



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA

CHRISTIANO LUNA ARRAES

IDENTIFICAÇÃO DE ÁREAS, DISCRIMINAÇÃO E ESTIMATIVA DE PRODUÇÃO DE
CULTURAS DE VERÃO POR MEIO DE PRODUTOS MODIS

*IDENTIFICATION OF AREAS, DISCRIMINATION AND PRODUCTION ESTIMATE OF
SUMMER CROP BY PRODUCT MODIS*

CAMPINAS - SP
FEVEREIRO DE 2014



**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA**

CHRISTIANO LUNA ARRAES

**IDENTIFICAÇÃO DE ÁREAS, DISCRIMINAÇÃO E ESTIMATIVA DE PRODUÇÃO DE
CULTURAS DE VERÃO POR MEIO DE PRODUTOS MODIS**

***IDENTIFICATION OF AREAS, DISCRIMINATION AND PRODUCTION ESTIMATE OF
SUMMER CROP BY PRODUCT MODIS***

Tese submetida à banca examinadora para a obtenção do título de Doutor em Engenharia Agrícola na área de concentração de Planejamento e Desenvolvimento Rural Sustentável, com a temática Geotecnologias Aplicadas ao Monitoramento de Áreas Agrícolas e Previsão de

Orientador: Prof. Dr. Rubens Augusto Camargo Lamparelli

Co-orientador: Prof. Dr. Jansle Vieira Rocha

ESTE EXEMPLAR CORRESPONDE A VERSÃO
FINAL DA TESE DEFENDIDA PELO ALUNO
CHRISTIANO LUNA ARRAES E ORIENTADO
PELO PROFESSOR DR. RUBENS AUGUSTO
CAMARGO LAMPARELLI

A handwritten signature in black ink, appearing to read "R. Lamparelli".

Rubens A. C. Lamparelli
Pesquisador
NIPE/UNICAMP
Matrícula 20.810-8

**CAMPINAS - SP
FEVEREIRO DE 2014**

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

Arraes, Christiano Luna, 1975-
Ar11i Identificação de áreas, discriminação e estimativa de produção de culturas de verão por meio de produtos MODIS / Christiano Luna Arraes. – Campinas, SP : [s.n.], 2014.

Orientador: Rubens Augusto Camargo Lamparelli.
Coorientador: Jansle Vieira Rocha.
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Sensoriamento remoto. 2. Soja. 3. Milho. 4. Processamento de imagens. I. Lamparelli, Rubens Augusto Camargo. II. Rocha, Jansle Vieira, 1961-. III. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Identification of areas, discrimination and estimated production of summer crops by MODIS products

Palavras-chave em inglês:

Remote sensing

Soybean

Maize

Image processing

Área de concentração: Planejamento e Desenvolvimento Rural Sustentável

Titulação: Doutor em Engenharia Agrícola

Banca examinadora:

Rubens Augusto Camargo Lamparelli [Orientador]

Teresa Cristina Tarlé Pissarra

Mara de Andrade Marinho

Alexandre Camargo Coutinho

Jerry Adriani Johann

Data de defesa: 26-02-2014

Programa de Pós-Graduação: Engenharia Agrícola

Este exemplar corresponde à redação final da **Tese de Doutorado** defendida por **Christiano Luna Arraes**, aprovada pela Comissão Julgadora em 26 de fevereiro de 2014, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

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

Profa. Dra. Teresa Cristina Tarlé Pissarra – Membro Titular
FCAV/Unesp

Profa. Dra. Mara de Andrade Marinho – Membro Titular
Feagri/Unicamp

Dr. Alexandre Camargo Coutinho – Membro Titular
Embrapa/CNPTIA

Prof. Dr. Jerry Adriani Johann – Membro Titular
Unioeste

RESUMO

Técnicas de sensoriamento remoto são úteis na determinação de áreas cultivadas, principalmente das commodities soja [*Glycine max (L.) Merr.*] e milho (*Zea mays L.*). Considerando que a Temperatura de Superfície Terrestre (TST) e o índice vegetativo *Normalized Difference Vegetation Index* (NDVI) podem auxiliar nas estimativas da produção destas culturas, o presente trabalho objetivou correlacionar os valores dessas variáveis e a produção das culturas de verão para uma série histórica de 11 anos, em microrregiões do Estado do Paraná. As máscaras de cultura de verão foram avaliadas por índice *Kappa* e exatidão global, encontrando valor médio superior a 0,68 e 84%, respectivamente. Ao avaliar a metodologia de geração de máscaras de cultura de verão utilizando equações polinomiais de segunda ordem com ajustes de R^2 superior a 0,75, se obtém *Kappa* igual a 0,86 e exatidão global de 93%, sendo ligeiramente superior aos resultados encontrados quando se utiliza a técnica de máximo-mínimo NDVI. Ao tentar diferenciar a soja do milho utilizando imagens orbitais os resultados mostram que em áreas com declividade acentuada não é possível separá-las, pois nestas áreas a ocorrência de confusão espectral dar-se de forma mais intensa, no entanto, em áreas planas foi possível distingui-las. As correlações lineares de Pearson entre os valores de TST e NDVI foram em média, superior a -0,58 na série temporal de 11 safras agrícolas. Os melhores coeficientes de determinação da regressão múltipla entre produção, NDVI e TST retornaram um valor médio de 64%, sendo um indicativo do potencial da TST e do NDVI em auxiliar as estimativas agrícolas. No entanto, a baixa resolução espacial das imagens de TST se torna um empecilho no monitoramento de pequenas áreas agrícolas, principalmente quando essas estão acometidas de nuvens.

Palavras-chave: Soja, Milho, Temperatura de superfície terrestre, Equações polinomiais e logarítmicas, NDVI e EVI.

ABSTRACT

Remote sensing techniques are useful in determining cultivated areas, mainly commodity crops as soybean [*Glycine max* (L.) Merr.] and corn (*Zea mays* L.). Considering that the Land Surface Temperature (LST) and the Normalized Difference Vegetation Index (NDVI) variables can estimate production of these crops, this study aimed to correlate the values of these variables and the production of summer crops for a historical series of 11 years at the State of Paraná, Brazil. Shades of summer crop were evaluated by Kappa coefficient and overall accuracy average value exceeding 0.68 and 84%, respectively. In evaluating the method of generating masks of summer crops using second order polynomial equations with adjustments R^2 greater than 0.75, the Kappa coefficient was equal to 0.86 Kappa and overall accuracy of 93%, being slightly higher than the results obtained when using the maximum-minimum NDVI technique. When trying apart soy to corn using orbital images, the results showed that in areas with steep slopes is not possible to separate them, because in these areas the occurrence of spectral confusion occurs more intensely. However in flat areas it was possible to distinguish them. The Pearson linear correlation between LST and NDVI values returned an average value greater than -0.58 in the time series of 11 agricultural crops. The better determination coefficients of multiple regressions between production, NDVI and LST returned an average value around 64%, being an indicator of the potential of LST and NDVI in assisting agricultural estimates. However, the low spatial resolution images of the LST become an obstacle in monitoring small agricultural areas, especially when these are affected by clouds.

Keywords: Soybean, Maize, Land Surface Temperature, Polynomial and logarithmic Equations.

SUMÁRIO

1 INTRODUÇÃO E JUSTIFICATIVA.....	1
1.1 Hipóteses.....	4
1.2 Objetivos.....	5
2 MATERIAIS E MÉTODOS.....	6
2.1 Materiais.....	6
2.1.1 Áreas de estudo.....	6
2.1.2 Dados espectrais.....	9
2.1.3 Dados de campo de soja e milho.....	10
2.2 Método.....	11
2.2.1 Processamento das imagens Modis.....	12
2.2.2 Processamento das imagens LANDSAT-5/TM.....	13
2.2.3 Análise estatística.....	14
3 RELIABILITY OF SUMMER CROP MASKS DERIVED FROM SECOND ORDER POLYNOMIAL EQUATIONS.....	16
3.1 Introduction.....	16
3.2 Study Area, Data and Method.....	18
3.2.1 Acquisition, Extraction and Re-Projection of MODIS/TERRA Images.....	21
3.2.2 Acquisition and Re-Projection of LANDSAT-TM 5 Images.....	22
3.2.3 Transformation of LANDSAT-TM 5 Images in Vectors.....	22
3.2.4 Visualization of the Temporal NDVI Profile for Summer Crops (Soybeans and Maize) in the MODIS Images.....	23
3.2.5 Identification of the Temporal NDVI Profile: the Beginning and the End of the Vegetative Cycle.....	23
3.2.6 Adequacy of Second Order Polynomial Equation for Each Pixel of a Temporal Series.....	24
3.2.7 Construction of the Mask for Summer Crops (Soybean and Maize), Based on the Determination Coefficients of Second Order Polynomial Equations.....	25
3.2.8 Construction of the Mask Summer Crops (Soybeans and Maize) Using the Maximum-Minimum NDVI Methodology.....	25

3.2.9 Application of the Kappa Index, Global Accuracy and Error Matrix.....	26
3.2.10 Comparison among Data from Cultivated Area (Summer Crops).....	27
3.3 Results and Discussion.....	27
3.4 Conclusions.....	33
Acknowledgments.....	33
REFERENCES.....	34
4 SPECTRAL SEPARATION OF MAIZE AND SOYBEAN CROPS USING LOGARITHMIC EQUATIONS APPLIED TO MODIS TIME-SERIES.....	37
4.1 Introduction.....	38
4.2 Data and Method.....	40
4.2.1. Study Area.....	40
4.2.2 Database.....	41
4.2.2.1 Acquisition of Modis/TERRA images.....	41
4.2.2.2 Acquisition and re-projection of LANDSAT-TM 5 image.....	41
4.3 Method.....	41
4.3.1 Generation of the angular coefficients of logarithmic equations.....	43
4.3.2 Supervised classification of Landsat-5/TM images.....	44
4.3.3 Acquisition of soybean and maize fields geographic position.....	45
4.3.4 Visualization of the EVI temporal profile of soybean and maize at MODIS images.....	45
4.3.5 Identification of the crops starting period and vegetative peak, in the temporal profile of EVI.....	45
4.4 Results and discussion.....	46
4.5 Conclusions.....	54
Acknowledgements.....	55
REFERENCES.....	56
5 RELAÇÃO ENTRE A RESPOSTA ESPECTRAL DE CULTURAS DE VERÃO E SUA PRODUÇÃO A PARTIR DE DADOS TST E NDVI DO SENSOR MODIS.....	60
5.1 Introdução.....	62
5.2 Material e Métodos.....	65

5.2.1 Aquisição e pré-processamento dos produtos Terra/MODIS.....	66
5.2.2 Aquisição e pré-processamento das imagens Lansat-5/TM.....	67
5.2.3 Geração das máscaras de culturas de verão e avaliação de sua acurácia.....	68
5.2.4 Extração dos valores de NDVI e TST.....	70
5.2.5 Análises estatísticas e estudo da relação múltipla do índice NDVI e valores da TST com a produção das culturas de verão.....	70
5.3 Resultados e discussão.....	71
5.4 Conclusão.....	83
Agradecimentos.....	83
REFERÊNCIAS.....	84

Aos meus pais, minha esposa, meus irmãos, família Moura e aos meus amigos.

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP – projeto: 2011/13748-8) pelo apoio financeiro.

Ao Programa de Doutorando no Brasil com Estágio no Exterior – PDEE (Processo BEX: 4565/11-8) pelo apoio financeiro e incrível experiência oferecida.

Ao Laboratorio de Teledetección – LATUV pertencente à Universidad de Valladolid na pessoa do Professor Phd José-Luis Casanova Roque, por participar integralmente deste trabalho, e pelo companheirismo.

A Universidade Estadual de Campinas (UNICAMP) e, em particular, à Faculdade de Engenharia Agrícola (FEAGRI), pela oportunidade de realizar este estudo e utilizar seus equipamentos e instalações.

A Universidade Estadual do Oeste Do Paraná (UNIOESTE) / Campus de Cascavel e, em particular, ao Prof. Dr. Erivelto Mercante, pela oportunidade de realizar parte deste estudo utilizando seus equipamentos e instalações.

Ao meu orientador Dr. Rubens A. C. Lamparelli, pelo conhecimento e experiência compartilhada, pela orientação e apoio na realização deste trabalho, pelo coleguismo e, principalmente, pela confiança em mim depositada quando aceitou ser o meu orientador.

Ao Dr. Jansle V. Rocha, pelo apoio e incentivo na realização deste trabalho e pelo coleguismo.

A Dra. Teresa Cristina Tarlé Pissarra (UNESP - Jaboticabal), pelo seu coleguismo e principalmente por te incentivado a minha carreira académica.

A Cooperativa Agroindustrial - COOPAVEL, pelo apoio técnico nas coletas de dados em campo, presteza em disponibilizar as informações e esclarecimentos dados ao longo desse trabalho.

Ao Phd. Pablo Salvador, Mr. Javier Rodriguez, Mr. Fernando Rodrigo e Don. Alejandro Ferrero (Laboratorio de Teledetección – LATUV), pela colaboração na realização deste trabalho, amizade e apoio fornecido na Espanha.

Ao Agmon M. Rocha, técnico do Laboratório de Geoprocessamento (FEAGRI/UNICAMP), que deu todo suporte para que esta tese fosse viabilizada.

Aos meus amigos do curso de pós-graduação em Engenharia Agrícola, que tornaram mais agradável o período que passamos juntos, no Laboratório de Geoprocessamento: Johann, Agmon, Gleyce, Rafael, Michele, Maria, Rafael Bispo, Ariadiny, Diego, Walter, Carlos, Márcio e Beatriz.

Aos meus pais: Marcondes Arraes e Maria Vilani, à minha irmã Candice, meus irmãos Giuliano e Antônio, a minha cunhada Mel e cunhado Eder e sobrinhos Laura, Diogo, Sofia, Marina e Rafael (o mais novo membro da família), por sempre acreditarem em mim e me apoiarem acima de tudo.

A Raimundo de Moura e Gardênia Arrais, por me acolher no seio desta família maravilhosa e pelo eterno amor e amizade a mim concedido.

A Jussara (minha esposa amada) pela ajuda e compreensão nos momentos mais difíceis, pelo companheirismo, amizade e carinho e principalmente pelo amor incondicional.

