nos últimos anos foi devido a consecutivas altas nos preços dos insumos. Os preços do café no Brasil são, invariavelmente, afetados pelas flutuações nos preços de insumos e mercado financeiro mundial.

Dada a importância do produto para gerar renda no Brasil e a instabilidade comercial, devido a uma série de fatores externos (MEHTA; CHAVAS, 2008), é fundamental a busca por ações que visem manter a sustentabilidade e estabilidade da produção. Isto requer excelência na capacidade de gerenciamento e compreensão dos sistemas produtivos, o que pode ser traduzido em habilidade no uso de tecnologia e obtenção de informações capazes de antecipar tendências de comportamento em resposta a uma variada gama de fatores influenciadores.

Uma das mais importantes informações da produção agrícola é a produtividade por unidade de área, que aliada à informação de área plantada, permite o conhecimento da produção total. Além disso, a produtividade pode ser entendida como um indicador da eficiência produtiva do sistema, ou seja, reconhecimento do lucro ou prejuízo da atividade.

Modelos e técnicas que formalizam os processos responsáveis pela produção das culturas favorecem o levantamento antecipado desta informação de forma

objetiva com base em fatores de produção, como condições climáticas e disponibilidade de água e nutrientes. No Brasil, a produtividade da cultura do café é estimada operacionalmente por métodos subjetivos, ou em estudos científicos com algum nível de formalismo matemático como nos modelos agrometeorológicos (PICCINI, et. al.,1999; CAMARGO et al., 2003; CARVALHO et al., 2003; SANTOS et al., 2006). No segundo caso, dada a complexidade das relações envolvidas, tais modelos operam, na maioria das vezes, de maneira pontual. No entanto, os modelos agrometeorológicos consideram em sua essência apenas a influência de parâmetros climáticos na produtividade. Uma das características mais marcantes da cultura cafeeira é o fenômeno da bienalidade da produção, o qual proporciona alternância entre baixas e altas produtividades a cada 2 anos.

A produtividade é um fenômeno relacionado à área foliar das culturas, a qual pode ser estimada por meio de índices derivados de imagens orbitais (FUNK; BUDDE, 2009).

Pode-se dizer que a produtividade é função do fenômeno da bienalidade da área foliar da cultura do café. Assim, pode variar ano a ano ou de lavoura para lavoura. Mesmo assim a produtividade pode ser obtida espacialmente por meio da associação de dados de imagens de satélites aos modelos agrometeorológicos. Em geral, esta associação é feita de forma indireta, ou seja, utilizam-se dados de sensoriamento remoto para estimar variáveis necessárias aos modelos agrometeorológicos (RIZZI, 2004; SUGAWARA, 2010; ROSA, 2007).

No caso da cafeicultura, tanto o desenvolvimento de modelos de produtividade quanto o monitoramento da produção por meio de dados de satélite constituem um grande desafio devido à diversidade de padrões de manejo e condições fitossanitárias da cultura. Adicionalmente, a produtividade é um fenômeno complexo que depende de várias combinações de fatores e condições de cultivo, o que torna difícil a sua modelagem. No entanto, o desenvolvimento de

novas plataformas orbitais e sensores tem resultado numa grande variedade de produtos com melhorias expressivas em resoluções espacial, espectral, radiométrica e temporal. Tais avanços favorecem a descrição da variabilidade de padrões da cultura cafeeira e obtenção de melhores correlações entre os dados espectrais e variáveis biofísicas da cultura, melhorando as possibilidades de aplicação de técnicas de sensoriamento remoto em estudos com café.

1.2. Hipótese

O emprego de dados de sensoriamento, para estimar variáveis utilizadas nos modelos agrometeorológicos, permite espacializar os resultados da produtividade da cultura cafeeira de maneira objetiva assim como uma descrição da variabilidade espacial.

1.3. Objetivo geral

Estimar a produtividade de lavouras cafeeiras por meio de uma metodologia que associa dados de sensoriamento remoto e um modelo agrometeorológico.

1.4. Objetivos específicos

Realizar um estudo em áreas pilotos, representativas do parque cafeeiro no Sul de Minas Gerais, para melhor compreender o comportamento dos dados espectrais derivados de imagens de satélite com relação às variações nos padrões da cultura cafeeira;

Analisar quais dados de sensoriamento remoto (imagens e índices de vegetação) são mais adequados para estimativas de variáveis a serem inseridas em um modelo de produtividade;

Avaliar correlações empíricas entre índices de vegetação derivados de dados de sensoriamento remoto e dados de produtividade do café coletados em campo;

Selecionar o melhor modelo empírico e utilizar estes dados para verificar as correlações entre índices de vegetação e a produtividade, visando à consideração da influência da produtividade do ano anterior no modelo a partir dos dados de sensoriamento remoto;

Determinar a evapotranspiração potencial e real para diferentes fases fenológicas do café por meio de parâmetros meteorológicos derivados de uma base de dados especializados;

Parametrizar os coeficientes de sensibilidade ao déficit hídrico e à produtividade do ano anterior, com base nos valores de evapotranspiração e produtividades relativas;

Estimar a produtividade das lavouras tomando como fatores de penalização da produtividade potencial o déficit hídrico, a produtividade do ano anterior;

2. REFERENCIAL TEÓRICO

2.1. Cultura cafeeira

O cafeeiro (*Coffea spp*) é uma planta perene, de porte arbustivo ou arbóreo originário das florestas tropicais da África. As espécies exploradas comercialmente nos grandes centros produtores são a *Coffea canephora* e *Coffea arabica*, responsáveis por 99% da produção comercial no mundo (DAMATTA et al., 2007). Cerca de 65% da produção mundial corresponde à espécie arábica e o restante à espécie canephora (FASSIO; SILVA, 2007). A espécie arábica produz uma bebida de qualidade superior e, por isso, tem maior aceitação nos mercados consumidores. A espécie canephora, vulgarmente conhecida como café Robusta ou Conilon, resiste melhor a variações nas condições climáticas e produz um café de bebida inferior, porém sua boa aceitação no mercado se deve ao preço reduzido e possibilidade de utilização na indústria de café solúvel, e nos chamados blends (misturas com arábica em diferentes proporções para formação de cafés).

No Brasil cerca de 80% da produção corresponde à espécie arábica e as cultivares Catuaí e Mundo Novo são as mais tradicionais. O café Conilon, responsável por 20% da produção, é cultivado em alguns Estados, sendo o Espírito Santo o maior produtor.

No mundo inteiro, dentre as commodities naturais, o café é superado apenas pela cadeia produtiva do petróleo, o que gera uma movimentação financeira de mais de 90 bilhões de dólares por ano e envolve mais de 500 milhões de pessoas entre o cultivo e geração do produto final (DAMATTA; RAMALHO, 2006). No Brasil estima-se que a atividade relacionada ao café gera cerca de 7 milhões de empregos diretos e indiretos e uma riqueza anual de 10 bilhões de reais (EMBRAPA Café, 2009).

2.1.1. Fenologia da cultura

O café é uma cultura perene que necessita de dois anos para completar seu ciclo vegetativo. A esquematização das diferentes fases fenológicas do cafeeiro favorece a compreensão do desenvolvimento da cultura e identificação de necessidades sazonais de água e iluminação (fotoperíodo), bem como a definição das melhores épocas para realizar tratamentos culturais específicos. De maneira geral, o café floresce na primavera, frutifica no verão, amadurece no outono e é colhido no inverno (MATIELLO, 1991). A Figura 2.1 apresenta a esquematização proposta por Camargo e Camargo (2001), que divide o ciclo fenológico do cafeeiro em seis fases distintas:

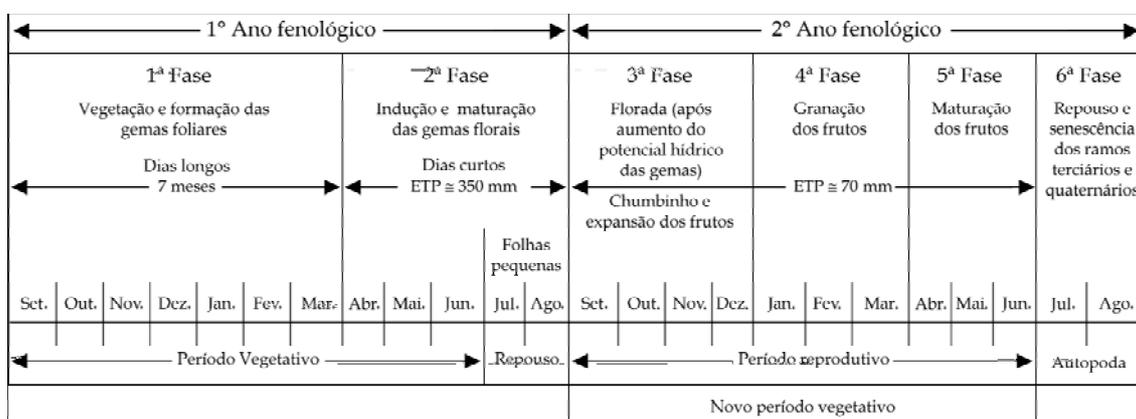


Figura 2.1 - Esquematização das fases fenológicas do cafeeiro arábica

FONTE: Adaptada de Camargo e Camargo (2001)

O ciclo inicia-se com o desenvolvimento de ramos vegetativos nos meses de chuva e dias longos (meados de setembro). Com a chegada do outono e encurtamento dos dias, já no ano civil seguinte, ocorre a indução das gemas reprodutivas que, ao amadurecerem, entram em estado de dormência até que haja disponibilidade hídrica suficiente para desencadear a florada. No final desta etapa (julho/agosto) a planta paralisa o seu crescimento. Após as primeiras chuvas, agora no segundo ano fenológico, inicia-se a florada, desenvolvimento e maturação dos frutos até uma nova fase de repouso (julho/agosto).

No esquema apresentado na Figura 2.1 é possível perceber a sobreposição das fases vegetativas e reprodutivas, que resulta na partição dos fotoassimilados para ambas as funções. Em cultivos a pleno sol os frutos atuam como drenos prioritários e a alocação de fotoassimilados para os frutos pode ser até 4 vezes maior do que aquela destinada ao crescimento de novos ramos (VAAST et al., 2005). Assim, quando a produção é alta, a planta direciona a maior parte dos fotoassimilados para os grãos em detrimento de novos ramos vegetativos. Como estes ramos novos serão os responsáveis pela produção do ano seguinte, a mesma será reduzida. Isto explica a bienalidade da produção, a qual é de extrema importância nas estimativas de produção da cultura do café. Picini (1999) ressalta a importância do efeito da bienalidade na produção do cafeeiro e sugere sua incorporação nos modelos agrometeorológicos aplicados à cultura.

2.1.2. Exigências climáticas

As exigências climáticas para o cultivo do café derivam das condições de clima vigentes no local de origem da planta. A espécie arábica é originária da Etiópia em altitudes entre 1600 e 2800 metros, onde a temperatura média anual fica em torno de 20 °C, as chuvas são bem distribuídas variando de 1600 a 2000 mm por ano e a estação seca dura cerca de 3 a 4 meses, coincidindo com o período frio (DAMATA; RAMALHO, 2006). A espécie robusta é originária do Congo, em altitudes que oscilam entre o nível do mar e 1200 metros, temperaturas entre 24 e 26 °C e chuvas superiores a 2000 mm por ano, distribuídas em 9 a 10 meses (COSTE, 1992). Nos seus locais de origem o cafeeiro se desenvolveu como planta de sub dossel, ou seja, crescimento em ambiente sombreado ou semissombreado (SYLVAIN, 1955; COSTE, 1992), assim, possíveis efeitos danosos causados por temperaturas extremas usualmente ocorrentes nestes países são minimizados.

Após um histórico de adaptação e melhoramento genético do cafeeiro para cultivo em condições brasileiras, temperaturas médias anuais em torno de 18 e 23 °C definem regiões aptas à cultura. Acima de 23 °C o desenvolvimento e a

maturação dos frutos são acelerados resultando em perda de qualidade do produto final, enquanto abaixo de 18 °C o desenvolvimento da planta é comprometido e a ocorrência de geadas pode inviabilizar o cultivo (CAMARGO, 1985). No entanto, algumas cultivares selecionadas têm se desenvolvido bem em regiões aonde as temperaturas médias anuais chegam a 24-25 °C (DAMATA; RAMALHO, 2006). Tais considerações são válidas para a espécie arábica. No caso da espécie robusta, segundo Matiello (1998), a temperatura média anual desejável varia entre 22 a 26 °C. Além disso, a espécie robusta é menos tolerante a baixas temperaturas do que a espécie arábica.

Ambas as espécies apresentam exigências de chuva entre 1200 a 1800 mm por ano, sendo que a espécie robusta se adapta bem a precipitações superiores a 2000 mm por ano (COSTE, 1992). Contudo, DaMata e Ramalho (2006) ressaltam que as exigências variam em função de características de retenção de água dos solos, umidade relativa do ar, cobertura de nuvens e práticas agrícolas empregadas.

2.1.3. Influência de fatores ambientais na produtividade

Componentes climáticas (precipitação, temperatura, radiação solar, etc.) podem explicar até 80% da variação na produtividade das culturas (PETR, 1991; FAGERIA, 1992). Além de influenciarem diretamente nos processos internos das plantas, as variáveis climáticas controlam também a ocorrência de fenômenos favoráveis ou prejudiciais ao desenvolvimento das mesmas. Hoogenboom (2000) comenta alguns dos efeitos de variáveis meteorológicas nas plantas:

- A temperatura do ar controla a taxa de desenvolvimento vegetativo numa proporção direta até certo ponto, quando então esta relação se inverte. A partir de uma dada temperatura (e isto varia em função da espécie) quanto maior a temperatura, menor a taxa de desenvolvimento da planta. Além disso, altas temperaturas favorecem o aparecimento de algumas doenças;

- A radiação solar é a energia motora para o processo fotossintético, influenciando na produção de fitomassa e fotoassimilados responsáveis pelos demais processos internos das plantas;
- A precipitação modifica as condições ambientais (umidade relativa do ar, água disponível do solo) que afetam o desenvolvimento das plantas em intensidades que vão depender da espécie, estágio de desenvolvimento e vigor vegetativo. Há plantas mais resistentes a condições de estresse hídrico, outras mais tolerantes a condições de encharcamento, assim como suas respostas a estes extremos podem variar em função da idade e condições fitossanitárias;
- A velocidade do vento e umidade relativa do ar, além de afetarem a evapotranspiração (perda conjunta de água por transpiração das folhas e evaporação direta do solo), podem favorecer o desenvolvimento e propagação de doenças e pragas.

Segundo DaMata e Ramalho (2006), deficiência de água e temperaturas desfavoráveis são as principais limitações climáticas para produção do cafeeiro.

O efeito da temperatura na produção final do cafeeiro se deve, em parte, ao fato da planta ser particularmente afetada tanto por temperaturas muito baixas quanto muito elevadas (BARROS et al., 1997; SILVA et al., 2004). Temperaturas negativas podem danificar totalmente folhas e frutos no ano de sua ocorrência além de comprometer a produção do ano seguinte (ANDROCIOLI FILHO et al., 1986). Weill (1999) relata que a ocorrência de temperaturas baixas influenciou na produtividade em cafeeiros no oeste paulista. A inclusão de fatores de penalização da produtividade em função de temperaturas baixas e elevadas vem produzindo resultados consistentes no Brasil (CAMARGO et al., 2003; SANTOS; CAMARGO, 2006).

Com relação às exigências hídricas, tanto o excesso e má distribuição de chuvas ou a falta podem afetar a produtividade. Déficit hídrico de 2 a 4 meses

durante a fase de dormência da planta é importante para estimular e uniformizar a florada (HAARER, 1958). A ocorrência de chuvas neste período e mesmo após a primeira florada resulta em múltiplas floradas e, conseqüentemente, ocorre desuniformidade da maturação dos frutos (RENA et al., 2001; RENA; BARROS, 2004). A grande variação na porcentagem de grãos verdes, maduros e secos resulta em problemas na operacionalização da colheita e qualidade da bebida (RENA; BARROS, 2004; GUERRA et al., 2006). Estudos para avaliar o rendimento da cultura cafeeira em função do fator hídrico revelam que a produtividade é sensível ao estresse hídrico, sobretudo nos estádios fenológicos de florescimento e formação de grãos (CAMARGO, 1987; PICINI, 1999; CARVALHO et al., 2003; SANTOS; CAMARGO, 2006).

2.1.4. Influência da fitomassa foliar na produtividade

A influência da fitomassa na produtividade das culturas agrícolas está relacionada com o processo de fotossíntese que ocorre a partir da interceptação da energia luminosa pelas folhas para desencadear os processos que vão resultar na produção de fotoassimilados. Os produtos fotoassimilados são distribuídos para as funções de crescimento vegetativo e reprodutivo da planta. Conseqüentemente pragas, doenças e outros fatores como seca influenciam a produtividade, devido à redução que podem causar na fitomassa (DaMATA et al., 2007).

A relação entre fitomassa e produtividade do cafeeiro pode ser afetada, em grande parte, pela ocorrência de doenças, sobretudo a ferrugem do cafeeiro (*Hemileia vastatrix*). Em anos de grande carga produtiva, os ataques de ferrugem são mais severos, o que resulta em intensa queda de folhas após a colheita e, conseqüentemente, redução na produção do ano seguinte (CHALFON, 1981; ESKES; CARVALHO, 1983; BROWN et al., 1995). Assim, ocorrência de ferrugem em anos de alta produção acentua ainda mais o efeito da bienalidade de produção do cafeeiro (ZAMBOLIM et al., 2002).

2.2. Estimativas de produtividade agrícola

O conhecimento da produção agrícola é fundamental para o planejamento do abastecimento interno e orientação de ações relativas ao mercado externo (SANTOS; CAMARGO, 2006). Tal informação pode ser obtida por meio do levantamento/monitoramento de safra ou, antecipadamente, através de modelos de previsão de safra. No primeiro caso a produção é estimada no decorrer da colheita, um procedimento subjetivo, que pela sua natureza não permite definir ações preventivas contra possíveis implicações de super ou sub produção. Já as estimativas antecipadas de safra apresentam o benefício extra da prevenção, ampliando a margem de atuação nas diversas esferas de planejamento da produção agrícola.

No Brasil as estimativas de safra vêm sendo realizadas predominantemente por métodos subjetivos que tomam por base o conhecimento de agentes de extensão, financiamento e comercialização. Baseado nesta metodologia, o Levantamento Sistemático da Produção Agrícola, divulgado mensalmente pelo IBGE, fornece informações referentes à estimativa de área plantada, produtividade média e produção de diversas culturas, a partir da fase de intenção de plantio até o final da colheita (IBGE, 2003).

O sucesso de um sistema de previsão de safra depende da sua capacidade em quantificar a influência do clima, fatores de produção e condições de manejo na produtividade e da capacidade em integrar apropriadamente os resultados (previsões) em diferentes escalas (HANSEN; JONES, 2000). Para tanto são desenvolvidos modelos matemáticos de previsão de safra com diferentes graus de complexidade, desde modelos derivados de regressões entre fatores de produção e produtividade até sofisticados modelos descritores dos processos envolvidos no fenômeno estudado, neste caso: a produtividade.

2.2.1. Modelos de produtividade

Sistemas agrícolas resultam da conjunção de uma série de fatores biológicos cujas relações com o ambiente são muitas vezes desconhecidas. Modelos de produtividade buscam integrar matematicamente a relação dos fatores biológicos e do ambiente para explicar uma dada produtividade. Uma maneira intuitiva de classificar os modelos seria pelo grau de complexidade das relações modeladas. Contudo, na literatura o assunto é abordado sob diferentes óticas de percepção, seja de maneira mais genérica, passível de aplicação a qualquer tipo de modelo (GOMES; VARRIALE, 2001), ou de maneira mais direcionada a modelos de produtividade agrícola (BAIER, 1979; ROBERTSON, 1983; ACOCK; ACOCK, 1991).

Segundo Baier (1979), os modelos podem ser classificados em: (i) modelos estatísticos empíricos, (ii) modelos de simulação de crescimento e (iii) modelos de análise da cultura em seu meio.

Os modelos estatísticos empíricos são os mais simples e relacionam dados derivados de observações de campo (produtividade) e dados climáticos por meio de técnicas estatísticas de regressão. As correlações observadas podem ser usadas na estimativa da produtividade. No entanto, estas correlações são susceptíveis a variações de outros fatores considerados relevantes na produtividade. Ademais, as variáveis climáticas usadas são espacialmente heterogêneas e nem sempre podem ser estimadas precisamente para grandes áreas. Portanto, estes modelos mostram-se restritos à aplicação em condições semelhantes àsquelas vigentes durante a coleta de dados, ou seja, não são apropriados para extrapolação para outras áreas. Ainda assim, diversos estudos adotam esta abordagem devido à sua simplicidade de aplicação e desempenho a nível local.

Os modelos de simulação de crescimento procuram representar matematicamente os processos físicos, químicos e fisiológicos intrínsecos ao desenvolvimento das plantas. Em suma, estes modelos buscam o

entendimento dos fenômenos expressos no estande baseado nos processos vigentes na planta. De fato, uma das mais poderosas ferramentas utilizadas nas estimativas de produtividade são os modelos de simulação de crescimento de culturas, dos quais o grupo de pesquisa da Universidade de Wageningen tem produzido uma verdadeira linhagem de sofisticados modelos fundamentados nos processos fisiológicos das plantas (BOUMAM, et al., 1996; VAN ITTERSUM et al., 2003). A título de informação podem-se citar os modelos genéricos SUCROS (VAN LAAR, et al., 1997), e LINTUL (SPITTERS, 1990; KOOMAN; HAVERKORT, 1995; HABEKOTTÉ, 1996, 1997; VAN DELDEN, 2001), e os específicos ORYZA2000 (BOUMAN et al., 2001), para arroz e APPLE (WAGENMAKERS, 1995), para maçã, dentre vários outros.

A aplicabilidade destes modelos supera o objetivo único de estimativas de produtividade, provendo ainda informações potenciais para melhoramento genético e planejamento de estratégias de manejo. O modelo WOFOST (BOOGAARD et al., 1998), por exemplo, constitui a base para gerar indicadores de produção do sistema de monitoramento e desenvolvimento das culturas (Crop Growth Monitoring System – CGMS) (SUPIT, 2000), atualmente operacional nos países da União Europeia.

Os modelos de análise da cultura em seu meio, que incluem os modelos agrometeorológicos, buscam uma representação simplificada das respostas das culturas (desenvolvimento morfológico, crescimento vegetativo ou produtividade) às variáveis ambientais como temperatura, umidade do solo, evapotranspiração, dentre outras. Estes modelos requerem o conhecimento da interação entre a planta, o solo e a atmosfera. Esta interação é transcrita para sistemas de equações que analisam as contribuições das variáveis meteorológicas na produtividade final de uma cultura agrícola (BAIER, 1979).

Este tipo de modelagem apresenta menos restrições que os modelos empírico-estatísticos. Além disso, são mais simples e requerem menor quantidade de informações do que os modelos de simulação do crescimento.

Embora ainda não existam no Brasil, em escala operacional, sistemas de previsão de safra estritamente objetivos, se destacam os esforços para desenvolvimento de modelos agrometeorológicos, os quais se baseiam na relação planta-clima para estimativas de produtividade (MORAES et al., 1998; PICINI et al., 1999; CAMARGO, 1999; FONTANA et al., 2001; MARTINS et al., 2006; SANTOS; CAMARGO, 2006).

A seguir são apresentadas as bases conceituais da modelagem proposta por Doorenbos & Kassam (1979) e alguns exemplos de aplicações em diferentes culturas no Brasil.

2.2.2. Modelos agrometeorológicos

Modelos agrometeorológicos evoluíram de estudos de correlação entre fotossíntese, processo responsável pela produtividade, e transpiração das plantas, a qual sugere o potencial de absorção de água (SHANTZ; PIEMEISEL, 1927). Desde então o princípio vem sendo aplicado nas estimativas de produtividade com algumas adequações metodológicas (DE WIT, 1958; JENSEN, 1968; STEWART et al., 1976; DOORENBOS & KASSAM, 1979) o que resultou em grande número de trabalhos.

Doorenbos e Kassam (1979) desenvolveram um modelo agrometeorológico para estimar a produtividade de culturas agrícolas baseado na hipótese de que o déficit hídrico constitui o grande limitador da produtividade das culturas. A quantificação do estresse hídrico é obtida por meio da relação entre a evapotranspiração real e a evapotranspiração potencial (ET_r/ET_0). Caso a evapotranspiração real da cultura seja menor que a capacidade potencial de um sistema de referência (evapotranspiração potencial) a cultura não está absorvendo água suficiente e a produtividade potencial será penalizada conforme a Equação 2.1:

$$Y = Y_p \left[\frac{ET_r}{ET_o} \right] \quad (2.1)$$

em que:

Y = produtividade estimada; Y_p = produtividade potencial; ET_r = evapotranspiração real; ET_o = evapotranspiração potencial.

Entretanto, a maneira pela qual o déficit hídrico afeta a produtividade pode variar entre as culturas. Faz-se necessário, então, introduzir um fator de correção deste efeito, definido experimentalmente para cada cultura, representando o fator de resposta à produtividade (k_y). Assim, a Equação 2.1 pode ser reescrita, conforme a Equação 2.2:

$$Y = Y_p \left[1 - k_y \left(1 - \frac{ET_r}{ET_o} \right) \right] \quad (2.2)$$

em que:

k_y = fator de resposta à produtividade

A estimativa do déficit hídrico pode ainda ser calculada em diferentes fases fenológicas da cultura e integrada durante todo o ciclo como um somatório (STEWART et al., 1976; DOORENBOS; KASSAM, 1979) ou um produtório (RAO et al., 1988; DOORENBOS; KASSAM, 1979) das deficiências hídricas nas diferentes fases.

A influência do fator hídrico estimado por meio da evapotranspiração relativa (ET_r/ET_o) foi avaliada por Martins et al. (2006) para estudos de produtividade da variedade de laranja Valência no Estado de São Paulo. Foram incluídos ainda no modelo dados de produção do ano anterior conforme o modelo descrito por Picini (1999). Os autores concluíram que o período fenológico de florescimento foi o mais sensível ao déficit hídrico e relataram bom

desempenho com um coeficiente de determinação (R^2) de 0,81 e índice de concordância Willmott (d) de 0,95.

Camargo (1999) utilizou o mesmo modelo e dados experimentais, mas sem a inclusão do fator produtividade do ano anterior. Os resultados obtidos foram semelhantes exceto pelos menores valores de R^2 e índice “d” encontrados, que foram 0,70 e 0,87, respectivamente.

Moraes et al. (1998) estimaram o rendimento da soja no Estado de São Paulo com base no modelo agrometeorológico. As variações metodológicas mais relevantes foram a penalização da produtividade em função: (i) da evapotranspiração relativa (ET_r/ET_0) ajustada também pelo modelo aditivo (STEWART et al., 1976; DOORENBOS; KASSAM, 1979) e; (ii) de excedentes hídricos derivados de balanços hídricos decendiais seqüenciais ocorridos durante os diferentes estádios fenológicos (desenvolvimento vegetativo; florescimento; formação de vagem e enchimento de grãos e maturação). Além disso, o trabalho foi conduzido em condições controladas (parcelas experimentais) e utilizando três grupos de maturação (cultivar precoce, semiprecoce e média). A inclusão do fator “excedente hídrico” em adição ao déficit hídrico resultou em melhor desempenho do modelo para os três grupos de maturação estudados.

Ainda com relação à cultura da soja, Fontana et al. (2001) utilizaram um modelo agrometeorológico para estimar a produtividade de soja em condições de lavoura no Rio Grande do Sul, a partir de dados de rendimento médio do Estado, derivados de estatísticas oficiais e dados meteorológicos de seis estações localizadas na região de estudo. O modelo ajustado foi o multiplicativo proposto por Jensen (1968) e foi aplicado mensalmente em dois modos: durante todo o ciclo fenológico da soja (modo completo) e somente durante os meses em que a sensibilidade da cultura ao déficit hídrico foi maior (modo reduzido), que coincide com o período de floração ao enchimento de grãos. O desempenho foi satisfatório em ambos os modos, com coeficientes de

determinação de 0,87 para o modo completo e 0,76 para o modo reduzido. Os autores ressaltam, entretanto, a viabilidade de aplicação do modo reduzido devido à possibilidade de estimativas com cerca de 30 dias antes da maturação fisiológica da soja na região.

Com relação à cafeicultura, o mesmo modelo foi aplicado por Picini et al. (1999) em condições experimentais no Estado de São Paulo. Foram considerados três estádios fenológicos do cafeeiro : (i) estágio de dormência das gemas florais/início do florescimento; (ii) estágio de florescimento/início de formação dos grãos e (iii) estágio de formação dos grãos/início de maturação – em diferentes combinações de duração. Os dados de (ET_r/ET_0) foram integrados nos diferentes estádios pelos modelos aditivo e multiplicativo. Foi incorporada ainda uma penalização pela produtividade do ano anterior, o que resultou nas Equações 2.3 e 2.4:

$$\frac{Y_r}{Y_p} = 1 - \left[ky_0 \left(\frac{Y_{aa}}{Y_p} \right) + \sum_{i=1}^n ky_i \left(1 - \frac{ET_r}{ET_0} \right) \right] \quad (2.3)$$

e

$$\frac{Y_r}{Y_p} = \left[1 - ky_0 \left(\frac{Y_{aa}}{Y_p} \right) * \prod_{i=1}^n \left(1 - ky_i \left(\frac{1 - ET_r}{ET_0} \right) \right) \right] \quad (2.4)$$

em que:

Y_r = produtividade estimada; Y_p = produtividade potencial da cultura; Y_r/Y_p = produtividade relativa; Y_{aa} = produtividade do cafeeiro do ano anterior; ET_r = evapotranspiração real; ET_0 = evapotranspiração potencial, ET_r/ET_0 = evapotranspiração relativa; ky_0 = coeficiente de penalização relativo à produtividade do ano anterior; ky_i = coeficiente de resposta da cultura à disponibilidade hídrica para os sucessivos estádios fenológicos do cafeeiro.

Os autores concluíram que o modelo multiplicativo, ao contrário de resultados obtidos com outras culturas, não se apresentou adequado e tende a acentuar o efeito da bienalidade produtiva do cafeeiro. Os elevados coeficientes de penalização relativos à produtividade do ano anterior (ky_0) indicaram a importância deste fator na estimativa de produtividade do cafeeiro e o estágio fenológico mais sensível ao déficit hídrico foi o de florescimento/início de formação dos grãos.

Apesar do melhor desempenho do modelo ajustado por somatório das deficiências hídricas, obtido por Picini e colaboradores, Santos e Camargo (2006) realizaram a parametrização do modelo multiplicativo, incorporando ainda, fatores de penalização por ocorrência de temperaturas mínima e máxima. Os autores ajustaram os melhores coeficientes de penalização (ky) por déficit hídrico e temperatura. Adicionalmente foram ajustados os melhores coeficientes de sensibilidade (ky_0) à produção do ano anterior. Os resultados foram obtidos para quatro regiões experimentais e as melhores combinações de coeficientes (ky e ky_0) resultaram em coeficientes de determinação (R^2) acima de 0,90. Ressalta-se que todos os resultados obtidos referem-se ao nível hierárquico de talhão homogêneo.

No Estado de Minas Gerais, Carvalho et al. (2003) aplicaram o modelo em três localidades representativas da produção de café na região sul do Estado. Neste caso, os resultados apresentam grande dispersão, tendência a superestimar a produtividade e foram considerados insatisfatórios. A distância entre a estação fornecedora dos dados meteorológicos e as glebas das quais foram consideradas as produtividades contribuiu para os fracos resultados. Outra explicação dada pelos autores foi o comportamento da bienalidade da produção numa das séries históricas consideradas, a qual apresentou alternância evidente até um ano em particular em que ocorre uma inversão na sequência.

2.3. Dados de sensoriamento remoto

2.3.1. Dados Landsat

O programa Landsat é, sem dúvida, o mais longo e bem sucedido programa de imageamento espacial e também o mais utilizado em pesquisas envolvendo atividade agrícola. As imagens possuem resolução espacial e espectral apropriadas à identificação de alvos agrícolas. O sensor TM (Thematic Mapper), a bordo dos satélites Landsat 4 e Landsat 5, radiância espectral incidente em cada elemento do detector é discretizada em 8 bits e sete bandas espectrais, sendo três na região do visível com resolução espacial de 30 metros, três na região do infravermelho próximo, também com 30 metros e uma na região do infravermelho termal, com resolução espacial de 120 metros. O sensor ETM+ (Enhanced Thematic Mapper plus), a bordo do Landsat 7 é semelhante ao TM tendo ainda incluída uma banda pancromática com resolução espacial de 15 metros e a banda do infravermelho termal com resolução melhorada de 60 metros. No entanto, este sensor parou de operar regularmente em 2003 em função de problemas técnicos.

2.3.1.1. Processamento de dados Landsat

Em seu formato original as diferentes bandas do Landsat são quantizadas em Níveis de Cinza. Estes valores são incompatíveis entre si devido a características específicas de cada sensor em cada faixa do espectro eletromagnético e condições ambientais nas quais as imagens são formadas.