As minhas sogras Teresa Soares e Socorro por todo amor e carinho.

À minha família, principalmente a família Arraes e Luna, por todo amor compartilhado.

Aos grandes amigos, pelos momentos felizes, e um agradecimento especial para os primos Luã, Ingrid & Kafé (Vinícios), Monique & Junior (Yasmim, Hugo, Gabriel e Ana Clara) e Lilla por me considerarem um irmão.

“Quanto mais pesquiso mais creio na existência de DEUS!”

LISTA DE FIGURAS

Figura 2.1 - Microrregiões do Estado do Paraná.....	6
Figura 2.2 - Municípios estudados.....	7
Figura 2.3 - Área de estudo Município de Cascavel – Paraná.....	8
Figura 2.4 - Grade de imagens Landsat-5/TM representando as imagens utilizadas no desenvolvimento desta pesquisa com datas, orbita e pontos.....	10
Figura 2.5 - Áreas com levantamento de dados de campo em Cascavel.....	11
Figura 2.6 - Fluxograma geral de atividades da tese.....	12
Figure 3.1 - Area under study.....	19
Figure 3.2 - Map of slopes, Cascavel municipality, Paraná State.....	20
Figure 3.3 - Flow diagram of the methodology.....	21
Figure 3.4 - “False color” composition R4G5B3, LANDSAT-TM 5.....	23
Figure 3.5 - Representation of the average NDVI temporal profile for summer crop with vegetative (VE to V5) and reproductive (R1 to R8) phases, Municipality of Cascavel - Paraná State, 2007-08 harvest.....	27
Figure 3.6 - Representation of an average NDVI temporal profile for targets which are not summer crops in the Cascavel municipality, 2007-08 harvest.....	28
Figure 3.7 - Comparison between LANDSAT-TM 5 image and the summer crop mask, obtained by polynomial methodology.....	30
Figure 3.8 - Comparison between LANDSAT-TM 5 image and summer crops mask, obtained with maximum-minimum NDVI methodology.....	31
Figure 4.1 - Municipalities studied in the State of Paraná.....	40
Figure 4.2 - Area under study in the municipality of Cascavel – Paraná State (A) soybean and maize cultivated at the same time, (B) soybean sown at Oct. 22 nd and (C) maize sown at Oct. 2 nd	42
Figure 4.3 - Flowchart of the methodology.....	43
Figure 4.4 - Supervised classification and fields in the municipality of Cascavel, in the State of Paraná.....	44
Figure 4.5 - Representation of the temporal profile of EVI medium for the cultivation of maize and soybean, with the vegetative stages (VE to V5) and reproductive (R1 to	

R8).....	46
Figure 4.6 - Angular coefficient and standard deviation for the 31 municipalities of north.....	47
Figure 4.7 - Angular coefficient and standard deviation for the 31 municipalities of south.....	48
Figure 4.8 - Slope map of the municipalities from the Paraná State.....	49
Figure 4.9 - Adjustment of logarithmic equations at the initial phase of maize development, for each of the 31 municipalities of the northern, during harvest 2007/2008.....	50
Figure 4.10 - Adjustment of logarithmic equations at the initial phase of maize development, for each of the 31 municipalities of the southern region, during harvest 2007/2008.....	50
Figure 4.11 - Adjustment of logarithmic equations at the initial phase of soybean development, for each of the 31 municipalities of the northern region, during harvest 2007/2008.....	51
Figure 4.12 - Adjustment of logarithmic equations at the initial phase of soybean development, for each of the 31 municipalities of the southern region, during harvest 2007/2008.....	51
Figure 4.13 - Soybean and maize mask for the 62 municipalities from the agriculture belt of Paraná State, harvest 2007/2008.....	53
Figura 5.1 - Microrregiões estudadas do Estado do Paraná.....	65
Figura 5.2 - Fluxograma.....	66
Figura 5.3 - Grade de imagens Landsat-5/TM representando as imagens utilizadas no desenvolvimento desta pesquisa com datas, orbita e pontos.....	68
Figura 5.4 - Representação do perfil temporal médio de NDVI para as culturas de verão, com as fases desenvolvimento vegetativo, maturação e senescência - Microrregião de Cascavel-PR.....	69
Figura 5.5 - Matriz representando o pixel puro de TST e NDVI.....	70
Figura 5.6 - TST médio, do Estado do Paraná, para os meses de setembro, outubro e novembro de 2000 a 2010.....	71

Continuação da Figura 5.6 - TST médio, do Estado do Paraná, para os meses de setembro, outubro e novembro de 2000 a 2010.....	72
Continuação da Figura 5.6 - TST médio, do Estado do Paraná, para os meses de setembro, outubro e novembro de 2000 a 2010.....	73
Figura 5.7 - (A) Soja em estágio VE; (B) Soja em estágio V2; (C) Soja em estágio V4 e (D) Soja em estágio V6 com aproximadamente 50% da área foliar recobrindo o solo..	76
Figura 5.8: (a) Relações entre valores médios de NDVI e TST para as safras de 2000 a 2006 e (b) relações entre valores médios de NDVI e TST para as safras de 2007 a 2011.....	82

LISTA DE TABELAS

Tabela 1. Exemplo de Informação Armazenada de cada Pixel dos Produtos MODIS...	13
Table 3.1. Monthly percentage of sowing and harvesting maize and soybean, Paraná State, harvest 2007/08.....	26
Table 3.2. Error matrix between the reference (LANDSAT-TM 5, “false color” R4G5B3) and the polynomial mask.....	29
Table 3.3. Error matrix between the reference (LANDSAT-TM 5) and the maximum-minimum NDVI mask.....	32
Table 3.4. Comparison between official IBGE data and masks obtained by the following methodologies: fitting of polynomial equations to temporal NDVI series, maximum-minimum NDVI and vectorization of LANDSAT-TM 5 image, harvest 2007/08.....	32
Table 4.1. Proportion of sowing and harvesting activities for soybean and maize in the State of Paraná.....	47
Table 4.2. Error matrix between the reference (Landsat-5/TM, “false color” R4G5B3) and the soybean and maize crop masks for the southern region, harvest 2007/2008.....	52
Table 4.3. Error matrix between the reference (Landsat-5/TM, “false color” R4G5B3) and the separability mask of soybean and maize for the northern region, harvest 2007/2008.....	52
Table 4.4. Maize and soybean crop areas using the methodology proposed compared to official IBGE data for the crop year 2007/08.....	54
Tabela 5.1. Produção, em milhões de toneladas, soja e milho para as safras de 2001 a 2011.....	73
Tabela 5.2. Índices <i>Kappa</i> , Exatidão Global e Erros de Omissão e Inclusão, para as 11 safras agrícolas.....	74
Tabela 5.3. Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para 39 microrregiões do Estado do Paraná, safra 2001 a 2006.....	77
Continuação da Tabela 5.3: Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para 39 microrregiões do Estado do Paraná, safra 2001 a 2006.....	78

Tabela 5.4. Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para microrregiões 39 do Estado do Paraná, safra 2007 a 2011.....	79
Continuação da Tabela 5.4: Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para microrregiões 39 do Estado do Paraná, safra 2007 a 2011.....	80
Tabela 5.5. Regressões lineares múltiplas obtidas com produção e os valores médios dos pixels puros de NDVI e TST para Microrregiões do Estado do Paraná.....	81

1 INTRODUÇÃO E JUSTIFICATIVA

A alta variabilidade climática nas regiões tropicais torna-se um dos principais problemas a ser contornado quando se pretende trabalhar com estimativas de safras agrícolas. Portanto, desenvolver ferramentas confiáveis para garantir maior acerto na estimativa das safras agrícolas é um desafio a ser superado. Informações sobre a dinâmica das culturas no Brasil são extremamente importantes, na medida em que os espaços ocupados por elas mudam constantemente em função do mercado, meio ambiente, migrações e políticas públicas. Os órgãos oficiais responsáveis pelas estimativas de áreas cultivadas, no âmbito do Brasil, são IBGE (Instituto Brasileiro de Geografia e Estatística) e a Conab (Companhia Nacional de Abastecimento/Ministério da Agricultura, Pecuária e Abastecimento) e no âmbito regional estão os vários órgãos ligados aos governos dos estados, como o Deral (Departamento de Economia Rural da Secretaria de Estado da Agricultura e do Abastecimento), no Paraná. Estes órgãos realizam pesquisas de campo e análise de dados, para estimativa das áreas produtivas, sendo que esses levantamentos são custosos e requerem elevados investimentos.

Vários estudos têm demonstrando que outras técnicas, como o uso do sensoriamento remoto, podem auxiliar no mapeamento de culturas agrícolas (DORAISWAMY et al., 2004; CHANG et al., 2007; QUIROGA; IGLESIAS, 2009; LV et al., 2013; THORP et al., 2012; CASA et al., 2012; TINGTING; CHUANG, 2010) e, por conseguinte na estimativa de suas áreas. Das várias características do sensoriamento remoto uma das mais importantes preenche as necessidades de atualizações constantes destas informações, no contexto do dinamismo da agricultura, subsidiando, com mais confiabilidade, as tomadas de decisões. Em concordância com a ideia acima exposta pode-se citar a iniciativa da Conab que agrega ao seu ferramental de análise, informações oriundas de sensoriamento remoto e geoprocessamento para subsidiar as decisões de estimativa de áreas e safras de culturas (CONAB, 2011).

O sensoriamento remoto para levantamento de área de agricultura vem sendo utilizado para mapeamento de culturas sejam elas temporárias ou permanentes (MERCANTE et al., 2009). É de consenso, na literatura, que o mapeamento de culturas

deve considerar o aspecto temporal do ciclo da cultura (SAKAMOTO et al., 2005; RUDORFF et al., 2007; LAMPARELLI et al., 2008).

Diversos autores estão utilizando índices de vegetação, os quais permitem explorar, mais eficientemente, os comprimentos de onda que apresentam respostas marcantes a determinados parâmetros biofísicos (área foliar, pigmentos fotossintetizantes) da vegetação (PONZONI; SHIMABUKUTO, 2007). Dentre os vários índices de vegetação existentes pode-se citar o NDVI (*Normalized Difference Vegetation Index*) e EVI (*Enhanced Vegetation Index*) (DEFRIES; TOWNSEND, 1994; HUETE et al., 1997), que operam nos comprimentos de onda do azul, vermelho e infra vermelho próximo. A utilização destes índices (EVI e NDVI) podem auxiliar no acompanhamento do ciclo das culturas e para tanto, o aspecto básico comum entre eles é o estudo do perfil espectral gerado a partir das variações que ocorrem no ciclo das culturas ao longo do tempo (RAMME et al. 2010; ESQUERDO et al., 2011). Outros pesquisadores, como Mkhabela et al. (2011) e Nuarsa et al. (2011), utilizaram séries temporais de imagens de satélite para acompanhar o desenvolvimento de culturas em grandes extensões de terras, tendo como relação direta a biomassa das culturas com esses índices de vegetação.

Alguns trabalhos, com abrangência local ou regional (MARTINEZ; GILBERT, 2009; ARVOR et al., 2011; ARRAES et al., 2013), têm testado o padrão espectro-temporal dos índices de vegetação, para identificar e mapear culturas agrícolas anuais (WARDLOW et al., 2008). Estes trabalhos abriram várias perspectivas no mapeamento de culturas, principalmente na rapidez com que a informação é gerada. Entretanto, os sensores de alta resolução temporal normalmente utilizados nessas atividades de monitoramento da dinâmica agrícola (*Moderate Resolution Imaging Spectroradiometer - MODIS, Advanced Very High Resolution Radiometer - AVHRR, Vegetation/SPOT*) apresentam baixa resolução espacial, prejudicando a qualidade dos mapeamentos, em especial na diferenciação dos alvos, o que pode tornar o mapeamento de áreas agrícolas menos confiáveis, refletindo diretamente nas estimativas de produção. Quando se fala em confiabilidade de mapeamento, normalmente são utilizados, métodos tradicionais como o índice *Kappa* e a Exatidão Global (CONGALTON, 1991), o que pode não ser suficiente para validar os mapeamentos realizados, com o uso do

sensoriamento remoto, sendo necessária uma nova abordagem que vise fornecer uma maior confiança no mapeamento de áreas agrícolas.

Neste cenário, a análise de novas alternativas que possibilitem um mapeamento sistemático que permita, por exemplo, a identificação e distinção das culturas da soja e do milho são extremamente importantes, pois devem levar em conta a intensa cobertura de nuvens que ocorre ao longo das safras de verão e o curto período de desenvolvimento da cultura (3 a 4 meses).

Assim, o sensor Modis, utilizado neste estudo, possui resolução espacial de 250, 500 e 1000 metros (HUETE et al., 1999). Apesar da sua baixa resolução espacial, torna-se uma alternativa interessante por conta da sua elevada resolução temporal. Podendo atender às necessidades de cobertura de áreas com alta frequência de nuvens e de monitoramento de alvos com elevada dinâmica espectral, como é o caso das culturas agrícolas.

Sakamoto et al. (2010) desenvolveram uma metodologia para estimar as fases fenológicas das culturas de verão (soja e milho), o que pode melhorar os modelos de estimativas de safra agrícola. Os autores diferenciaram quatro fases fenológicas para o milho (V2 à V5 como sendo início vegetativo; R1 como sendo início da fase de florescimento; R5 formação de grão e R6 maturação) e para a soja (V1 a Vn estádios vegetativos; R5 formação das sementes; R6 enchimento de grãos e R7 como sendo o inicio da maturação), concluindo que a utilização de sensoriamento remoto, como ferramenta auxiliar, pode contribuir na escolha da melhor época de se fazer os tratos culturais como adubação e manejo da irrigação.

Segundo Bhattacharya et al. (2011) a temperatura é outra variável importante que influencia no desenvolvimento da planta e, portanto, na produtividade final. Segundo Prasad et al. (2006), Jonna et al. (2007), Wu et al. (2011) e Cai e Sharma (2010), a Temperatura de Superfície Terrestre (TST) pode ser correlacionada de forma direta com os vários índices de vegetação, como por exemplo, o EVI e o NDVI, para as mais diferentes culturas, podendo assim contribuir de forma substancial nas estimativas das safras agrícolas.