A conversão dos Níveis de Cinza para valores físicos de radiância, que é a grandeza medida por cada sensor, incorpora parâmetros de ganho e offset (Equação 2.5) ou L_{\min} e L_{\max} (Equação 2.6). O ganho e offset são determinados antes do lançamento do satélite, sendo mais difíceis de serem utilizados pela comunidade de usuários uma vez que ao longo do tempo ocorrem distorções na resolução nominal introduzidas pelo envelhecimento dos sensores. Os valores de L_{\min} e L_{\max} representam os valores de Radiância mínima e máxima que o sensor é capaz de registrar, associados aos valores de ND=0 e ND=2x

(em que x é o número de bits no qual a imagem será quantizada e são atualizados frequentemente pós-lançamento dos satélites).

$$L_0(\lambda) = ND(\lambda) - offset(\lambda)/G(\lambda) \quad (2.5)$$

em que:

$L_0(\lambda)$ = radiância medida pelo sensor na faixa espectral λ ; $ND(\lambda)$ = Número digital ou Nível de cinza da imagem na faixa espectral λ ; $offset(\lambda)$ = ND para compensar a corrente escura do detector que é a resposta do detector mesmo quando não recebe qualquer quantidade de radiação incidente na faixa espectral λ ; $G(\lambda)$ = valor de ganho normalmente ajustado para impedir que o valor medido sature positivamente quando observa objetos claros ou negativamente quando observa objetos escuros;

$$L_0(\lambda) = (L_{mín}(\lambda) + \frac{(L_{máx}(\lambda) - L_{mín}(\lambda))}{2^x}) * ND(\lambda) \quad (2.6)$$

em que:

$L_0(\lambda)$ = radiância medida pelo sensor na faixa espectral λ ; $L_{mín}(\lambda)$ = radiância mínima que o sensor é capaz de registrar na faixa espectral λ ; $L_{máx}(\lambda)$ = radiância máxima que o sensor é capaz de registrar na faixa espectral λ ; x = número de bits no qual a imagem será quantizada (atualmente varia entre 8 e 16); $ND(\lambda)$ = Número digital ou Nível de cinza da imagem na faixa espectral λ ;

Os valores de radiância permitem comparar imagens de diferentes faixas espectrais ou bandas, entretanto a radiância é um parâmetro dependente da fonte de radiação e deve ainda ser convertida em fatores de reflectância aparente (topo da atmosfera) para eliminar esta dependência, conforme mostrado na Equação 2.7.

$$\rho_a(\lambda) = \frac{\pi * L_0(\lambda) * d^2}{E_{sun}(\lambda) * \cos\theta} \quad (2.7)$$

em que:

$\rho_a(\lambda)$ = Fator de reflectância bidirecional aparente na faixa espectral λ ; $L_0(\lambda)$ = radiância bidirecional aparente na faixa espectral λ ($\text{mW.cm}^{-2}.\text{sr}^{-2}.\mu\text{m}^{-1}$); d = distância Sol-Terra em unidades astronômicas; $E_{sun}(\lambda)$ = Irradiância média do sol no topo da atmosfera na faixa espectral λ ($\text{mW.cm}^{-2}.\text{sr}^{-2}.\mu\text{m}^{-1}$); θ = ângulo solar zenital;

Após a conversão dos Níveis de Cinza para valores físicos - radiância e reflectância aparente - há de se considerar ainda variações não lineares na sensibilidade dos detectores do sensor ao longo do tempo bem como variações na geometria de iluminação dos alvos, as quais influenciam nas propriedades espectrais destes alvos. Dada a dificuldade de quantificar precisamente essas influências, Hall et al. (1991) propuseram um procedimento inicialmente denominado Retificação Radiométrica. O procedimento consiste numa função empírica baseada nas variações dos valores de reflectância de objetos, supostamente invariantes nas imagens, como estradas, corpos d'água e sombras. Uma vez que estes objetos não se alteram ou se alteram muito pouco ao longo do tempo, eventuais variações entre duas imagens são atribuídas aos efeitos de geometria de iluminação e sensibilidade dos detectores. A função é então derivada das medições de duas imagens, uma imagem numa data específica, tomada como referência, e outra em uma data diferente, a qual se deseja normalizar e então aplicada à imagem a ser normalizada.

Um dos aspectos mais morosos deste método é definir estas feições invariantes sobre as quais a normalização é baseada (SCHOTT et al., 1988; HALL et al., 1991; MORAN et al., 1992; YANG; LO, 2000; FURBY; CAMPBELL, 2001; DU et al., 2002). CANTY et al. (2004, 2008) propuseram, então, a seleção de pixels invariantes em imagens bitemporais baseados na técnica de detecção de mudanças definida por Nielsen et al. (1998, 2007), denominada

detecção multivariada de alterações (Multivariate Alteration Detection - MAD). Estas feições são, então, usadas na normalização radiométrica tornando o procedimento rápido, totalmente automatizado e mais confiável quando comparado à seleção manual dessas feições invariantes.

2.3.2. Dados Modis

O sensor Modis (MODerate resolution Imaging Spectroradiometer) foi projetado para atender a três segmentos dentro projeto EOS (Earth Observing System) relacionados com a atmosfera, oceano e continentes. Consiste de um espectroradiômetro com 36 bandas numa gama de variação espectral que vai de 0,4 a 14,4 μm e resolução espacial de 250 metros (2 bandas), 500 metros (5 bandas) e 1000 metros (29 bandas). A resolução temporal varia de 1 a 2 dias em função da latitude, o que o torna o melhor instrumento orbital para o monitoramento de culturas agrícolas. As bandas espectrais foram selecionadas a fim de atender às pesquisas de atmosfera, oceano e superfície terrestre, existindo ainda bandas específicas para correção atmosférica.

O sensor apresenta resolução radiométrica de 12 bits, o que resulta em alta sensibilidade radiométrica e excelentes respostas para cada banda (STRAHLER et al., 1995). A quantização em 12 bits permite detectar até 4096 níveis de cinza para cada banda e está ligada à capacidade dos sensores em discretizar a radiância espectral incidente em cada elemento do detector. Por questões de processamento os dados são convertidos em 16 bits e assim disponibilizados para a comunidade científica.

O campo de visada instantâneo (FOV) do sensor é de 55° permitindo o imageamento de uma faixa de 2.330 Km dependendo da latitude. Em função desta larga faixa de imageamento, do efeito de curvatura da terra, rotação da terra e velocidade angular de varredura do espelho, a resolução espacial nominal varia à medida que se aproxima das bordas da imagem, caracterizando um efeito denominado 'bow-tie' (SCHOTT, 1997). Este efeito é ilustrado na Figura 2.2.

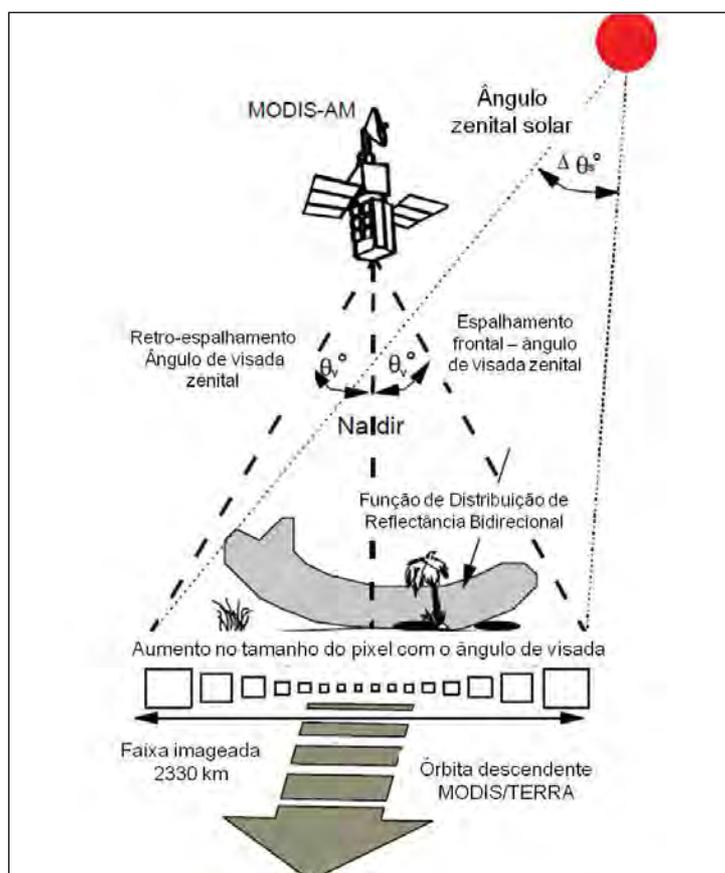


Figura 2.2 - Representação pictórica do efeito de aumento do tamanho dos pixels do Modis em função do distanciamento do zênite.

Fonte: adaptada de Van Leeuwen et al. (1999).

Dentre os diversos algoritmos de processamento dos dados, tem-se o de geolocalização. Após diversos procedimentos de atualização e aperfeiçoamento para remover erros sistemáticos de medidas de orientação externa, este algoritmo permite atualmente uma precisão de 20 metros para as bandas de resolução espacial de 250 metros de 56 metros para as bandas de 500 metros (XIONG et al., 2005).

Assim os produtos de imagens Modis apresentam excelente qualidade radiométrica e geolocalização. Os produtos Modis fornecem base de dados para estudos relativos ao uso e ocupação do solo, além de permitirem o monitoramento da cobertura vegetal do planeta, possibilitando identificar quais as mudanças da vegetação e suas relações com o clima e tempo (JUSTICE et

al., 2002). Como exemplo de produtos Modis disponíveis tem-se: refletância de superfície (MOD09); temperatura de superfície (MOD11); albedo (MCD43), índice de vegetação (MOD13). Nesta pesquisa foram utilizados os produtos MOD13.

Dois índices de vegetação são derivados globalmente a partir de imagens Modis. O NDVI (Normalized Difference Vegetation Índice) e o EVI (Enhanced Vegetation Índice). O EVI apresenta sensibilidade melhorada a diferenças em condições de vegetação esparsa a densa. Ambos se complementam nos estudos globais de vegetação e melhoram as possibilidades de extração de parâmetros biofísicos. O algoritmo de geração utiliza uma função de distribuição de reflectância de cada pixel das bandas originais para normalizar as reflectâncias ao nadir e uma geometria de incidência da radiação solar padronizada.

Os produtos são então disponibilizados em forma de *tiles* ou quadrantes (Figuras 2.3 e 2.4) tomando como base uma grade de projeção sinusoidal com uma área de 10° de latitude por 10° de longitude (aproximadamente 1.200 km por 1.200 km na linha do Equador).

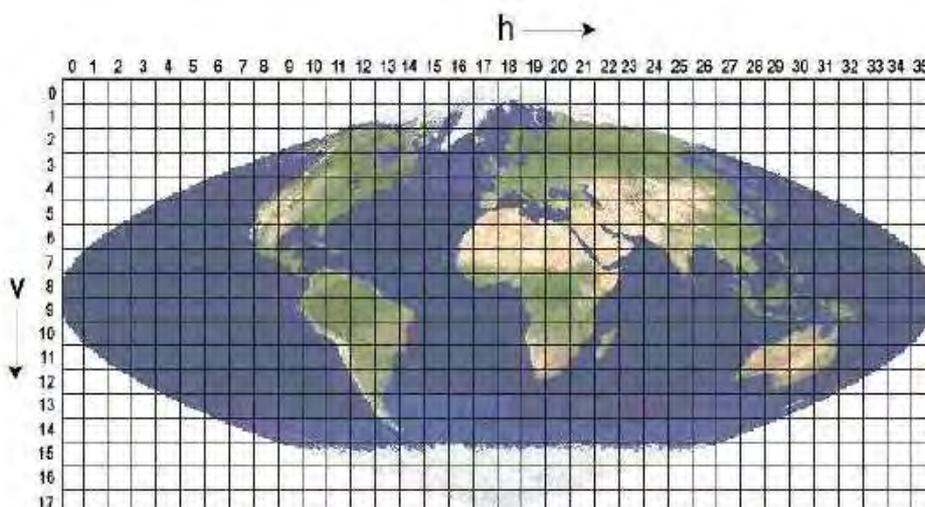


Figura 2.3 - Distribuição dos *tiles* Modis (18 x 36) em projeção sinusoidal

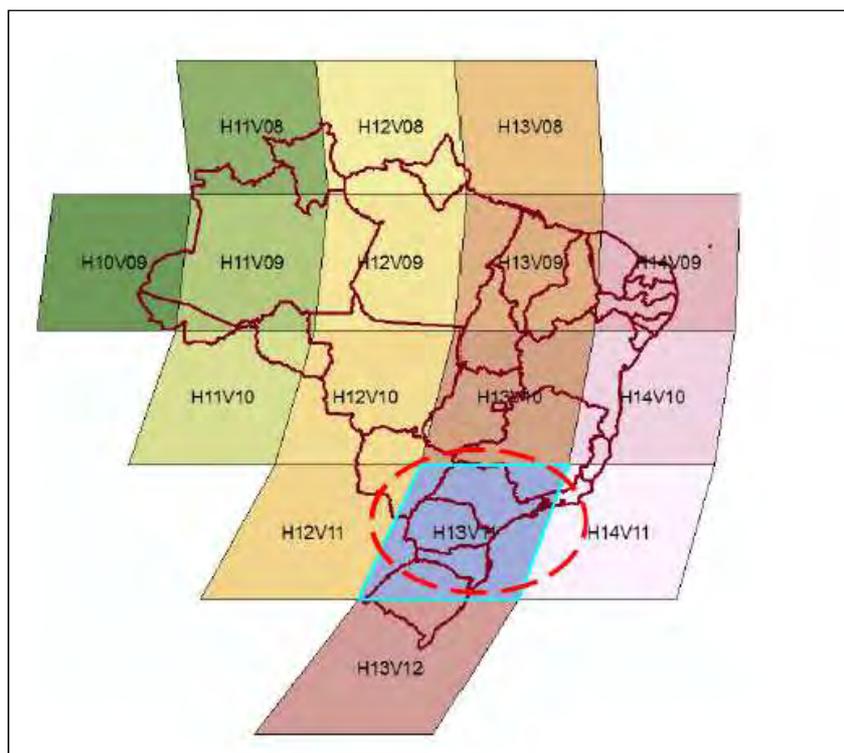


Figura 2.4 - Detalhe do tile H13V11, referente à área de estudo, entre as cenas disponíveis para o território brasileiro.

Fonte: Adaptada de Adami (2012)

2.3.3. Processamento de séries temporais

Na América do Sul a resolução temporal diária de dados Modis representa uma característica de alto interesse, por aumentar significativamente a chance de adquirir imagens livres de nuvens e permitir obter longas séries temporais de imagens. Estas séries possibilitam o acompanhamento do ciclo e identificação de estádios fenológicos de culturas agrícolas (FREITAS; SHIMABUKURO, 2008; GALFORD et al., 2008; SAKAMOTO et al., 2010; VERBESSELT et al., 2010). A análise de séries temporais de imagens Modis pode ser utilizada para identificar mudanças sazonais na vegetação decorrentes de variações nas condições climáticas, estádios de desenvolvimento das culturas ou alterações nos tipos de uso e cobertura do solo.

Em geral, séries temporais de imagens de satélites incluem várias componentes de ruídos como aerossóis e fatores de distribuição de reflectância bidirecional (SAKAMOTO et al., 2005), presença de nuvens e falhas no detector (HOLBEM, 1986; GUTMAN, 1991; TEILLET et al., 1997; SIMPSON; STITT, 1998; HIRD; MCDERMID, 2009). Assim, a redução de ruídos ou modelos de ajuste dos dados observados é necessária antes que análises mais detalhadas sejam realizadas. As ferramentas para este tipo de processamento envolvem métodos de suavização como filtros de média e polinomiais (VAN DIJK et al., 1987), janelas móveis para seleção de valores máximos (VIOVY et al., 1992), Operações de janelas temporais (PARK et al., 1999), ajustes de curvas logísticas (ZHANG et al., 2003), análise Fourier (ATKINSON et al., 2012), Wavelet (SAKAMOTO et al., 2005, 2006; FREITAS et al., 2011).

2.3.3.1. Wavelets

Wavelets são definidas como ondas pequenas (ondeletes em francês) e possuem propriedades que as tornam adequadas a servirem de base para decompor outras funções (MORLET et al., 1982). Por meio da decomposição de uma série temporal por Wavelet é possível determinar os modos dominantes de variabilidade e de que forma estes modos se comportam no tempo (MEYER, 1992). O que as diferencia da transformada de Fourier é que a transformada Wavelet, além da frequência, também considera a escala. Os algoritmos Wavelet processam dados em diferentes escalas e resoluções, permitindo que seja analisado tanto o geral quanto o específico (MORETTIN, 1999).

As funções Wavelet contínuas são comumente utilizadas para visualizar e analisar um sinal, enquanto que as Wavelet discretas são utilizadas para decompor e filtrar qualquer série temporal. A sua aplicabilidade neste aspecto advém do fato de que estas funções não provocam redundâncias de coeficientes entre escalas (MORETTIN, 1999). A transformada de Wavelet decompõe uma função definida no domínio do tempo em outra função, definida

no domínio do tempo e no domínio da frequência, conforme é definida pela Equação 2.8:

$$Wf(a,b) = \int_{-\infty}^{+\infty} f(x) \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) dx \quad (2.8)$$

em que:

a é um parâmetro de escala; b é o parâmetro de mudança; ψ representa a wavelet mãe (Daubechies, 1988);

Um passo crítico na análise por Wavelets é a escolha arbitrária da função ψ . Segundo Farge (1992), esse problema é verificado na escolha arbitrária de outras transformadas tais como a Fourier, por exemplo. A escolha de ψ ainda constitui questão aberta na análise de sinais e está relacionada com o problema que se deseja estudar.

Para que uma função seja considerada como ψ ela tem que satisfazer condições de admissibilidade (função integrável com média zero), de similaridade (ser a mesma função em qualquer escala), de inversão (permitir recuperar a série temporal a partir dos dados filtrados) e regularidade (as Wavelets devem ter domínio espacial finito e espaçado regularmente).

Desde que sejam conhecidas às características gerais do sinal a ser investigado, a opção pela ψ deverá ser efetuada de tal forma que a mesma possua atributos similares aos do sinal, tais como assimetria ou não, variação brusca ou suave no tempo.

2.4. Sensoriamento remoto na estimativa de produtividade de culturas agrícolas

O desenvolvimento de novas plataformas orbitais e sensores tem resultado numa grande variedade de produtos com melhorias expressivas em resoluções espacial, espectral, radiométrica e temporal. Tais melhorias sugerem uma

expansão da aplicabilidade destes dados para além do mapeamento da cobertura superficial terrestre.

Enquanto a maioria dos modelos de produtividade opera pontualmente, há vantagens em se saber mais a respeito da variabilidade espacial da produtividade. A inserção de dados de sensoriamento remoto nos modelos de produtividade pode contribuir para ampliar as previsões em escalas mais abrangentes.

A contribuição do sensoriamento remoto nas estimativas de produção pode ocorrer: (i) na forma de mapas para identificar e quantificar áreas agrícolas; (ii) ferramenta para caracterizar e mapear atributos de solos que permitem gerar parâmetros da produtividade; (iii) ferramenta para gerar dados meteorológicos; (iv) estimativas de parâmetros biofísicos das culturas. Nestes casos os dados são usados como entrada em modelos de produtividade, mas existe, ainda, a possibilidade de obter correlações entre as variáveis espectrais e dados de produtividade (BALAGHI et al., 2008; REN et al., 2008).

2.4.1. Estimativas de variáveis biofísicas

A radiação eletromagnética incidente na vegetação interage com a mesma de maneira diferenciada ao longo do espectro eletromagnético, em função de três características básicas das folhas: pigmentação, estrutura fisiológica e conteúdo de água (GATES et al., 1965; CURRAN et al., 1992; FOURTY et al., 1996). Uma área com cultura agrícola é representada numa imagem de satélite por níveis de cinza. Os valores dos níveis de cinza estão relacionados com a intensidade da energia refletida ou emitida pelo dossel da cultura. Logo, depende da banda espectral de atuação do sensor e de parâmetros relacionados à cultura, como densidade de plantio, estádios de desenvolvimento, tratos culturais, entre outros, que por sua vez, estão correlacionados com as características de produção das culturas. Esta dualidade constitui o elo de integração de dados de sensoriamento remoto e modelos de produtividade.

A maneira na qual uma cultura é representada numa imagem sugere determinados valores de variáveis biofísicas como, por exemplo, densidade de plantio, IAF e idade das lavouras. Logo, estes valores podem ser estimados a partir das imagens para, então, serem utilizados como entrada nos modelos de produtividade. O índice de área foliar é um exemplo claro e, portanto, um dos mais utilizados como elemento de ligação entre técnicas de sensoriamento remoto e modelos de produtividade.

2.4.2. Índice de área foliar – IAF

O índice de área foliar é definido pela razão entre a área superficial total das folhas de uma planta e a superfície ocupada por esta planta no solo. O IAF é uma característica chave da vegetação devido ao papel das folhas em controlar diversos processos físicos e biológicos das plantas (DARVISHZADEH et al., 2008), como por exemplo, fotossíntese, respiração e transpiração, fundamentais do ponto de vista da produtividade agrícola. Originalmente o IAF foi concebido por meio de medições em laboratório e métodos indiretos que permitem a correlação com outros parâmetros biofísicos das culturas. Inúmeros são os procedimentos para determinar o IAF para os mais variados cultivos (JONCKHEERE et al., 2004). Genericamente pode ser representado pela Equação 2.9:

$$IAF = \left[\sum_{i=1}^N ai \right] : b \quad (2.9)$$

em que:

IAF = índice de área foliar (adimensional); ai= área superficial da folha i (cm²); N = número total de folhas de uma planta; e b = área superficial ocupada pela planta (cm²)

2.4.3. Índices de vegetação

As folhas apresentam características ópticas distintas nos comprimentos de onda do visível e infravermelho próximo do espectro eletromagnético. Enquanto pigmentos como a clorofila e carotenóides absorvem grande parte da radiação visível (baixa reflectância), notadamente a luz vermelha e azul, a estrutura interna foliar proporciona elevado espalhamento e reflectância na região do infravermelho próximo. Este comportamento antagônico pode ser usado para realçar a presença da vegetação nas imagens por meio dos chamados Índices de Vegetação (IV), os quais relacionam as respostas da vegetação nestas duas faixas espectrais.

O Índice de Vegetação mais básico é aquele que descreve a relação do fluxo radiante refletido na região do infravermelho próximo e aquele refletido no vermelho, então denominado Razão Simples (JORDAN, 1969). Contudo, vegetações densas refletem muito pouco na região do vermelho e esta razão aumenta sem limites. Assim, foi proposto o Índice de Vegetação por Diferença Normalizada ou NDVI (Normalized Difference Vegetation Index) que, como diz o nome, foi normalizado para o intervalo de -1 a $+1$. Desde então, inúmeros índices vêm sendo propostos, sempre visando superar alguma limitação específica como efeito do solo e interferências atmosféricas. A Tabela 2.1 apresenta alguns dos índices de vegetação mais comuns:

Tabela 2.1– Resumo de alguns Índices de vegetação, formulação e Autores.

IV	Formulação*	Autores
Ratio Vegetation Index (RVI)	$RVI = \frac{\rho_{IV}}{\rho_V}$	Jordan (1969)
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{(\rho_{IV} - \rho_V)}{(\rho_{IV} + \rho_V)}$	Rouse et al. (1974)
Soil Adjusted Vegetation Index (SAVI)	$SAVI = \frac{(1+L).(\rho_{IV} - \rho_V)}{(\rho_{IV} + \rho_V + L)}$	Huete (1988)
Enhanced Vegetation Index (EVI)	$EVI = G. \frac{(\rho_{IV} - \rho_V)}{(\rho_{IV} + C_1 \cdot \rho_V - C_2 \cdot \rho_A + L)}$	Huete et al. (2002)
Perpendicular Vegetation Index (PVI)	$PVI = \frac{1}{\sqrt{a^2 + 1}} (\rho_{IV} - a \cdot \rho_V - b)$	Richardson e Wiegand (1977)
Modified Chlorophyll Absorption in the Reflectance Index (MCARI)	$MCARI = \left[(\rho_{0,70} - \rho_{0,67}) - 0,2(\rho_{0,70} - \rho_{0,55}) \left(\frac{\rho_{0,70}}{\rho_{0,67}} \right) \right]$	Daughtry et al. (2000)

* ρ_{IV} = Refletância no infravermelho; ρ_V = refletância no vermelho; L = ajuste da linha do solo; G = fator de ganho (2,5); C_1 e C_2 são coeficientes de resistência de aerossóis, dados por 6 e 7,5 respectivamente; ρ_A = refletância no Azul; “a” e “b” são parâmetros da linha do solo; $\rho_{0,70}$ = refletância do alvo a 0,70 μm ; $\rho_{0,67}$ = refletância do alvo a 0,67 μm ; $\rho_{0,55}$ = refletância do alvo a 0,55 μm ; $PD_{\lambda(i)}$ = primeira derivada para a refletância do ponto médio i, entre as bandas j e j+1; $P_{\lambda(i)}$ =refletância na banda j;

2.4.3.1. Índices de vegetação para estimativa de IAF

Altas correlações podem ser obtidas entre medições espectrais das folhas, passíveis de registro a partir de imagens de satélites, e a quantidade de massa foliar, que por sua vez se reflete no IAF.

Apesar do embasamento consistente e óbvia correlação entre IAF e a capacidade das plantas em refletir a radiação incidente, vários fatores contribuem para limitar o poder preditivo destas imagens para estimar o IAF, dentre eles, propriedades de solos subjacentes, condições atmosféricas e efeitos bidirecionais. Em geral, duas abordagens principais têm sido extensamente reportadas na literatura: uso de correlações empíricas e modelos físicos baseados na teoria de transferência radiativa. Para o escopo deste trabalho apenas as correlações empíricas serão consideradas.

Modelos empíricos são baseados em técnicas estatísticas para observar as correlações entre o IAF obtido por medições *in situ* e dados derivados de produtos de sensoriamento remoto como os índices de vegetação (por exemplo, o NDVI). As principais vantagens são a simplicidade e eficiência computacional. Porém, as correlações são susceptíveis a variações na geometria do dossel, estrutura da folha, efeitos atmosféricos etc, o que as tornam válidas apenas para condições similares às aquelas no momento das medições. Ademais, índices de vegetação apresentam sensibilidade preferencialmente para valores baixos de IAF (TURNER et al., 1999).

Uma das limitações dos IV nas estimativas de IAF é o efeito de saturação, quando aplicados a dosséis muito densos. Sendo assim, a sensibilidade destes índices decresce assintoticamente quando os valores de IAF aumentam muito (LÜDEKE et al., 1991; GAO, 1996; BIRKY, 2001; WANG et al., 2005) como no caso de dosséis cafeeiros, florestais e pomares.

Pensando em minimizar o efeito de saturação, Delalieux et al. (2008) desenvolveram um índice hiperespectral baseado na combinação de duas bandas na região do infravermelho (sLAIDI – standardized LAI Determining Index) para estimativas de IAF. As faixas espectrais definidas como ideais para estimativa de IAF coincidem com aquelas encontradas por Schlerf et al. (2005) que buscavam um IV hiperespectral ideal para identificar a estrutura de dossel e IAF e encontraram faixas nas feições de absorção por água (885/948nm e 1.088/1.148nm). Isto coincide ainda com o IV hiperespectral NDWI, sugerido por Ustin et al. (2002), considerado útil em estudos com dados de sensoriamento remoto para estimativa do conteúdo de água em dosséis (HILL et al., 2006). Portanto, a razão usada no cálculo do sLAIDI (1.250/1.050), embora similar às razões usadas para determinar o conteúdo de água em dosséis certamente se presta ao estudo do IAF. Da mesma forma, acredita-se que índices de vegetação propostos para identificar o conteúdo de água em dosséis vegetais, possam ser utilizados para estimar IAF.

Gitelson (2004) propôs uma alteração no NDVI aplicando um fator multiplicativo à reflectância no infravermelho próximo para linearizar a relação entre IAF e NDVI. O índice resultante, então denominado WDRVI (Wide Dynamic Range Vegetation Index), apresentou uma sensibilidade a valores altos de IAF três vezes maior que o NDVI.

Uma vez que os índices de vegetação representam bem a fitomassa ou o IAF, e correlações podem ser obtidas entre IAF e produtividade, os mesmos podem também ser usados diretamente nas correlações com a produtividade. Funk et al. (2009) apresentam uma série de trabalhos envolvendo estimativas de produtividade de culturas agrícolas e índices de vegetação derivados de imagens de satélite.

2.4.4. Aplicações no Brasil

As primeiras estimativas de produtividade de culturas agrícolas no Brasil fundamentadas na integração de dados espectrais e modelos agrometeorológicos foram realizadas por Rudorff e Batista (1990), para a cultura da cana-de-açúcar, e Rudorff e Batista (1991), para a cultura do trigo, sob a pressuposição de que o componente agrometeorológico represente a influência do clima e o componente espectral o efeito coletivo dos demais fatores responsáveis na produtividade observada. O modelo proposto, então denominado agrometeorológico-espectral, incorpora um índice de vegetação ao modelo agrometeorológico numa função estatística tradicional conforme Equação 2.10:

$$Y = a_0 + a_1IV + a_2Y_e \quad (2.10)$$

em que:

Y = produtividade estimada; IV = Índice de vegetação; Y_e = produtividade estimada pelo modelo agrometeorológico e; a_0 , a_1 e a_2 são os coeficientes de regressão;

Para ambas as culturas o modelo integrado proporcionou melhores resultados do que os modelos agrometeorológico e espectral quando aplicados isoladamente.

Recentemente Melo et al. (2008) aplicaram a mesma abordagem em estimativas da produtividade de soja no Rio Grande do Sul, por meio de uma longa série de dados meteorológicos e imagens NOAA/AVHRR para gerar o índice de vegetação NDVI. Parte dos dados foi usada para ajuste do modelo e parte usada para validação. Ao comparar as produtividades estimadas e observadas obteve-se um coeficiente de correlação de 0,96 para os dados de ajuste e 0,94 para o conjunto de validação. A adição da componente espectral proporcionou um ganho de 5% na exatidão da estimativa em relação ao uso do modelo agrometeorológico isoladamente.

Sugawara (2002) adaptou o modelo agrometeorológico a um sistema de informações geográficas (SIG) para estimativas espacializadas de produtividade da soja, o qual foi nomeado AGROMET. Para tanto, as variáveis meteorológicas obtidas de 32 estações localizadas no Estado do Paraná foram espacializadas por meio de técnicas de interpolação. Foram utilizados dois tipos de imagens: (1) NOAA-AVHRR para extração do índice de vegetação NDVI, a ser usado na estimativa da produtividade potencial; e (2) uma imagem CBERS utilizada para definir os limites para aplicar a rotina de cálculo do modelo, ou seja, identificação e mapeamento das áreas de soja.

Baseados no AGROMET, Rizzi e Rudorff (2007) também incorporaram dados espectrais ao mesmo modelo visando estimar a produtividade de soja no Rio Grande do Sul. Igualmente, a entrada da variável espectral (NDVI derivado de imagens Modis) no modelo se deu através do cálculo da produtividade máxima ou potencial. Outra preocupação dos autores foi a correção dos dados de produtividade utilizados com base nas informações oficiais de produção final e área plantada ajustada com base nas imagens de satélite. As estimativas foram

significativamente iguais aos dados oficiais corrigidos, entretanto foi observada uma melhor distribuição espacial dos valores de produtividade.

Com relação à cafeicultura, Rosa (2007) aplicou os procedimentos definidos por Rizzi (2004) visando adaptar o modelo AGROMET para a cultura do café. A principal alteração metodológica foi a utilização do modelo numérico de previsão do tempo ETA no fornecimento de dados meteorológicos espacializados. Além de eliminar a etapa de interpolação de dados a partir de estações meteorológicas, a resolução espacial do modelo (40 km) supera a distância usual entre as estações no Brasil, o que pode representar uma vantagem em utilizar estes dados. A qualidade das estimativas obtidas decresce da escala regional para a escala municipal. O pior desempenho do modelo em escala municipal foi confirmado ao comparar os resultados com aqueles obtidos pelo modelo agrometeorológico aplicado a nível municipal, o qual apresentou resultado melhor. As vantagens do modelo agrometeorológico-espectral foram a espacialização dos resultados e a possibilidade de previsões antecipadas devido à utilização de dados meteorológicos do modelo ETA. Fatores de correção pela produtividade do ano anterior e ocorrência de temperaturas máxima e mínima constituem desafio no sentido de adaptar o modelo de Santos e Camargo (2006) para estimativas espacializadas da produtividade.

2.4.5. Avaliação dos modelos

Na etapa de avaliação dos resultados são aplicados testes estatísticos para verificar a exatidão e a precisão do modelo. O mais comum deles é a análise de regressão, a qual possibilita obter parâmetros representativos do comportamento do modelo, tais como: o coeficiente de correlação de Pearson (r), o coeficiente de determinação (R^2); o erro médio quadrático (EMQ) e o comportamento dos resíduos (NETER et al., 1996).