Parida et al. (2008) observam que a variação na TST é determinada, principalmente, pelos diferentes tipos de cobertura vegetal. Ao compararem valores de

TST com dados de temperatura do ar, para as mais diferentes culturas, encontraram correlação superior a 0,80, o que demonstra o potencial da TST em auxiliar nas estimativas de safras agrícolas. Li et al. (2008) mostram a possibilidade de utilização de dados orbitais no monitoramento do estresse hídrico, no Norte da China. Utilizaram dados de TST do sensor Modis combinado com valores de NDVI, para o cálculo do índice *Temperature vegetation dryness* (TVDI), o qual pode ser relacionado com as condições de umidade do solo (GOWARD et al., 2002; CHEN et al., 2011; BAJGIRAN et al., 2012; SONA et al., 2012; SUN et al., 2012).

Estudos realizados por Chang et al. (2007) nos Estados Unidos mostraram a importância da utilização de dados de sensoriamento remoto de alta resolução temporal no monitoramento de culturas agrícolas, devido à possibilidade de acompanhar as alterações fenológicas das culturas. Os autores ainda desenvolveram modelos de estimativa de safra para as culturas de verão em nível nacional, estadual e municipal, utilizando dados de TST e dados de NDVI, ambos obtidos do sensor Modis. Os autores encontraram coeficientes de correlação superiores a 0,90 quando comparados com os dados oficiais do governo. Prasad et al. (2006) e Sakamoto et al. (2013) encontram valores de correlação superiores a 0,75 entre dados observados e dados obtidos por técnicas de sensoriamento remoto.

A metodologia proposta para correlacionar os dados de NDVI, TST e produção foi fundamentada nas necessidades térmicas destas culturas, visto que, segundo Embrapa Soja (2008), as culturas de verão necessitam de temperatura do solo entre 20 e 30°C principalmente entre fases VE até o estádio V6.

Portanto traçar uma metodologia que leve em consideração não só os índices de vegetação como também a TST, obtida por sensores remotos, tem se tornado um grande desafio e, portanto, fruto de investigação deste trabalho.

1.1 Hipóteses

As seguintes hipóteses foram levantadas:

Os perfis temporais de NDVI podem ser ajustados a curvas de equações polinomiais de segunda ordem conferindo maior confiança às máscaras geradas (artigo 1);

É possível diferenciar as culturas agrícolas soja e milho utilizando coeficientes angulares das equações logarítmicas, ajustadas aos perfis temporais de EVI, no início do desenvolvimento vegetativo (artigo 2);

Existe correlação entre o padrão espectral da biomassa, expresso pelo índice de vegetação NDVI e pela TST, no decorrer do ciclo de desenvolvimento das culturas de verão, e a produção em escala de microrregião (artigo 3).

1.2 Objetivos

Dentro deste contexto, este trabalho teve como objetivo geral estabelecer uma relação entre NDVI, temperatura de superfície terrestre e produção das culturas de verão (soja e milho), por microrregiões no Estado do Paraná, para a série temporal de 2001 a 2011. O objetivo foi dividido em três partes, no formato de artigos, organizado da seguinte maneira:

O primeiro artigo intitulado: “Reliability of Summer Crop Masks Derived from Second Order Polynomial Equations”. Teve como objetivo desenvolver uma metodologia capaz de gerar máscaras de culturas de verão baseada em equações polinomiais de segunda ordem, ajustadas aos perfis temporais de NDVI para o município de Cascavel - PR, em que os coeficientes de determinação destas equações são o grau de confiança da máscara.

No segundo artigo intitulado: “Spectral separation of maize and soybean crops using logarithmic equations applied to MODIS time-series” teve como objetivo desenvolver uma metodologia capaz de separar, espectralmente, as culturas de soja e milho, baseando-se em coeficientes angulares de equações logarítmicas ajustadas as séries temporais do índice de vegetação EVI, geradas com imagens do sensor Modis, para 62 municípios do Estado do Paraná.

O terceiro artigo, fonte do objetivo geral desta tese, é intitulado por: “Relação entre a resposta espectral de culturas de verão e sua produção, a partir de dados TST e NDVI do sensor Modis” e tem como objetivo gerar modelos matemáticos capazes de

explicar a relação existente entre a produção das culturas de verão e as variáveis espectrais NDVI, Temperatura da superfície terrestre por microrregiões no Estado do Paraná para a série temporal de 2001 a 2011.

2 MATERIAIS E MÉTODOS

2.1 Materiais

2.1.1 Áreas de estudo

O estudo foi realizado em três áreas distintas sendo elas:

- 1) 39 microrregiões do Estado do Paraná, localizado na região Sul do Brasil (Figura 2.1), que é responsável por 21.4% da área cultivada com soja e milho, referente à safra 2010/11, em âmbito nacional (IBGE, 2013).

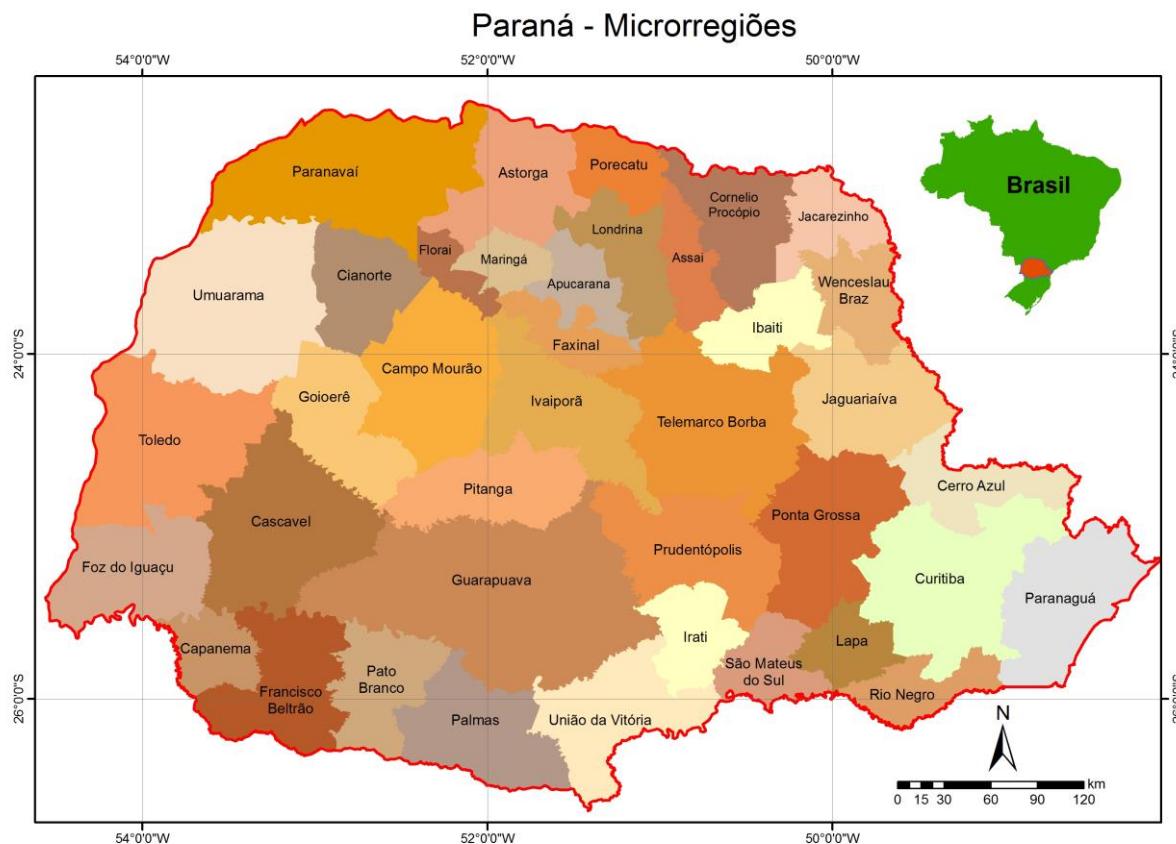


Figura 2.1: Microrregiões do Estado do Paraná.

- 2) 62 municípios todos localizados nas mesorregiões: Centro-Sul Paranaense, Oeste Paranaense e Centro Ocidental Paranaense, que estão entre as latitudes $22^{\circ}29'30"S$ e $26^{\circ}42'59"S$, e as longitudes $48^{\circ}02'24"W$ e $54^{\circ}37'38"W$ (Figura 2.2).

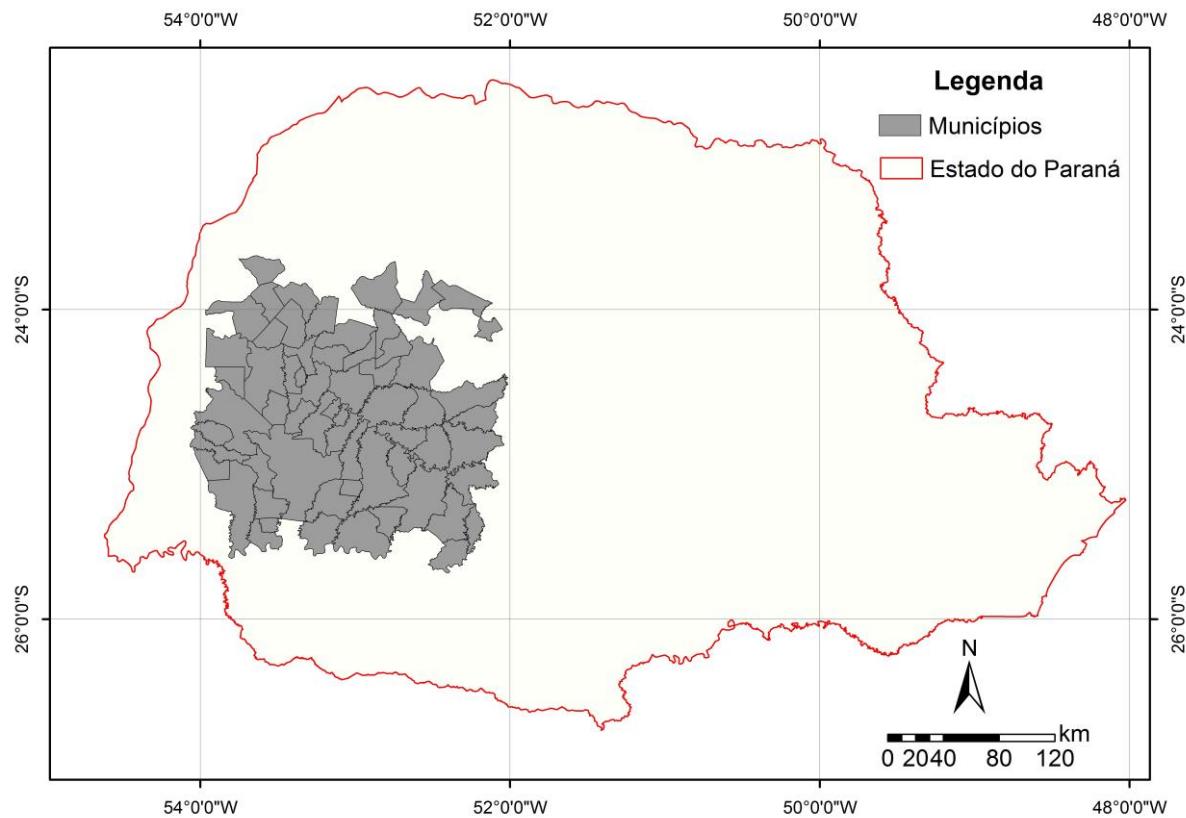


Figura 2.2: Municípios estudados.

- 3) E por fim no Município de Cascavel, localizado entre as latitudes $22^{\circ}29'30"S$ e $26^{\circ}42'59"S$, e as longitudes $48^{\circ}02'24"W$ e $54^{\circ}37'38"W$ (Figura 2.3).

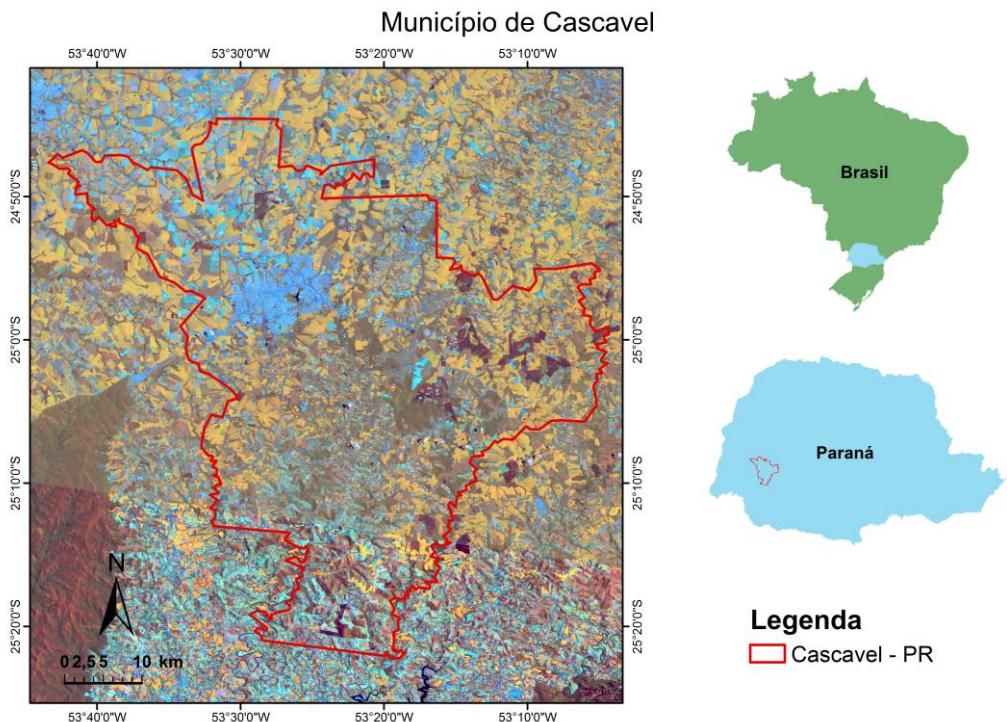


Figura 2.3: Área de estudo Município de Cascavel – Paraná.