O coeficiente de correlação de Pearson (r) mede o grau de correlação linear entre duas variáveis e indica se as variáveis têm relação positiva (variando

entre 0 e 1) ou negativa (variando entre 0 e -1). A relação positiva indica um aumento da variável dependente em decorrência de aumento na variável independente. A correlação negativa indica diminuição nos valores da variável dependente à medida que ocorre aumento dos valores da variável independente.

O coeficiente de determinação (R^2) é uma medida de precisão que indica qual proporção da variabilidade da variável dependente que é explicada pela variabilidade da variável independente, ou seja, indica o quanto da variância da variável dependente foi explicado pela variável independente, variando entre 0 e 1.

O EMQ indica o desvio padrão em torno da reta de regressão, sendo sua unidade igual à unidade da variável dependente. O comportamento dos resíduos indica se há necessidade de se incluir alguma outra variável no modelo, se a reta é a melhor função ou se há outra função que pode ajustar melhor o comportamento dos dados e se há dependência temporal e/ou espacial (NETER et al., 1996).

A análise de modelos consiste em uma equação de regressão linear em que valor estimado (E) ou variável dependente é obtido através do valor observado (O) ou variável independente, conforme expresso na Equação 2.11 (NETER et al., 1996):

$$E = a + bO \quad (2.11)$$

em que: **a** representa o intercepto e **b** o coeficiente angular.

A equação de regressão ideal é aquela em que o valor de 'a' tenha a maior probabilidade de ser igual a zero, indicando que a função passe pela origem e que o valor de 'b' tenha a maior probabilidade de ser igual a um, pois desta forma, o valor estimado é igual ao valor encontrado no campo. Associado à análise de regressão, Willmott et al. (1985) desenvolveram um teste para

avaliar o ajuste do modelo com relação aos dados de campo, ou seja, medir o erro médio absoluto (EMA), medir o EMQ e decompor o EMQ em erro médio quadrático sistemático (EMQS) e erro médio quadrático aleatório (EMQA). Para isso os autores consideram que o vetor d é a diferença entre o j -ésimo valor estimado (e) menos o j -ésimo valor observado (o), conforme Equação 2.12:

$$d = p_i - o_i \quad (2.12)$$

O erro médio pode ser descrito pela equação 2.13:

$$E^{\frac{1}{\gamma}} = \left[\frac{(\sum_{j=1}^N \omega |d_j|^\gamma)}{\sum_{j=1}^N \omega_j} \right]^{\frac{1}{\gamma}} \quad 0 < \gamma \quad (2.13)$$

em que:

N representa o número total de elementos; ω é um escalar, quando ω representa uma amostragem no espaço ou no tempo o seu valor é igual a distância entre os elementos, em outros casos, ω assume o valor um. As estimativas de EMA e EMQ são dadas pelas Equações 2.14 e 2.15, respectivamente:

$$E^{\frac{1}{\gamma}} = EMA, \quad se \quad \gamma = 1 \quad (2.14)$$

$$E^{\frac{1}{\gamma}} = EMQ, \quad se \quad \gamma = 2 \quad (2.15)$$

Em uma comparação destas duas medidas de erro, Willmott e Matsuura (2005) e Willmott et al. (2009) concluíram que a métrica EMA é preferível, porque EMQ é sensível não apenas ao tamanho de erro, mas também à variabilidade do erro e ao número de pontos de dados.

O índice de ajuste (WILLMOTT et al., 1985) pode ser definido pela Equação 2.16:

$$d_{\gamma} = 1 - \left[\frac{(\sum_{j=1}^N \omega_j |d_j|^{\gamma})}{\sum_{j=1}^N \omega_j (|p_j - \bar{o}| + |o_j - \bar{o}|)^{\gamma}} \right], \quad 0 < \gamma \quad (2.16)$$

em que:

\bar{o} representa a média ponderada dos valores observados, obtido por meio da Equação 2.17:

$$\bar{o} = \frac{\sum_{j=1}^N \omega_j o_j}{\sum_{j=1}^N \omega_j} \quad (2.17)$$

Segundo Willmott et al. (1985) os valores de γ iguais a um ou dois são mais apropriados. Quando γ for igual a um, este valor irá se assemelhar à média e quando for igual a dois, assemelha-se à variância. O domínio desta função está entre zero e um. Valores próximos de zero indicam pouco ajuste entre os dados estimados e os dados observados. Por outro lado, valores próximos a um indicam um bom ajuste entre os dados observados e os dados estimados. Com isto, os autores alteraram o índice de ajuste de Willmott, (1981) para d2 e estabeleceram o índice de ajuste modificado, d1.

A divisão do EMQ em EMQS e EMQA é realizada por meio das Equações 2.18 e 2.19, respectivamente:

$$EMQ_S = \left[\frac{(\sum_{j=1}^n \omega_j |\hat{p}_j - o_j|^2)}{\sum_{j=1}^N \omega_j} \right]^{\frac{1}{2}} \quad (2.18)$$

$$EMQ_A = \left[\frac{(\sum_{j=1}^n \omega_j |\hat{p}_j - p_j|^2)}{\sum_{j=1}^N \omega_j} \right]^{\frac{1}{2}} \quad (2.19)$$

em que:

\hat{p} é o valor estimado pela equação 2.11, para o j -ésimo elemento.

Desta forma tem-se a divisão completa do erro (Equação 2.20):

$$EMQ^2 = EMQ_S^2 + EMQ_A^2 \quad (2.20)$$

A verificação do intervalo de confiança e redução da influência de valores anômalos nos parâmetros estimados pode ser feita, segundo Willmott et al (1985) pela técnica "Bootstrap". A técnica "Bootstrap" permite determinar as propriedades de um estimador por meio de medições destas propriedades quando amostradas de uma distribuição aproximada (EFRON, 1982). Cada nova amostra possui a probabilidade de $1/n$ de ser obtida. As amostras são escolhidas de forma aleatória e as estimativas recalculadas. Com a simulação da curva função densidade de probabilidade da variável obtém-se os valores de média, variância, mediana, assimetria e curtose, permitindo, assim, estabelecer o intervalo de confiança para as estimativas do modelo, que permitem a intercomparação dos resultados obtidos. O índice Willmott indica o grau de exatidão entre valores observados e estimados, sendo que quanto mais próximo de 1 (um), melhor a exatidão do modelo em prever a variável dependente.

3. MATERIAL E MÉTODOS

3.1. Área de estudo

Os estudos foram realizados na Mesorregião Sul/Sudoeste do Estado de Minas Gerais, onde a área cultivada com café corresponde a mais da metade da área de café total do Estado. A região foi escolhida em função da sua representatividade no cenário nacional da produção de café, diversidade de ambientes e sistemas de cultivo e presença de instituições de excelência em pesquisa cafeeira potencialmente parceiras na geração e análise de dados.

O clima na região é enquadrado como Cwb (subtropical de altitude), segundo a classificação de Köppen, com invernos secos e verões brandos. As temperaturas mínimas podem chegar a 5° C e as máximas a 34° C. As altitudes variam entre 500 e 2.500 metros com média em torno de 980 metros e declividades predominantes de até 12% (ROSA, 2007).

De acordo com levantamento de solos divulgado em Geominas (1996), a região apresenta variações das principais classes de solos preconizadas pelo Sistema Brasileiro de Classificação de Solos, ou seja, Latossolos, Argissolos, Cambissolos e Neossolos.

A região é constituída de 146 municípios que respondem juntos por cerca de 46% da área total de café plantada no Estado de Minas Gerais (Bernardes et al., 2012).

3.1.1. Áreas piloto

Três áreas piloto representativas do núcleo cafeeicultor na região foram utilizadas para levantamentos de campo para coleta de dados. São elas: (i) Boa Esperança/Campo do Meio/Campos Gerais/Três Pontas; (ii) Alfenas e; (iii) São Sebastião do Paraíso/Monte Santo/Itamogi.

Os dados levantados nestas áreas foram analisados individualmente (produtividade dos talhões de café) para verificar ajuste dos modelos em escala local e também em conjunto para aplicar na escala municipal (produção total por município). A Figura 3.1 apresenta os limites geográficos da região Sul/Sudoeste de Minas e subáreas piloto com a distribuição dos pontos amostrados:

Distribuição dos dados de campo no Sul/Sudoeste de MG

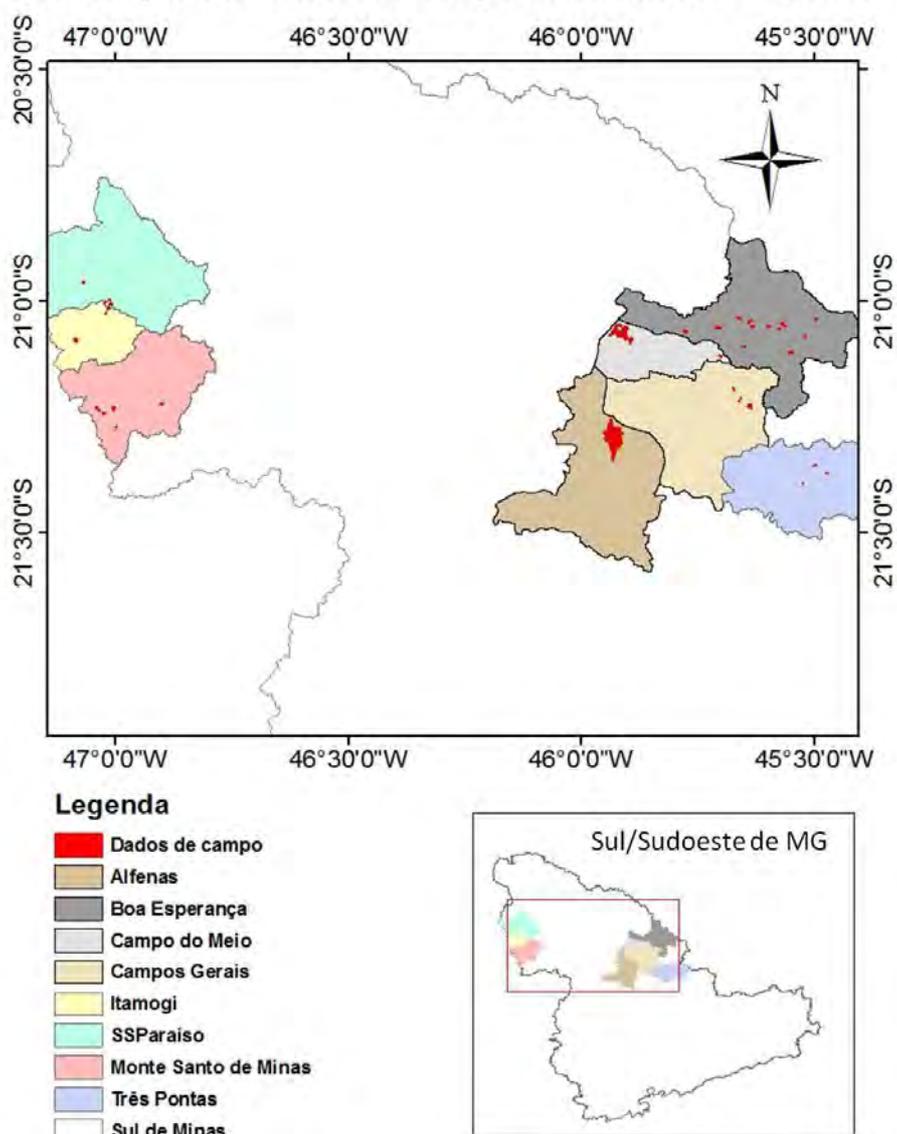


Figura 3.1 - Distribuição dos dados de campo nas áreas piloto selecionadas.

3.2. Dados

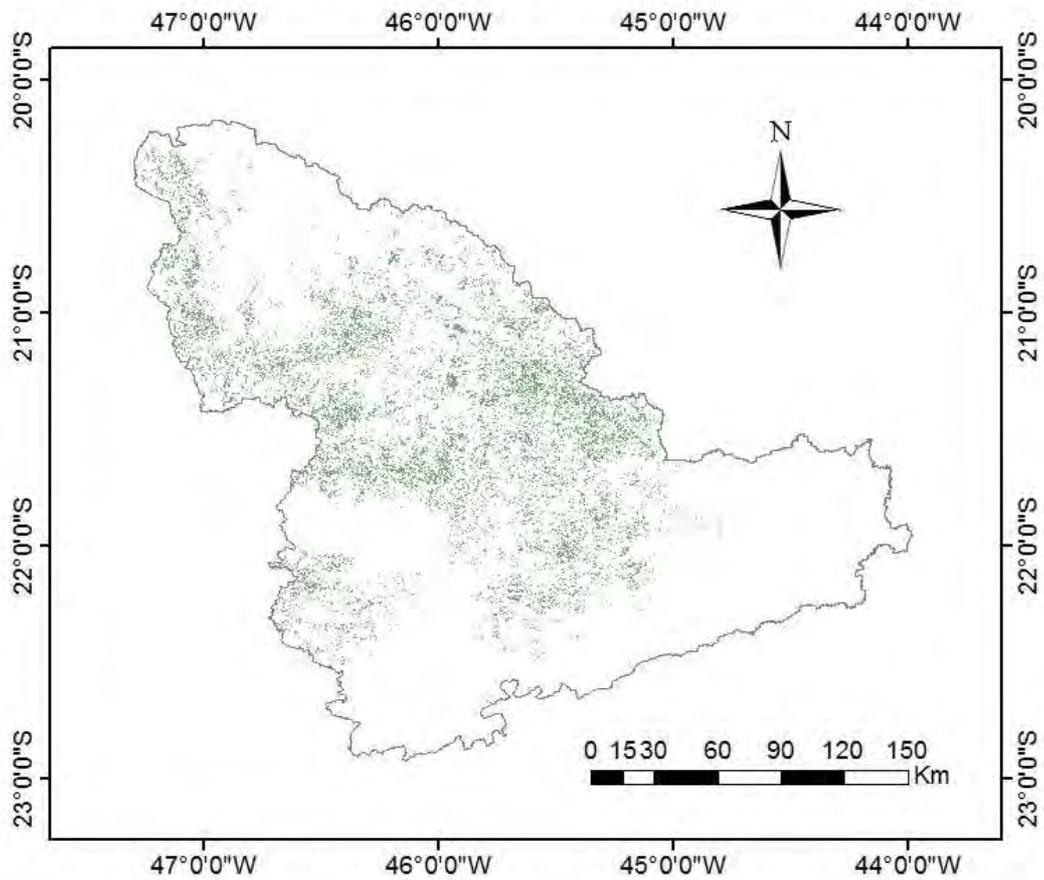
3.2.1. Imagens de satélite

Foram utilizadas imagens Modis e do TM/Landsat-5 como dados básicos para obter os índices de vegetação NDVI e o EVI. As imagens disponíveis para anos anteriores também foram obtidas para identificar padrões de bienalidade da produção por meio dos índices de vegetação. Além dos índices de vegetação, foram extraídas das imagens as áreas cafeeiras visando aplicar as rotinas para cálculo da produtividade apenas dentro das áreas de café.

3.2.2. Mapa de área cafeeira

Para realizar os cálculos de estimativa da produtividade do ano anterior a partir dos índices de vegetação foi utilizado um mapa base contendo as áreas cafeeiras, obtido a partir da interpretação de imagens do ano de 2007 (Moreira et al., 2007), conforme mostrado na Figura 3.2.

Mapa de áreas cafeeiras no Sul/Sudoeste de Minas Gerais – 2007



Legenda

- Áreas cafeeiras
- Sul/Sudoeste de MG

Fonte:
Mapa gerado por interpretação visual de
imagens Landsat (Moreira et al., 2010)



Figura 3.2 - Mapa base de áreas cafeeiras do Sul/Sudoeste de Minas Gerais.

3.2.3. Dados meteorológicos

Os dados meteorológicos utilizados no balanço hídrico foram derivados das previsões do modelo numérico de previsão do tempo ETA: (i) temperatura média do ar ($^{\circ}\text{C}$), (ii) precipitação pluviométrica (mm.dia^{-1}), (iii) radiação solar ($\text{cal.cm}^{-2}.\text{dia}^{-1}$), (iv) velocidade do vento (km.dia^{-1}) e, (v) umidade relativa do ar (%). Adicionalmente os dados de altimetria, necessários para cálculo do fator W, utilizado para obter a evapotranspiração potencial, foram extraídos dos arquivos do ETA. Estes dados são fornecidos pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC/INPE) em resoluções espaciais de 40 x 40 km e 20 x 20 km. Além da espacialização das variáveis em questão estes dados foram obtidos antecipadamente, melhorando as possibilidades de aplicar em modelos de previsão de produtividade.

3.2.4. Dados de campo

Foram coletados em campanhas de campo dados de produtividade de 118 lavouras entre os anos de 2001 e 2010 e parâmetros de cultivo (densidade de plantio, idade, variedade) em nível de talhão homogêneo. Informações adicionais fornecidas pelos produtores foram úteis para auxiliar na interpretação dos resultados como produtividade do ano anterior, ocorrência de geadas, pragas e doenças, que também foram consideradas.

Os dados foram divididos em dois conjuntos distribuídos espacialmente. Um com dados de 70 lavouras para construção e parametrização dos modelos empíricos e outro com dados de 48 lavouras para avaliação dos resultados finais. Uma vez que não foi possível obter as produtividades para todas as lavouras em todos os anos o número total (lavoura x anos disponíveis) de dados utilizados nos modelos e validação é variável. Para avaliar o modelo em escala municipal foram utilizados também dados de produção total dos municípios disponíveis no site do IBGE.

3.3. Metodologia

3.3.1. Descrição do modelo

O modelo agrometeorológico proposto por Doorenbos e Kassam (1979) é descrito pela Equação 3.1:

$$Y_{est} = Y_p \left[1 - k_y \left(\frac{ET_r}{ET_o} \right) \right] \quad (3.1)$$

em que:

Y_{est} = produtividade agrícola penalizada por fatores climáticos e edáficos; Y_p = produtividade máxima ou potencial na ausência de deficiência hídrica; k_y = Coeficiente de resposta que penaliza a produtividade em função do déficit hídrico; ET_r = Evapotranspiração real (mm); ET_o = Evapotranspiração máxima ou potencial;

Ao introduzir neste modelo dados de sensoriamento remoto, com o objetivo de obter estimativas de produtividade espacializadas, deu-se origem ao modelo denominado de agrometeorológico-espectral. A abordagem utilizada nesta pesquisa difere, fundamentalmente, daquela empregada por Rizzi (2004), Rosa (2007) e Sugawara (2010), que utilizaram dados de sensoriamento remoto para calcular o índice de área foliar (IAF) usado no cálculo do fator de compensação de crescimento (F_{cc}), uma variável empregada no cálculo da produtividade máxima ou potencial (Y_p).

A inserção da variável espectral no modelo foi feita por estes autores conforme é mostrado nas Equações 3.2 a 3.5.

$$Y_p = F_{cc} * F_r * F_{pa} * ND * PMB \quad (3.2)$$

em que: Y_p = produtividade máxima potencial (kg ha^{-1}); F_{cc} = fator de compensação do crescimento; F_r = fator de respiração; F_{pa} = fator de

produtividade agrícola; ND = número de dias da quinzena; PMB = produção de matéria seca bruta do grupo da cultura

O Fcc é calculado pela Equação 3.3 que foi definida por Sugawara (2002) com base em dados tabulares apresentados em Doorenbos e Kassam (1979).

$$Fcc = 0,515 - e^{(-0,664 - (0,515 * IAF))} \quad (3.3)$$

em que: Fcc = fator de compensação do crescimento; IAF = índice de área foliar.

Sendo assim, os valores de IAF podem ser adquiridos em medições de campo ou a partir das imagens de satélite, por meio do Índice de Vegetação por Diferença Normalizada (NDVI). Os valores do NDVI são derivados do produto Mod13Q1 ou de imagens das bandas do Vermelho e do Infravermelho próximo do mesmo sensor Modis.

No caso de utilizar o produto Mod13Q1, essas imagens devem, primeiramente, ser transformadas em imagens fração da cobertura do solo conforme a Equação 3.4 proposta por Choudhury et al. (1994).

$$Fc = 1 - \left[\frac{IV \max - IV}{IV \max - IV \min} \right]^{0,6} \quad 3.4$$

em que: Fc = fração do solo coberto pela cultura; $IV \max$ e $IV \min$ = valores de máximo e de mínimo do IV da imagem; IV = valor do IV de cada pixel da imagem.

Assim, o IAF será estimado pela Equação 3.5, conforme Norman et al, (2003).

$$IAF = -2 \ln(1 - Fc) \quad (3.5)$$

em que: Fc = fração do solo coberto pela cultura obtido na equação anterior e IAF = índice de área foliar para cada pixel da imagem

Uma vez que as correlações empíricas empregadas nestas equações passam por uma série de extrapolações e são definidas originalmente a partir de dados obtidos de culturas anuais, optou-se por adotar uma produtividade máxima padrão para a cultura do café, e integrar a componente espectral (imagens e valores de NDVI e EVI) na produtividade do ano anterior, obtendo-se assim equações empíricas mais realísticas por utilizarem dados da cultura cafeeira.

Desta maneira, o aspecto chave da metodologia consiste em identificar os dados de sensoriamento remoto (imagens e índices de vegetação) capazes de gerar correlações com a produtividade de lavouras cafeeiras de modo a permitir a incorporação da produtividade do ano anterior (Y_{aa}) ao modelo, possibilitando estimar a produtividade de maneira espacializada. Pretende-se utilizar tais correlações na estimativa da produtividade do ano anterior (Y_{aa}) para ser incorporada ao modelo agrometeorológico descrito pela Equação 3.6:

$$Y_{est} = Y_p \left\{ \left(ky_0 \left(\frac{Y_{aa}}{Y_p} \right) \right) + \left[\left(ky_i \left(1 - \frac{ET_r}{ET_o} \right) \right) \right] \right\} \quad (3.6)$$

em que:

Y_{est} = produtividade estimada; ky_0 = coeficiente de penalização pela produtividade do ano anterior; Y_{aa} = produtividade do ano anterior (estimadas a partir de imagens de satélite); Y_p = produtividade potencial; ky_i = coeficiente de resposta da cultura à disponibilidade hídrica no estágio i ; ET_r = Evapotranspiração real; ET_o = Evapotranspiração potencial.

O trabalho foi dividido em três etapas: (i) Processamento de imagens de satélite e correlações com dados de campo (item 3.3.2); (ii) Processamento de dados meteorológicos e integração aos dados de sensoriamento remoto (item 3.3.3); e (iii) Geração da produtividade estimada e validação (item 3.3.4). A Figura 3.3 apresenta o fluxo de trabalho realizado:

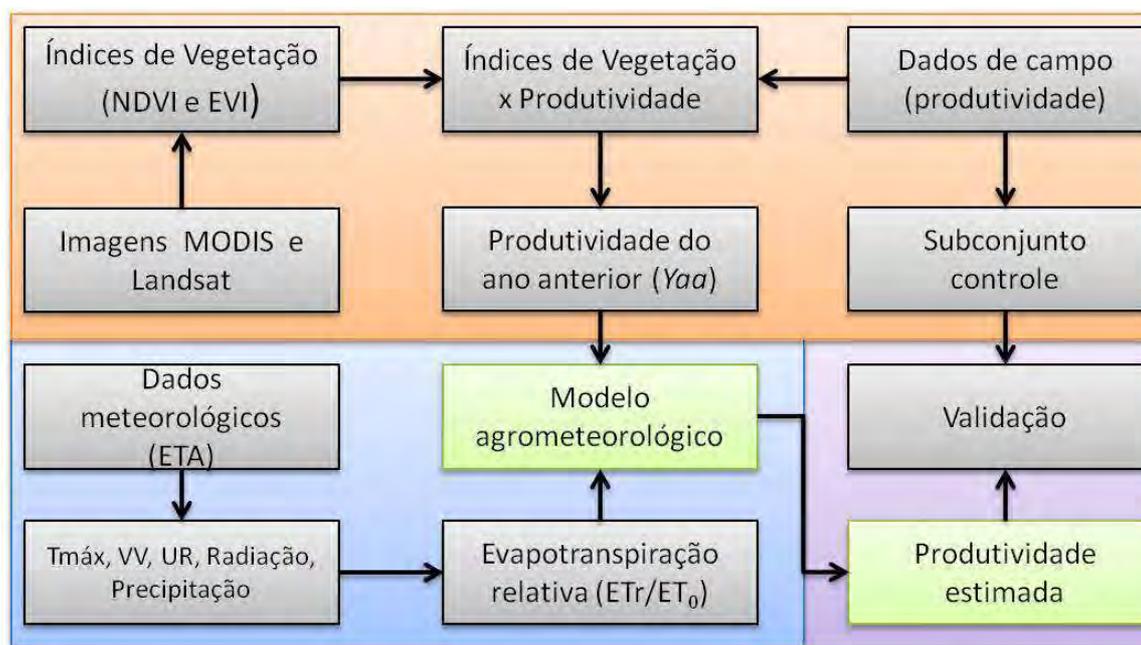


Figura 3.3 - Fluxograma das etapas de trabalho

3.3.2. Etapa 1 – processamento de imagens de satélite e correlações com dados de campo

Na primeira etapa fez-se o processamento de imagens e foram observadas as correlações entre índices de vegetação derivados de imagens Modis e do TM/Landsat e dados de produtividade coletados em campo com a finalidade de obter correlações passíveis de serem usadas na segunda etapa. Imagens Modis foram avaliadas em virtude da sua alta resolução temporal, apropriada ao monitoramento de áreas agrícolas, enquanto que as imagens TM/Landsat pela melhor resolução espacial.

3.3.2.1. Mapa de áreas cafeeiras

O mapeamento de áreas cafeeiras da região Sul/Sudoeste de Minas Gerais, realizado por Moreira et al. (2007), foi utilizado como base para procedimentos para selecionar pixels nas imagens Modis e extrair valores médios de índices de vegetação nas imagens do TM/Landsat referentes às áreas cafeeiras

(Figura 3.2). Os procedimentos em que este mapa base é empregado são descritos a seguir nas seções referentes aos dados Modis e TM/Landsat.

3.3.2.2. Dados Modis

As imagens Modis utilizadas correspondem ao produto MOD13, numa série temporal de índices de vegetação EVI (HUETE; JUSTICE; LIU, 1994; LIU; HUETE, 1995; HUETE; LIU; BATCHILY; VAN LEEUWEN, 1997) e NDVI (ROUSE et al., 1974) (23 cenas por ano) compreendendo o período entre os anos de 2006 e 2009. O objetivo desta análise foi verificar, dada a resolução temporal dos dados, as melhores métricas derivadas de índices de vegetação e períodos do ano para obter as melhores correlações entre dados orbitais e a produtividade do cafeeiro.

As imagens Modis, obtidas originalmente no formato HDF (Hierarchical Data Format) e projeção sinusoidal, foram processadas no aplicativo MRTTool – Modis Reprojection Tool. Os dados foram reprojatados para coordenadas geográficas latitude e longitude, datum WGS84 e então convertidos para o formato GeoTIFF.

3.3.2.2.1. Seleção de pixels

Ao utilizar imagens Modis ou produtos derivados das mesmas, como os índices de vegetação EVI e NDVI, para obter dados a serem utilizados em modelos de produtividade de cafezais da região Sul/Sudoeste de Minas Gerais, depara-se com dois tipos de dificuldades. A primeira está relacionada com o tamanho das lavouras. Nesta região, boa parte das lavouras de café contém área menor do que a área mínima representável pelos pixels da imagem (6,25 ha). A segunda diz respeito ao posicionamento das lavouras em relação ao direcionamento do pixel da imagem Modis. Muitas lavouras, mesmo tendo área maior do que a do pixel Modis, mas por terem direcionamentos diferentes da grade (matriz) de pixels da imagem há uma mistura espectral no pixel. Assim, haverá uma mistura espectral de talhões de café com outros tipos de cobertura da terra.

Este pixel é impuro para ser utilizado na extração de informações a serem aplicadas nos modelos de produtividade ou para análise da correlação com a produtividade. Além disso, deve-se pensar nos diferentes padrões espectrais de lavouras. Para eliminar a interferência destes dois tipos de problemas relatados, foram selecionados somente os pixels que representassem 100% da área com café. Então, foi gerada uma grade vetorial dos pixels de imagem Modis, a qual foi sobreposta ao mapa com as áreas de café e à composição colorida (4R,5G,3B) de imagens do TM/Landsat-5, conforme mostrado na Figura 3.4(A). A partir do cruzamento destas duas informações fez-se uma amostragem de pixels com resposta espectral exclusivamente de lavouras de café. As imagens TM/Landsat foram georreferenciadas de modo a estarem co-registradas com as imagens Modis, conforme procedimento descrito por Roy et al. (2008).

Ao observar o comportamento espectral de lavouras de café na composição colorida TM4(R), TM5(G) e TM3(B) (Figura 3.4 B), observa-se variações no padrão espectral do cafeeiro que vai de um matiz amarelado a um vermelho mais intenso. Essa variação é relacionada com densidade de plantio, idade, tipo de substrato e outros fatores.

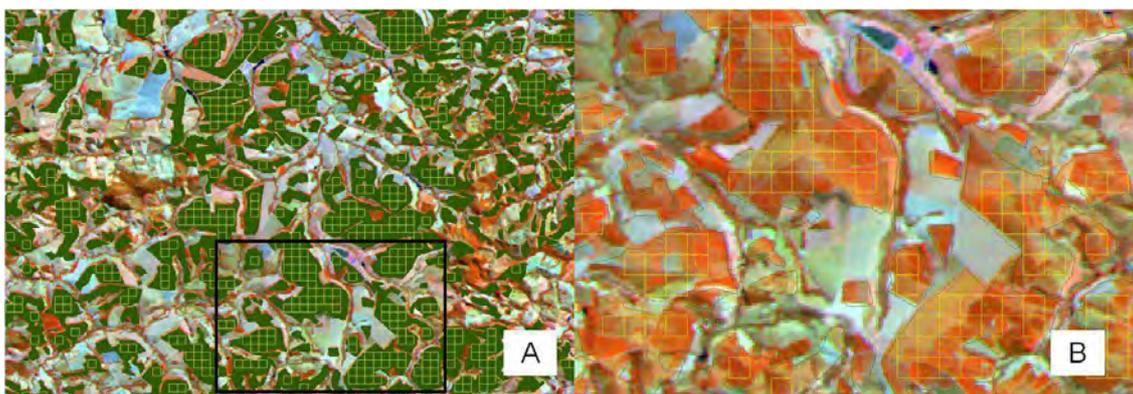


Figura 3.4 - Sobreposição dos limites de pixels Modis em áreas cafeeiras; (A) grade da imagem Modis sobreposta ao mapa de café para individualizar pixels totalmente ocupados por café, cor verde; (B) Variabilidade de lavouras, dentro de um pixel, realçada nas imagens TM/Landsat-5, composição de bandas 4R, 5R, 3B

Assim, foram calculadas estatísticas de pixels do TM/Landsat (Banda 3) circunscritos em pixels Modis para minimizar o efeito de mistura espectral. Foi utilizada a banda 3 em função da interação da radiação eletromagnética nesta faixa espectral com a vegetação (grande absorção), o que a torna ideal para caracterização da vegetação. O coeficiente de variação foi usado para quantificar a variabilidade. Valores de coeficiente de variação menores indicam menor variação dos pixels Landsat dentro de pixels Modis, sugerindo a presença de grandes talhões homogêneos. A Figura 3.5 ilustra o processamento realizado para seleção dos pixels e análise dos padrões temporais.

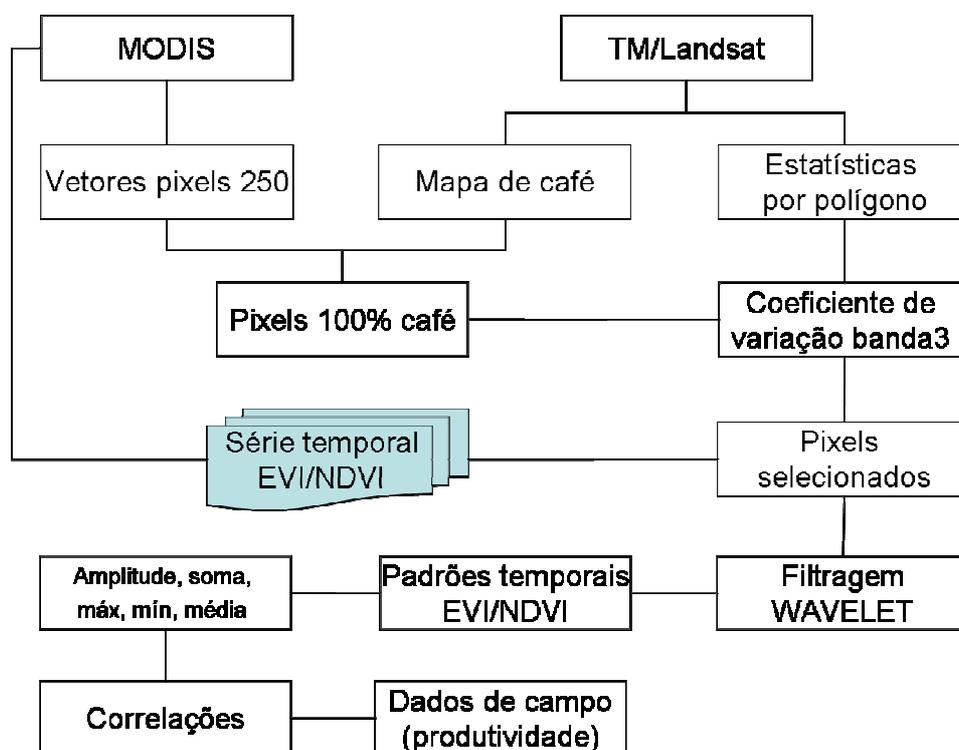


Figura 3.5 - Processamento realizado para seleção de pixels e avaliação das correlações entre dados Modis e dados de produtividade.

As estatísticas dos dados TM/Landsat e a seleção de pixels Modis totalmente ocupados por áreas cafeeiras foram realizadas pela ferramenta “Estatísticas de Imagem por Polígono” disponível no sistema SPRING (CÂMARA et al.,1996).

Inicialmente foi gerado um vetor cadastral a partir das imagens Modis, onde cada objeto corresponde exatamente a um pixel. Este vetor foi usado para o cálculo das estatísticas (coeficiente de variação) da imagem banda 3 do TM/Landsat. O vetor foi atualizado com dados do mapa de áreas cafeeiras para obter a porcentagem de área de café em cada objeto. Foi feita, então, uma consulta ao banco de dados por meio de operadores zonais para obter os objetos com 100% de áreas cafeeiras e coeficiente de variação menor que 40 (talhões homogêneos).

3.3.2.2.2. Filtragem da série temporal

A série temporal da qual foram selecionados os pixels no período entre 2006 e 2009 foi então filtrada utilizando uma função Wavelet (Equação 3.7) (SAKAMOTO et al., 2005, 2006; FREITAS et al., 2011) para eliminar ruídos ou pixels inválidos causados pela presença de nuvens. Ao admitir que a frequência das componentes de ruído nas séries temporais de índices de vegetação é maior que as mudanças sazonais nestes índices para áreas cafeeiras, a reconstrução da série selecionando as altas frequências permite a filtragem dos dados sem alterar o padrão sazonal de mudanças.

$$Wf(a,b) = \int_{-\infty}^{+\infty} f(x) \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) dx \quad (3.7)$$

em que:

a é um parâmetro de escala; b é o parâmetro de mudança; ψ representa a wavelet mãe (Daubechies, 1988);

3.3.2.2.3. Métricas derivadas dos índices de vegetação Modis

Em cada ano agrícola foi calculada a amplitude de variação dos índices de vegetação pela diferença entre os valores máximos e mínimos em cada pixel no ano agrícola (Figura 3.6). O objetivo desta etapa foi quantificar a magnitude da perda de folhas das lavouras dentro de cada ano. Foi assumido que os

índices de vegetação representam bem a área foliar das lavouras e variações anuais nestes índices expressam a perda ou ganho de folhas ao longo do ano.

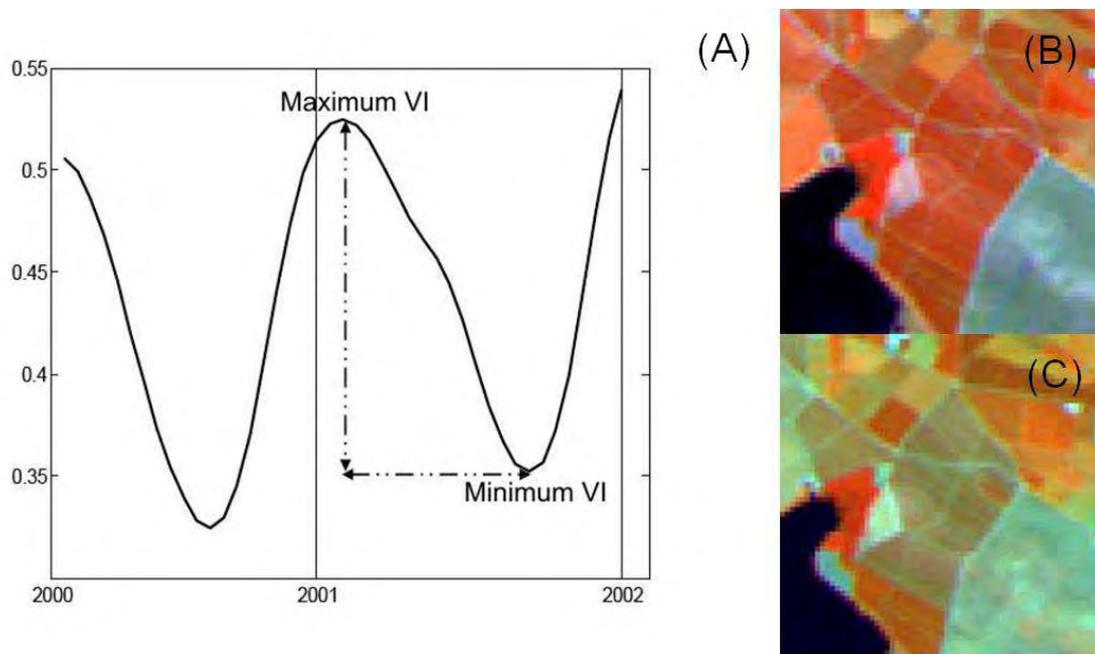


Figura 3.6 - Amplitude de variação anual dos IV para os pixels selecionados (A); Padrão de lavoura em seu máximo índice de vegetação no mês de março (B) e mínimo índice de vegetação no mês de agosto (C);

Além da amplitude avaliou-se, ainda, para cada pixel, o somatório dos valores de índices de vegetação (KASTENS et al., 2005; MARSDEN et al., 2010) no ano agrícola, valor máximo, mínimo e médio ao longo de cada ano para identificar qual parâmetro melhor se correlaciona com a produtividade.

3.3.2.2.4. Dados de produtividade

Para o período de 2001 a 2010 foram levantados junto aos produtores dados de produtividade (sacas de café beneficiado por hectare) nas lavouras correspondentes aos pixels amostrados nos municípios de Boa Esperança, Campo do Meio, Campos Gerais, Três Pontas, São Sebastião do Paraíso, Monte Santo e Itamogi.

Os dados de produtividade das lavouras e dados de EVI e NDVI (amplitude, máxima, média e mínima) foram normalizados com relação ao valor máximo dentro da série temporal conforme as Equações 3.8 e 3.9.

$$P_n = \frac{P_a}{P_m} \quad (3.8)$$

$$IV_n = \frac{IV_a}{IV_m} \quad (3.9)$$

em que:

P_n = Produtividade normalizada; P_a = Produtividade no ano; P_m = Produtividade máxima na série; IV_n = Índice de Vegetação normalizado; IV_a = Índice de Vegetação no ano; IV_m = Índice de Vegetação máximo na série;

3.3.2.2.5. Análise das correlações

As correlações (coeficientes de correlações de Pearson) foram observadas em duas diferentes situações: (i) correlações entre variações na produtividade e variações nos índices de vegetação no mesmo par de anos (Equações 3.10 e 3.11), assumindo que um aumento na produtividade entre 2 anos pode resultar num aumento na variação dos índices de vegetação no mesmo par de anos e (ii) correlações entre variação nos índices de vegetação e variação na produtividade do ano seguinte (Equações 3.11 e 3.12), assumindo que um aumento nos índices de vegetação pode resultar em aumento da produtividade do ano seguinte. Esta abordagem foi adotada a fim de realçar o efeito da bienalidade e também para identificar uma possível alternância nos padrões de índices de vegetação em função da produtividade a cada 2 anos. A Tabela 3.1 apresenta o número de dados utilizados e o número de dados válidos quando considerada a diferença entre 2 anos.

$$\Delta P_i = Pn_i - Pn_{i-1} \quad (3.10)$$

$$\Delta IV_i = IVn_i - IVn_{i-1} \quad (3.11)$$

$$\Delta P_{i+1} = Pn_{i+1} - Pn_i \quad (3.12)$$

em que:

ΔP_i = variação na produtividade no ano (i); Pn_i = produtividade normalizada no ano (i); Pn_{i-1} = produtividade normalizada no ano anterior ($i-1$); ΔIV_i = variação no índice de vegetação no ano (i); IVn_i = índice de vegetação normalizado no ano (i); IVn_{i-1} = índice de vegetação normalizado no ano anterior ($i-1$); ΔP_{i+1} = variação na produtividade no ano seguinte ($i+1$); Pn_{i+1} = produtividade normalizada no ano seguinte ($i+1$); Pn_i = produtividade normalizada no ano (i);

Tabela 3.1 - Número de dados de produtividade amostrados para cada ano (n_i) e número válido de unidades amostrais quando calculada a diferença (variação) entre dois anos ($n_i - n_{i-1}$).

ANO	2002	2003	2004	2005	2006	2007	2008	2009
n_i	20	25	27	32	37	37	37	35
$n_i - n_{i-1}$	-	20	25	27	32	37	37	35

3.3.2.3. Dados Landsat

3.3.2.3.1. Processamento das imagens (correção radiométrica, atmosférica e normalização)

Imagens TM/Landsat, bandas 1, 3 e 4 correspondentes à órbita/ponto 219/75, tomadas no mês de agosto de cada ano da série temporal foram utilizadas para gerar índices de vegetação (NDVI e EVI) como estimadores da fitomassa foliar dos talhões de café amostrados em campo.

Para gerar os índices de vegetação foram realizadas: (i) correção radiométrica das bandas originais de modo a permitir comparar e elaborar cálculos com dados de bandas diferentes; (ii) correção atmosférica para simular a interferência da atmosfera na resposta espectral dos objetos registrados nas imagens e; (iii) normalização radiométrica para minimizar variações na geometria de iluminação e sensibilidade dos detectores do sensor.

O procedimento de correção radiométrica foi feito pela definição dos parâmetros de calibração I_{min} e I_{max} definidos para o sensor TM do Landsat (CHANDER et al., 2009) para converter os níveis digitais (DN) em valores de radiância.

A correção atmosférica foi feita no módulo FLAASH (Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes) que opera sobre o modelo de transferência radiativa MODTRAN4 (ANDERSON et al., 1999).

A normalização radiométrica das imagens foi executada pelo procedimento automatizado desenvolvido por Canty (2004, 2008), cujo código é disponibilizado para execução em linguagem idl no aplicativo ENVI.

As imagens resultantes foram então usadas para gerar índices de vegetação NDVI (ROUSE et al., 1974) e EVI (HUETE et al., 2002), para toda a série temporal. A Figura 3.8 ilustra as etapas de coleta de dados, processamento e

análise para obter modelos de correlação com dados espectrais, biofísicos e produtividade dos talhões de café.

3.3.2.3.2. Extração dos iv por talhões

Os talhões de café amostrados em campo foram identificados e mapeados nas imagens TM/Landsat e vetorizados por interpretação visual para extrair os valores do NDVI e EVI correspondentes aos mesmos. Foram obtidas as médias (Banda 3) dos pixels circunscritos aos talhões de café e também o valor mais frequente (moda) por meio de estatísticas zonais calculadas no Sistema de Informações Geográficas.

Para extrair estes valores de talhões de café individualizados de toda a região Sul/Sudoeste de Minas Gerais foi utilizado o mapa de áreas cafeeiras obtido por Moreira et al. (2007). Uma vez que o mapa identifica apenas a existência de áreas cafeeiras como uma única classe, os talhões não são individualizados. Sendo assim, fez-se uma segmentação das imagens Landsat a fim de individualizar os diferentes talhões de café dentro das áreas representadas no mapa base. A sobreposição dos vetores resultantes da segmentação com o mapa base permitiu obter uma máscara, contendo os talhões de café individualizados, segundo o padrão espectral, conforme ilustrado na Figura 3.7.

Assim, à semelhança do procedimento realizado com os talhões de café amostrados em campo, foram obtidas também as médias e moda dos pixels circunscritos aos talhões de café contidos na máscara por meio de estatísticas zonais calculadas no Sistema de Informações Geográficas.

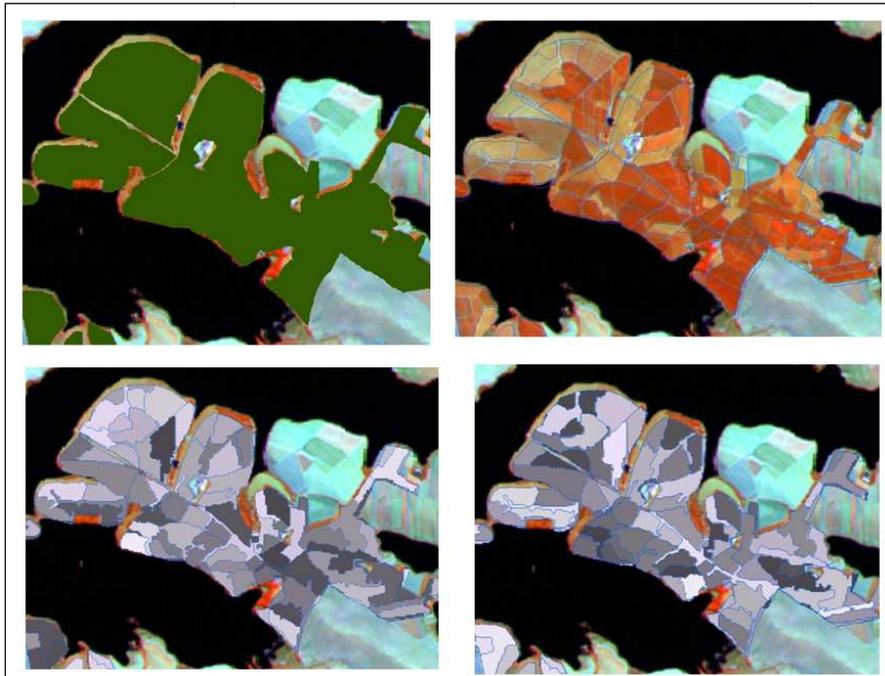


Figura 3.7 - Segmentação das imagens Landsat para individualizar os talhões de café e converter de valores de índices de vegetação - média e moda - para cada talhão homogêneo de café.

3.3.2.3.3. Análise das correlações

Os valores de NDVI e EVI, média e moda, obtidos de cada polígono de café amostrado, somados às outras características biofísicas obtidas em campo foram correlacionados com valores de produtividade por meio de regressão *stepwise*, para avaliar os melhores modelos para estimar a produtividade do cafeeiro. O procedimento constrói iterativamente uma sequência de modelos de regressão pela adição ou remoção de variáveis em cada etapa e seleciona a variável com maior valor do coeficiente associado (teste de F) para o modelo. A cada nova variável é realizado um novo teste de F parcial, cujo valor de F está associado à inclusão da nova variável. Se este valor atinge um limiar predefinido, a variável é mantida. Assim, novas variáveis vão sendo sucessivamente inseridas, testadas e mantidas ou eliminadas até que nenhuma nova variável possa ser adicionada ou retirada do modelo.

As variáveis independentes originais referem-se aos valores de índice de vegetação (média e moda), idade e densidade de plantio. Durante o processo de seleção das melhores variáveis foram obtidas derivações dessas variáveis (razão e diferença entre 2 anos, quadrado, soma de quadrados) e interações entre elas (produto de 2 variáveis) para obter novas variáveis independentes a serem testadas nos modelos. O fluxograma da Figura 3.8 ilustra as etapas de coleta de dados, processamento e análise para obter modelos de correlação com dados espectrais, biofísicos e produtividade dos talhões de café selecionados.

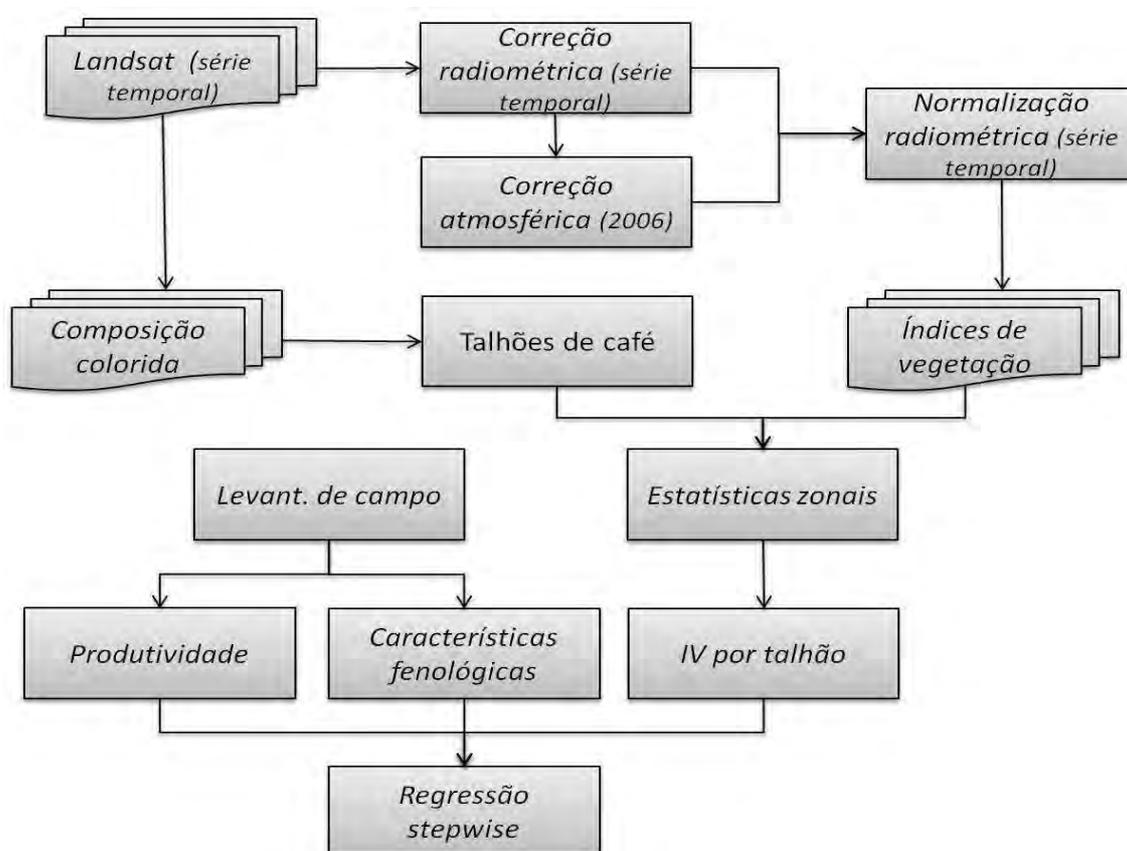


Figura 3.8 - Etapas de coleta de dados, processamento e análise para obtenção de modelos de correlação com dados espectrais, biofísicos e produtividade dos talhões de café.

3.3.3. Etapa 2 – Processamento de dados meteorológicos e integração aos dados de sensoriamento remoto

3.3.3.1. Modelo agrometeorológico

Na segunda etapa o modelo de Doorembos e Kassam (1979) foi ajustado para a cultura cafeeira com adaptações para inclusão do efeito da produtividade do ano anterior conforme Santos e Camargo (2006) – Equação 3.13:

$$Y_{est} = Y_p \left\{ \left(k_{y_0} \left(\frac{Y_{aa}}{Y_p} \right) \right) + \left[1 - \left(k_{y_i} \left(1 - \frac{ET_r}{ET_0} \right) \right) \right] \right\} \quad (3.13)$$

em que:

Y_{est} = produtividade estimada; k_{y_0} = coeficiente de penalização pela produtividade do ano anterior; Y_{aa} = produtividade do ano anterior; Y_p = produtividade potencial; k_{y_i} = coeficiente de resposta da cultura à disponibilidade hídrica no estadio i ; ET_r = Evapotranspiração real; ET_0 = Evapotranspiração potencial;

Produtividade potencial (Y_p) – foi considerado um valor fixo correspondente ao valor máximo obtido na série de dados acrescido de 10% com o objetivo de eliminar qualquer efeito do ambiente inibidor deste potencial (KANEMASU, 1983; PICINI, 1999).

Produtividade do ano anterior (Y_{aa}) – A produtividade do ano anterior foi acrescida ao modelo com base nas correlações entre os índices de vegetação derivados das imagens de satélite e dados de campo, constituindo assim a componente espectral, ou seja, o elo de ligação entre os dados meteorológicos e os dados orbitais.

Componentes meteorológicas – As variáveis meteorológicas necessárias para os cálculos da evapotranspiração potencial (ET_0) e evapotranspiração real (ET_r) foram obtidas do modelo ETA (BLACK, 1994). Os elementos

meteorológicos requeridos para o cálculo são: temperatura média do ar ($^{\circ}\text{C}$); velocidade do vento a 2 metros de altura ($\text{km}\cdot\text{dia}^{-1}$); umidade relativa do ar (%); insolação ($\text{horas}\cdot\text{dia}^{-1}$) para o cálculo da evapotranspiração potencial (ET_0) e precipitação pluvial ($\text{mm}\cdot\text{dia}^{-1}$) para o cálculo da evapotranspiração real (ETr).

As previsões do modelo ETA regional são fornecidas duas vezes ao dia, com condição inicial as 00:00 e 12:00 horas UTC (Tempo Universal Coordenado) e englobam previsões para sete dias em um intervalo de seis horas. Na obtenção destas variáveis foram utilizados os dados da previsão de 24 horas (um dia) com condição inicial às 00:00 do UTC e resolução espacial horizontal de 40×40 km. Estes dados foram disponibilizados em quatro horários diários (00:00, 06:00, 12:00 e 18:00 UTC). Eventuais falhas nos dados foram corrigidas da seguinte forma:

- a) precipitação pluvial, pelo cálculo da média entre o horário anterior e posterior ou quando estes dados também não estavam disponíveis, pela média entre os dados do dia anterior e do dia posterior, nos mesmos horários da falha e;
- b) demais variáveis, pelo cálculo do valor médio entre os dados do dia anterior e do dia posterior, nos mesmos horários da falha.

Os quatro dados diários de cada variável meteorológica foram adequados para representar um único dado diário. Neste procedimento, a composição do dia foi iniciada no horário 06:00 UTC e finalizada no horário 00:00 UTC. Estes horários foram escolhidos em função do fuso horário da área de estudo ter defasagem de -3 horas em relação à hora UTC (sem considerar o horário de verão).

A precipitação pluviométrica diária foi obtida conforme a Equação 3.14 (VIEIRA JUNIOR et al., 2009):

$$Pe_{diária} = Pe_{06} + Pe_{12} + Pe_{18} + Pe_{00} \quad (3.14)$$

em que:

$Pe_{diária}$ é a precipitação pluviométrica acumulada em um dia (mm.dia^{-1}); Pe_{06} é a precipitação acumulada (mm) entre 00:00 e 06:00 UTC; Pe_{12} é a acumulada (mm) entre 06:00 e 12:00 UTC; Pe_{18} é a precipitação acumulada (mm) entre 12:00 e 18:00 UTC e; Pe_{00} é a precipitação acumulada (mm) entre 18:00 e 00:00 UTC.

A temperatura média diária foi obtida pelo cálculo da média entre a temperatura mínima e a temperatura máxima (ALLEN et al., 1998), de acordo com a Equação 3.15:

$$Tmed_{diária} = \frac{T_{min} + T_{max}}{2} \quad (3.15)$$

em que:

$Tmed_{diária}$ é a temperatura média do ar diária ($^{\circ}\text{C}$); T_{min} é a temperatura mínima do ar, dada pela temperatura do horário 0600 UTC ($^{\circ}\text{C}$) e; T_{max} é a temperatura máxima do ar, representada pela temperatura ($^{\circ}\text{C}$) do horário 18:00 UTC.

A radiação solar incidente média diária foi obtida com o cálculo da média da radiação solar incidente estimada nos horários 12:00, 18:00 e 00:00 UTC, com base na seguinte Equação 3.16:

$$Roc_{diária} = \frac{Roc_{12} + Roc_{18} + Roc_{00}}{3} \times 2,06 \quad (3.16)$$

em que:

$Roc_{diária}$ é a radiação solar incidente média diária ($\text{cal.cm}^{-2}.\text{dia}^{-1}$); Roc_{12} é a radiação solar incidente no horário 12:00 UTC (w.m^{-2}); Roc_{18} é a radiação

solar incidente às 18:00 UTC ($W.m^{-2}$); R_{c00} é a radiação solar incidente no horário 00:00 UTC ($W.m^{-2}$) e; 2,06 é o fator de conversão dos dados em $W.m^{-2}$ para $cal.cm^{-2}.dia^{-1}$ (ALLEN et al., 1998);

A velocidade média diária do vento a 2 m de altura ($m.s^{-1}$) foi calculada pela Equação 3.17:

$$V_{diária} = \frac{V_{06}+V_{12}+V_{18}+V_{00}}{4} \times 0,748 \quad (3.17)$$

em que:

$V_{diária}$ é a velocidade do vento média diária a 2 m de altura ($m.s^{-1}$); V_{06} é a velocidade do vento a 10 m ($m.s^{-1}$) no horário 06:00 UTC; V_{12} é a velocidade do vento a 10 m ($m.s^{-1}$) no horário 12:00 UTC; V_{18} é a velocidade do vento a 10 m ($m.s^{-1}$) às 18:00 UTC; V_{00} é a velocidade do vento ($m.s^{-1}$) a 10 m no horário 00:00 UTC e; 0,748 é o fator de conversão da velocidade do vento a 10 m para 2 m de altura (ALLEN et al., 1998);

A umidade relativa média diária do ar (%) foi calculada por meio da Equação 3.18:

$$UR_{diária} = \frac{UR_{06}+UR_{12}+UR_{18}+UR_{00}}{4} \quad (3.18)$$

em que:

$UR_{diária}$ é a umidade relativa média diária do ar (%); UR_{06} é a umidade relativa do ar às 06:00 UTC; UR_{12} é a umidade relativa do ar no horário 12:00 UTC; UR_{18} é a umidade relativa do ar às 18:00 UTC; UR_{00} é a umidade relativa do ar no horário 00:00 UTC;

Os dados originais, obtidos em grades no formato ASCII (Standard Code for Information Interchange) na resolução espacial de 40 km, foram reinterpolados para resolução de 30 metros a fim de compatibilizar os dados com a resolução espacial do TM/Landsat-5.

Diferentes combinações de períodos para agrupamento das evapotranspirações relativas (ET_r/ET_0) foram consideradas conforme reportados na literatura (MATIELLO, 1991; PICINI et al., 1999; CARVALHO et al., 2003) (Tabela 3.2). Em cada um destes períodos obteve-se a média das evapotranspirações relativas (média de nove valores referentes à escala decendial – três decêndios x três meses para cada período).

Tabela 3.2 - Diferentes combinações das durações dos períodos considerados nas análises dos efeitos das evapotranspirações relativas utilizadas na parametrização e teste do modelo agrometeorológico.

Combinações/ Períodos	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun
A1	■												
A2				■									
A3							■						
B1	■												
B2					■								
B3								■					
C1		■											
C2						■							
C3									■				
D1	■												
D2					■								
D3								■					
D4											■		

Coefficientes de resposta (ky's) – Os parâmetros do modelo apresentam diferentes pesos na estimativa da produtividade, representados pelos coeficientes K_y (K_{y_0} - coeficiente de resposta relativo à produtividade do ano anterior; K_{y_i} - coeficientes de resposta relativos à evapotranspiração relativa nos períodos considerados). Estes coeficientes foram obtidos por meio de regressão linear múltipla (Equação 3.13) utilizando os dados de produtividade observados em campo e dados de evapotranspiração relativa calculados a partir dos dados do modelo ETA. Os modelos foram avaliados por meio do intervalo de confiança para os coeficientes e pelo coeficiente de determinação dos modelos (R^2).

3.3.3.2. Evapotranspiração potencial (ET₀)

A Evapotranspiração potencial (ET₀) foi computada pelo método de Penman, proposta por Frère e Popov (1980) e é descrita pela Equação 3.19:

$$ET_0 = \frac{W \times Rlt + f(V) \times (pv - pvr)}{1 + W} \quad (3.19)$$

em que:

ET₀= Evapotranspiração potencial; w = fator em função da temperatura e altitude (Tabela 3.3); Rlt= radiação líquida total (mm.dia⁻¹), ou definida por Doorenbos e Kassam (1979) como: Rlt = 0,75×Rocr–Rol, em que Rocr é a radiação de onda curta real, (mm.dia⁻¹) e Rol é a radiação de onda longa líquida (mm.dia⁻¹), ou seja, Rol = f (T).f (n / N).f (pvr), em que f(T) é o efeito da temperatura sobre a Rol, ou f (T) = 1,385.10⁻¹².1440.(273 +T)⁴ , onde T é a temperatura média (°C), f(n/N) é o efeito taxa de insolação, ou f (n/N) = 0,1+(0,9×(n/N)), sendo n é a duração da insolação (horas) e N a duração máxima da insolação (horas); e f(pvr) é o efeito da pressão do vapor ou f (pvr) = 0,56 - (0,079. pv), sendo pv a pressão de saturação do vapor (mbar); f(V)= função do vento, ou f (V) = 0,27(1+V), onde V é o vento a 2m de altura (m.s⁻¹), equação determinada por Doorenbos e Kassam (1979); pv= pressão de saturação do vapor (mbar) (Tabela 3.4); pvr= pressão de saturação real do vapor (mbar), ou pvr = pv.(UR/100), onde UR é a umidade relativa do ar.

Tabela 3.3 - Fator W em função da temperatura média do ar ($T_{\text{média}}$ em $^{\circ}\text{C}$) e altitude (metros)

$T_{\text{média}}$ ($^{\circ}\text{C}$)	Altitude (metros)						
	0	200	400	600	800	1000	1200
10	1,25	1,28	1,31	1,34	1,37	1,41	1,44
11	1,32	1,35	1,39	1,42	1,45	1,49	1,53
12	1,4	1,43	1,47	1,5	1,54	1,57	1,62
13	1,48	1,52	1,55	1,59	1,63	1,67	1,71
14	1,57	1,61	1,64	1,68	1,72	1,77	1,81
15	1,66	1,7	1,74	1,78	1,82	1,87	1,92
16	1,76	1,8	1,85	1,89	1,94	1,98	2,04
17	1,86	1,91	1,95	2	2,05	2,1	2,15
18	1,97	2,02	2,06	2,11	2,17	2,22	2,28
19	2,08	2,13	2,18	2,23	2,29	2,34	2,4
20	2,19	2,25	2,3	2,36	2,42	2,47	2,54
21	2,32	2,37	2,43	2,49	2,55	2,61	2,68
22	2,44	2,5	2,56	2,63	2,69	2,75	2,83
23	2,58	2,64	2,71	2,77	2,84	2,9	2,98
24	2,72	2,78	2,85	2,92	2,99	3,06	3,14
25	2,86	2,93	3	3,08	3,15	3,22	3,31
26	3,01	3,09	3,16	3,24	3,32	3,4	3,49
27	3,17	3,25	3,33	3,41	3,49	3,57	3,67
28	3,34	3,42	3,5	3,59	3,67	3,76	3,86
29	3,51	3,6	3,68	3,77	3,86	3,95	4,06
30	3,69	3,78	3,87	3,97	4,06	4,16	4,27
31	3,88	3,98	4,07	4,17	4,27	4,37	4,49
32	4,07	4,18	4,28	4,38	4,49	4,59	4,71
33	4,27	4,38	4,48	4,59	4,7	4,81	-
34	4,48	4,59	4,7	4,82	4,93	-	-
35	4,71	4,83	4,95	5,06	-	-	-

Fonte: adaptada de Frère e Popov (1980, p. 60).

Tabela 3.4 - Pressão de saturação do vapor (pv) em função da temperatura média do ar (T méd)

T méd (°c)	10	11	12	13	14	15	16	17	18	19
pv (mbar)	12,3	13,1	14	15	16,1	17	18,2	19,4	20,6	22
T méd (°c)	20	21	22	23	24	25	26	27	28	29
pv (mbar)	23,4	24,9	26,4	28,1	29,8	31,7	33,6	35,7	37,8	40,1
T méd (°c)	30	31	32	33	34	35	36	37	38	39
pv (mbar)	42,4	44,9	47,6	50,3	53,2	56,2	59,4	62,8	66,3	69,9

Fonte: adaptada de Doorenbos e Kassam (1979, p. 20).

3.3.3.3. Evapotranspiração real (ETr)

A Evapotranspiração Real (ETr), calculada pelo balanço hídrico de Thornthwaite, depende de três fatores: (i) Evapotranspiração máxima da cultura (ETm); (ii) água remanescente no solo (ARS); e (iii) Índice de água disponível no solo (IADS).

A ETm é calculada a partir da Evapotranspiração potencial (ET₀), descrita anteriormente, multiplicada pelo Coeficiente de cultura (Kc) determinado experimentalmente para cada cultura. No caso do cafeeiro o valor adotado foi igual a 1 (um), conforme CAMARGO e PEREIRA (1994). A água remanescente no solo foi calculada através da Equação 3.20:

$$ARS = (1 - p) \times cras \times D \quad (3.20)$$

em que:

ARS= água remanescente no solo (mm); p= fração de esgotamento da água no solo (Tabela 3.5); cras= capacidade de retenção de água no solo; D= profundidade do sistema radicular (m);

Tabela 3.5 - Fração de esgotamento de água no solo (p)

ETm (mm.dia ⁻¹)								
2	3	4	5	6	7	8	9	10
0,875	0,8	0,7	0,6	0,55	0,5	0,45	0,425	0,4

Fonte: Adaptada de Doorenbos e Kassam (1979, p. 28).