Baseado na classificação de Köeppen, o Estado do Paraná possui três tipos de clima: Af - clima tropical, super-úmido, sem estação seca, praticamente isento de geadas (temperatura média de todos meses superiores a 18°C), localizado na Planície Litorânea; Cfa - clima subtropical, úmido, mesotérmico, com verões quentes e geadas pouco frequentes (temperatura média do mês mais quente superior a 22°C), sem estação seca. Encontrado também nas regiões Norte, Oeste e Sudoeste, compreendendo parte do Planalto de Guarapuava, e nas zonas da Serra do Mar e do Vale do Ribeira; e Cfb - clima subtropical, úmido, mesotérmico, com verões frescos e geadas severas e demasiadamente frequentes no inverno (temperatura média do mês mais quente inferior a 22°C), sem estação seca encontrado nos Planaltos de Curitiba e Ponta Grossa e parte do Planalto de Guarapuava (VIANELLO; ALVES, 1991).

Os solos da área de estudo são predominados pelos Nitossolos e Neossolos encontrados principalmente no Litoral Paranaense; pelos Cambissolos e afloramentos rochosos encontrados na Serra do Mar; pelos Cambissolos, Argissolos, Latossolos e Neossolos encontrados no Planalto de Curitiba; no Planalto de Ponta Grossa são encontrados solos mais rasos com fertilidade natural menor, comparado com os solos

encontrados no Planalto de Guarapuava que são profundos, bem desenvolvidos e de alta fertilidade natural, onde se destacam os Latossolos, Argissolos e Nitossolos (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, 1999). Segundo levantamento do Paraná (1987), o relevo do Paraná apresenta três principais características, sendo elas:

- a parte leste do Estado é constituída de relevo movimentado com altitudes mais elevadas ocorrendo na Serra do Mar e na parte Sul do Estado;
- a partir da Serra do Mar as altitudes decrescem no sentido Leste para Oeste;
- a maior parte do território está contida entre as altitudes de 300 a 600 metros acima do nível do mar.

2.1.2 Dados espectrais

Os dados espectrais utilizados foram obtidos pelo sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) presente na plataforma TERRA, que possui 12 subprodutos. Os subprodutos utilizados neste trabalho foram os índices de vegetação NDVI e EVI, composição de 16 dias, resolução espacial de 250m do MOD13Q1; e também a TST, composição de 8 dias e resolução espacial de 1000m do produto MOD11A2, ambas em formato “hdf” e projeção Sinusoidal (HUETE et al., 1999). Estas imagens foram obtidas do site da NASA (NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, 2012 que as disponibiliza gratuitamente). Ainda foram adquiridas imagens do satélite Landsat-5 sensor TM (Thematic Mapper) referentes às bandas 3 (0,63 a 0,69 µm – vermelho), 4 (0,76 a 0,90 µm - infravermelho próximo) e 5 (1,55 a 1,75 µm - infravermelho médio) para as órbitas e pontos: 221/076; 222/076, 223/076, 223/077 e 223/078 (Figura 2.4), nas datas 22/03/2001, **18/01/2002, 17/01/2004, 26/01/2005, 14/02/2006, 05/03/2007, 04/02/2008, 22/02/2009** e 16/03/2011 sendo que nas datas em negrito as culturas se encontram em pico vegetativo. As imagens foram solicitadas através do catálogo de imagens disponibilizado gratuitamente pelo Instituto Nacional de Pesquisas Espaciais – INPE (INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2012).

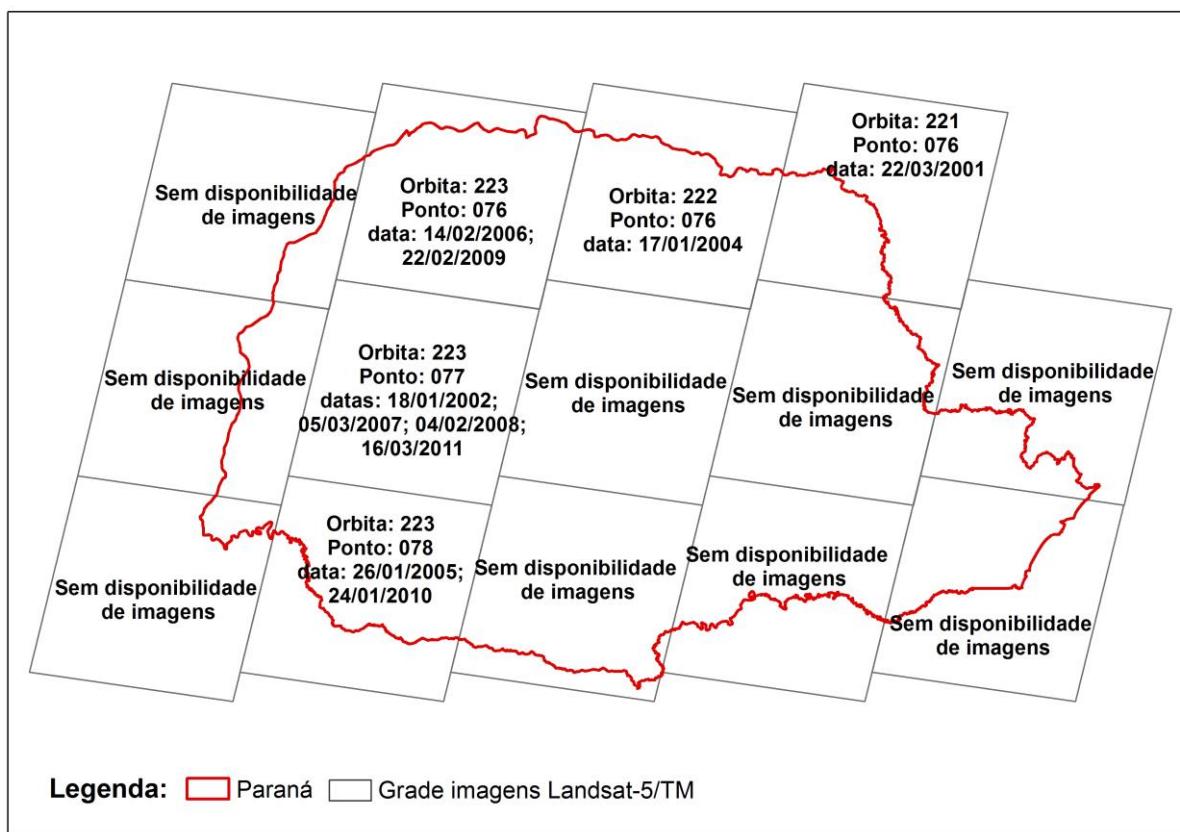


Figura 2.4: Grade de imagens Landsat-5/TM representando as imagens utilizadas no desenvolvimento desta pesquisa com datas, órbita e pontos.

2.1.3 Dados de campo de soja e milho

Os dados referentes à data de semeadura das culturas de verão soja e milho para as safras de 2005 a 2011 foram obtidos junto a Cooperativa Agroindustrial, unidade de Cascavel – PR (COOPAVEL), sendo que foram visitadas propriedades localizadas tanto na região norte quanto na região sul do Município de Cascavel. As informações de data de semeadura foram levantadas por meio de entrevistas com os técnicos agrícolas da Coopavel. (Figura 2.5).

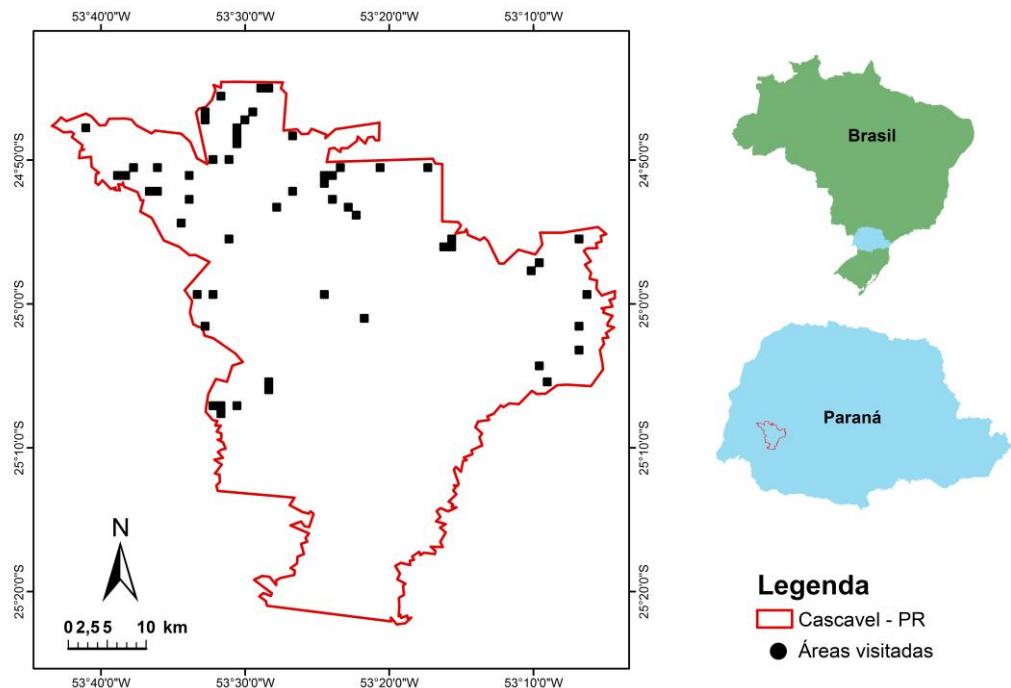


Figura 2.5: Áreas com levantamento de dados de campo em Cascavel.

2.2 Método

Com o objetivo de facilitar o entendimento das principais etapas do desenvolvimento da pesquisa é apresentado na Figura 2.6, o fluxograma geral. Entretanto em cada artigo também serão apresentados fluxogramas mais detalhados das etapas executadas.

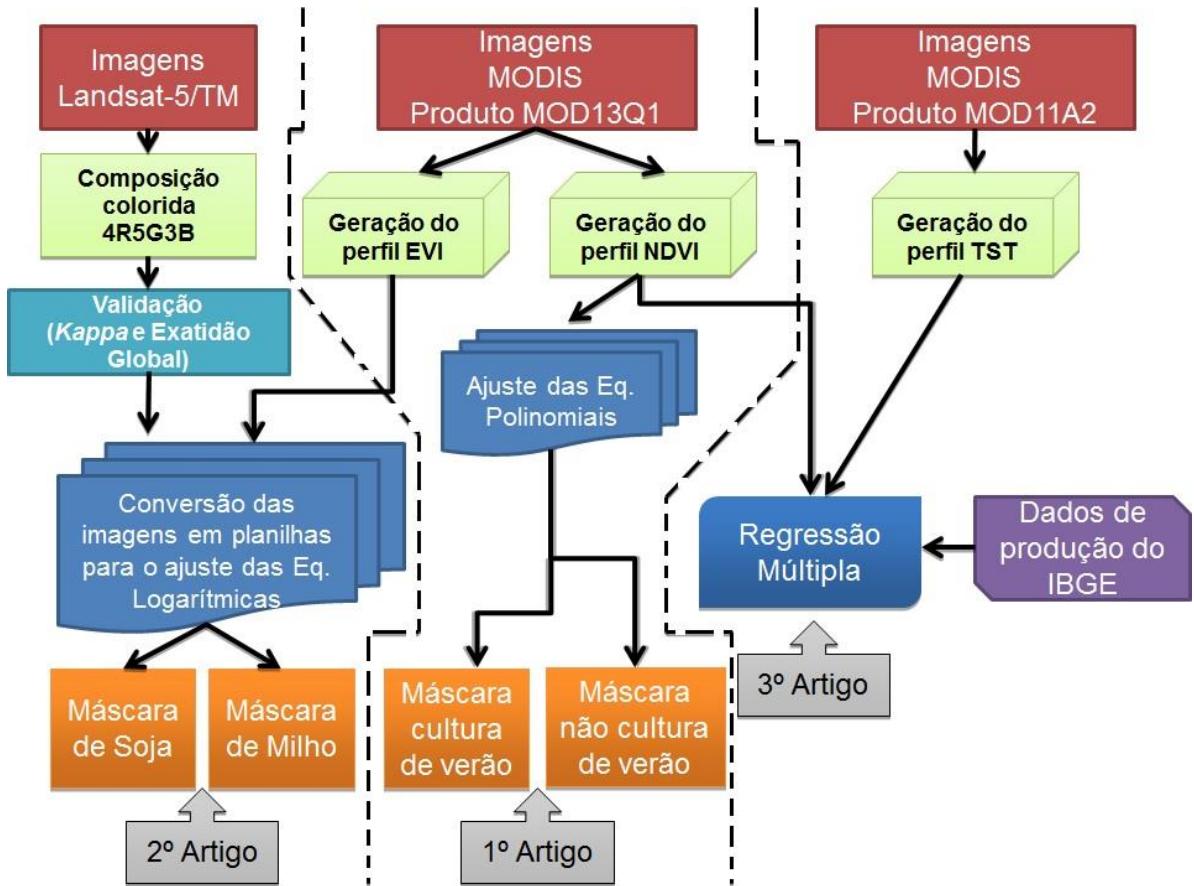


Figura 2.6: Fluxograma geral de atividades da tese.

2.2.1 Processamento das imagens Modis

A etapa de pré-processamento das imagens Modis envolve aplicação do produto *Quality Assurance* (QA), conversão para valores de 0 a 1 dos produtos EVI e NDVI e por fim conversão das imagens de TST para graus célsius.

Os ruídos, segundo Huete et al. (1999), interferem negativamente no valor de radiância dos diferentes alvos. Para eliminar este efeito aplicou-se o produto *Quality Assurance* (QA) que é uma máscara que fornece informações da qualidade associado a cada pixel da imagem, permitindo ao usuário uma análise qualitativa. A máscara de (QA) apresenta valores de pixel conforme código da tabela 1 (GUA et al., 2009). O código binário (Tabela 1) utilizado para gerar as máscaras com valores de 0 e 1 as quais foram multiplicadas por cada imagem de NDVI, EVI e TST com a finalidade de

eliminar possíveis problemas com nuvens e ruidos foi o “00”, pois segundo Justice et al. (1998) esses pixels são produzidos com boa qualidade.