Para a capacidade de retenção de água no solo (*cras*), assumiu-se um valor médio de 100 mm, valor usual aplicado para Latossolos e Argissolos (EMBRAPA, 1999; FARIAS et al., 2000). Em um diagnóstico físico-ambiental da cafeicultura no Estado de Minas Gerais, foi observado que mais de 80% da cafeicultura mineira se encontra predominantemente sobre estes dois tipos de solos (BERNARDES et al., 2012). Sendo assim adotou-se o valor de *cras* usual para estes solos o qual foi também adotado por MATIELLO (1991), CAMARGO & PEREIRA (1994) e PICINI (1998).

A profundidade do sistema radicular (D) adotada foi de 1 metro, valor definido por Franco e Inforzato (1946) como a profundidade média de exploração das raízes de cafeeiros adultos nas condições do Estado de São Paulo. A água remanescente do solo (ARS) é um dos parâmetros utilizados para o cálculo do índice de água disponível no solo (IADS) conforme a Equação 3.21:

$$IADS = \frac{Pe + ARMp - ARS}{ETmq} \quad (3.21)$$

em que:

IADS= índice de água disponível no solo; *Pe*= precipitação da quinzena (mm acumulado); *ARMp*= disponibilidade real de água no solo no início da quinzena, calculado pelo balanço hídrico de Thornthwait-Matter (mm/profundidade de raiz) (Mota, 1979; adaptado por Rudorff, 1985); *ARS*= água remanescente no solo (mm); *ETmq*= evapotranspiração quinzenal (mm/quinzena).

Assim, o valor de ETr foi determinado a partir dos valores contidos na Tabela 3.6, considerando-se que quando IADS é maior ou igual a 1, então ETr é igual a ETm e quando IADS é menor do que 0, a evapotranspiração relativa (E_{Tr}/E_{T_0}) é bastante pequena, dificultando muito o crescimento das plantas.

Tabela 3.6 - Evapotranspiração real (ETr) em mm.dia^{-1} em função do índice de água disponível no solo (IADS), Evapotranspiração máxima (ETm) e água remanescente no solo (ARS)

	IADS=0,83					IADS=0,67				
	ETm (mm.dia^{-1})					ETm (mm.dia^{-1})				
ARS (mm)	2	4	6	8	10	2	4	6	8	10
25	1,9	3,8	5,6	7,3	9,1	1,8	3,3	4,8	6,1	7,5
50	2	3,9	5,7	7,6	9,4	1,9	3,6	5,2	6,7	8,1
100	2	3,9	5,9	7,8	9,6	1,9	3,8	5,5	7,2	8,8
150	2	4	5,9	7,8	9,7	2	3,8	5,7	7,4	9,1
200	2	4	5,9	7,9	9,8	2	3,9	5,7	7,5	9,3
	IADS=0,50					IADS=0,33				
	ETm (mm.dia^{-1})					ETm (mm.dia^{-1})				
ARS (mm)	2	4	6	8	10	2	4	6	8	10
25	1,6	2,8	3,8	4,8	5,8	1,3	2,1	2,8	3,5	4,2
50	1,7	3,2	4,4	5,5	6,5	1,6	2,7	3,5	4,3	5
100	1,9	3,5	5	6,3	7,6	1,8	3,2	4,3	5,3	6,2
150	1,9	3,7	5,3	6,7	8,1	1,8	3,4	4,7	5,9	7
200	1,9	3,7	5,4	7	8,5	1,9	3,5	5	6,3	7,5
	IADS=0,83					IADS=0,67				
	ETm (mm.dia^{-1})					ETm (mm.dia^{-1})				
ARS (mm)	2	4	6	8	10	2	4	6	8	10
25	1,1	1,5	1,8	2,2	2,5	0,8	0,8	0,8	0,8	0,8
50	1,4	2,1	2,8	3	3,3	1,2	1,5	1,6	1,7	1,7
100	1,7	2,8	3,6	4,2	4,7	1,5	2,3	2,8	3	3,2
150	1,7	3,1	4,2	5	5,7	1,7	2,7	3,5	4	4,3
200	1,8	3,3	4,5	5,5	6,4	1,7	3	4	4,7	5,1

Fonte: Adaptada de Doorenbos e Kassam (1979, p. 34).

3.3.4. Etapa 3 – Geração da produtividade estimada e avaliação

A terceira etapa refere-se à integração final do modelo agrometeorológico aos dados espectrais (estimador da produtividade do ano anterior – Y_{aa}), para estimativa da produtividade da cultura cafeeira e aplicação de técnicas estatísticas para validar os dados de produtividade estimados, tomando como referência valores levantados em campanhas de campo e estatísticas agrícolas em nível municipal.

A avaliação dos resultados foi feita por meio de regressão dos valores de produtividade estimados com os dados de referência coletados em campo (estimativas por lavouras) e dados do IBGE (estimativas por municípios) para análise das medidas de precisão – coeficiente de correlação (r), o coeficiente de determinação (R^2), o erro médio quadrático (EMQ) e o comportamento dos resíduos (NETER et al., 1996). Adicionalmente foi calculado o índice d_1 proposto por Wilmot et al. (1981) e d_2 (WILMOT et al., 1985), comumente usados em estudos desta natureza como medidas de exatidão (PICINI et al., 1999; CARVALHO et al., 2003; SANTOS e CAMARGO, 2006).

A produtividade estimada em sacas por hectare (avaliada no âmbito de lavouras) foi convertida em produção total por município a fim de avaliar o desempenho dos modelos empregados nas estimativas da produtividade total (quilogramas por município) em comparação às estatísticas disponibilizadas pelo IBGE. A conversão foi feita por meio das ferramentas de análise espacial, disponíveis em um sistema de informações geográficas, a produtividade em sacas por hectare foi multiplicada pela área de cada polígono de café mapeado, o que resultou na produção em quilogramas por lavoura. Esta produção foi somada dentro dos limites de cada município a fim de obter a produção total por município.

4. RESULTADOS

4.1. Correlações entre produtividade e dados Modis

Objetivou-se aqui investigar os melhores dados e época para estimativa da produtividade sem a pretensão de utilizar os modelos em etapas futuras uma vez que, devido à baixa resolução espacial, apenas grandes talhões homogêneos se prestaram à análise após o processo de seleção de pixels.

4.1.1. Variação anual dos índices de vegetação

Embora o café seja uma cultura anual que supostamente apresente pequenas variações na área foliar ao longo do ano, observou-se grandes variações nos valores de índices de vegetação dentro de cada ano, como ilustrado na Figura 4.1, correspondente aos resultados da filtragem dos dados para um pixel amostrado.

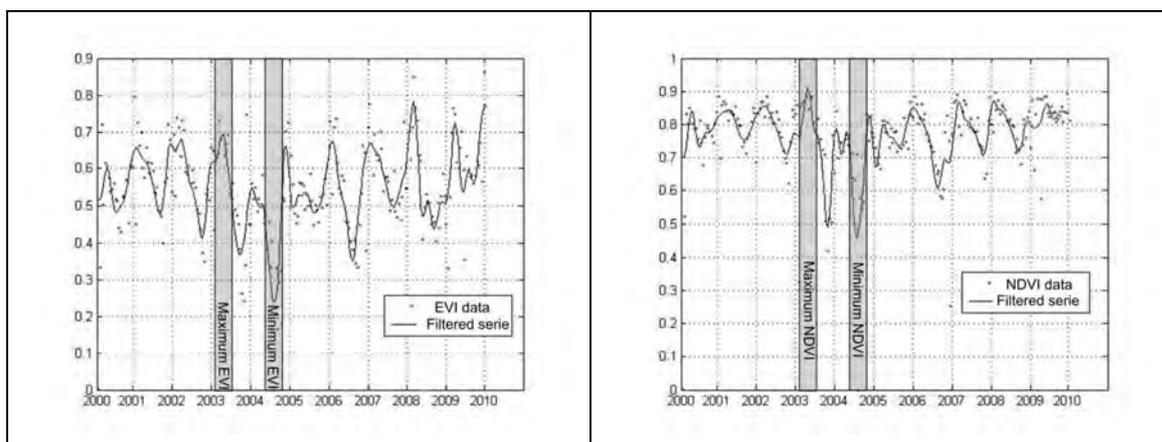


Figura 4.1 - Séries temporais dos valores de NDVI e EVI para a cultura do café no período de 2000 a 2010 – dados originais e filtrados

Os valores de NDVI e EVI representativos de grandes talhões homogêneos de café alcançaram seus máximos e mínimos em Março/Abril e em Agosto/Setembro respectivamente, os quais representam o final das estações chuvosa e seca na região de estudo.

Os valores mínimos de NDVI e EVI também coincidem com o período de pós-colheita, quando a cultura normalmente perde parte da fitomassa, devido a danos causados pelo processo de colheita. Assim, à parte da variação sazonal do clima na redução da fitomassa, os baixos valores encontrados para o NDVI e o EVI também são causados pela prática da colheita.

4.1.2. Análise das correlações entre variações nos dados de campo e nos índices de vegetação em cada par de anos

Os resultados das correlações entre variações nos dados de campo e nos índices de vegetação no mesmo ano (ΔI_{Vi} vs ΔP_i) no período de 2002/2003 a 2008/2009 são apresentados na Tabela 4.1.

Tabela 4.1 - Coeficientes de correlação de Pearson (r), coeficientes de determinação (R²) e valor-p (p) para as variações na produtividade do café e nas métricas de Índices de Vegetação no mesmo ano, para o período de 2002 a 2009.

METRICA		2002/03	2003/04	2004/05	2005/06	2006/07	2007/08	2008/09
	n	20	25	27	32	37	37	35
ampEVI	r	0,56	0,50	0,48	0,32	0,40	0,20	0,41
	R ²	0,32	0,25	0,23	0,10	0,16	0,04	0,17
	p	0,01	0,01	0,01	0,07	0,01	0,23	0,01
sumEVI	r	-0,33	0,12	-0,06	-0,20	-0,49	-0,40	-0,47
	R ²	0,11	0,01	0,00	0,04	0,24	0,16	0,22
	p	0,15	0,59	0,78	0,26	<0,01	0,01	<0,01
maxEVI	r	0,29	0,34	0,24	0,12	-0,05	-0,15	-0,10
	R ²	0,08	0,11	0,06	0,01	0,00	0,02	0,01
	p	0,22	0,11	0,22	0,53	0,78	0,38	0,56
minEVI	r	-0,46	-0,38	-0,50	-0,45	-0,65	-0,54	-0,55
	R ²	0,21	0,14	0,25	0,20	0,42	0,30	0,31
	p	0,04	0,07	0,01	0,01	<0,01	<0,01	<0,01
avrgEVI	r	-0,33	0,12	-0,06	-0,20	-0,49	-0,40	-0,47
	R ²	0,11	0,01	0,00	0,04	0,24	0,16	0,22
	p	0,15	0,59	0,78	0,26	<0,01	0,01	<0,01
ampNDVI	r	0,44	0,33	0,10	0,41	0,42	0,26	0,11
	R ²	0,20	0,11	0,01	0,17	0,18	0,07	0,01
	p	0,05	0,11	0,61	0,02	0,01	0,12	0,52
sumNDVI	r	-0,15	0,25	0,10	0,07	-0,36	-0,40	-0,23
	R ²	0,02	0,06	0,01	0,01	0,13	0,16	0,05
	p	0,52	0,23	0,61	0,69	0,03	0,01	0,18
maxNDVI	r	0,11	0,07	0,07	0,37	-0,20	-0,30	-0,19
	R ²	0,01	0,00	0,00	0,14	0,04	0,09	0,04
	p	0,64	0,75	0,73	0,03	0,23	0,07	0,28
minNDVI	r	-0,45	-0,52	-0,30	-0,36	-0,66	-0,45	-0,21
	R ²	0,20	0,27	0,09	0,13	0,43	0,20	0,04
	p	0,05	0,01	0,12	0,04	<0,01	<0,01	0,23
avrgNDVI	r	-0,15	0,25	0,10	0,07	-0,36	-0,40	-0,23
	R ²	0,02	0,06	0,01	0,01	0,13	0,16	0,05
	p	0,52	0,23	0,61	0,69	0,03	0,01	0,18

ampEVI - amplitude EVI; sumEVI - soma EVI; maxEVI - máximo EVI; minEVI - mínimo EVI; avrgEVI - média EVI; ampNDVI - amplitude NDVI; sumNDVI - soma NDVI; maxNDVI - máximo NDVI; minNDVI - mínimo NDVI; avrgNDVI - média NDVI;

Embora as correlações sejam menores do que as encontradas em outros estudos com culturas anuais (BALAGHI et al., 2008; REN et al., 2008; MKHABELA et al., 2001; PANDA et al., 2010; BECKER-RESHEF et al., 2011), as correlações foram significativas para algumas métricas e indicam uma dependência da área foliar em relação à produtividade do café no mesmo par de anos. Brunsel et al. (2009) observaram resultados semelhantes, em que

índices de vegetação obtidos de imagens Modis convertidos em fração de cobertura da vegetação se correlacionaram com a produtividade do cafeeiro.

A métrica amplitude de variação ao longo do ano (ampEVI e ampNDVI) apresentou correlação positiva com a produtividade e mostrou que um aumento na produtividade entre 2 anos consecutivos resultou em maior amplitude de variação nos índices de vegetação no mesmo par de anos. Nesta situação deduz-se que maiores níveis de desfolha ocorrem quando a produtividade aumenta de um ano para outro. Entretanto em alguns anos esta correlação não foi significativa. Resultados similares foram obtidos por Silva et al. (2010) em estudo ao nível de talhão em que os autores encontraram correlações de até 0,9 entre a produtividade e desfolha do cafeeiro no Sul de Minas Gerais. Esta desfolha foi atribuída a danos mecânicos causados pela colheita e a um maior índice de ocorrência de doenças como a ferrugem do cafeeiro (CHALFOUN, 1981; AVELINO et al., 2006; COSTA et al., 2006).

As correlações entre produtividade e desfolha foram, entretanto, mais significativas com os valores mínimos de índices de vegetação dentro de cada ano agrícola (métricas minEVI e minNDVI). Os melhores coeficientes de correlação foram $r = -0.65$ para minEVI e $r = -0.66$ para minNDVI (Figura 4.2).

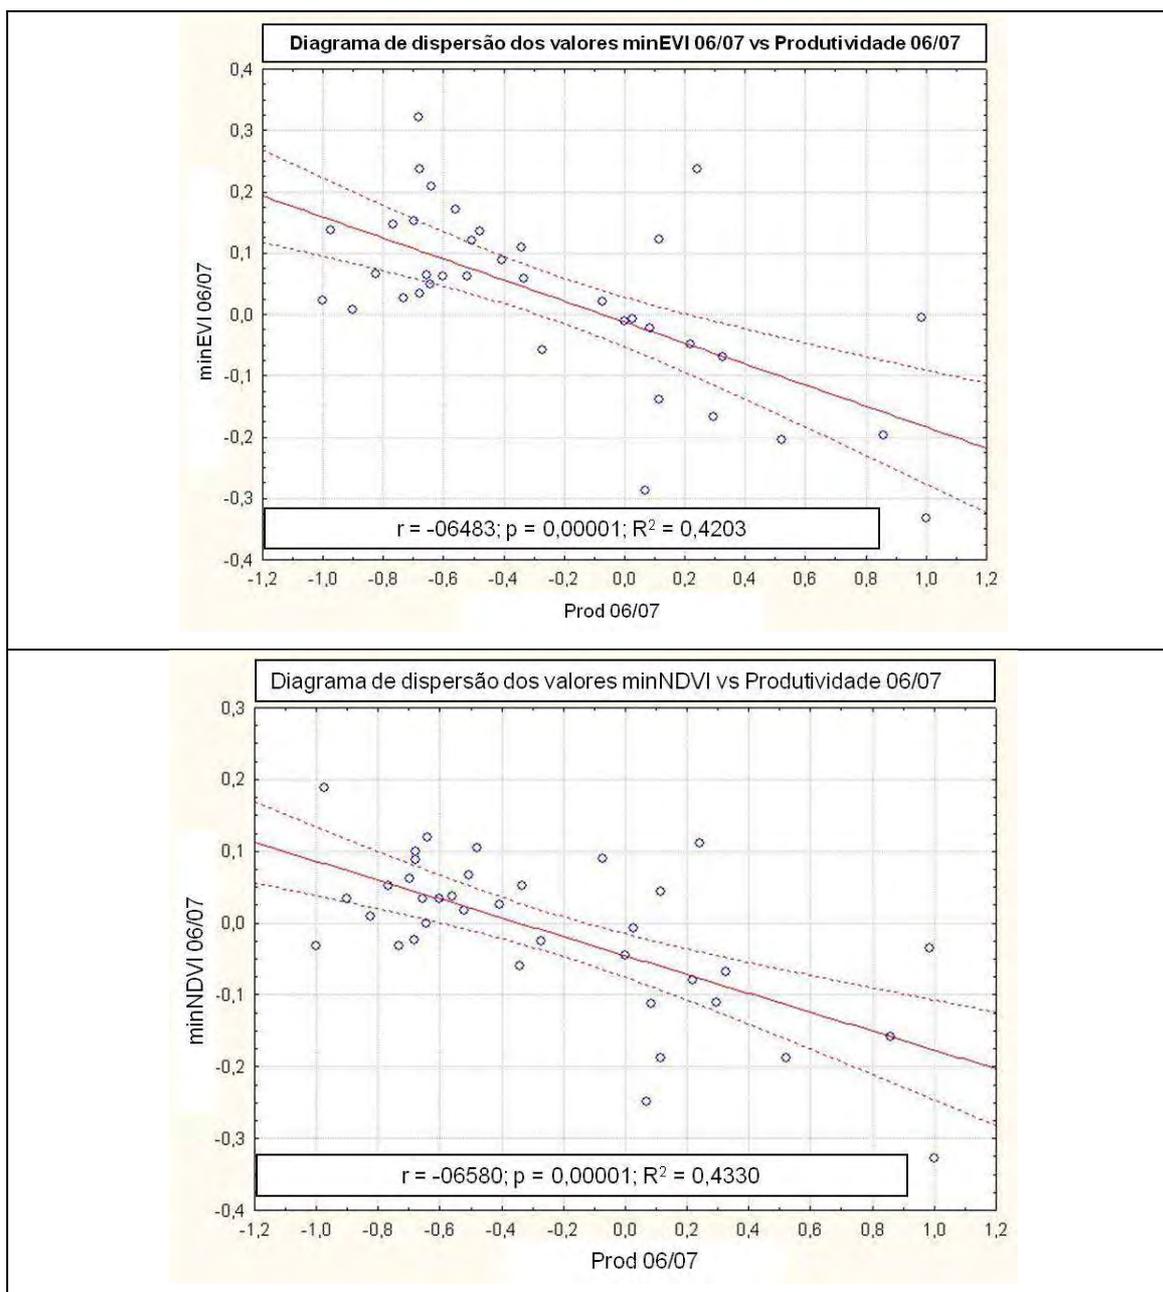


Figura 4.2 - Correlação entre variações na produtividade e variações nos valores mínimos de índices de vegetação no mesmo ano.

As correlações inversas, observadas em todos os anos, indicam que incrementos positivos na produtividade resultaram em redução nos valores mínimos de índices de vegetação, o que sugere uma maior perda de folhas durante a colheita em anos de maior produtividade. Os valores mínimos de índices de vegetação ocorreram entre os meses de Agosto e Setembro,

período correspondente ao final da estação seca e situação de menor fotoperíodo (CAMARGO; CAMARGO, 2001). Contudo este período também é quando a colheita está sendo finalizada.

Os melhores resultados obtidos com os valores mínimos do NDVI apontam o melhor período para aquisição de imagens para serem usadas em estudos desta natureza, uma vez que a probabilidade de obter imagens livres de cobertura de nuvens é grande. Além disso, dada a existência de imagens de melhor resolução espacial, como as do TM/Landsat, bons resultados também são esperados, uma vez que a maior limitação dos dados Modis, neste caso, é a sua baixa resolução espacial.

As métricas soma de índices de vegetação (sumEVI e sumNDVI), valores máximos (maxEVI e maxNDVI) e média (avrgEVI e avrgNDVI) não mostraram tendências constantes nas análises de correlação. Funk et al. (2009) relataram diversos estudos sugerindo que índices de vegetação do meio até o final das estações de crescimento de culturas representam melhor as produtividades do que a integração (soma) ou valores máximos.

A Tabela 4.2 apresenta as correlações entre variações nas métricas de índices de vegetação e variações na produtividade no ano consecutivo no período entre 2002/2003 a 2007/2008.

Tabela 4.2 - Coeficientes de correlação de Pearson (r), coeficientes de determinação (R²) e valor-p (p) para as variações nas métricas de índices de vegetação e variações na produtividade do ano seguinte.

		2002/03	2003/04	2004/05	2005/06	2006/07	2007/08
	n	20	25	27	32	37	37
ampEVI	r	-0,57	-0,55	-0,56	-0,33	-0,48	-0,24
	r ²	0,33	0,30	0,31	0,11	0,23	0,06
	p	0,01	0,01	<0,01	0,06	<0,01	0,17
sumEVI	r	0,52	0,06	0,10	0,18	0,49	0,47
	r ²	0,27	0,00	0,01	0,03	0,24	0,22
	p	0,02	0,79	0,61	0,31	<0,01	<0,01
maxEVI	r	-0,17	-0,29	-0,27	-0,16	0,01	0,20
	r ²	0,03	0,08	0,07	0,02	0,00	0,04
	p	0,49	0,17	0,18	0,39	0,93	0,25
minEVI	r	0,62	0,55	0,53	0,29	0,74	0,62
	r ²	0,39	0,30	0,28	0,09	0,55	0,39
	p	<0,01	0,01	<0,01	0,10	<0,01	<0,01
avrgEVI	r	0,52	0,06	0,10	0,18	0,49	0,47
	r ²	0,27	0,00	0,01	0,03	0,24	0,22
	p	0,02	0,79	0,61	0,31	<0,01	<0,01
ampNDVI	r	-0,63	-0,47	-0,26	-0,34	-0,40	-0,30
	r ²	0,39	0,22	0,07	0,12	0,16	0,09
	p	<0,01	0,02	0,19	0,06	0,01	0,08
sumNDVI	r	0,34	0,03	-0,04	-0,12	0,38	0,42
	r ²	0,12	0,00	0,00	0,01	0,14	0,17
	p	0,14	0,91	0,83	0,53	0,02	0,01
maxNDVI	r	0,00	-0,08	-0,12	-0,33	0,24	0,30
	r ²	0,00	0,01	0,01	0,11	0,06	0,09
	p	1,00	0,70	0,56	0,67	0,15	0,08
minNDVI	r	0,65	0,68	0,46	0,27	0,63	0,48
	r ²	0,43	0,46	0,21	0,07	0,39	0,23
	p	<0,01	<0,01	0,02	0,14	<0,01	<0,01
avrgNDVI	r	0,34	0,03	-0,04	-0,12	0,38	0,42
	r ²	0,12	0,00	0,00	0,01	0,14	0,17
	p	0,14	0,91	0,83	0,53	0,02	0,01
ampEVI - amplitude EVI; sumEVI - soma EVI; maxEVI - máximo EVI; minEVI - mínimo EVI; avrgEVI - média EVI; ampNDVI - amplitude NDVI; sumNDVI - soma NDVI; maxNDVI - máximo NDVI; minNDVI - mínimo NDVI; avrgNDVI - média NDVI;							

Os resultados da análise estatística mostraram que as correlações entre as variações nos índices de vegetação e a variação na produtividade do ano seguinte apresentaram melhores resultados para os valores mínimos de EVI e NDVI (minEVI e minNDVI). Os melhores coeficientes de correlação foram 0,74 para minEVI e 0,68 para minNDVI respectivamente (Figura 4.3).

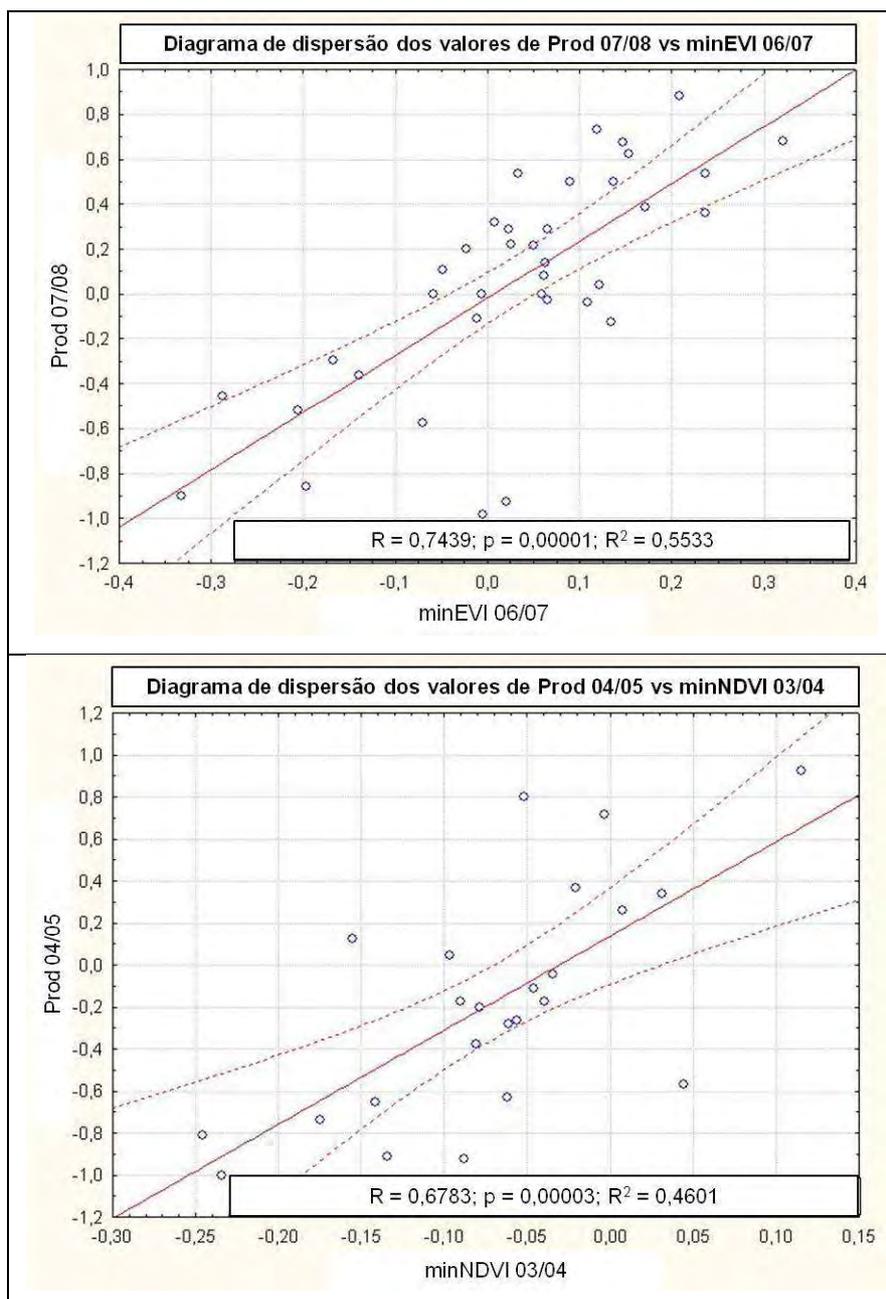


Figura 4.3 - Correlação entre variações nos valores mínimos de IV (minEVI e minNDVI) e variações na produtividade do café no ano seguinte.

Ao observar os valores do coeficiente de determinação (R^2) nota-se que tanto os valores mínimos do EVI (0,55) e do NDVI (0,46) explicaram 55% e 46% respectivamente a variação da produtividade dos cafezais considerados como piloto nesta pesquisa.

Estes baixos coeficientes indicam que, embora os índices de vegetação expressem a fitomassa, a produtividade é um fenômeno mais complexo que não depende apenas do índice de área foliar (fitomassa), mas também de fatores relacionados ao meio ambiente. Altos valores de produtividade resultam de condições adequadas de fitomassa, no entanto, apenas isso não assegura altos níveis de produtividade, especialmente em anos de stress hídrico ou temperaturas mínimas extremas durante fases fenológicas críticas (CAMARGO e CAMARGO, 2001; DaMATTA et al., 2001). Ademais, o procedimento para seleção de pixels representativos de grandes talhões homogêneos de café foi cuidadosamente elaborado conforme detalhado no item 3.3.2.2.1. No entanto, a baixa resolução espacial dos dados Modis pode representar dificuldade em se obter pixels sem mistura espectral de diferentes padrões de lavouras.

As piores correlações ocorreram no ano de 2006 (variação nos índices de vegetação de 2006 vs variação na produtividade de 2007), com coeficientes de correlação de 0,29 para minEVI e 0,27 para minNDVI, respectivamente. Este fato está correlacionado a um déficit hídrico que ocorreu entre Abril e Outubro de 2006 (Rosa, 2007). Vários fatores influenciam a produtividade, mas o déficit hídrico é um dos mais importantes (CARR, 2001). De acordo com o balanço hídrico para a localidade de Guaxupé (Figura 4.4), observa-se também uma longa seca em 2007 que avançou durante 9 meses até meados de Novembro, que afetou o desenvolvimento da florada e, conseqüentemente, as relações entre a produtividade daquele ano e os índices de vegetação do ano anterior (2006), que também apresentou déficit hídrico num período prolongado, conforme detectado por Rosa (2007). Para a análise entre a produtividade e os índices de vegetação do mesmo ano, a seca contínua não parece ter afetado as correlações porque, neste caso, as relações podem ter sido baseadas em outros fatores como a ocorrência de doenças (BROWN et al, 1995) e danos mecânicos causados pela colheita (SILVA et al., 2010).

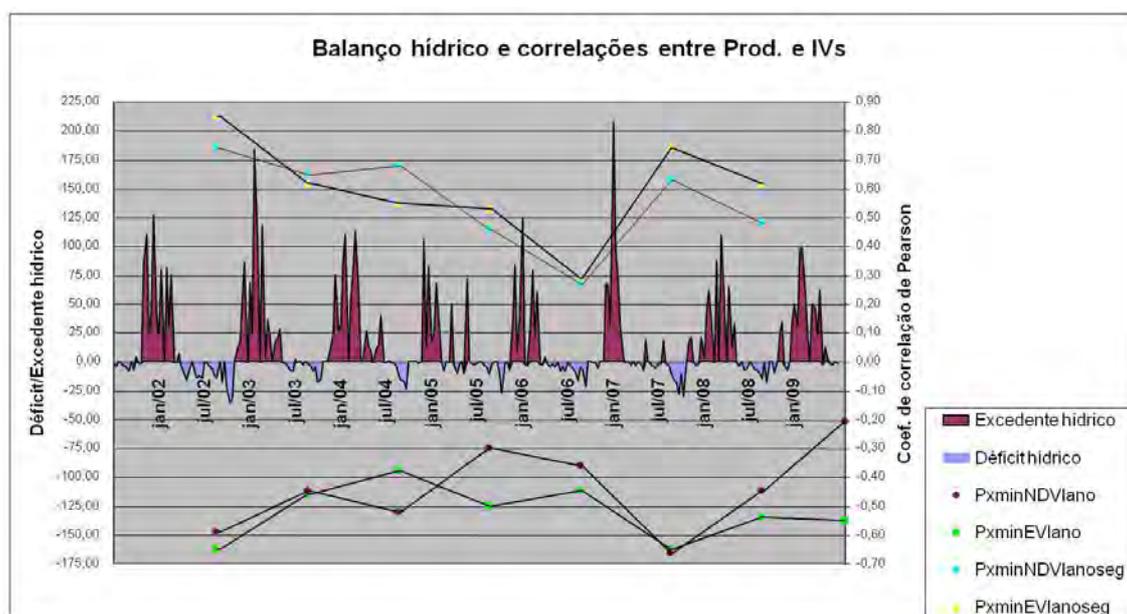


Figura 4.4 - Balanço hídrico para o município de Guaxupé e coeficientes de correlação de Pearson entre os anos de 2002 a 2009.

De maneira geral, os valores das correlações entre índices de vegetação e produtividade do ano seguinte foram inversos e maiores do que quando considerados os índices de vegetação e a produtividade do mesmo ano. Os sinais negativos indicam que em um mesmo ano, a produtividade afetou os índices de vegetação em virtude da maior incidência de doenças e maiores danos causados pela colheita (ambos promovem queda de folhas). Em anos consecutivos os índices de vegetação apresentaram correlação positiva com a produtividade, uma vez que os ramos formados em um ano são responsáveis pela produtividade do ano seguinte.

Os valores das correlações mostraram que os índices de vegetação não explicam exclusivamente a produtividade porque existem vários fatores contribuindo para a produtividade final, mas estes índices podem ser associados a dados meteorológicos para estimativas da produtividade ou serem usados como indicadores úteis da bienalidade da cultura.

As análises de correlação entre valores mínimos de índices de vegetação (NDVI e EVI) e produtividade do café apresentaram melhores resultados e, conseqüentemente, expressam melhor o efeito combinado de variações sazonais do clima e danos mecânicos causados pela colheita.

A despeito da baixa resolução espacial dos dados Modis e o fato de que a produtividade é um fenômeno complexo, porque depende de vários fatores, os índices de vegetação foram capazes de expressar tendências nas correlações entre fitomassa e a produtividade do cafeeiro.

As melhores correlações foram observadas com dados obtidos num período em que há disponibilidade de imagens de melhor resolução espacial livres de nuvens, indicando que os dados do TM/Landsat podem ser úteis nas estimativas da produtividade em associação com dados meteorológicos.

4.2. Correlações entre produtividade e dados obtidos de imagens do TM/Landsat

No caso das imagens do TM/Landsat, devido à sua resolução espacial permitir uma distinção apropriada das lavouras de café, o objetivo foi obter modelos mais robustos, empregando o máximo de observações de campo possível, para, então, serem utilizados posteriormente em conjunto com os dados meteorológicos na estimativa final da produtividade. Os modelos são passíveis de aplicação em toda área mapeada de café na região, pois o mapa base foi derivado das mesmas imagens.

4.2.1. Modelos fundamentados em variáveis espectrais e variáveis biofísicas (parâmetros culturais)

Os modelos gerais (que utilizam dados das cultivares Mundo Novo e Catuaí juntas) com maior poder explicativo da variável dependente – produtividade – resultaram de combinações de variáveis espectrais (Índices de vegetação) e variáveis biofísicas (parâmetros culturais).

Nesta pesquisa foram obtidos 3 modelos e as variáveis biofísicas incluídas nestes modelos foram: idade das lavouras e densidade de plantio, que são variáveis importantes na produtividade do cafeeiro. Estas variáveis foram utilizadas isoladamente ou em combinação com alguma outra variável. No modelo 1, a idade das lavouras e a densidade de plantio foram combinadas com os índices de vegetação NDVI e EVI (Tabela 4.3). Nos modelos 2 e 3 foi considerada como variável apenas a densidade de plantio das cultivares Catuaí e Mundo Novo respectivamente (Tabelas 4.4 e 4.5). A idade, mesmo considerando apenas o período produtivo, influencia a produtividade à medida que aumenta a sensibilidade ao déficit hídrico da cultura (Arruda et al., 2003), ou seja, a produção do cafeeiro se torna mais sensível à redução da ETr ao longo dos anos. Carvalho et al. (2010) encontraram correlações positivas entre produtividade e características de crescimento das plantas, as quais estão associadas à idade. A influência da densidade de plantio sobre a produtividade do cafeeiro também é relatada em diversos estudos (TOLEDO e BARROS, 1999; BRACCINI et al., 2002, 2005; PAULO et al., 2005; AUGUSTO et al., 2006; CARVALHO et al., 2006; BRAGANÇA et al., 2009; PEREIRA et al., 2011) e pode ser facilmente deduzida uma vez que maior número de plantas por área resulta em maior produção por área.

Tabela 4.3 - Variáveis e resultados do teste estatístico (Parâmetro estimado, Erro padrão, valor F e valor p) obtidos a partir do modelo 1 aplicado quando combinou-se idade da lavoura e densidade de plantio com os índices de vegetação NDVI e EVI (r=0,71)

Variável	Estimativa do parâmetro	Erro padrão	F	Valor p
Intercepto	488,55025	87,60943	31,10	<,0001
IdaDens	-0,00006434	0,00002522	6,51	0,0112
IdaNDVI_mo	-0,91017	0,15946	32,58	<,0001
IdaEVI_aa_mo	1,90415	0,26171	52,94	<,0001
DifNDVI	-651,91877	86,73368	56,50	<,0001
DifNDVI2	228,11537	45,20479	25,46	<,0001
SqDifNDVI	7,41086	3,99505	3,44	0,0646
DifSqNDVI	1630,06251	240,82246	45,82	<,0001
SqRNDVI	-485,27744	87,43859	30,80	<,0001
EVI2	-9,46029	4,08083	5,37	0,0211
DifEVI_mo2	60,90663	19,90687	9,36	0,0024

IdaDens - idade*densidade; IdaNDVI_mo - idade*NDVI moda; IdaEVIaa_mo - idade*EVI moda do ano anterior; DifNDVI - diferença entre NDVI média de 2 anos consecutivos; DifNDVI2 - diferença entre NDVI média de 2 anos consecutivos ao quadrado; SqDifNDVI - Soma dos quadrados da diferença do EVI de 2 anos consecutivos; DifSqNDVI - Diferença da soma dos quadrados de NDVI de 2 anos consecutivos; SqRNDVI - soma dos quadrados da razão de NDVI de 2 anos consecutivos; EVI2 - EVI ao quadrado; DifEVI_mo2 - diferença entre EVI moda de 2 anos consecutivos ao quadrado;

Tabela 4.4 - Variáveis e resultados do teste estatístico (Parâmetro estimado, Erro padrão, valor F e valor p) obtidos para os resultados do modelo 2, aplicado somente com a densidade de plantio ($r=0,67$)

Variável	Parâmetros estimados	Erro padrão	F	Valor p
Intercepto	964,24295	360,64284	7,15	0,0079
densidade	-0,00097545	0,00035388	7,60	0,0062
NDVI	-965,87591	362,10443	7,12	0,0081
NDVI2	209,84051	115,01401	3,33	0,0691
SqNDVI	1129,34264	347,31423	10,57	0,0013
NDVI_mo2	-520,27514	168,34971	9,55	0,0022
NDVI_mo_aa	2172,79240	651,00147	11,14	0,0010
SqNDVI_mo_aa	-2431,21438	699,41456	12,08	0,0006
DifNDVI_mo2	241,38016	45,10174	28,64	<,0001
Dif2NDVI_mo	426,39407	156,12945	7,46	0,0067
DifSqNDVI_mo	898,60119	193,67669	21,53	<,0001
SqRNDVI_mo	-578,20448	128,83757	20,14	<,0001
DifEVI	-5,81200	3,35742	3,00	0,0845
SqEVI_mo_aa	23,15649	12,60071	3,38	0,0671
DifEVI_mo2	53,50799	19,01838	7,92	0,0052
SqdifEVI_mo	11,22698	3,80104	8,72	0,0034
Dif2EVI_mo	-45,93923	13,77327	11,12	0,0010

NDVI - Normalized Difference Vegetation Index; NDVI2 - NDVI ao quadrado; SqNDVI - Soma dos quadrados do NDVI; NDVI_mo2 - NDVI moda ao quadrado; NDVI_mo_aa - NDVI do ano anterior moda; SqNDVI_mo_aa - Soma dos quadrados do NDVI moda ano anterior; DifNDVI_mo2 - Diferença entre NDVI maioria ao quadrado; dif2NDVI_mo - Diferença ao quadrado do NDVI maioria; DifDqNDVI_mo - Diferença da soma dos quadrados de NDVI moda; SqRNDVI_mo - Soma dos quadrados da razão do NDVI moda; DifEVI - Diferença do EVI; SqEVI_mo_aa - Soma dos quadrados do EVI moda ano anterior; DifEVI_mo2 - Diferença do EVI moda ao quadrado; SqDifEVI_mo - Soma dos quadrados da diferença do EVI moda; Dif2EVI_mo - Diferença ao quadrado do EVI moda;

Tabela 4.5 - Variáveis e resultados do teste estatístico (Parâmetro estimado, Erro padrão, valor F e valor p) obtidos para os resultados do modelo 3, aplicado somente com a densidade de plantio ($r=0,64$)

Variável	Estimativa do parâmetro	Erro padrão	F	Valor p
Intercepto	286,12605	64,81678	19,49	<,0001
Densidade	-0,0007194	0,00033585	4,59	0,0330
DifNDVI	-696,45143	77,71423	80,31	<,0001
DifNDVI2	324,58536	41,29511	61,78	<,0001
SqDifNDVI	14,95966	5,14884	8,44	0,0039
DifSqNDVI	1605,8073	222,36088	52,15	<,0001
RNDVI	-325,40307	82,23189	15,66	<,0001
RNDVI2	43,22902	18,36411	5,54	0,0192

DifNDVI - diferença entre NDVI média de 2 anos consecutivos; DifNDVI2 - diferença entre NDVI média de 2 anos consecutivos ao quadrado; SqDifNDVI - soma dos quadrados da diferença entre NDVI média de 2 anos consecutivos; DifSqNDVI - Diferença da soma dos quadrados de NDVI média ; RNDVI - razão entre NDVI média de 2 anos consecutivos; RNDVI2 - razão entre NDVI média de 2 anos consecutivos ao quadrado;

As variáveis espectrais selecionadas foram os índices de vegetação NDVI e EVI (média e moda dos valores circunscritos aos polígonos de café) do ano em que se estimou a produtividade ou do ano anterior e todas as suas combinações oferecidas no algoritmo de regressão *stepwise* (quadrado, diferença entre 2 anos, razão entre 2 anos, soma de quadrados), descritos nas Tabelas 4.3, 4.4 e 4.5. Conforme observado anteriormente com as imagens Modis os índices de vegetação exibem tendências de correlação com a produtividade embora não expliquem exclusivamente o fenômeno.

Embora as correlações demonstrem tendências na produtividade em função de índices de vegetação e variáveis biofísicas, os modelos gerais (que utilizam dados das duas cultivares juntas) explicam apenas 40 a 50 % da variação da produtividade resultante das lavouras. Tal fato pode ser explicado pela diversidade de fatores que compõem a produtividade da cultura, os quais não são todos incluídos no modelo, ou seja, limitações inerentes à complexidade da modelagem da produtividade em si (RESTREPO, et al., 2009).

Mesmo combinados com variáveis biofísicas medidas em campo, os modelos não explicam bem a produtividade ao ponto de serem utilizados exclusivamente para obter estimativas. Além disso, uma vez que variáveis biofísicas necessitam ser obtidas pontualmente para cada lavoura, não é possível estimar espacialmente a produtividade a partir destes modelos. A Tabela 4.6 apresenta o tamanho das amostras, número de variáveis testadas e os parâmetros estatísticos para os 3 melhores modelos gerais.

Tabela 4.6 – Tamanho das amostras, número de variáveis por modelo, valor F, valor p, coeficiente de correlação (r) e coeficiente de determinação (R²) obtidos para os 3 modelos gerais que apresentaram as melhores correlações.

Modelo	Tamanho da Amostra	Variáveis	F	Valor p	r	R ²
1	308	10	30.54	<.0001	0,71	0,50
2	308	16	15.90	<.0001	0,67	0,46
3	308	7	30.58	<.0001	0,64	0,41

Em virtude dos baixos valores de correlação encontrados para os modelos gerais, fez-se uma avaliação dos modelos obtidos para as cultivares isoladamente, o que resultou em grande melhoria no caso da cultivar Catuaí, mas não para a cultivar Mundo Novo (Tabelas 4.7, 4.8 e 4.9). O modelo obtido para a cultivar Catuaí utilizou apenas variáveis derivadas dos índices de vegetação e o modelo para a cultivar Mundo Novo utilizou variáveis de índices de vegetação e a variável biofísica idade. Apesar dos melhores resultados obtidos para a cultivar Catuaí, não foi possível concluir que ela apresente melhor correlação entre produtividade e índices de vegetação do que a cultivar Mundo Novo, uma vez que o número de unidade amostrada é diferente.

Tabela 4.7 – Tamanho da amostra, Número de variáveis, valor F, valor p, r e R², obtidos para as cultivares Catuaí e Mundo Novo.

Modelo	Tamanho da Amostra	Número de Variáveis	F	Valor p	r	R ²
Catuaí	47	3	40,70	<.0001	0,85	0,73
Mundo Novo	179	4	31,72	<.0001	0,64	0,42

Tabela 4.8 – Variáveis utilizadas no modelo, valor dos parâmetros estimados, Erro padrão, valor F e valor p, obtidos para o cultivar Catuaí (r=0,85).

Variável	Estimativa do parâmetro	Erro padrão	F	Valor p
Intercepto	-868,03064	286,81626	9.16	0.0042
EVI_mo_aa	-5164,78515	1443,74720	12.80	0.0009
EVI_mo_aa2	2474,14240	581,12362	18.13	0.0001
SqEVI_mo_aa	4013,31488	1219,30722	10.83	0.0020

EVI_mo_aa - EVI moda do ano anterior; EVI_mo_aa2 - EVI moda do ano anterior ao quadrado; SqEVI_mo_aa - soma dos quadrados do EVI moda do ano anterior;

Tabela 4.9 - Variáveis utilizadas no modelo, valor dos parâmetros estimados, Erro padrão, valor F e valor p, obtidos para o cultivar Catuaí (r=0,64).

Variável	Estimativa do parâmetro	Erro padrão	F	Pr > F	Valor p
Intercepto	9,60622	3,52851	4002,51757	7,41	0,0071
Idade	-0,35604	0,17924	2130,70907	3,95	0,0486
SqDifEVI_mo	-26,70978	20,11528	952,13506	1,76	0,1860
Dif2EVI_mo	-302,4205	72,35589	9433,75867	17,47	<,0001
DifSqEVI_mo	174,29312	69,10120	3435,57440	6,36	0,0126

SqDifEVI_mo - soma de quadrados da diferença entre EVI moda de 2 anos consecutivos; Dif2EVI_mo - diferença ao quadrado do EVI moda de 2 anos consecutivos; DifSqEVI_mo - diferença da soma de quadrados do EVI moda de 2 anos consecutivos;

O fato da inclusão de variáveis biofísicas em conjunto com as variáveis espectrais nos modelos resultar em correlações com a produtividade confirma a influência destas variáveis na composição da produtividade.

4.2.2. Modelos fundamentados em variáveis espectrais

A inclusão das variáveis: densidade de plantio e idade das lavouras resultou em modelos gerais com maior poder explicativo da variável dependente.

Entretanto, não permitem obter estimativas da produtividade de maneira espacializada, uma vez que necessitam ser obtidas pontualmente para cada lavoura. Com o objetivo de obter a produtividade de forma espacializada foram avaliados, então, modelos que usaram, como variável independente, apenas os índices de vegetação.

A Tabela 4.10 apresenta os três modelos (Cat, MN e Cat+MN), o número de unidades amostrais utilizadas e de variáveis empregadas em cada modelo, parâmetros estatísticos obtidos com dados de todas as cultivares juntas (modelos gerais) e dados das cultivares Catuaí e Mundo Novo em separado. As Tabelas 4.11, 4.12 e 4.13 apresentam as variáveis e parâmetros estatísticos para os modelos obtidos para as cultivares Catuaí, Mundo Novo e as duas cultivares juntas. Estes modelos utilizando apenas variáveis espectrais apresentam menor número de variáveis independentes e correlações inferiores aos modelos incluindo as variáveis espectrais e variáveis biofísicas (Tabelas 4.3 e 4.7).

Tabela 4.10 - Parâmetros estatísticos obtidos para os melhores modelos utilizando dados das cultivares Catuaí e Mundo Novo e dados agregados de ambas as variedades (Catuaí e Mundo Novo)

Modelo	Tamanho da amostra	Número de variáveis	Valor F	Pr > F	r	R ²
Catuaí (Cat)	47	4	26.60	<.0001	0,84	0,71
Mundo Novo (MN)	179	3	24.77	<.0001	0,53	0,29
Cat + MN	308	4	30.96	<.0001	0,52	0,28

Quando avaliadas ambas as cultivares de café juntas (Cat + MN), as correlações foram menores que as observadas para as cultivares isoladamente. Observa-se que o Catuaí apresentou melhor correlação ($r=0,84$) e que 71% da produtividade foi explicada pelos valores dos índices de vegetação. Por outro lado a cultivar Mundo Novo apresentou uma correlação menor ($r=0,53$) e apenas 29% da produtividade foi explicada pelos valores dos índices de vegetação.

Nestes modelos as variáveis selecionadas referem-se à diferença ou razão entre índices de vegetação de 2 anos consecutivos ou ao índice de vegetação do ano anterior, as quais refletem a característica da bienalidade da produção. Estes resultados estão de acordo com os obtidos os índices de vegetação do de imagens Modis e estudos relacionando bienalidade da produção e fitomassa do cafeeiro (BRUNSELL et al., 2009; SILVA et al., 2010).

Tabela 4.11 – Variáveis, valores das estimativas dos parâmetros, erro padrão, valor t e valor p obtidos a partir do modelo aplicado para o cultivar Catuaí (r=0,84)

Variável	Estimativa do parâmetros	Erro padrão	t	Valor p
Intercepto	16.27718	17.90754	0.91	0.3686
LogNDVI	32.94207	11.06294	2.98	0.0048
RNDVI	27.36909	16.71203	1.64	0.1090
SqDifEVI	-39.2525	10.03345	-3.91	0.0003
Dif2EVI_mo	-84.2843	31.84300	-2.65	0.0114

LogNDVI - logaritmo do NDVI média; RNDVI - razão entre NDVI média de 2 anos consecutivos; SqDifEVI - soma dos quadrados da diferença entre EVI média de 2 anos consecutivos; Dif2EVI_mo - diferença ao quadrado do EVI moda de 2 anos consecutivos;

Tabela 4.12 - Variáveis, valores das estimativas dos parâmetros, Erro padrão, valor t e valor p obtidos a partir do modelo aplicado para o cultivar Mundo Novo (r=0,53)

Variável	Estimativa do Parâmetro	Erro padrão	t	Valor p
Intercepto	33,13735	1,25852	26.33	<.0001
Dif2EVI	-43,21947	11,01245	-3.92	0.0001
DifEVI_mo	161,80155	58,69922	2.76	0.0065
Dif2EVI_mo	-266,9368	76,78549	-3.48	0.0006

Dif2EVI - diferença ao quadrado do EVI média de 2 anos consecutivos; DifEVI_mo - diferença entre EVI moda de 2 anos consecutivos; Dif2EVI_mo - diferença ao quadrado do EVI moda de anos consecutivos;.

Tabela 4.13 - Variáveis, valores das estimativas dos parâmetros, erro padrão, valor t e valor p obtidos a partir do modelo aplicado para as duas variedades juntas ($r=0,52$)

Variavel	Estimativa do parâmetro	Erro padrão	Valor t	Valor p
Intercepto	9,10010	8,17456	1.11	0.2665
EVI2	-31,65130	11,42119	-2.77	0.0059
SqEVI_aa	46,21187	13,35190	3.46	0.0006
Dif2EVI_mo	-174,2893	29,81623	-5.85	<.0001
DifSqEVI_mo	118,36871	29,69437	3.99	<.0001

EVI2 - EVI ao quadrado; SqEVI_aa - soma dos quadrados do EVI média do ano anterior; Dif2EVI_mo - diferença ao quadrado do EVI moda de dois anos consecutivos; DifSqEVI_mo - diferença da soma dos quadrados do EVI moda de 2 anos consecutivos;

Os resultados novamente mostram que a produtividade é explicada parcialmente pelos índices de vegetação, que, por sua vez, estão relacionados com a área foliar das lavouras. É fato conhecido que a fitomassa constitui um dos principais fatores de produção das culturas, uma vez que quanto maior a fitomassa, maior a absorção de energia e maior é a produção de fotoassimilados para enchimento de grãos (RODRÍGUEZ et al., 2011). No entanto, outros fatores se somam para compor a produtividade, como, por exemplo, a ocorrência de pragas e doenças e, principalmente, a disponibilidade hídrica, não incluída até aqui. Ainda que a fitomassa seja apropriada, se ocorrer déficit hídrico significativo num período crítico, pode haver quebra da produtividade.

As correlações entre produtividade e índices de vegetação derivados de imagens Modis, conforme descrito no item anterior, foram claramente afetadas pela ocorrência de déficit hídrico prolongado em regiões produtoras de café no Sul/Sudoeste de Minas Gerais (BERNARDES et al., 2012). Não se objetivou aqui comparar o desempenho dos dados Modis aos dados TM/Landsat, uma vez que as especificidades de cada imagem conduziram a objetivos diferentes.

Assim, mesmo apresentando baixo poder explicativo da variação na produtividade, os modelos podem ser úteis para integrar aos dados meteorológicos na modelagem da produtividade do cafeeiro, suprimindo uma

lacuna em modelos agrometeorológicos, por exemplo, aquela deixada pela não consideração da produtividade do ano anterior (PICCINI et al., 1999; BERNARDES et al., 2012).

Tendo em vista que ainda não é possível realizar o mapeamento dos cafezais na região Sul/Sudoeste de Minas Gerais por cultivares, para que assim o modelo seja aplicado a cada uma delas, o modelo utilizando apenas variáveis espectrais com dados de ambas as cultivares (Catuaí e Mundo Novo), embora apresentasse o pior resultado nas correlações, foi empregado na estimativa da produtividade do ano anterior para toda a região correspondente à cena 219/75 do Landsat. Assim a Equação 4.1 foi selecionada para estimativa da produtividade do ano anterior a ser incluída no modelo final.

$$Y_{aa} = 9,1 - 31,65EVI^2 + 46,21SqEVI_{aa} - 174,28DifEVI_{mo} + 118,36DifSqEVI_{mo} \quad (4.1)$$

em que:

EVI² - EVI ao quadrado; SqEVI_{aa} - soma dos quadrados do EVI média do ano anterior; Dif²EVI_{mo} - diferença ao quadrado do EVI moda de dois anos consecutivos; DifSqEVI_{mo} - diferença da soma dos quadrados do EVI moda de 2 anos consecutivos;

4.3. Parametrização dos coeficientes de resposta

De posse das variáveis Produtividade potencial (Y_p), Produtividade do ano anterior (Y_{aa}) e Componentes meteorológicas (ET_r/ET_0), necessárias ao modelo final definido pela Equação 3.13, foram obtidos os coeficientes de resposta (K_y) de cada componente.

A parametrização foi obtida considerando as 4 diferentes sequências de períodos representativos das fases fenológicas do cafeeiro, conforme descritos na Tabela 3.2. Os modelos foram avaliados por meio de intervalos de confiança para os coeficientes e pelo coeficiente de determinação dos modelos (R^2).

Os coeficientes foram obtidos por regressão linear múltipla em que a Equação 3.13 é formulada com todos os parâmetros necessários em ambos os lados da igualdade – Produtividade observada (em lugar da produtividade estimada) e Produtividade potencial (Y_p), Produtividade do ano anterior (Y_{aa}) e Componentes meteorológicas (ET_r/ET_0). A regressão define então os coeficientes que otimizam a igualdade.

A Tabela 4.14 apresenta os coeficientes relativos à produtividade do ano anterior (K_{y_0}) e às variáveis de penalização hídrica (ky_i) para as 4 diferentes sequências de períodos consideradas e as estatísticas dos modelos (Tabela 3.2).

Tabela 4.14 - Valores de coeficientes de resposta da cultura à produtividade do ano anterior (ky_0) e à disponibilidade hídrica (ky_i) considerando as diferentes sequências de durações dos períodos da variável hídrica (Evapotranspiração relativa - ER/EP) e parâmetros estatísticos dos modelos.

		Sequência A	Sequência B	Sequência C	Sequência D
Coeficientes	Intercepto	0,0702	1,8926	1,5271	10,346
	ky_0	-0,5101	-0,5882	-0,5160	-0,5004
	ky_1	4,5968	-0,8516	-0,0845	-0,8553
	ky_2	-0,5514	-0,7205	-0,7592	0,3533
	ky_3	-0,5471	-0,5276	-0,3007	0,1067
	ky_4	-	-	-	-0,8244
Intervalo	Intercepto	-2.5109 2.6513	0.3314 3.4539	0.0671 2.9871	-1.0271 3.0963
	ky_0	-0.7633 - 0.2570	-0.8493 - 0.3270	-0.7810 - 0.2509	-0.8013 - 0.1995
	ky_1	-2.3573 11.5510	-3.9677 2.2646	-1.7711 1.6021	-4.7059 2.9953
	ky_2	-1.7205 0.6177	-1.9080 0.4670	-2.2330 0.7147	-1.1653 1.8720
	ky_3	-1.6760 0.5817	-1.4165 0.3613	-1.0353 0.4340	-0.9968 1.2102
	ky_4	-	-	-	-2.3575 0.7088
Estatísticas	R^2	0.3896	0.4178	0.3658	0.2646
	F	54.249	59.196	49.017	23.741
	p	0,0017	0,0011	0,0031	0,063
	Var erro	0,0673	0,0622	0,0699	0,0870

Em todas as sequências de períodos indicativos das fases fenológicas do cafeeiro, o coeficiente de resposta à produtividade do ano anterior foi o que apresentou maior valor em módulo, o que enfatiza a importância desta variável (produtividade do ano anterior) na produtividade do cafeeiro.

Conforme observado nos intervalos de confiança construídos, os coeficientes para esta variável foram estatisticamente diferentes de zero. Os resultados concordam com os obtidos por Carvalho et al. (2003) que encontraram valores similares com dados do município de Alfenas - MG.

Com relação aos parâmetros para as variáveis de penalização hídrica (ky_1 a ky_4) os coeficientes ky_1 e ky_4 apresentaram os maiores valores para as combinações A, B e D, o que indicou a maior importância da evapotranspiração relativa na fase entre Abril a Setembro (ky_1) que corresponde à indução e maturação das gemas florais (CAMARGO; CAMARGO, 2001). Para a combinação C, em que a fase representativa do Ky_1 se prolongou até o mês de Outubro, o coeficiente foi o menor dentre os três. O coeficiente ky_2 mostrou-se o segundo mais importante indicando a fase entre Setembro a Dezembro, correspondente ao florescimento e início da formação dos frutos como segunda mais importante na produtividade.

Embora estes dois coeficientes sejam reconhecidos como os mais importantes na produtividade do cafeeiro, sua ordem de importância difere aqui dos resultados normalmente observados em outros trabalhos (PICINI et al., 1999; CARVALHO et al., 2003).

O coeficiente ky_3 apresentou os menores valores indicando a pouca influência da deficiência hídrica neste período referente à pós-maturação dos frutos.

4.4. Estimativas de produtividade com o modelo final

De posse de todas as variáveis necessárias e dos coeficientes de resposta (ky) para as componentes espectral (Produtividade do ano anterior – Y_{aa}) e meteorológicas (Evapotranspiração relativa nas diferentes fases fenológicas do cafeeiro – E_{Tr}/E_{T_0}) foram obtidos a partir da Equação 3.13 os 4 modelos variando apenas os coeficientes de penalização. Os modelos são descritos nas Equações 4.2 a 4.5, que foram empregadas nas estimativas da produtividade das lavouras, conforme descrito no item 3.3.1:

$$Y_{estA} = Y_p \left[0,0702 - 0,5101 \left(\frac{Y_{aa}}{Y_p} \right) + 4,5968 \left(\frac{ET_r}{ET_o} \right) - 0,5514 \left(\frac{ET_r}{ET_o} \right) - 0,5471 \left(\frac{ET_r}{ET_o} \right) \right] \quad 4.2$$

$$Y_{estB} = Y_p \left[1,8926 - 0,5882 \left(\frac{Y_{aa}}{Y_p} \right) - 0,8516 \left(\frac{ET_r}{ET_o} \right) - 0,7205 \left(\frac{ET_r}{ET_o} \right) - 0,5276 \left(\frac{ET_r}{ET_o} \right) \right] \quad 4.3$$

$$Y_{estC} = Y_p \left[1,5271 - 0,5160 \left(\frac{Y_{aa}}{Y_p} \right) - 0,0845 \left(\frac{ET_r}{ET_o} \right) - 0,7592 \left(\frac{ET_r}{ET_o} \right) - 0,3007 \left(\frac{ET_r}{ET_o} \right) \right] \quad 4.4$$

$$Y_{estD} = Y_p \left[10,346 - 0,5004 \left(\frac{Y_{aa}}{Y_p} \right) - 0,8553 \left(\frac{ET_r}{ET_o} \right) + 0,3533 \left(\frac{ET_r}{ET_o} \right) + 0,1067 \left(\frac{ET_r}{ET_o} \right) - 0,8244 \left(\frac{ET_r}{ET_o} \right) \right] \quad 4.5$$

em que:

Y_{est} = Produtividade estimada para cada condição; Y_p = Produtividade potencial tomada como a máxima dentro da série; Y_{aa} = Produtividade do ano anterior (estimada a partir da equação 4.1); ET_r = Evapotranspiração real; ET_o = Evapotranspiração potencial; ET_r/ET_o = Evapotranspiração relativa.

4.4.1. Estimativa de produtividade por lavouras

A avaliação do modelo foi feita a partir de um conjunto de dados de 40 talhões de café entre os anos de 2006 a 2010, obtidos junto à Fazenda Ipanema localizada no município de Alfenas-MG. A produtividade de cada talhão foi comparada à produtividade estimada pelo modelo para os mesmos talhões. Procedeu-se à análise de regressão linear simples com avaliação do modelo pelos intervalos de confiança para o coeficiente de determinação (R^2), erro médio absoluto (EMA), erro médio quadrático (EMQ) (NETER et al., 1996) e pela concordância expressa pelo índice d_1 de Willmott et al. (1981) e índice d_2 (WILLMOTT et al., 1985). O índice d , com variação entre 0 e 1, indica o grau de exatidão entre valores estimados e observados, enquanto o coeficiente de determinação (R^2) indica a precisão do modelo, ou seja, quanto da variação da variável dependente é explicada por aquela das variáveis independentes.

Os resultados são apresentados na Tabela 4.15 para os modelos empregando diferentes combinações de agrupamento dos dados meteorológicos na parametrização dos coeficientes de penalização hídrica – Ky_i . Os gráficos de dispersão entre produtividade observada e estimada dos 4 modelos com diferentes coeficientes de penalização ky são apresentados nas Figuras 4.5 a 4.8.