Tabela 1. Exemplo de Informação Armazenada de cada Pixel dos Produtos MODIS.

Código por “Pixel” da QA	Significado
00	“Pixel” produzido com boa qualidade, não sendo necessário um exame mais detalhado da QA.
01	“Pixel” produzido com uma qualidade não definida, sendo necessário um exame mais detalhado da QA.
10	“Pixel” não produzido devido aos efeitos das nuvens.
11	“Pixel” não produzido por outras razões, além dos efeitos das nuvens.

FONTE: Adaptada de Justice et al. (1998, p.1243).

Para converter NDVI e EVI em escala de 0 a 1 foi utilizada as Equações 1 e 2. No entanto para o produto TST foi utilizado a Equação 3. Esses procedimentos foram realizados em programação IDL.

$$NDVI = \frac{ND}{10.000} \quad (1)$$

$$EVI = \frac{ND}{10.000} \quad (2)$$

$$TST(^{\circ}C) = (ND * 0.02) - 273,15 \quad (3)$$

NDVI = *Normalized Difference Vegetation Index*;

EVI = *Enhanced Vegetation Index*;

TST = Temperatura de Superfície Terrestre em graus célsius;

ND = Valor numérico digital do pixel da imagem.

2.2.2 Processamento das imagens LANDSAT-5/TM

A etapa de pré-processamento das imagens Landsat envolvem reprojeções para o sistema sinusoidal, a mesma dos produtos EVI, NDVI e TST. Gerou-se a composição “falsa cor” utilizando as bandas 3, 4 e 5 posicionando-as nos canais 4 (vermelho), 5 (verde) e 3 (azul) da composição colorida RGB. Nesta composição, a vegetação, que tem alta refletividade na faixa espectral do infravermelho próximo (banda 4 do Landsat), assume tonalidades de magenta, o que possibilita uma maior diferenciação do alvo de interesse Sanches et al. (2005).

2.2.3 Análise estatística

Para verificar a acurácia da máscara, foram aplicados três métodos: matriz de erro, exatidão global (EG) e índice *Kappa*. A matriz de erro analisa erros de inclusão e omissão. Já a exatidão global quantifica o total de acertos em relação ao total de amostras sorteadas sobre a imagem classificada. O índice *Kappa* (LANDIS; KOCH, 1977) determina a concordância ou exatidão da classificação feita a partir da imagem bruta. Para tal foram sorteados aleatoriamente pontos sobre a máscara de forma estratificada e desproporcional. Em seguida, estes pontos foram exportados para as imagens Landsat-5/TM, por apresentar maior resolução espacial, para verificar o número de acertos entre o mapeamento das culturas de verão geradas e as culturas de verão nas imagens R4G5B3 dos Landsat-5/TM.

O número de pontos sorteados sobre as máscaras das culturas de verão para cada ano agrícola foi baseado em Jensen (1986), onde o número mínimo de pontos pode ser determinado pela Equação 4.

$$n = \left[\frac{4(p)(1-p)}{E^2} \right] \quad (4)$$

sendo:

n = número mínimo de pontos para a amostra;

p = percentual de exatidão esperado (>0.8);

E = erro permitível, em %.

A partir da matriz de confusão foram obtidos os índices EG, utilizando a Equação 5, e o índice *Kappa* utilizando a Equação 6, para todas as safras pré-estabelecidas.

$$EG = \frac{A}{n} \times 100 \quad (5)$$

sendo:

EG = exatidão global;

A = total de acertos;

n = número total de pontos.

$$K = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (X_{i+} \times X_{i+})}{n^2 - \sum_{i=1}^r (X_{i+} \times X_{i+})} \quad (6)$$

sendo:

K = coeficiente *kappa* de concordância;

n = número de observações (pontos amostrais);

r = número de linhas da matriz de erro;

X_{ii} = observações na linha *i* e coluna *i*;

X_{i+} = total marginal da linha *i*;

x_{+i} = total marginal da coluna *j*.

3 RELIABILITY OF SUMMER CROP MASKS DERIVED FROM SECOND ORDER POLYNOMIAL EQUATIONS

Christiano L. Arraes, Rubens A. C. Lamparelli, Jansle V. Rocha, Julio C. D. M. Esquerdo, Pablo Salvador, Javier Rodríguez, José-Luis Casanova Roque, Julia Sanz Justo & Beatriz G. Benatti.

Abstract – Remote Sensing techniques are useful to determine planted areas, especially of commodities like maize and soybeans (summer crops). The vegetation indexes as NDVI (Normalized Difference Vegetation Index) have been used to map agricultural areas due to its low cost and accessibility. Therefore the objective of this study was to develop a new methodology to generate masks of summer crops based on fitting second order polynomial equations to temporal NDVI profiles. The results showed that selecting polynomial equations with R^2 fitting above 0.75, a Kappa index of 0.86 and a global accuracy of 93% are obtained. This is slightly higher than the results obtained when using the maximum-minimum NDVI technique, with a Kappa index of 0.82 and a global accuracy of 91%. However, while quantifying the areas under study, it was verified that the mask used by the proposed methodology was closer to the official IBGE data, with a difference of -10.25%, followed by the vector technique with 23% and by the maximum-minimum NDVI, with a difference of 42.8%.

Keywords: *Glycine max (L.) Merr;* *Zea mays (L.)*; polynomial equations, NDVI, MODIS

3.1 Introduction

Information on the dynamics of crops in Brazil are extremely important because the space occupied by them changes constantly due to market, environment, migration and public policy, to mention only a few factors. The governmental bodies responsible for the estimation of cultivated areas in Brazil are IBGE (Brazilian Institute for Geography and Statistics) and CONAB (National Company for Provision/Ministry for Agriculture,

Livestock and Provision) and at regional level, there are several organizations connected to State governments such as DERAL/SEAB (Department of Rural Economy from the Paraná State, Secretary for Agriculture).

These institutions perform field surveys and data analysis for the estimation of areas, which are expensive and time consuming. In the literature there are other techniques, such as remote sensing, that help to map agricultural fields (DORAISWAMY et al., 2004; CHANG et al., 2007) and consequently to estimate planted areas. Among the several remote sensing characteristics, one of the most important is its temporality, filling out the need of up-to-date information, in the dynamic agriculture context, subsidizing reliably decision making. In accordance with this, CONAB took the initiative to aggregate to its analysis tools, information derived from remote sensing and geo-processing, to subsidize decisions for the estimation of areas and harvesting from cultures (CONAB, 2012).

Remote sensing has been used to survey planted areas from both temporary and permanent crops (MERCANTE et al., 2009). It is a consensus in the literature that mapping of crops must take into account the temporal aspect of the vegetative cycle (SAKAMOTO et al., 2005; RUDORFF et al., 2007; LAMPARELLI et al., 2008). Several authors are using the vegetation indices, which allow a more efficient exploration of wavelengths that present significant responses to certain biophysical parameters (foliar area, photo-synthesizing pigments) of vegetation (PONZONI; SHIMABUKURO, 2007).

Among the several vegetation indices, the NDVI (Normalized Difference Vegetation Index), proposed by Rouse et al. (1973) can be mentioned, which operates in the red and near-infrared wavelengths. This index allows improving the monitoring of the crop development, and for this purpose, the basic aspect to be considered is the study of the spectral profile, obtained from variations of NDVI with time (ESQUERDO et al., 2011; RAMME et al., 2010). Some studies, at local or regional levels (MARTINEZ; GILABERT, 2009) have already tested the performance of using changes of vegetation indices with time to identify and map annual crops (WARDLOW et al., 2008). These works had opened several new perspectives for the speed at which the areal information is generated. However In spite of digital the advancement of mapping, some questions still remain unanswered.

A crucial open issue for the generation of areal information is the reliable separation of targets. Studies by Nuarsa et al. (2011) have correlated values of rice productivity with NDVI data, adjusting the temporal evolution with second-order polynomial equations. They found R^2 values greater than 0.9. When considering the reliability of mapping, which here is defined as a “masks”, one reports to traditional test methods such as the Kappa index and the global accuracy (CONGALTON, 1991; CONGALTON, 2001), which are not sufficient to validate mapping made with remote sensing data. A new approach is necessary to correlate more directly classification with statistics.

Due to that, we proposed to develop an appropriate methodology to generate masks of summer crops, based on second order polynomial equations, fitted to temporal NDVI profiles in the municipality of Cascavel, Paraná State, adopting the determination coefficients from these equations as indications of the reliability levels of the mask.

3.2 Study Area, Data and Method

This study was accomplished at the Cascavel municipality, within the agricultural belt of Paraná State, located between latitude S 24°44'33.72" and S 25°22'16.59", longitude W 53°04'21.12" and W 53°43'23.88", occupying an area of 2,103 Km² (Figure 3.1). The climate type, according to Köppen (1931) is cfb, Sub-tropical humid, with average annual temperatures of 19°C, average temperature in the hottest month above 22°C, and average temperature of the coldest month below 18°C. The predominant soil types of this region are Oxisols, Ultisols and Alfisols (INSTITUTO DE TERRAS, CARTOGRAFIA E GEOCIÊNCIAS, 2008).

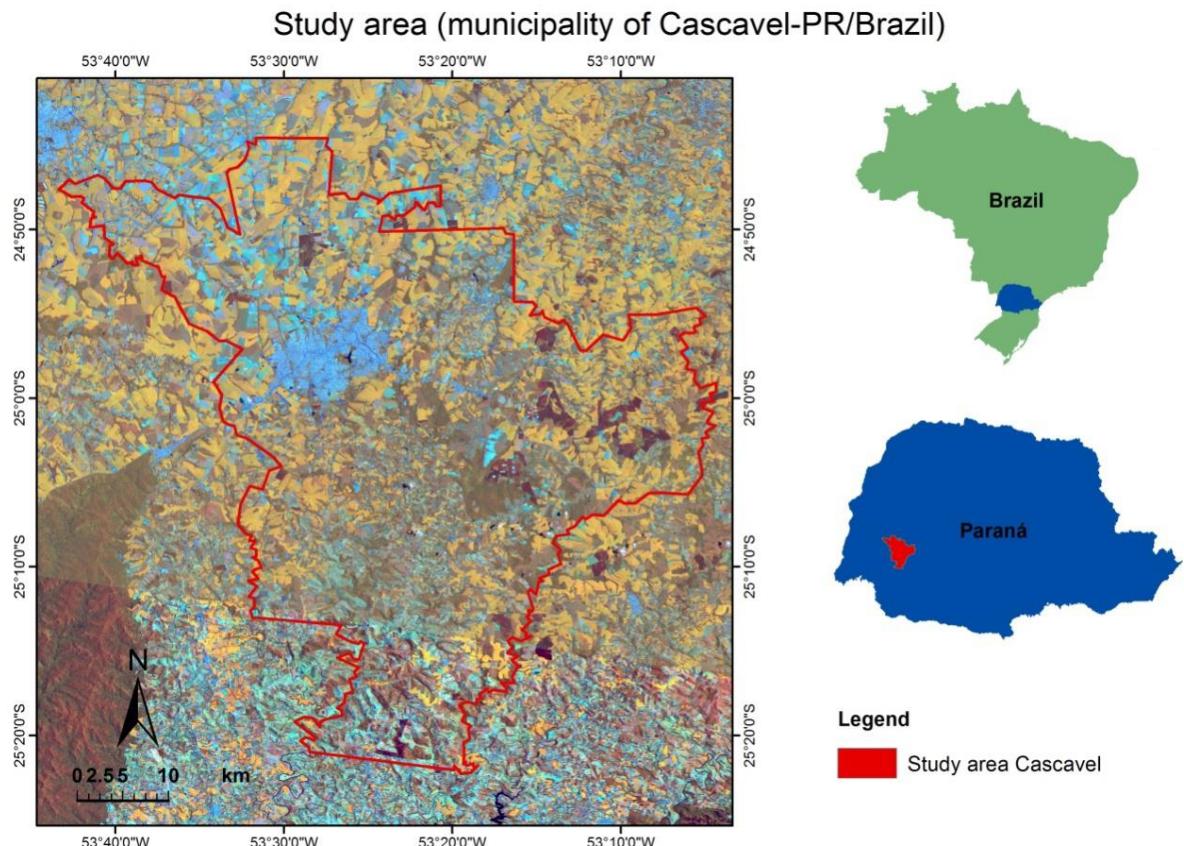


Figure 3.1: Area under study.

The slopes are smooth on the northern section and smooth to undulating at the southern section according to Figure 3.2. The largest part of the municipality presents slopes between 0 and 10%, followed by slopes of 10 to 20%, predominantly at its southern portion (ITCG, 2008).

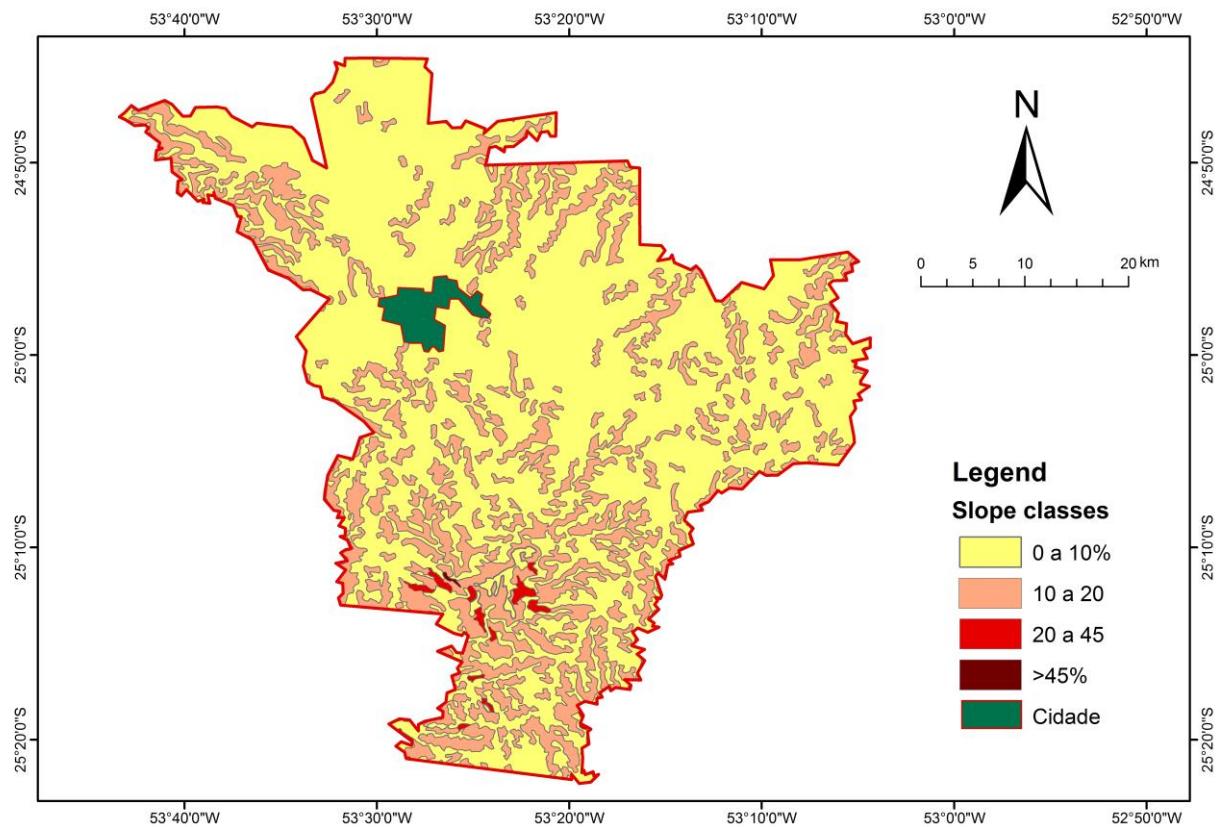


Figure 3.2: Map of slopes, Cascavel urban area (city), Paraná State.

The flow diagram presented at the Figure 3.3 describes the steps of the work considering, basically, two goals:

- To generate a mask based on second order polynomial equations, fitted to temporal NDVI profile;
- To compare the mask generated, in step 1, with the mask generated by visual interpretation of TM/Landsat 5 images (RGB-453)

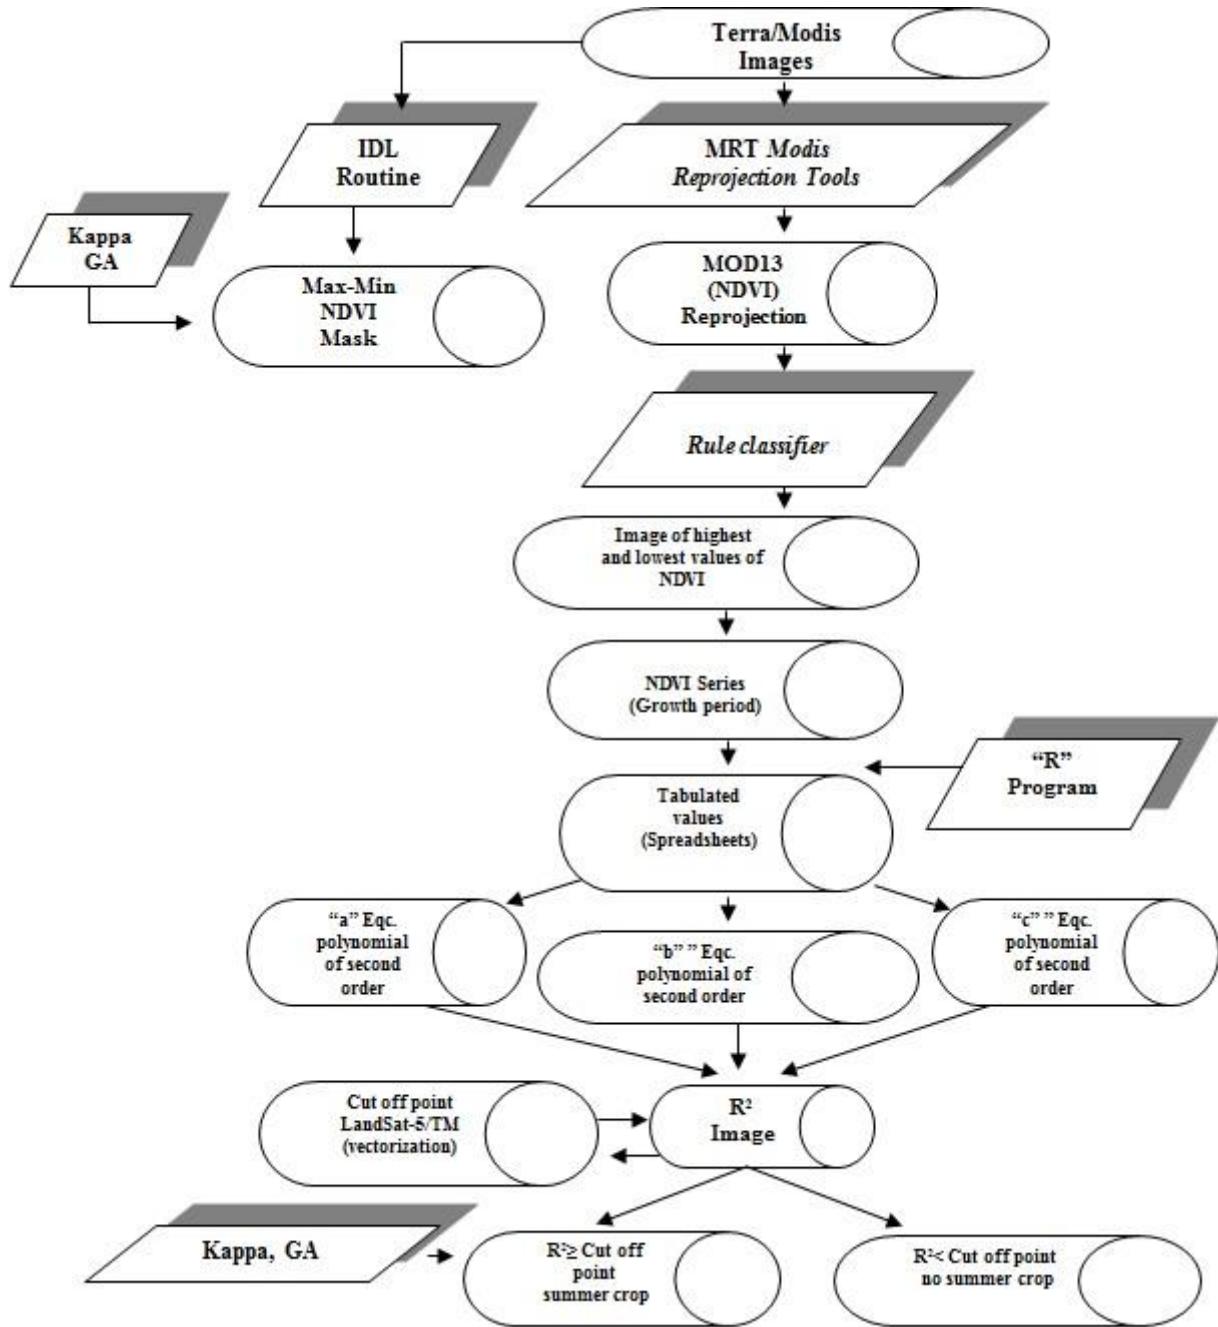


Figure 3.3: Flow diagram of the methodology.

3.2.1 Acquisition, Extraction and Re-Projection of MODIS/TERRA Images

In this study used spectral data from MODIS (Moderate Resolution Imaging Spectrometer), onboard TERRA satellite, product MOD13Q1 (HUETE et al., 1999), referring to NDVI. This product was downloaded, free of costs, from NASA homepage

(NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, 2012). For the image extraction followed by re-projection, we used software MRTools (MODIS Re-projection Tools), developed by NASA. The raw HDF (Hierarchical Data Format) images were processed to separate the NDVI product from all others, as well as re-projected of the lat/long coordinates, datum WGS-84. At the end of the procedure, the images were saved in GeoTiff format and manipulated on ENVI 4.5 program.

3.2.2 Acquisition and Re-Projection of LANDSAT-TM 5 Images

LANDSAT-TM 5 images were acquired at bands 3 (0.63-0.69 μm - red), 4 (0.76-0.90 μm - near infrared) and 5 (1.55-1.75 μm medium infrared) scenes 223/077 and 223/078 from Feb. 4th, 2008. These images are available, free of costs, from INPE (INPE, 2012), the Brazilian National Institute for Space Research.

3.2.3 Transformation of LANDSAT-TM 5 Images in Vectors

To transform those areas of summer crops (soybeans and maize) in vectors, initially a color composition with RGB-453 was used. In this composition, at maximum vegetative time (peak vegetative) the summer crops present a spectral standard that allows its visual discrimination from other targets (Figure 3.4) followed by its manual transformation in vectors using program ArcGIS 9.3 (SANCHES et al., 2005). From this procedure a map of summer crops mask was generated. This map was used as a reference to find the cutoff point at the construction of the mask originated from the methodology of the polynomial equations.

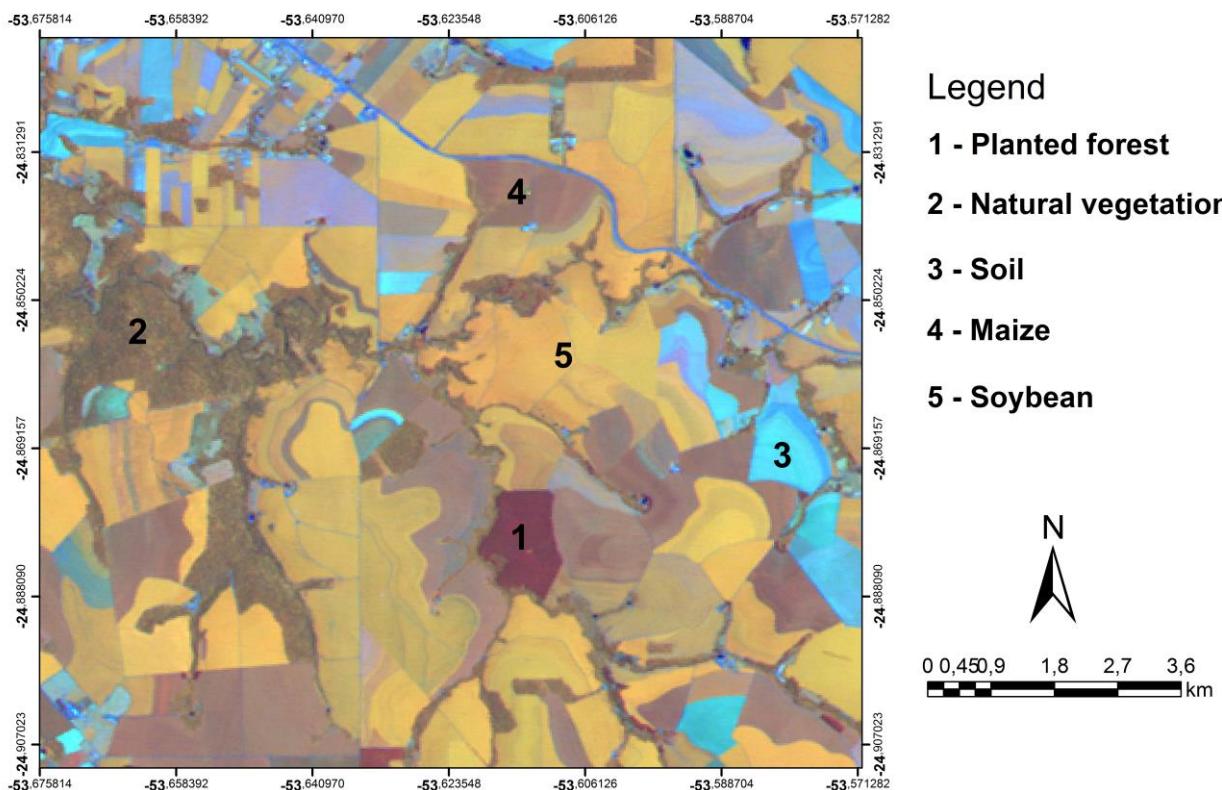


Figure 3.4: “False color” composition R4G5B3, LANDSAT-TM 5.

3.2.4 Visualization of the Temporal NDVI Profile for Summer Crops (Soybeans and Maize) in the MODIS Images

The temporal NDVI profile for the agricultural year under analysis was processed with the ENVI 4.5 software, function Z profile (Spectrum). A set of 12 images, every 16 days, totaling 192 days, was necessary, which corresponds in average to the growing cycle of summer crops (soybeans and maize).

3.2.5 Identification of the Temporal NDVI Profile: the Beginning and the End of the Vegetative Cycle

Having the temporal profile, the beginning and the crop end of the cycle were identified by observing the standard of the curves generated with function Z (Spectrum) from ENVI 4.5, where changes referring to vegetal physiology can be diagnosed. According to Zhang et al. (2003) the NDVI profiles can show the phenological phase of the culture. Therefore sections were made on the temporal profiles to get only the crop cycle for the harvest of 2007/08. For this task the tool Rule Classifier, also from ENVI 4.5, was used. This tool identifies those dates (bands) with the lowest and highest values found in the temporal profile of the vegetation index. In this case, these values were considered as the beginning (lowest value) and the peak (highest value) of the vegetative period, according to a study by Zhang et al. (2003) who identified the different phonological phases of vegetative development in the NDVI temporal profiles.

3.2.6 Adequacy of Second Order Polynomial Equation for Each Pixel of a Temporal Series

After the identification of the NDVI temporal profiles, they were set in a matrix format (spreadsheets), where each spreadsheet corresponded to a date, and each cell of each spreadsheet to a pixel. With a dataset, the cell corresponding to a certain pixel at any X, Y position (geographical coordinates) a second order polynomial function was defined, using program R. The determination coefficient (R^2) for each equation indicates the degree of fitting of equations to the observed data. Values of R^2 were calculated following Equation 1 below:

$$R^2 = \left(\frac{SQP}{SQT} \right) \times 100\% \quad (1)$$

where,

SQT is the sum of squares from the dependent variable, and SQP is the sum of squares, because it is a polynomial surface.