Tabela 4.15 - Valores do coeficiente de determinação (R^2), Erro Médio Absoluto (EMA), Erro Médio Quadrático (EMQ), e índices de Willmott d_1 e d_2 , resultantes da regressão linear entre os dados de produtividade observados em campo e os dados estimados pelo modelo. (^a Limites do intervalo de confiança ($\alpha=0,01$) com valores estimados pelo *Bootstrap*)

Parâmetro estatístico	Sequência A		Sequência B		Sequência C		Sequência D	
	Inf	Sup	Inf	Sup	Inf	Sup	Inf	Sup
R^2	0,50	0,69	0,39	0,65	0,20	0,46	0,29	0,53
EMA	13,73	17,46	14,25	18,32	16,51	21,43	16,33	20,96
EMQ	18,51	23,15	19,34	24,12	22,61	28,66	22,06	28,11
d_1	0,45	0,53	0,40	0,48	0,36	0,42	0,38	0,44
d_2	0,59	0,70	0,52	0,62	0,41	0,49	0,43	0,50

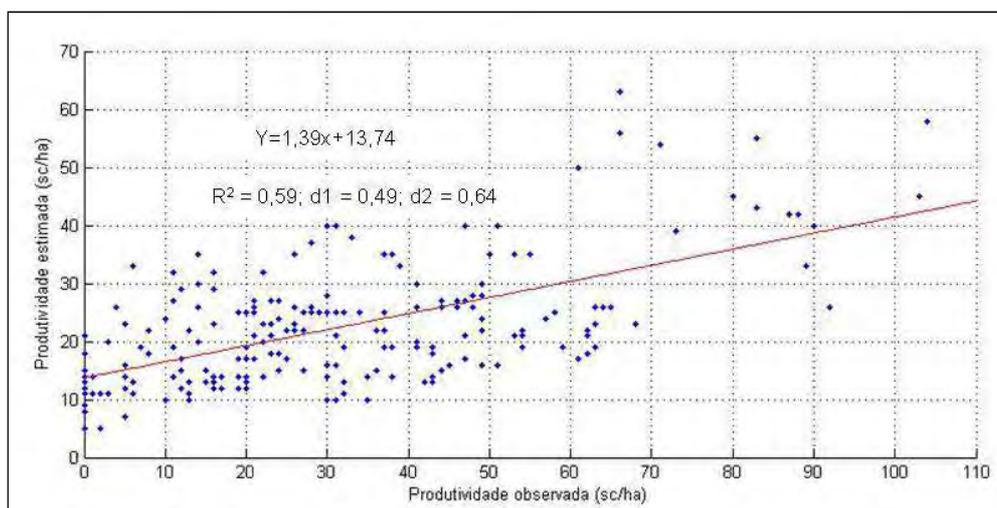


Figura 4.5 1

Figura 4.5 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo A

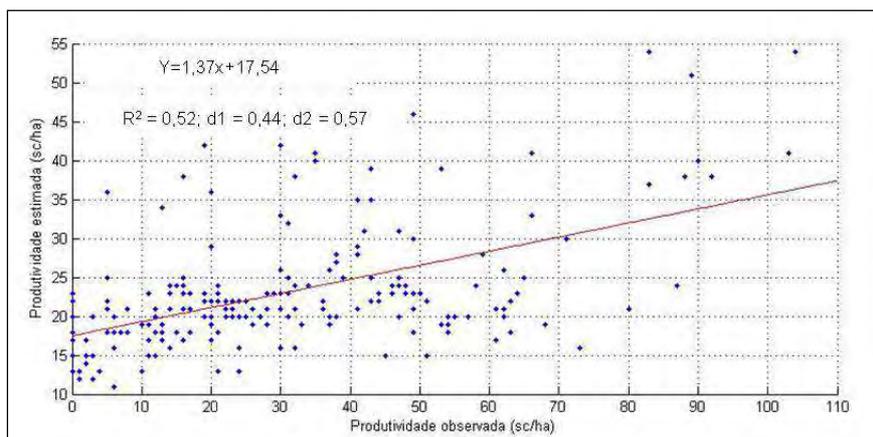


Figura 4.6 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo B

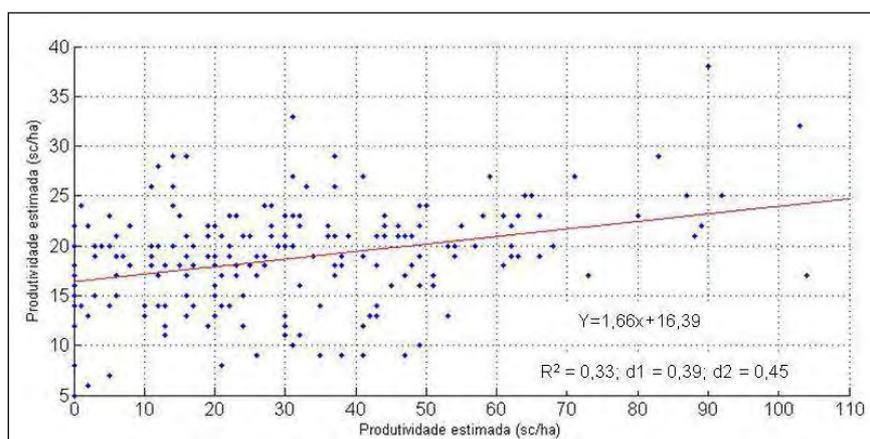


Figura 4.7 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo C

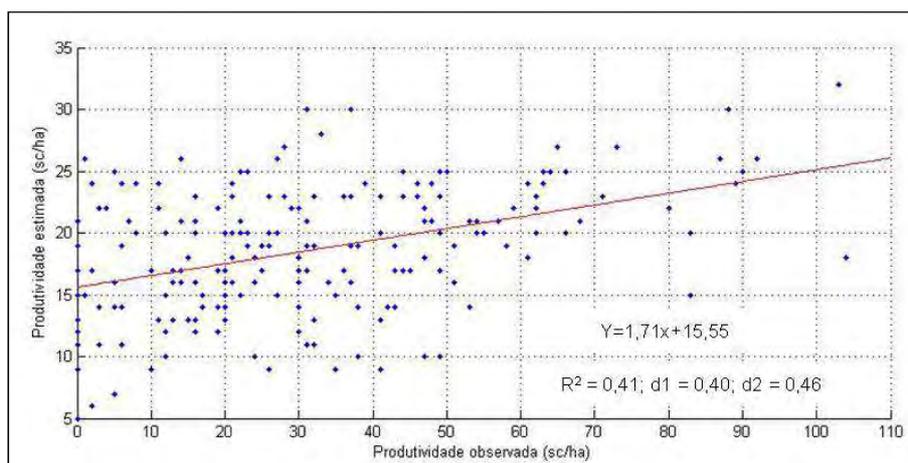


Figura 4.8 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo D

De maneira geral, as estimativas no âmbito de talhão foram ruins, com coeficientes de determinação (R^2) e índices Willmott (d_1 e d_2) baixos e erros (EMA e EMQ) altos para todas as condições de parametrização dos ky. Em diversos estudos empregando pontualmente modelos semelhantes ao empregado nesta pesquisa, os autores relatam desempenhos bastante superiores (PICINNI et al., 1999; GONZAGA et al., 2003; SANTOS et al., 2006). Há de se considerar, entretanto, as limitações inerentes às estimativas de dados meteorológicos espacializados e generalizar os parâmetros para cálculo da evapotranspiração relativa, quando comparados a medições pontuais (estações meteorológicas). Na maioria dos estudos em que foi empregado o modelo agrometeorológico na cultura do café, os dados utilizados foram medidos em estações meteorológicas nas proximidades dos objetos de estudo, ou seja, as lavouras nas quais as produtividades são estimadas.

Rosa (2007) em seu modelo agrometeorológico-espectral utilizou a variável espectral para obter a produtividade potencial da cultura e relata diminuição do desempenho das estimativas à medida que o modelo é aplicado em áreas menores com maior detalhamento. Uma provável explicação é exatamente a generalização dos dados meteorológicos como a resolução original dos dados ETA de 40 km, além das limitações inerentes ao modelo que gera essencialmente estimativa. Sugawara (2010), ao avaliar o potencial dos dados ETA em comparação com dados de estações meteorológicas, observou que o modelo superestima os valores de precipitação e apresenta também diferenças significativas entre os valores de temperatura máxima e mínima, comparado ao obtidos nas estações meteorológicas, sendo estas subestimadas. Tal fato se deve à grande variabilidade espacial das variáveis meteorológicas dentro de uma célula de 40 x 40 km. Entretanto, as possibilidades de evolução na modelagem de dados climáticos resultando em melhores estimativas podem contribuir para modelagem de estimativas da produtividade espacialmente distribuída.

Outra explicação para os resultados ruins é a fragilidade dos modelos empíricos derivados dos índices de vegetação. Os modelos empíricos empregados a partir de índices de vegetação derivados dos dados TM/Landsat para incorporar da variável espectral (estimativa da produtividade do ano anterior) também foram muito limitados (seção 4.1).

Ainda assim, a integração entre os dados espectrais e meteorológicos resultou em desempenho superior àqueles obtidos apenas com os dados de sensoriamento remoto, o que sugere um efeito positivo nesta integração. Conforme observado na Tabela 4.10 (seção 4.2), os coeficientes de determinação das regressões entre produtividade e índices de vegetação foram menores do que aqueles obtidos com o modelo final integrando os índices de vegetação e a evapotranspiração relativa (Tabela 4.15).

Para o modelo A os erros EMA e EMQ foram menores. Este modelo apresentou ainda os melhores intervalos de R^2 e índices d. Esta sequência de meses também foi relatada por Picini et al. (1999) como a de melhor desempenho nas estimativas da produtividade de café. Em termos estatísticos este modelo foi significativamente melhor quando comparado com os modelos C e D, uma vez que os intervalos de confiança para os índices d não se sobrepõem. Todavia, os erros obtidos (EMA e EMQ) pelo modelo construído sob a condição A não se diferem dos erros sob o modelo D, pois os intervalos se sobrepõem.

4.4.2. Estimativa da produção total por município

Para esta análise, à semelhança da análise realizada ao nível de lavouras, foram obtidos os parâmetros: coeficiente de determinação (R^2), erro médio absoluto (EMA), erro médio quadrático (EMQ) (NETER et al., 1996) e pela concordância expressa pelo índice d_1 de Willmott et al. (1981) e índice d_2 (WILLMOTT et al., 1985).

Foram somadas as produções de 50 municípios do Sul/Sudoeste de Minas Gerais que estavam totalmente contidos na área de abrangência da imagem Landsat (cena 219/75) entre os anos 2006 a 2010, o que totalizou 250 observações.

A Tabela 4.16 apresenta os parâmetros estatísticos dos 4 modelos obtidos com os diferentes coeficientes de penalização K_y . Os gráficos de dispersão entre produtividade observada e estimada pelos 4 modelos são apresentados nas Figuras 4.9 a 4.12.

Tabela 4.16 - Valores de coeficiente de determinação (R^2), Erro Médio Absoluto (EMA), Erro Médio Quadrático (EMQ), e índices de Willmott d_1 e d_2 , resultantes da regressão linear entre os dados de produção total por município e os dados estimados pelo modelo.

Parâmetro estatístico	Sequência A*		Sequência B		Sequência C		Sequência D	
	Inf	Sup	Inf	Sup	Inf	Sup	Inf	Sup
R^2	0,86	0,93	0,67	0,80	0,78	0,89	0,79	0,90
EMA	1607	2147	2740	3903	1903	2630	1786	2455
EMQ	2490	3526	4863	6904	3133	4309	2963	4179
d_1	0,78	0,83	0,65	0,74	0,73	0,80	0,75	0,81
d_2	0,92	0,96	0,77	0,88	0,87	0,93	0,89	0,94

^a Limites do intervalo de confiança ($\alpha=0,01$) com valores estimados pelo *Bootstrap*

Embora as estimativas ao nível de lavouras tenham apresentado baixo desempenho, ao nível de municípios os modelos se comportaram melhor. Os erros variaram entre 1.600 a 3.900 kg (EMA) e 2.490 a 6.904 kg (EMQ), o que equivale a 26 a 115 sacas por município. Os valores de R^2 e índices d também foram maiores, variando entre 0,67 a 0,93 para R^2 , 0,65 a 0,83 para o índice d_1 e 0,77 a 0,96 para o índice d_2 . Rosa (2007), ao avaliar o desempenho do modelo agrometeorológico-espectral em escala municipal, observou que em 50% dos municípios avaliados houve diferenças relativas de até 20% entre os dados estimados e os dados de referência do IBGE, no entanto as diferenças nas produtividades estimadas por município não foram estatisticamente

diferentes. Vale ressaltar que os resultados da Tabela 4.16 referem-se à produção total por município e não produtividade.

A conversão da produtividade, parâmetro estimado pelos modelos, em produção total por município contribuiu para as melhores correlações com os dados do IBGE, uma vez que a produção total incorpora a variável área nas estimativas. Tomando-se o mapa de áreas cafeeiras do ano de 2007 como referência e admitindo-se a sua exatidão, a área de café por município passa a ser um fator importante na produção total, incorporando a exatidão do mapa de áreas cafeeiras à qualidade das estimativas de produção total.

Isto sugere que mesmo utilizando-se o mapa de áreas cafeeiras relativo ao ano de 2007 para estimativas de produção total por município nos anos de 2006 e 2008 a 2010, as correlações permaneceram altas. Tal fato, se deve à característica perene da cultura do café e a pequena alteração no parque cafeeiro entre os anos. Moreira (2011) mostra que esta pequena alteração na área de café entre os anos permite um período de monitoramento de até 3 anos como satisfatório para mapeamento da cultura, ainda assim neste período a variação na área em café não passa de 6%.

Com relação aos diferentes modelos, ao variar os coeficientes de penalização K_y , o modelo A apresentou novamente o melhor desempenho. Ao analisar os intervalos das estatísticas, o modelo A foi melhor somente em relação ao modelo B visto que os intervalos não se sobrepõem.

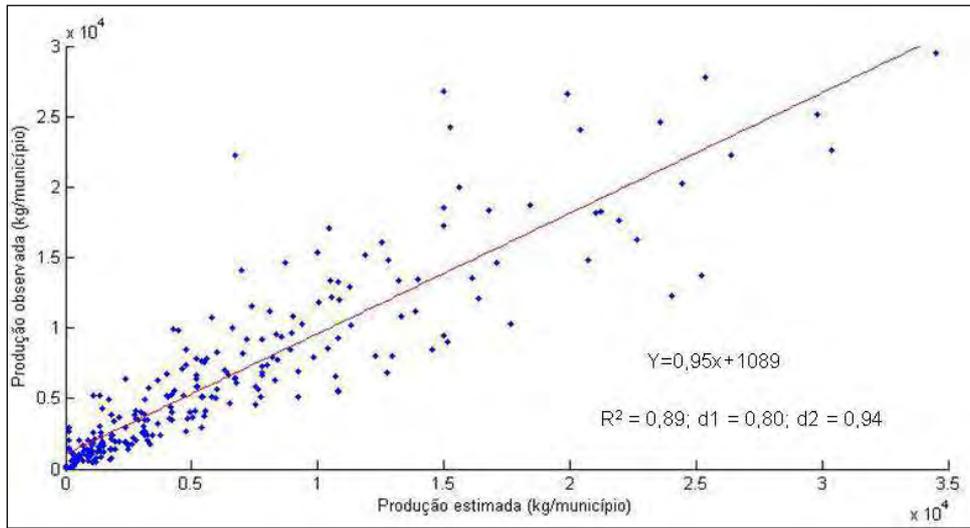


Figura 4.9 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo A

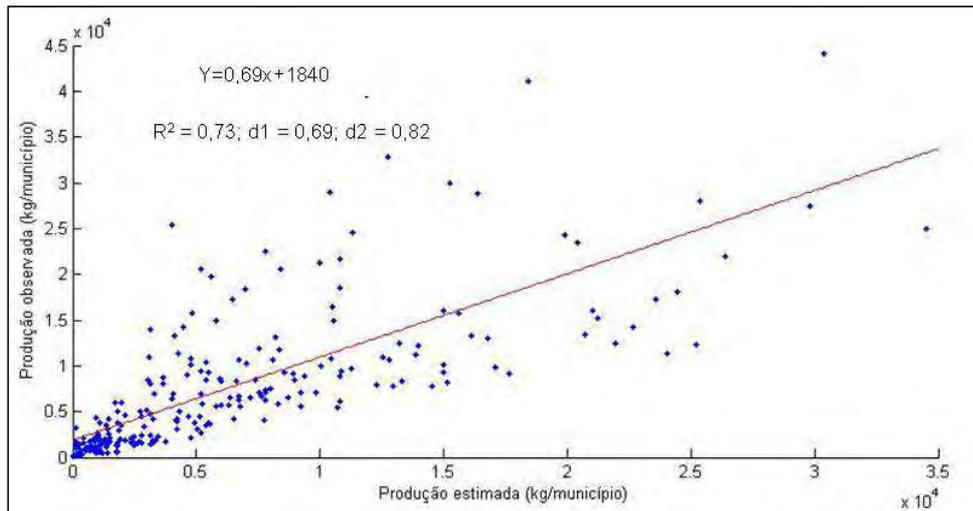


Figura 4.10 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo B

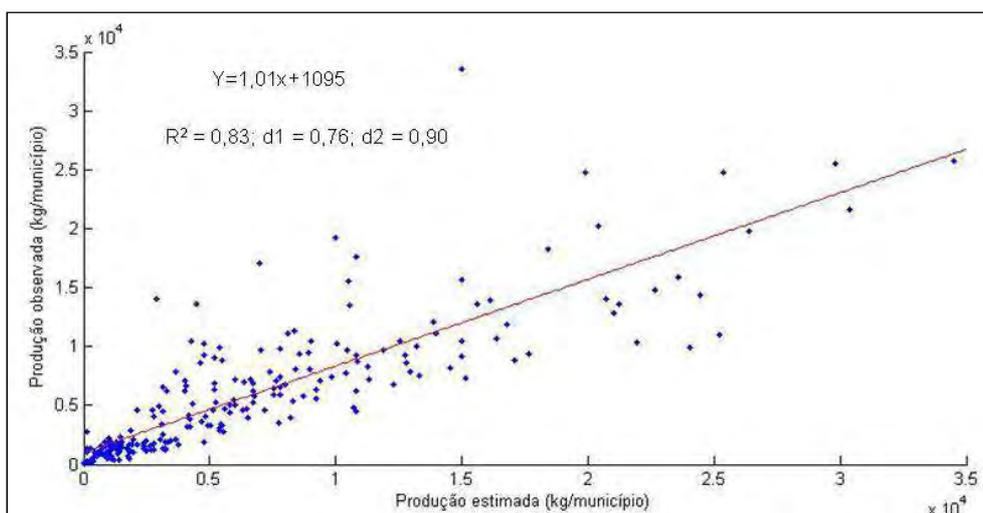


Figura 4.11 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo B

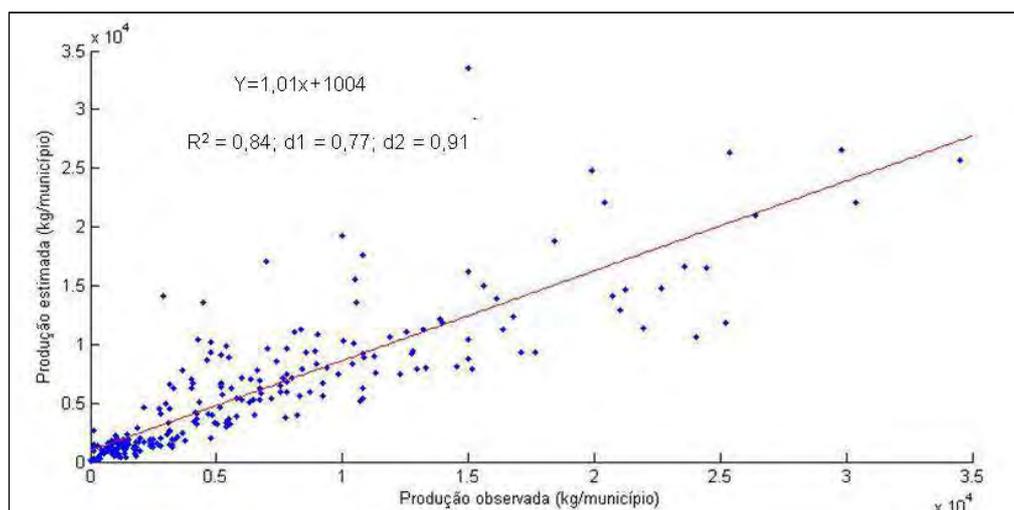


Figura 4.12 - Diagrama de dispersão entre produtividade observada e estimada utilizando o modelo C

4.4.3. Influência do mapa de áreas cafeeiras nas estimativas da produção através dos modelos para anos diferentes

A produção total por município é uma grandeza que depende não só da produtividade, mas também da área total plantada no município, a qual pode variar entre os anos. Nesta pesquisa foi utilizado apenas o mapa das áreas cafeeiras referente ao ano de 2007, como máscara, para obter a produtividade do café no período de 2006 a 2010. Assim, fez-se uma avaliação dos

resultados obtidos pelos modelos ano a ano com o intuito de observar se o desempenho seria pior à medida que se distanciasse do ano de 2007, ou seja, é necessário usar um mapa de café referente ao mesmo ano da estimativa da produtividade ou basta um mapa neste período. A Figura 4.13 apresenta os diagramas boxplot com os intervalos dos índices Willmott (d) e coeficientes de determinação (R^2) para cada ano nas estimativas da produção total por municípios.

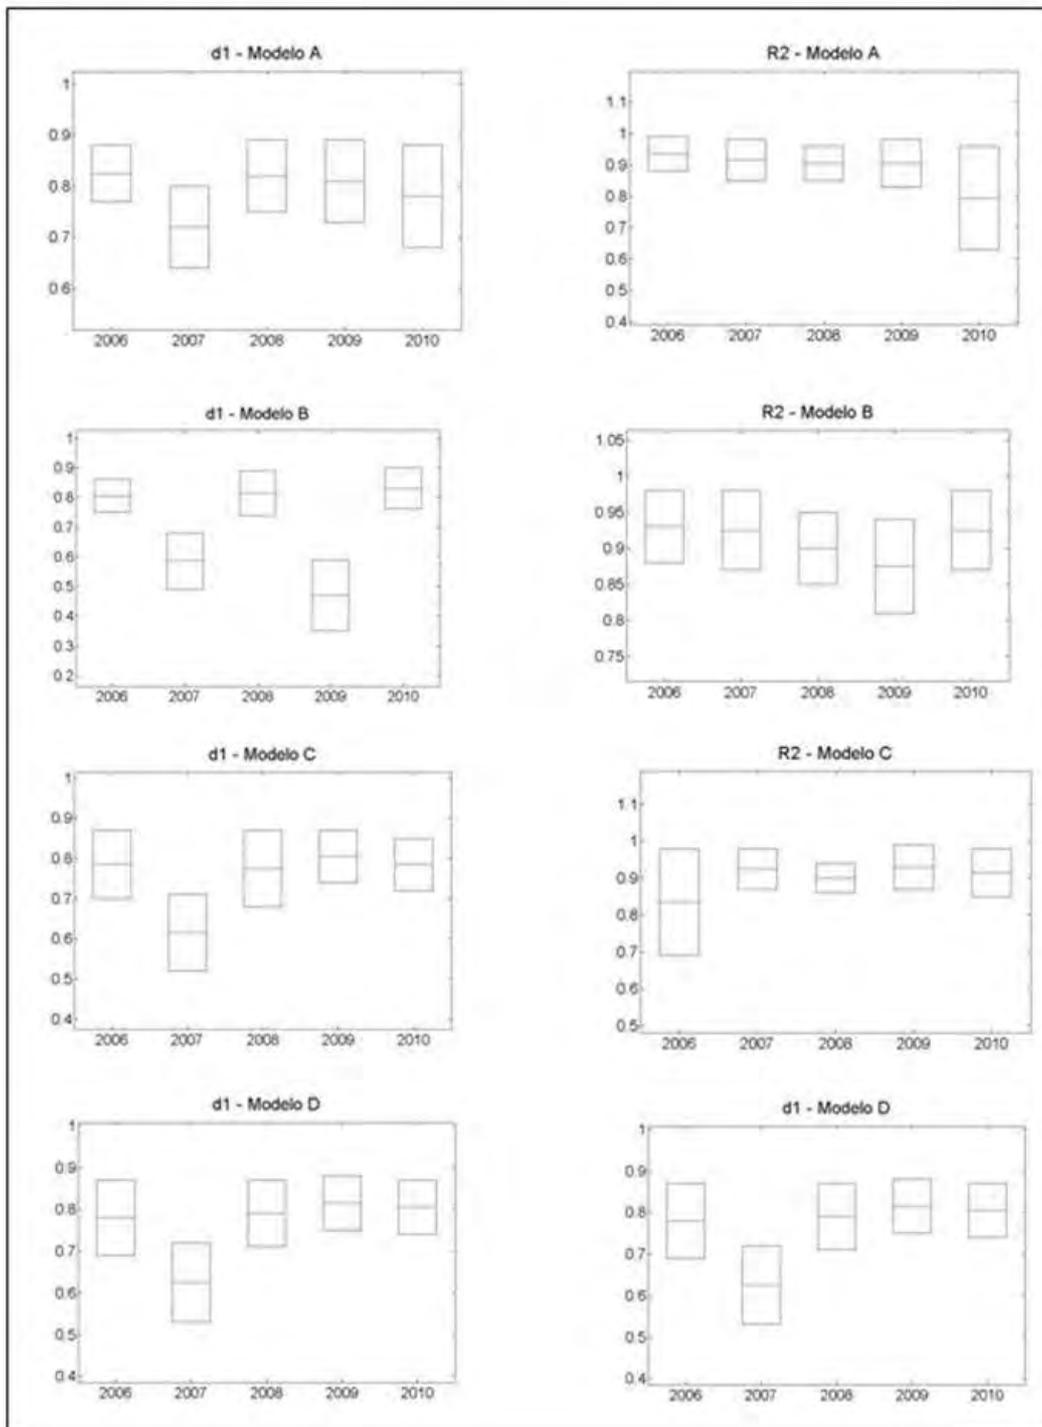


Figura 4.13 - Diagramas boxplot com os intervalos de confiança de índices Willmott (d) e coeficientes de determinação (R^2) ano a ano para cada modelo obtido – análise ao nível de município.

De maneira geral não há diferença no desempenho das estimativas nos diferentes anos avaliados uma vez que os intervalos obtidos para os índices Willmott e coeficientes de determinação se sobrepõem. À exceção do modelo B, os modelos se comportaram de forma similar para estimar a produção do café em todos os anos.

Ao analisar os índices Willmott, nota-se que, para os modelos C e D, as estimativas no ano de 2007 foram piores que o ano de 2008, o que não pode ser dito para os modelos A e B. Para o modelo A, o desempenho das estimativas foi estatisticamente semelhante em todos os anos, já que os intervalos definidos para os coeficientes de determinação e índices Willmott se sobrepõem. O modelo B apresentou desempenhos superiores nos anos de 2006, 2008 e 2010 e inferiores nos anos de 2007 e 2009.

Com relação aos coeficientes de determinação, não houve diferença nos desempenhos entre os anos para nenhum dos modelos, o que reforça a ideia de que, mesmo utilizando um mapa de áreas cafeeiras de apenas um ano para estimativas da produção total por municípios nos demais anos, dentro de uma série de cinco anos, as estimativas não foram afetadas.

5. CONCLUSÕES

As correlações entre a produtividade e os índices de vegetação obtidos a partir de dados das imagens Modis, embora muito baixas, expressaram as tendências na produtividade em função das variações nos índices de vegetação. As melhores correlações foram observadas em períodos nos quais houve disponibilidade de imagens de melhor resolução espacial livres de nuvens.

Os modelos gerais que empregaram variáveis de índices de vegetação derivados de imagens TM/Landsat e variáveis biofísicas explicaram melhor a variabilidade da produtividade do cafeeiro do que aqueles que consideraram apenas as variáveis de índices de vegetação.

Os modelos específicos obtidos para a variedade Catuaí apresentaram as melhores correlações com a produtividade, enquanto que o modelo para a variedade Mundo Novo não teve bom desempenho.

A parametrização dos coeficientes de penalização confirmou a grande influência da produtividade do ano anterior na produtividade do cafeeiro. Os coeficientes de resposta referentes à componente meteorológica indicaram que as fases de indução e maturação das gemas florais (ky_1) e florescimento e início da formação dos frutos (ky_2) foram as mais importantes na produtividade.

A integração de dados TM/Landsat ao modelo agrometeorológico de Doorenbos & Kassam resultou em estimativas espacializadas da produtividade do cafeeiro melhores do que aquelas obtidas com os dados TM/Landsat e Modis isoladamente.

No âmbito de lavouras as estimativas espacializadas da produtividade por meio da integração de dados TM/Landsat ao modelo agrometeorológico de Doorenbos e Kassam apresentaram coeficientes de determinação e índices Willmott baixos e erros altos, o que indica que o modelo não se mostrou

satisfatório. O modelo A, em que os coeficientes de penalização por déficit hídrico – ky_1 , ky_2 e ky_3 – referem-se aos trimestres Jun/Jul/Ago, Set/Out/Nov e Dez/Jan/Fev respectivamente, foi significativamente melhor que os modelos C e D.

Ao avaliar a produção total por municípios, os modelos apresentaram resultados melhores, sendo que o modelo A foi estatisticamente superior ao modelo B.

REFERÊNCIAS BIBLIOGRÁFICAS

ACOCK, B. & ACOCK, M. C. Potential for using long-term field research data to develop and validate crop simulators. **Agronomy Journal**, Madison, 83:56-61, 1991.

ALLEN, L. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration** - guidelines for computing crop water requirements. Rome: Food and Agriculture Organization of the United Nations, 1998. 300p. (FAO Irrigation and drainage paper 56).

ANDERSON, G. P.; PUKALL, B.; ALLRED, C. L.; JEONG, L. S.; HOKE, M.; CHETWYND, J. H.; ADLER-GOLDEN, S. M.; BERK, A.; BERNSTEIN, L. S.; RICHTSMEIER, S. C.; ACHARYA, P. K.; MATTHEW, M. W. FLAASH and MODTRAN4: state-of-the-art atmospheric correction for hyperspectral data. In: AEROSPACE CONFERENCE, 1999, Snowmass at Aspen, CO, USA. **Proceedings...** Snowmass at Aspen, CO: IEEE, 1999. v. 4, p.177-181.

ANDROCIOLI FILHO, A. F.; SIQUEIRA, R.; CARAMORI, P. H.; PAVAN, M. A.; SERA, T.; SODERHOLM, P. K. Frost injury and performance of coffee at 23° S in Brazil. **Experimental Agriculture**, v. 22, p. 71-74, 1986.

ATKINSON, P. M.; JEGANATHAN, C.; DASH, J.; ATZBERGER, C. Inter-comparison of four models for smoothing satellite sensor time-series data to estimate vegetation phenology. **Remote Sensing of Environment**, v. 123, n. 0, p. 400-417, 2012.

AUGUSTO, H. S.; MARTINEZ, H. E. P.; SAMPAIO, N. F.; CRUZ, C. D.; PEDROSA, A. W. Produtividade de cultivares de café (*Coffea arabica* L.) sob espaçamentos adensados. **Revista Ceres**, v.53, p.539-547, 2006.

AVELINO, J.; Zelaya, H.; Merlo, A.; Pineda, A.; Ordoñez, M.; Savary, S. The intensity of a coffee rust epidemic is dependent on production situations. **Ecological Modelling**, v. 197, n. 3-4, p. 431-447, 2006.

BAIER, W. Note on the terminology of crop-weather models. **Agricultural Meteorology**, v. 20, n. 2, p. 137-145, April. 1979.

BALAGHI, R.; TYCHON, B.; EERENS, H.; JLIBENE, M. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco. **International Journal of Applied Earth Observation and Geoinformation**. v. 10, 438–452, 2008.

BARROS, R.S.; MOTA, J.W.S.; DAMATTA, F.M.; MAESTRI, M. Decline of vegetative growth in *Coffea arabica* L. in relation to leaf temperature, water

potential and stomatal conductance. **Field Crops Research**, v. 54, p. 65–72, 1997.

BECKER-RESHEF, I.; VERMOTE, E.; LINDEMAN, M.; JUSTICE, C. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. **Remote Sensing of Environment**, 2010, v.114, p. 1312-1323.

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**, v. 4, n. 9, p. 2492-2509, 2012.

BERNARDES, T.; MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Diagnóstico ambiental da cafeicultura no Estado de Minas Gerais - Brasil. **Coffee Science**, v. 7, p. 139-151, 2012.

BIRKY, A. K. NDVI and a simple model of deciduous forest seasonal dynamics. **Ecological Modelling**. v. 143, p. 43-58, 2001.

BLACK, T. L. The New NMC Mesoscale Eta Model: description and forecast examples. **Weather and Forecasting**, v. 9, n. 2, p. 265-278, 1994/06/01 1994.

BOOGAARD, H.L.; VAN DIEPEN, C.A.; RÖTTER, R.P.; CABRERA, J.C.M.A. and VAN LAAR, H.H. **WOFOST 7.1** - user guide for the WOFOST 7.1 crop growth simulation model and WOFOST Control Center 5.1. Techn. Doc. 52, Alterra, WUR, Wageningen, The Netherlands, 1998. 144p.

BOUMAN, B. A. M.; KROPFF, M. J.; TUONG, T. P.; WOPEREIS, M. C. S.; TEN BERGE, H. F. M.; VAN LAAR, H. H. **ORYZA2000**: modeling lowland rice Los Baños (Philippines)/Wageningen: International Rice Research Institute/Wageningen University and Research Centre, , 2001. 235p. (ISBN 971-22-0171-6).

BOUMAN, B. A. M.; VAN KEULEN, H.; VAN LAAR, H. H.; Rabbinge, R. The 'School of de Wit' crop growth simulation models: A pedigree and historical overview. **Agricultural Systems**, v. 52, n. 2–3, p. 171-198, 1996.

BRACCINI, A. de L.; SCAPIM, C. A.; VIDIGAL FILHO, P.S.; BRACCINI, M. do C. L.; BORGES, S. C.; ALBRECHT, L. P. Características agronômicas e produção de frutos e grãos em resposta ao aumento na densidade populacional do cafeeiro. **Acta Scientiarum. Agronomy**, v.27, p.269-279, 2005.

BRACCINI, M. do C. L.; BRACCINI, A. de L.; SCAPIM, C. A.; VIDIGAL FILHO, P.S.; ZABINI, A.V. Produção de grãos, concentração e aproveitamento de

nutrientes em resposta ao aumento na densidade de plantio do cafeeiro. **Acta Scientiarum Agronomy**, v.24, p.1205-1211, 2002.

BRAGANÇA, S. M.; SILVA, E. B.; MARTINS, A. G.; SANTOS, L. P.; LANI, J. A.; VOLPI, P. S. Resposta ao cafeeiro conilon à adubação de NPK em sistema de plantio adensado. **Coffee Science**, v.4, p.67-75, 2009.

BROWN, J. S.; WHAN, J. H.; KENNY, M. K.; MERRIMAN, P. R. The effect of coffee leaf rust on foliation and yield of coffee in Papua New Guinea. **Crop Protection**, v.14, n. 7, p. 589-592, 1995.

BRUNSELL, N. A., PONTES, P. P. B. AND LAMPARELLI, R. A. C. Remotely sensed phenology of coffee and its relationship to yield. **GIScience and Remote Sensing**, v.46, n.3, p. 289-304, 2009.

CÂMARA, G.; SOUZA, R.C.M.; FREITAS, U.M.; GARRIDO, J.C.P. SPRING: Integrating remote sensing and GIS with object-oriented data modelling. **Computers and Graphics**, v.15, p.13-22, 1996.

CAMARGO, A. P. O clima e a cafeicultura no Brasil. **Informe Agropecuário**. v. 11, p. 13-26, 1985.

CAMARGO, A. P. Balanço hídrico, florescimento e necessidade de água para o cafeeiro. In: SIMPÓSIO SOBRE O MANEJO DE ÁGUA NA AGRICULTURA, 1987. Campinas, **Anais...**, Campinas: Fundação Cargill, p. 53-90, 1987.

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

CAMARGO, A. P.; PEREIRA, A. R. **Agrometeorology of the coffee crop**. Geneva: World Meteorological Organization. WMO/TD. n. 615, 43p. 1994.

CAMARGO, M. B. P. de. Modelo agrometeorológico de estimativa de produtividade para o cultivar de laranja valência. **Bragantia**, Campinas, v. 58, n. 1, p. 171-178, 1999.

CAMARGO, M. B. P.; SANTOS, M. A.; PEDRO JUNIOR, M. J.; FAHL, J. I.; BRUNINI, O.; MEIRELES, E. J. L.; BARDIN, L. Modelo agrometeorológico de monitoramento e de estimativa de quebra de produtividade como subsidio à previsão de safra de café (*Coffea arabica* L.): resultados preliminares. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 3., 2003. Porto Seguro. **Anais...** Porto Seguro: Consórcio Brasileiro de Pesquisa e Desenvolvimento do Café, p. 75-76, 2003.

CANTY, M. J.; NIELSEN, A. A. Automatic radiometric normalization of multitemporal satellite imagery with the iteratively re-weighted MAD transformation. **Remote Sensing of Environment**, v. 112, n. 3, p. 1025-1036, 2008

CANTY, M. J.; NIELSEN, A. A.; SCHMIDT, M. Automatic radiometric normalization of multitemporal satellite imagery. **Remote Sensing of Environment**, v. 91, n. 3-4, p. 441-451, 2004.

CARVALHO, L. G.; SEDIYAMA, G. C.; CECON, P. R. e ALVES, H. M. R. Avaliação de um modelo agrometeorológico para a previsão de produtividade de café em três localidades da Região Sul do Estado de Minas Gerais. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 11, n. 2, p. 343-352, 2003.

CARVALHO, G. R.; MENDES, A. N. G.; BARTHOLO, G. F.; NOGUEIRA, A. M.; AMARAL, M. A. Avaliação de produtividade de progênies de cafeeiro em dois sistemas de plantio. **Ciência e Agrotecnologia**, v.30, p.838-843, 2006.

CARVALHO, A. M. D.; MENDES, A. N. G.; CARVALHO, G. R.; BOTELHO, C. E.; GONÇALVES, F. M. A.; FERREIRA, A. D. Correlação entre crescimento e produtividade de cultivares de café em diferentes regiões de Minas Gerais, Brasil. **Pesquisa Agropecuária Brasileira**, v. 45, p. 269-275, 2010.

CARR, M. K. V. The water relations and irrigation requirements of coffee. **Experimental Agriculture**, v. 37, n. 1, p. 1-36, 2001.

CHALFOUN, S. M. Relações de diferentes índices de infecção de ferrugem sobre a produção de cafeeiro em algumas localidades do estado de Minas Gerais. **Fitopatologia Brasileira**, v. 6, p. 137-142, 1981.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, v.113, n.5, p.893-903, 2009.

CHOUDHURY, B. J.; AHMED, N. U.; IDSO, S. B.; REGINATO, R. J.; DAUGHTRY, C. S. T. Relations between evaporation coefficients and vegetation indices studied by model simulations. **Remote Sensing of Environment**, v. 50, n. 1, p. 1-17, 1994.

COSTA, M. J. N.; ZAMBOLIM, L.; RODRIGUES, F. A. Efeito de níveis de desbaste de frutos do cafeeiro na incidência da ferrugem, no teor de nutrientes, carboidratos e açúcares redutores. **Fitopatologia Brasileira**, v. 31, p. 564-571, 2006.

COSTE, R. **Coffee: the plant and the product**. London: MacMillan, 1992.

CURRAN, P.J.; DUNGAN, J.L.; MACLER, B.A.; PLUMMER, S.E. and PETERSON, D.L. Reflectance spectroscopy of fresh whole leaves for the estimation of chemical concentration. **Remote Sensing of Environment**, v. 39, 153–166, 1992.

DAMATTA, F. M.; RAMALHO, J. D. C. Impacts of drought and temperature stress on coffee physiology and production: a review. **Brazilian Journal of Plant Physiology**, v.18, n.1, p.55-81, 2006.

DAMATTA F. M.; RENA, A. B. Tolerância do café à seca. In: ZAMBOLIN, L. (Ed.). **Tecnologias de produção de café com qualidade**, Viçosa: Universidade Federal de Viçosa. p.65-100, 2001.

DAMATTA, F. M.; RONCHI, C. P.; MAESTRI, M.; BARROS, R. S. Ecophysiology of coffee growth and production. **Brazilian Journal of Plant Physiology**, v. 19, n. 4, p. 485-510, 2007.

DARVISHZADEH, R.; SKIDMORE, A.; SCHLERF, M. and ATZBERGER, C. Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in a heterogeneous grassland. **Remote Sensing of Environment**, v. 112, p. 2592–2604, 2008.

DAUGHTRY, C.S.T.; WALTHALL, C.L.; KIM, M.S.; BROWN DE COLSTOUN, E.; MCMURTREY III, J.E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**. v. 74 , p. 229-39, 2000.

DELALIEUX, S.; SOMERS, B.; HEREIJGERS, S.; VERSTRAETEN, W. W.; KEULEMANS, W. and COPPIN, P. A near infrared narrow-waveband ratio to determine Leaf Area Index in orchards. **Remote Sensing of Environment**. v. 112, p. 3762-3772, 2008.

DE WIT, C.T. **Transpiration and crop yields**. Wageningen: Institute of Biological and Chemical Research on Field Crop and Herbage, 1958.

DOORENBOS, J. & KASSAM, A. H. **Yield response to water**. Rome, FAO, 1979. 197p. (FAO Irrigation and Drainage Paper, 33)

DU, Y.; TEILLET, P. M.; CIHLAR, J. Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection. **Remote Sensing of Environment**, v. 82, n. 1, p. 123-134, 2002.

EFRON, B. **The Jackknife, the bootstrap, and the other resampling plans**. Philadelphia Society of Industrial Mathematics, 1982. 92p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Sistema brasileiro de classificação de solos**. Brasília: Embrapa Produção de Informação, 1999. 412 p.

EMBRAPA CAFÉ. **Histórico**. 2009. Disponível em: <<http://www22.sede.embrapa.br/cafe/unidade/historico.htm>>. Acesso em: 4 maio 2009

ESKES, A. B.; CARVALHO, A. Variation for incomplete resistance to *Hemileia vastatrix* in *Coffea arabica*. **Euphytica**, v. 32, p. 625-637, 1983.

FARGE, M. Wavelet transforms and their applications to turbulence. **Annual Review of Fluid Mechanics**, v.24, n.1, p.395-458. 1992.

FARIAS, J. R. B.; NEPOMUCENO, A. F.; NEUMAIER, N.; OYA, T. Ecofisiologia. In: EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **A cultura da soja no Brasil**. [CD-ROM]. Londrina: Embrapa Soja, 2000.

FAGERIA, N. K., 1992. **Maximizing crop yields**. New York:Marcel Dekker.

FASSIO, L. H.; SILVA, A. E. S. Importância econômica e social do café conilon. In: FERRÃO, R. G.; FONSECA, A. F. A.; BRAGANÇA, S. M.; FERRÃO, M. A. G.; DE MUNER, L. H. (eds), **Café Conilon**. Vitória: . Seag/Incaper, 2007. p.37-49.

FONTANA, D. C.; BERLATO, M. A.; LAUSCHNER, M. L. e WANKE, R. de M. Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v. 36, n. 3, p. 399-403, mar. 2001.

FOURTY, T.; BARET, F.; JACQUEMOUD, S.; SCHMUCK, G. e VERDEBOUT, J. Leaf optical properties with explicit description of its biochemical composition: direct and inverse problems. **Remote Sensing of Environment**, v. 56, n. 2, 104–117, 1996.

FRANCO, C. M. & INFORZATO, R. O sistema radicular do cafeeiro nos principais tipos de solos do Estado de São Paulo. **Bragantia**. Campinas, n.6, n.9, p.443-478, 1946.

FREITAS, R. M.; ARAÍ, E.; ADAMI, M.; SOUZA, A. F.; SATO, F. Y.; SHIMABUKURO, Y. E.; ROSA, R. R.; ANDERSON, L. O.; RUDORFF, B. F. T. Virtual laboratory of remote sensing time series: visualization of MODIS EVI2 data set over South America. **Journal of Computational Interdisciplinary Sciences**, v.2, n.1, p.57-68. 2011.

FREITAS, R. M. & SHIMABUKURO, Y. E. Combining wavelets and linear spectral mixture model for MODIS satellite sensor time-series analysis. **Journal of Computational Interdisciplinary Sciences**, v.1, n.1, p.51-56. 2008.

FRÈRE, M.; POPOV, G. F. **Prognóstico de cosechas basado en datos agrometeorológicos**. Roma: Organización de las Naciones Unidas para la Agricultura y la Alimentación, 1980. 66p. (FAO - Producción y Protección Vegetal Cuaderno Técnico n. 17).

FUNK, C. & BUDDE, M. E. Phenologically-tuned MODIS NDVI-based production anomaly estimates for Zimbabwe. **Remote Sensing of Environment**, v.113, n. 1, p.115-125, 2009.

FURBY, S. L. & CAMPBELL, N. A. Calibrating images from different dates to like-valuecounts. **Remote Sensing of Environment**, v. 77, p. 186-196, 2001.

GAO, B. NDWI – a normalized difference water index for remote sensing of vegetation water from space. **Remote Sensing of Environment**, v. 58, p. 257-266, 1996.

GALFORD, G. L.; Mustard, J. F.; Melillo, J.; Gendrin, A.; Cerri, C. C.; Cerri, C. E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, v. 112, n. 2, p. 576-587, 2008.

GATES, D. M.; KEEGAN, H. J.; SCHLETER, J. C. and WIEDNER, V. R. Spectral properties of plants. **Applied Optics**, v. 4, p. 11–20, 1965.

GEOMINAS PRODEMGE - Companhia de Tecnologia da Informação do Estado de Minas Gerais, 1996. **Mapas/downloads**. Disponível em: <<http://www.geominas.mg.gov.br>>. Acesso em: 4 Ago 2009.

GITELSON, A. A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **Journal of plant physiology**, v. 161, p. 165-573, 2004.

GOMES, A. A. G. & VARRIALE, M. C. **Modelagem de ecossistemas: uma introdução**. Santa Maria, UFSM, 2001. 503p.

GUERRA, A. F.; ROCHA, O. C.; RODRIGUES, G. C.; SANZONOWICZ, C. Manejo da irrigação do cafeeiro, com estresse hídrico controlado, para uniformização de florada. In: ZAMBOLIM, L. (ed). **Boas práticas agrícolas na produção de café**, Viçosa: Universidade Federal de Viçosa, 2006. p.83-116.

GUTMAN, G. G. Vegetaion indices from AVHRR: An update and future prospects. **Remote Sensing of Environment**, v. 35, n.2-3, p.121-136. 1991.

- HAARER, A. E. **Modern coffee production**. London: Leonard Hill, 1958.
- HABEKOTTÉ, B. **Winter oilseed rape**; analysis of yield formation and crop type design for higher yield potential. 1996, 156p. PhD Thesis, Wageningen University, The Netherlands, 1996. ISBN 90-5485-514-2.
- HABEKOTTÉ, B. **Description, parameterization and user guide of LINTUL-BRASNAP 1.1**; a crop growth model of winter oilseed rape (*Brassica napus* L.). Quantitative Approaches in Systems Analysis, no 9, C.T. de Wit Graduate School for Production Ecology and Resource Conservation. The Netherlands: Wageningen University, 1997, 40p.
- HALL, F. G., STREBEL, D. E., NICKESON, J. E., GOETZ, S. J. Radiometric rectification: toward a common radiometric response among multitemporal, multisensor images. **Remote Sensing of Environment**. v. 35, p. 11-27, 1991.
- HANSEN, J. W. & JONES, J. W. Scaling-up crop models for climate variability applications. **Agricultural Systems**. v. 65, n.1, p. 43–72, 2000.
- HILL, M. J.; HELD, A. A.; LEUNING, R.; COOPS, N. C.; HUGHES, D. & CLEUGH, H. A. MODIS spectral signals at a flux tower site: Relationships with high-resolution data, and CO₂ flux and light use efficiency measurements. **Remote Sensing of Environment**, v. 103, p. 351–368, 2006.
- HIRD, J. N.; MCDERMIND, G. J. Noise reduction of NDVI time series: An empirical comparison of selected techniques. **Remote Sensing of Environment**, v. 113, n.1, Jan, p. 248-258. 2009.
- HOLBEN, B. N. Characteristics of maximum-value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, v.7, n.11, p.1417-1434, 1986.
- HOOGENBOOM, G. Contribution of agrometeorology to the simulation of crop production and its applications. **Agricultural and Forest Meteorology**, v. 103, p. 137–157, 2000.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v.25, n.3, p. 295-309, 1988.
- HUETE, A. R.; DIDAN, K.; MUIRA, T.; RODRIGUEZ, E.P.; GAO, X.; FERRERRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

HUETE, A. R., JUSTICE, C., & LIU, H. Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of Environment**, v.49, p.224– 234, 1994.

HUETE, A. R., LIU, H. Q., BATCHILY, K., & VAN LEEUWEN, W. J. D. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing. Environment**, v. 59, p. 440–451, 1997.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Levantamento sistemático da produção agrícola**. 2003. Disponível em: <www.ibge.gov.br/home/estatistica/indicadores/agropecuaria/lspa/>. Acesso em: 31 julho. 2009.

INTERNATIONAL COFFEE ORGANIZATION (ICO). **The world economic crisis and the coffee sector**. February 2009. Available at: <http://www.ico.org/documents/ed-2059e-economic-crisis.pdf>. Access: 2013 Apr. 08.

JENSEN, M.E. Water consumptions by agricultural plants. KOZLOWSKI, T.T. (ed.). **Water deficits and plant growth**New York: Academic Press, New York. , v. 2, p. 1-22.

JONCKHEERE I.; FLECK S.; NACKAERTS, K. MUYS, B.; COPPIN, P., WEISS M.; BARET, F. Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. **Agricultural and Forest Meteorology**, v. 121, p. 19–35, 2004.

JORDAN, C.F. Derivation of leaf area index from quality of light on the forest floor. **Ecology**, v. 50, p. 663–666, 1969.

JUSTICE, C. O.; Townshend, J. R. G.; Vermote, E. F.; Masuoka, E.; Wolfe, R. E.; Saleous, N.; Roy, D. P.; Morisette, J. T. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 3-15, 2002.

KASTENS, J. H.; KASTENS, T. L.; KASTENS, D. L. A.; PRICE, K. P.; MARTINKO, E. A. & LEE, R. Y. Image masking for crop yield forecasting using AVHRR NDVI time series imagery. **Remote Sensing of Environment**, v.99, p.341- 356., 2005.

KANEMASU, E. T. Yield and water-use relationships: some problems of relating grain yield to transpiration. In: TAYLOR, H. M.; JORDAN, W. R.; SINCLAIR, T. R. (eds.). **Limitations to efficient water use in crop production**. Madison: American Society of Agronomy, 1983. cap. 9B, p. 413-417.

KOOMAN, P.L.; HAVERKORT, A.J. Modelling development and growth of the potato crop influenced by temperature and daylength: LINTUL-POTATO. In: HAVERKORT, A.J., MACKERRON, D.K.L. (Eds.). **Potato ecology and modeling of crops under conditions limiting growth**. Dordrecht, The Netherlands: Kluwer Academic Publishers, 1995. p. 41-59. Current Issues in Prod. Ecology, 3.

LIU, H. Q.; HUETE, A. R. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **IEEE T. Geoscience Remote Sensing**, v. 33, p. 457-465, 1995.

LÜDEKE, M.; JANECEK, A.; KOHLMAIER, G. H. Modelling the seasonal CO₂ uptake by land vegetation using the global vegetation index. **Tellus**, 43B, p. 188–196, 1991.

MARSDEN, C.; LE MAIRE, G.; STAPE, J.-L.; SEEN, D.L.; ROUPSARD, O.; CABRAL, O.; EPRON, D.; LIMA, A.M.N.; NOUVELLON, Y., Relating modis vegetation index time-series with structure, light absorption and stem production of fast-growing eucalyptus plantations. **Forest Ecology Management**, v.259, p.1741-1753, 2010.

MARTINS, A. N. & ORTOLANI, A. A. Estimativa de produção de laranja valência pela adaptação de um modelo agrometeorológico. **Bragantia**, Campinas, v.65, n.2, p.355-361, 2006.

MATIELLO, J. B. **Café conillon: como plantar, tratar, colher, preparar e vender**. Rio de Janeiro: MM Produções Gráficas, 1998.

MATIELLO, J. B. **O café: do cultivo ao consumo**. São Paulo: Editora Globo, 1991. 319p. (Coleção do Agricultor - Grãos).

MEHTA, A. & CHAVAS, J. P. Responding to the coffee crisis: What can we learn from price dynamics? **Journal of Development Economics**, v. 85, p. 282–311, 2008.

MELO, R. W. de; FONTANA, D. C.; BERLATO, M. A. and DUCATI, J. R. An agrometeorological-spectral model to estimate soybean yield, applied to southern Brazil. **International Journal of Remote Sensing**, v. 29, n. 13-14, p. 4013-4028, July 2008.

MEYER, Y. **Wavelets and operators**. Cambridge: Cambridge Univ. Press. 1992. 223p.

MKHABELA, M. S.; BULLOCK, P.; RAJ, S.; WANG, S.; YANG, Y. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. **Agricultural and Forest Meteorology**, 2011, 151, 385-393.

MORAES, A. V. de C.; CAMARGO, M. B. P.; MASCARENHAS, H. A. A.; MIRANDA, M. A. C. de e PEREIRA, J. C. V. A. Teste e análise de modelos agrometeorológicos de estimativa de produtividade para a cultura da soja na região de Ribeirão Preto. **Bragantia**, Campinas, v. 57, n. 2, p. 393-406, 1998.

MORAN, M. S.; Jackson, R. D.; Slater, P. N.; Teillet, P. M. Evaluation of simplified procedures for retrieval of land surface reflectance factors from satellite sensor output. **Remote Sensing of Environment**, v. 41, n. 2-3, p. 169-184, 1992.

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

MOREIRA, M. A.; ADAMI, M.; BERNARDES, T.; RUDORFF, B. F. T. Análise da dinâmica espaço-temporal da área cafeeira na região sul/sudoeste de Minas Gerais nos anos safras 2006 a 2008. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR), 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 489-496. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). Disponível em: <<http://urlib.net/3ERPFQRTRW/39ULPC5>>. Acesso em: 08 abr. 2013..

MORETTIN, P. A. **Ondas e ondaletas**: da análise de Fourier a análise de Ondeletas. São Paulo: Editora da USP-SP. 1999. 272P.

MORLET, J.; ARENS, G.; FOURGEAU, E.; GLARD, D. Wave propagation and sampling theory - Part I: Complex signal and scattering in multilayered media. **Geophysics**, v.47, n.2, p.203-221. 1982.

MOTA, F. S. **Meteorologia agrícola**. São Paulo: Nobel, 1979. 376 p.

NORMAN, J. M.; ANDERSON, M. C.; KUSTAS, W. P.; FRENCH, A. N.; MECIKALSKI, J.; TORN, R.; DIAK, G. R.; SCHMUGGE, T. J. Remote sensing of evapotranspiration for precision-farming applications. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2003, July 21-25, Toulouse, France. **Proceedings...** Toulouse, 2003.

NETER, J.; KUTNER, M.H.; NACHTSHEIM, C.J. and WASSERMAN, W. **Applied linear statistical models** 4. ed. New York: McGraw-Hill. 1996. 1408p.

NIELSEN, A. A.; CONRADSEN, K.; SIMPSON, J. J. Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: new approaches to change detection studies. **Remote Sensing of Environment**, v. 64, n. 1, p.1-19, 1998.

NIELSEN, A. A. The Regularized Iteratively Reweighted MAD Method for Change Detection in Multi- and Hyperspectral Data. **Image Processing, IEEE Transactions on**, v. 16, n. 2, p. 463-478, 2007.

PANDA, S.S.; AMES, D.P.; PANIGRAHI, S., Application of vegetation indices for agricultural crop yield prediction using neural network techniques. **Remote Sensing**, v. 2, p. 673-696, 2010.

PAULO, E. M.; JUNIOR, E. F.; FAZUOLI, L. C. Comportamento de cultivares de cafeeiro em diferentes densidades de plantio. **Bragantia**, v.64, p.397-409, 2005.

PARK, J., TATEISHI, R., MATSUOKA, M. A proposal of the Temporal Window Operation (TWO) method to remove high-frequency noises in AVHRR NDVI time series data. **Journal of the Japan Society of Photogrametry and Remote Sensing**, v. 38, p.36-47, 1999.

PEREIRA, S. P.; BARTHOLO G. F.; BALIZA, D. P.; SOBREIRA, F. M.; GUIMARÃES, R. J. Crescimento, produtividade e bienalidade do cafeeiro em função do espaçamento de cultivo. **Pesquisa Agropecuária Brasileira**, v. 46, p.152-160, 2011.

PETR, J. **Weather and yield**. Amsterdam, Netherlands: Elsevier, 1991.

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

PONTE S. The 'Latte Revolution'? Regulation, Markets and Consumption in the Global Coffee Chain. **World Development** v. 30, n. 7, p. 1099–1122, 2002.

RAO, N. H.; SARMA, P. B. S. and CHANDER, S. A simple dated water-production function for use in irrigated agriculture. **Agricultural Water Management**, v. 13, p. 25-32, 1988.

REN, J.; CHEN, Z.; ZHOU, Q. and TANG, H. Regional yield estimation for winter Wheat with MODIS-NDVI data in Shandong, China. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, p. 403-413, 2008.

RENA, A.B.; BARROS, R. S. Aspectos críticos no estudo da floração do café. In: Zambolim L. (ed), **Efeitos da irrigação sobre a qualidade e produtividade do café**. Viçosa: Universidade Federal de Viçosa, 2004. p.149-172.

RENA, A. B.; BARROS, R. S.; MAESTRI, M. Desenvolvimento reprodutivo do cafeeiro. In: ZAMBOLIM, L. (ed). **Tecnologias de produção de café com qualidade**. Viçosa: Universidade Federal de Viçosa, 2001. p.101-128,

RESTREPO, E. C. M.; PULGARIN, J. A.; ROBLEDO, A. J.; HERRERA, N. M. R.; ZEA, F. A. Q. **Modelo para simular la producción potencial del cultivo del café en Colombia**. FNC-Cenicafé, 2009.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, p. 1541-52, 1977.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. 214 p. (INPE-12271-TDI/983). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2004.

RIZZI, R. & RUDORFF, B.F.T. Imagens do sensor MODIS associadas a um modelo agrônomo para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v.42, n.1, p.73-80, jan. 2007.

ROBERTSON, G.W. **Guidelines on crop-weather models**. Geneve: World Meteorological Organization, 1983, 115p. (World Climate Application Programmer, 50).

RODRÍGUEZ, D. et al. A coffee agroecosystem model: I. Growth and development of the coffee plant. **Ecological Modelling**, v. 222, n. 19, p. 3626-3639, 2011.

ROSA, V. G. C. **Modelo agrometeorológico-espectral para monitoramento e estimativa da produtividade do café na região Sul/Sudoeste do estado de Minas Gerais**. Dissertação (Mestrado em Agronomia). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007, 143p.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3., 1974, Greenbelt. **Proceedings...** Greenbelt: NASA, 1974. (NASA SP-351, 3010-3017).

ROY, D.P.; JU, J.; LEWIS, P.; SCHAAF, C.; GAO, F.; HANSEN, M.; LINDQUIST, E. Multi-temporal MODIS-Landsat data fusion for relative radiometric normalization, gap filling, and prediction of Landsat data. **Remote Sensing of Environment**, v. 112, p. 3112-3120, 2008.

RUDORFF, B. F. T. **Dados Landsat na estimativa da produtividade agrícola da cana-de-açúcar**. São José dos Campos. 114p. (INPE-3744-TDL/202). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, 1985.

RUDORFF, B. F. T.; BATISTA, G. T. Yield estimation of sugarcane based on agrometeorological-spectral models. **Remote Sensing of Environment**, v.33, n.3, p. 182–192, Sept. 1990.

RUDORFF, B. F. T.; BATISTA, G. T. Wheat yield estimation at the farm level using LANDSAT TM and agrometeorological data. **International Journal of Remote Sensing**, v.12, p. 2477-2484, 1991.

SAKAMOTO, T., M. YOKOZAWA, TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N.; OHNO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, v. 96, n.3-4, p. 366-374, 2005.

SANTOS, M. A.; CAMARGO, M. B. P. Parametrização de modelo agrometeorológico de estimativa de produtividade do cafeeiro nas condições do estado de São Paulo. **Bragantia**, Campinas, v. 65, n.1, p.173-183, 2006.

SCHLERF, M.; ATZBERGER, C.; HILL, J. Remote sensing of forest biophysical variables using HyMap imaging spectrometer data. **Remote Sensing of Environment**, v. 95, 177–194, 2005.

SCHOTT, J. R. **Remote sensing: the image chain approach**, New York: Oxford University Press, 1997.

SCHOTT, J. R.; SALVAGGIO, C.; VOLCHOK, W. J. Radiometric scene normalization using pseudoinvariant features. **Remote Sensing of Environment**, v. 26, n. 1, p. 1-16, 1988.

SHANTZ, H.J. & PIEMEISEL, L.N. The water requirement of plants at Akron, Colorado. **Journal of Agriculture Research**, v. 34, p. 1093-1190, 1927.

SILVA, F. M.; ALVES, M. C.; SOUZA J. C. S.; OLIVEIRA, M. S. Efeitos da colheita manual na bialidade do cafeeiro em Ijaci, Minas Gerais. **Ciência e Agrotecnologia**, v. 34, n. 5, p. 625-632, 2010.

SILVA, E. A.; DAMATTA, F. M.; DUCATTI, C.; REGAZZI, A. J.; BARROS, R. S. Seasonal changes in vegetative growth and photosynthesis of Arabica coffee trees. **Field Crops Research**, v. 89, p. 349-357, 2004.

SIMPSON, J. J.; STITT, J. R. A procedure for the detection and removal of cloud shadow from AVHRR data over land. **Geoscience and Remote Sensing**, IEEE Transactions on, v.36, n.2, p.880-897. 1998.

SPITTERS, C.J.T. Crop growth models: their usefulness and limitations. **Acta Horticulture**, v. 267, p. 349-368, 1990.

STEWART, J. I.; HAGAN, R. M. and PRUITT, W. O. **Production functions and predicted irrigation programs for principal crops as required for water resources planning and increased water use efficiency**. Washington: U.S. Department of Interior, 1976. Final report.

STRAHLER, A. H.; MOODY, A.; LAMBIN, E. **MODIS Land cover product: Algorithm Theoretical Basis Document (ATBD)**. Version 3.0, 1995. Disponível em : <modis.gsfc.nasa.gov/data/dataproduct/pdf/MOD1440.PDF>. Acesso em: 7nov.2002.

SUGAWARA, L. M. **Avaliação de modelo agrometeorológico e imagens NOAA/AVHRR no acompanhamento e estimativa de produtividade da soja no Estado do Paraná**. 2002. 181p. (INPE-8702-TDI/794). Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2002. Disponível em: <<http://urlib.net/dpi.inpe.br/lise/2002/11.18.18.05>>. Acesso em: 08 abr. 2013.

SUGAWARA, L. M. **Variação interanual da produtividade agrícola da cana-de-açúcar por meio de um modelo agrônômico**. 2010. 114 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/38CSKHB>>. Acesso em: 08 abr. 2013.

SUPIT, I. **An exploratory study to improve predictive capacity of the crop growth monitoring system as applied by the european commission**. 2000, 180p. PhD Thesis, Wageningen University, The Netherlands, ISBN 90-804443-5-9, 2000.

SYLVAIN, P. Some observations on coffea arabica L. in Ethiopia. **Turrialba** 5, p. 37-53, 1955.

TEILET, P. M.; STAENZ, K; WILLIAM, D. J. Effects of spectral, spatial, and radiometric characteristics on remote sensing vegetation indices of forested regions. **Remote Sensing of Environment**, v.61, n.1, p.139-149. 1997.

TOLEDO, S.V.; BARROS, I. Influência da densidade de plantio e sistema de podas na produção de café. **Pesquisa Agropecuária Brasileira**, v.34, p.1379-1384, 1999.

TURNER, D. P.; COHEN, W. B.; KENNEDY, R. E.; FASSNACHT, K. S. and BRIGGS, J. M. Relationships between leaf area index and Landsat TM spectral vegetation indices across three temperate zone sites. **Remote Sensing of Environment**, v. 70, p. 52–68, 1999.

USTIN, S. L.; ROBERTS, D. A.; GARDNER, M., & DENNISON, P. Evaluation of the potential of Hyperion data to estimate wildfire hazard in the Santa Ynez Front Range, Santa Barbara, California. In:INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2002and CANADIAN SYMPOSIUM ON REMOTE SENSING, 24., 24–28 June 2002,Toronto, Canada, . **Proceedings...** Piscataway, NJ: IEEE, 2002. p. 796–798.

VAAST, P.; ANGRAND, J.; FRANCK, N.; DAUZAT, J.; GÉNARD, M. Fruit load and ring-barking affect carbon allocation and photosynthesis of leaf and fruit of *Coffea arabica* in the field. **Tree Physiology**, v. 25, p. 753-760, 2005.

VAN DELDEN, A. **Yielding ability and weed suppression of potato and wheat under organic nitrogen management**. 2001, 197p. PhD Thesis, Wageningen University, The Netherlands, 2001. ISBN 90 5808 519_/8.

VAN DIJK, A.; CALLIS, S. L.; SAKAMOTO, C. M.; DECKER, W. L. Smoothing vegetation index profiles: An alternative method for reducing radiometric disturbance in NOAA/AVHRR data. **Photogrammetric Engineering and Remote Sensing**, v. 53, p. 1059-1067. 1987.

VAN ITTERSUM, M.K.; LEFFELAAR, P.A.; VAN KEULEN, H.; KROPFF, M.J.; BASTIAANS, L. and GOUDRIAAN J. On approaches and applications of the Wageningen crop models. **European Journal of Agronomy**, v. 18, p. 201–234, 2003.

VAN LAAR, H.H.; GOUDRIAAN, J.;VAN KEULEN, H. **SUCROS97**: simulation of crop growth for potential and water-limited production situations. Quantitative Approaches in Systems Analysis, n. 14. C.T. de Wit Graduate School for Production Ecology and Resource Conservation. Wageningen, The Netherlands, 1997. p. 52 appendices

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**, v. 69, n. 3, p. 264-280, 1999.

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 1, p. 106-115, 2010.

VIEIRA JUNIOR, P. A. et al. Previsões meteorológicas do Modelo Eta para subsidiar o uso de modelos de previsão agrícola no Centro-Sul do Brasil. **Ciência Rural**, v. 39, p. 412-420, 2009.

VIOVY, N.; ARINO, O.; BELWARD, A. S. The best index slope extraction (BISE): A method for reducing noise in NDVI time-series. **International Journal of Remote Sensing**, v. 13, p. 1585-1590. 1992.

WAGENMAKERS, P.S. **Light relations in orchard systems**. 1995, 151p. PhD Thesis, Wageningen University, The Netherlands, ISBN 90-5485-340-9, 1995.

WANG, Q.; ADIKU, S.; TENHUNEN, J.; GRANIER, A. On the relationship of NDVI with leaf area index in a deciduous forest site. **Remote Sensing of Environment**, v. 94, p. 244-255, 2005.

WEILL, M. A. M.; ARRUDA, F. B.; OLIVEIRA, J. B.; DONZELI, P. L.; van RAIJ, B. Avaliação de fatores edafoclimáticos e do manejo na produção de cafeeiros (*Coffea arabica* L.) no oeste paulista. **Revista Brasileira de Ciência do Solo**, v. 23, p. 891-901, 1999.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v.2, p.184-194. 1981.

WILLMOTT, C.J.; DAVIS, R.E.; FEDDEMA, J.J.; KLINK, K.M.; LEGATES, D.R.; ROWE, C.M.; ACKLESON, S.G. and O'DONNELL, J. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v.90, n.C12, p. 8995-9005, 1985.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate Research**, v.30, n.1, Dec. 19, 2005, p.79-82. 2005.

WILLMOTT, C. J.; MATSUURA, K.; ROBESON, S. Ambiguities inherent in sums-of-squares-based error statistics. **Atmospheric Environment**, v.43, n.3, p.749-752. 2009.

XIONG XIAOXIONG; NIANZENG CHE; BARNES, W. Terra MODIS on-orbit spatial characterization and performance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 2, p. 355-365, 2005.

YANG, X.; LO, C. P. Relative radiometric normalization performance for change detection from multi-date satellite images. **Photogrammetric Engineering and Remote Sensing**, v.66, n.8, p.967-980, 2000.

ZAMBOLIM, L.; VALE, F. X. R. do; COSTA, H.; PEREIRA, A. A.; CHAVES, G. M. Epidemiologia e controle integrado da ferrugem-do-cafeeiro. In: ZAMBOLIM,

L. (ed.). **O estado da arte de tecnologias na produção de café**. Viçosa: UFV, cap. 10, p. 369-450, 2002.

ZHANG, X.; FRIEDL, M. A.; STRAHLER, A. H.; HODGES, J. C. F.; GAO, F.; REED, B. C.; et al. Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, v. 84, p.471-475. 2003.