The R program at the end of the fitting process, using the method of least squares, returned the values of coefficients “a”, “b” and “c” for the second order polynomial equations.

3.2.7 Construction of the Mask for Summer Crops (Soybean and Maize), Based on the Determination Coefficients of Second Order Polynomial Equations

These coefficients were adjusted to the temporal NDVI profiles for each pixel and an image was generated (the so-called “reliability image”), where each pixel corresponds to the value of the determination coefficient. Afterwards 2 classes were discriminated: 1st determination coefficients larger or equal to 0.75. ($R^2 \geq 0.75$) and 2nd determination coefficients smaller than 0.75 ($R^2 < 0.75$), for the average NDVI profile. In order to determine this point, the known areas occupied with summer crops were considered, using for this purpose the vectors obtained from the LANDSAT-TM 5 image, described earlier.

3.2.8 Construction of the Mask Summer Crops (Soybeans and Maize) Using the Maximum-Minimum NDVI Methodology

This methodology consists on the use of several NDVI images to obtain the so-called “Minimum NDVI image” and “Maximum NDVI image”. The methodology was considered due to take in consideration the natural profile presented by NDVI representing the growing cycle in annual crops, that is, minimum values at the beginning of the cycle increasing during the growing season and decreasing after growing peak. Hence the methodology has considered the variation in maximum-minimum amplitude in NDVI values. Due to the variability of sowing dates, which can be checked in the maize and soybean agricultural calendars for Paraná State, at Table 3.1 (PARANÁ, 2011) the maximum and minimum were considered taking in account a time of period instead of just one date.

Table 3.1: Monthly percentage of sowing and harvesting maize and soybean, Paraná State, harvest 2007/08.

Crop year	Situation	Au g	Sep	Oct	Nov	Dec	Jan	Feb	Mar	Apr	May	Ju n	Jul
Crop 2007/08	Sowing maize	1%	14 %	55 %	27 %	3%	-	-	-	-	-	-	-
	Harvesting maize	-	-	-	-	-	1%	13 %	36 %	33 %	13 %	3%	1%
Crop 2007/08	Sowing soybean	-	-	23 %	63 %	14 %	-	-	-	-	-	-	-
	Harvesting soybean	-	-	-	-	-	-	11 %	45 %	34 %	10 %	-	-

Fonte: SEAB/DERAL (2011).

For the generation of minimum NDVI images, which includes the sowing phase, scenes from September to November were processed and for the maximum NDVI image, corresponding to the vegetative peak, images from December to February were used, so that the entire vegetative cycle was included, independently of the sowing date, which varies a lot in the region under study. This procedure was implemented in IDL language, according to a methodology described by Fernandes et al. (2011).

3.2.9 Application of the Kappa Index, Global Accuracy and Error Matrix

For the statistical verification of the accuracy from the second order polynomial functions over each pixel at the polynomial mask, three methods were applied, namely: the error matrix or contingency, global accuracy (GA) and Kappa index (Landis & Koch, 1977). To do that, 100 points were drafted over the polynomial masks and minimum-maximum NDVI, on a stratified and disproportionate form. Afterwards these points were exported to an image obtained by LANDSAT-TM 5 because it has a relative higher spatial resolution (30 m at the visible bands) to verify the number of agreement hits with class summer culture (polynomial methodology), as well as by the maximum-minimum NDVI, and so to obtain the error matrices.

3.2.10 Comparison among Data from Cultivated Area (Summer Crops)

Comparisons were made among summer crop areas, obtained by the maximum-minimum NDVI method described at item 2.8: vector data over LANDSAT-TM 5 data from Feb. 4th, 2008, and data obtained with the methodology proposed using, for comparison purposes, official data delivered by governmental agencies (IBGE, 2012).

3.3 Results and Discussion

The methodology proposed for generating summer crop masks (soybean and maize) by second order polynomial equations adjusted to temporal NDVI profiles was based on the standard of both crops in the field, because they have unique patterns of temporal profiles, according to a graphic representation (Figure 3.5). One verified that the temporal NDVI profiles follow a tendency, and that it is possible to adjust second order polynomial equations for each pixel of the temporal series. The vegetative cycle of summer crops is characterized by two distinct periods, which command its phenology (INPI, 2009). These two periods were identified in the Cascavel municipality, based on the average temporal NDVI profile, namely: 1st at the beginning of the photosynthesis activity until flowering (VE to V5) with an average cycle of 50 days; 2nd period extending from the formation of pods till the full maturation (R1 to R8), encompassing approximately seventy days. These phases depend on the varieties cultivated and on the climatic effects (GARCIA et al., 2007).

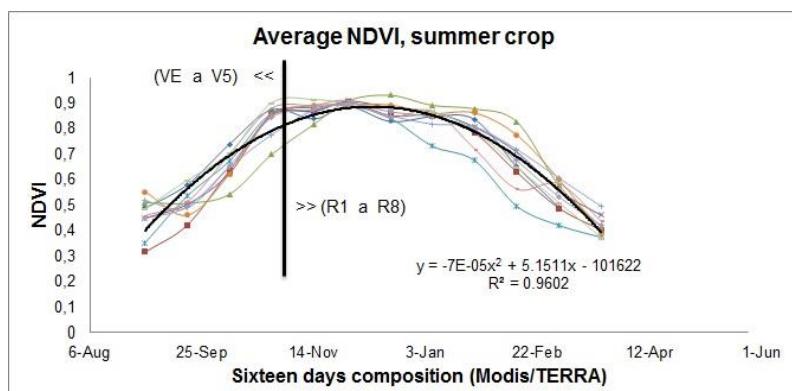


Figure 3.5: Representation of the average NDVI temporal profile for summer crop with vegetative (VE to V5) and reproductive (R1 to R8) phases, Municipality of Cascavel - Paraná State, 2007-08 harvest.

The cutoff chosen, considering the average value of the determination coefficients found within the crop mask, was 0.75. Since this is a relatively high value, it was assumed that the adjusted polynomial equation, would represent its vegetative development cycle. Zhang et al. (2003) reported that it is possible to adjust functions to temporal NDVI series for the phenology of some characteristic ecosystems. Nuarsa et al. (2011) found R^2 values between 0.916 and 0.973 by adjusting NDVI temporal evolutions with polynomial equations of second order in rice crops. These R^2 values are agreed with the results obtained in the present work.

As for the temporal NDVI profiles, which don't represent the summer crop, the fittings to the second order polynomial equations gave a low determination coefficient, in average below 0.57. Figure 3.6 shows the fitting of the second order polynomial equations to targets which are not summer crops.

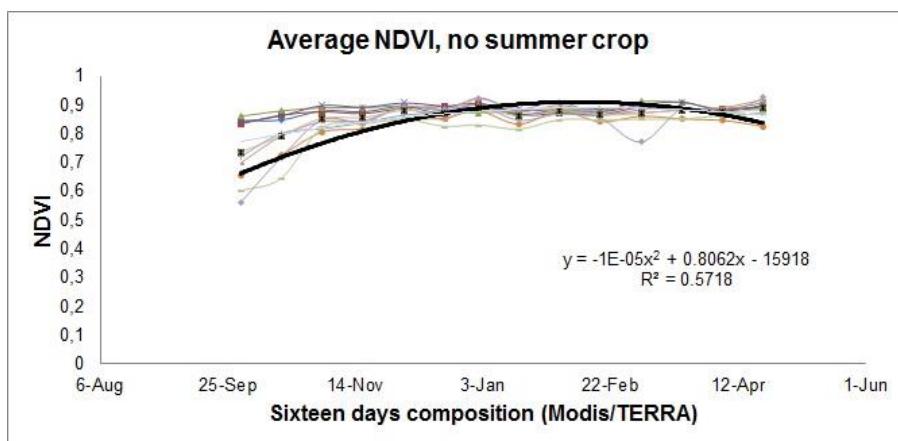


Figure 3.6: Representation of an average NDVI temporal profile for targets which are not summer crops in the Cascavel municipality, 2007-08 harvest.

Table 3.2 shows the error matrix between the mask generated from the LANDSAT-TM 5 image and the summer crop mask, generated by the methodology proposed, using $R^2 > 0.75$. This limit was chosen because the area generated is very close to that one originated from the LANDSAT-TM 5 image. One observes coherence among them, expressed by the Kappa index (KI) 0.86 and the global accuracy (GA) of 93%, indicating that the mask generated from R^2 values above 0.75 are tolerable to select summer crops in temporal NDVI series. Studies performed by Zhou et al. (2008) found an EG between 88.9% and 95.2%, used to validate high spatial resolution images.

This result indicates that the mask has an excellent reliability to map summer crops with the methodology presented.

Table 3.2: Error matrix between the reference (LANDSAT-TM 5, “false color” R4G5B3) and the polynomial mask.

Polynomial Mask	Reference (Image - LandSat-5/TM, false color R4G5B3)		Total	Inclusion Error (%)
	Summer crop	No summer crop		
Summer crop	46	4	50	8
No summer crop	3	47	50	6
Total	49	51	100	IK = 0.86
Omission Error (%)	0.1	7.8	-	EG = 93%

However, the 8% inclusion values for summer crops and 6% for non-summer crops can be explained by the fact that the reference image is dated from February 2008. At this date, according to the Secretary for Agriculture and Provision of Paraná / Dept. of Rural Economy - SEAB/DERAL (2011), many regions, above 24%, had already been harvested, presenting high error values. Some of the points randomly drafted, could have been these regions. This fact was proven by temporal NDVI profiles, presenting a typical standard of summer crops. When comparing visually the LANDSAT-TM 5 composition R4G5B3 (Figure 3.7a) with the polynomial mask (Figure 3.7b) one verifies that at the southern center of the municipality there was a lower occurrence of summer crops, in spite of a more rolling terrain if compared to the northern section of the municipality.

This may be the reason why farmers prefer to plant maize in small areas, instead of soybeans, because maize can be harvested manually, on the contrary of soybeans, whose harvest have to be performed only mechanically with higher costs. One observes also that these are bare soil areas, planted with summer crops, because the NDVI temporal profile reveals this condition and these areas were easily observed in LANDSAT-TM 5 RGB-453 composition images. It is also probable to be maize, because this corn is normally planted before soybean. This observation can be corroborated by the analysis of the LANDSAT-TM 5 reference image, indicating it (Figure 3.7a). This analysis is strengthened by the importance of continuous temporal monitoring, delivered by the Modis sensor, with a higher temporal resolution than TM.

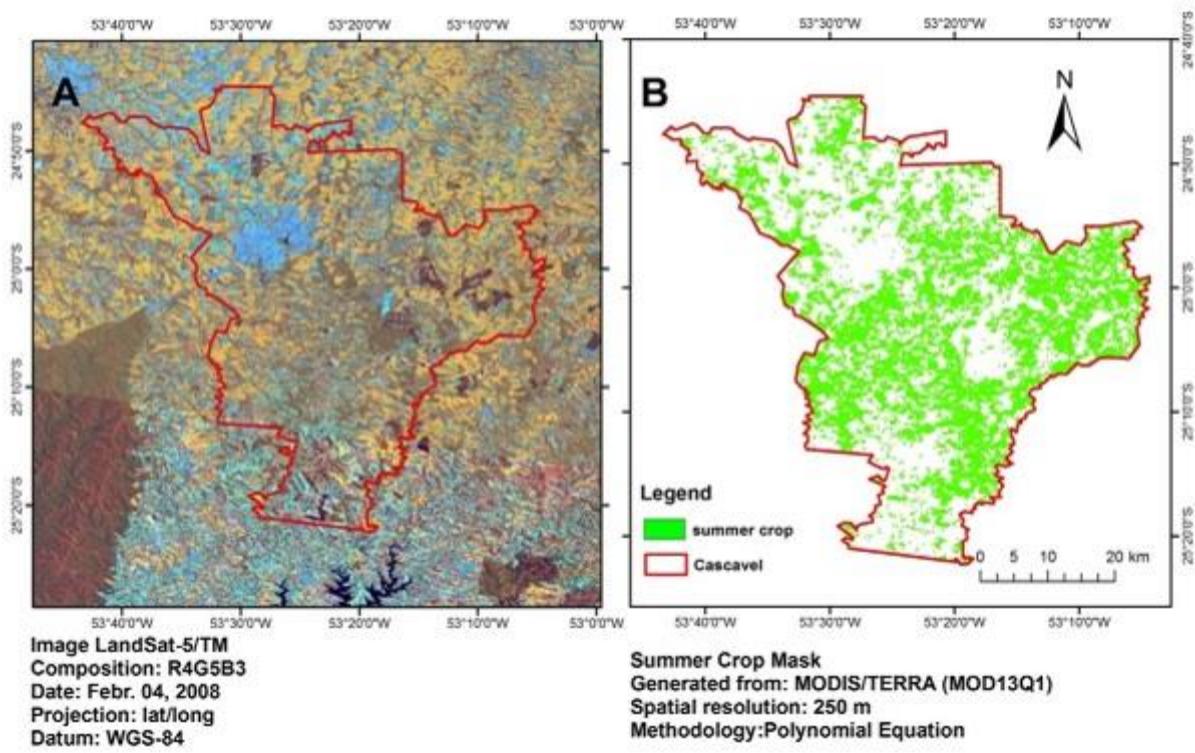


Figure 3.7: Comparison between LANDSAT-TM 5 image and the summer crop mask, obtained by polynomial methodology.

When correlating the mask obtained with the maximum-minimum NDVI methodology with the LANDSAT-TM-5 reference (Figure 3.8a), one verifies that the central-southern region of the State didn't have many selected areas, related to the mask obtained by the polynomial methodology (Figure 3.8b). Probably this is due to the fact the minimum-maximum NDVI methodology is based on the difference between both maximum (vegetative peak) and minimum (sowing) NDVI, considering as cutoff point those values where this difference is not significant, which can cause omission errors. However, the mask generated by the polynomial methodology with R^2 fitting above 0.75 considers more information, because fitting is done over the entire temporal series of NDVI, and therefore it presents a higher chance to identify the crops, whereas the maximum-minimum NDVI methodology considers only part of the cycle.

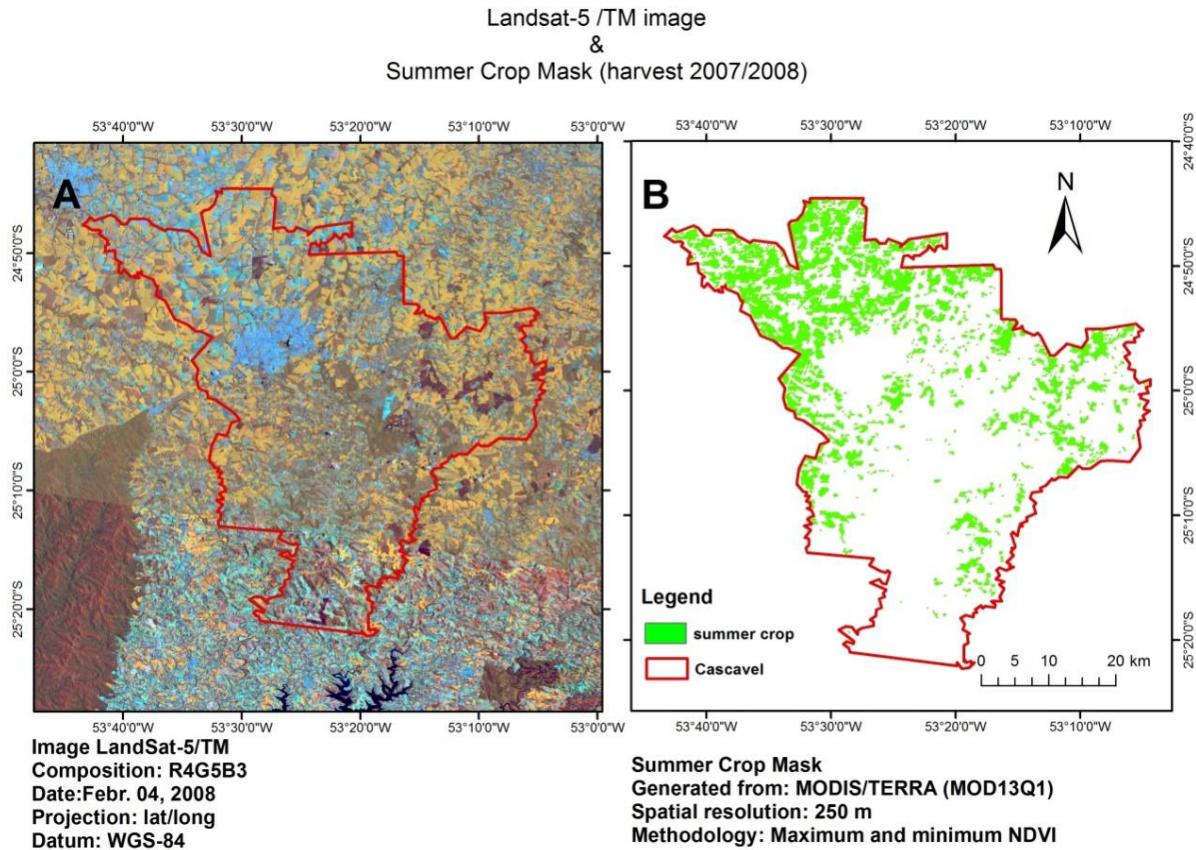


Figure 3.8: Comparison between LANDSAT-TM 5 image and summer crops mask, obtained with maximum-minimum NDVI methodology.

Table 3.3 shows the error matrix between the LANDSAT-TM 5 image and the summer crops mask, generated by the maximum-minimum NDVI methodology. One verifies here that the Kappa values of 0.82 and global accuracy of 91% are slightly below those obtained by the polynomial methodology, but the omission error of 0.04% for the summer crops demonstrates that the maximum-minimum NDVI mask was excellent for the identification of summer crops. However when observing the omission error (12.7%) for the non-summer crops, indicates that the methodology was not able to select all the areas of summer crops, testified by the omission areas in the center south, differently from the polynomial methodology which presented an omission error of 7.8%, probably because much more areas of bare soil were identified as summer crops, according to the temporal NDVI profile of these areas.

Table 3.3: Error matrix between the reference (LANDSAT-TM 5) and the maximum-minimum NDVI mask.

max-min Mask	Reference (Image - LandSat-5/TM, false color R4G5B3)		Total	Inclusion Error (%)
	Summer crop	No summer crop		
Summer crop	43	7	50	14
No summer crop	2	48	50	4
Total	45	55	100	IK = 0.82
Omission Error (%)	0.04	12.7	-	EG = 91%

Comparing the areas of summer crops (soybean and maize) determined by the 3 methodologies, fitting polynomial equations to the temporal NDVI series, maximum-minimum NDVI and vectorization of LANDSAT-TM 5 image, one verifies that the proposed methodology of polynomial equation fitting approached most to the official IBGE data for the harvest under study. A differential error of -10.25% was found, followed by vectorization with 23.5% and by the maximum-minimum NDVI mask, with a difference of 42.8%, according to Table 3.4.

Table 3.4: Comparison between official IBGE data and masks obtained by the following methodologies: fitting of polynomial equations to temporal NDVI series, maximum-minimum NDVI and vectorization of LANDSAT-TM 5 image, harvest 2007/08.

<i>Variables</i>	<i>Harvest</i>
	2007/08
Area IBGE (ha)	82.850,00
Polynomial Mask area(ha)	91.346,94
Difference (IBGE –Polynomial Mask) (ha)	8.497,00
Difference (%)	10.25
max-min NDVI Mask area (ha)	47.385,902
Difference (IBGE –max-min NDVI Mask) (ha)	35.464,00
Difference (%)	- 42.8
Vectorized Area from LandSat-5/TM (ha)	63.337,444
Difference (IBGE – Vectorized Area) (ha)	19.513,00
Difference (%)	- 23.5

3.4 Conclusions

The NDVI product, a 16 days composition, generated with Modis sensor images, allowed to draw temporal profiles of the summer crops and to correlate them with the corresponding phenologic phase. The mask generation methodology for the summer crops by polynomial equations fitted to the temporal NDVI profiles with R^2 above 0.75, obtained a global accuracy of 93%, slightly above the global accuracy found with the maximum-minimum NDVI methodology of 91%.

The results indicate that the methodology of mask generation for the summer crops by fitting of polynomial equations to temporal NDVI series obtained good results and it is close to the official IBGE data. They presented a lower omission error when compared to the maximum-minimum NDVI technique, indicating a higher precision at the classification, because it included more areas of summer crops.

Acknowledgments

We thank CNPq Scientific Initiation Scholarship as well as my sincere gratitude to CAPES/PDSE program scholarship for doctoral foreign stay and FAPESP for finance the project number: 2011/13748-8.

REFERENCES

- CHANG, J., HANSEN, M. C., PITTMAN, K., CARROLL, M., DIMICELI, C. Corn and soybean mapping in the United States using MODIS time-series data sets. **Agronomy Journal**, n. 99, p. 1654-1664, 2007. Disponível em: <<http://dx.doi.org/10.2134/agronj2007.0170>>. Acesso em: 15 fev. 2014.
- COMPANHIA NACIONAL DE ABASTECIMENTO. **GeoSafras**, 2012. Disponível em: <<http://geoweb.conab.gov.br/conab/>>. Acesso em: 15 fev. 2014.
- CONGALTON, R. G. A review of assessing the accuracy classifications of remotely sensed data. **Remote Sensing of Environment**, n. 37, p. 35-46, 1991. Disponível em: <[http://dx.doi.org/http://dx.doi.org/10.1016/0034-4257\(91\)90048-B](http://dx.doi.org/http://dx.doi.org/10.1016/0034-4257(91)90048-B)>. Acesso em: 05 jan. 2014.
- CONGALTON, R. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire**, n. 10, p. 321-328, 2001. Disponível em: <<http://dx.doi.org/10.1071/WF01031>>. Acesso em 13 fev. 2014.
- DORAISWAMY, P. C.; HATFIELD, J. L.; JACKSON, T. J.; AKHMEDOVA, B., PRUEGER, J.; STERNA, A. Crop condition and yield simulations using Landsat and MODIS. **Remote Sensing of Environment**, n. 92, p. 548-559, 2004. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2004.05.017>>. Acesso em: 13 fev. 2014.
- ESQUERDO, J. C. D. M.; ZULLO, J.; ANTUNES, J. F. G. Use of DVI/AVHRR time series profiles for soybean crop monitoring in Brazil. **International Journal of Remote Sensing**, v. 32, n. 13, p. 3711-3727, 2011. Disponível em: <<http://dx.doi.org/10.1080/01431161003764112>>. Acesso em: 10 jan. 2014.
- FERNANDES, J. L.; ROCHA, J. V.; LAMPARELLI, R. A. C. Sugarcane yield estimates using time series analysis of spot vegetation images. **Scientia Agrícola**, n. 68, p. 139-146, 2011. Disponível em: <<http://dx.doi.org/10.1590/S0103-90162011000200002>>. Acesso em: 05 jan. 2014.
- GARCIA, A.; PÍPOLO, A. E.; LOPES, I. A. N.; PORTUGAL, F. A. F. **Instalação da lavoura de soja: época, cultivares, espaçamento e população de plantas**. Londrina: Embrapa Soja, 2007.
- HUETE, A.; JUSTICE, C.; LEEUWEN, W. V. (1999). **Modis vegetation index (mod 13) Algorithm theoretical basis document version 3**. University of Arizona. Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf>. Acesso em: 10 jan. 2014.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Banco de dados agregados**: Sistema IBGE de Recuperação Automática – SIDRA, 2012. Disponível em:

<<http://www.sidra.ibge.gov.br>>. Acesso em 15 jan. 2014.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Catálogo de imagens**

LANDSAT. São José dos Campos, SP, 2012. Disponível em: <<http://www.inpe.br/>>.

Acesso em: 10 jan. 2014.

INSTITUTO DE TERRAS, CARTOGRAFIA E GEOCIÊNCIAS. **Dados Cartográficos do Paraná**, 2008. Disponível em: <<http://www.itcg.pr.gov.br>>. Acesso em: 13 fev. 2014.

INTERNATIONAL PLANT NUTRITION INSTITUTE. **Como a planta da soja se desenvolve**. Piracicaba, n. 11, p. 2-23, 2009. Disponível em: <[http://www.ppi-ppic.org/ppiweb/BRAZIL.NSF/\\$webindex/434692071948C16083256B2700392EB](http://www.ppi-ppic.org/ppiweb/BRAZIL.NSF/$webindex/434692071948C16083256B2700392EB)>. Acesso em: 01 fev. 2014.

KOPPEN, W. **Grundriss der Klimakunde**. Berlin: Walter de Gruyter, 1931.

LAMPARELLI, R. A. C.; WASTE, M. O. C.; MERCANTE, E. Mapeamento de plantios de soja (*Glycine max* (L.) Merril) mediante dados MODIS/TERRA E TM/LANDSAT 5: um comparativo. **Engenharia Agrícola**, n. 28, p. 334-344, 2008. Disponível em: <<http://dx.doi.org/10.1590/S0100-69162008000200014>>. Acesso em: 10 jan. 2014.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, n. 33, p. 159-174, 1977. Disponível em: <<http://www.jstor.org/stable/2529310>>. Acesso em: 05 jan. 2014.

MARTINEZ, B.; GILABERT, M. A. Vegetation dynamics from NDVI time series analysis using the wavelet transform. **Remote Sensing of Environment**, n. 113, p. 1823-1842, 2009. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2009.04.016>>. Acesso em: 13 jan. 2014.

MERCANTE, E.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A.; ROCHA, J. V. Características espectrais da soja ao longo do ciclo vegetativo com imagens Landsat 5/TM em área agrícola no oeste do Paraná. **Engenharia Agrícola**, n. 29, p. 328-338, 2009. Disponível em: <<http://dx.doi.org/10.1590/S0100-69162009000200016>>. Acesso em: 07 jan. 2014.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **REVERB | ECHO**, 2012. Disponível em: <http://www.echo.nasa.gov/reverb/about_reverb.htm>. Acesso em: 09 jan. 2014.

NUARSA, I. W.; NISHIO, F.; HONGO, C. Relationship between rice spectral and rice yield using Modis data. **Journal of Agricultural Science**, v. 3, n. 2, p. 80-88, 2011. Disponível em: <<http://dx.doi.org/10.5539/jas.v3n2p80>>. Acesso em: 10 set. 2013.

PARANÁ. Secretaria da Agricultura e do Abastecimento. Departamento de Economia Rural. Banco de Dados da Produção Agropecuária. **Situação mensal de plantio, colheita e comercialização de produtos agrícolas no Paraná**. 2011. Disponível em: <<http://www.agricultura.pr.gov.br/arquivos/File/deral/pss.xls>>. Acesso em: 07 jan. 2014.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: A. Silva Vieira, 2007.

RAMME, F. L. P.; LAMPARELLI, R. A. C.; ROCHAa, J. V. Perfis temporais NDVI MODIS, na cana-soca, de maturação tardia. **Engenharia Agrícola**, v. 30, n.3, p.480-494, 2010. Disponível em: <<http://dx.doi.org/10.1590/S0100-69162010000300012>>. Acesso em: 12 jan. 2014.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: ERTS SYMPOSIUM, 3., 1973, São Paulo. **Annals**...São Paulo, 1973, p. 309-317. Disponível em: <<http://hdl.handle.net/2060/19740022614>>. Acesso em: 13 jan. 2014.

RUDORFF, B. F. T.; SHIMABUKUTO, Y.; CEBALLOS, J. C. **O sensor Modis e suas aplicações ambientais no Brasil**. São José dos Campos: Parêntese, 2007.

SAKAMOTO, T., YOKOZAWA, M.; TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N.; OHO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, n. 96, p. 366-374, 2005. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2005.03.008>>. Acesso em: 16 jan. 2014.

SANCHES, I. D.; EPIPCHANIO, J. C. N.; FORMAGGIO, A. R. Culturas agrícolas em imagens multitemporais do satélite Landsat. **Agriculturas**, v. 52, n. 1, p. 83-96, 2005. Disponível em: <www.iea.sp.gov.br/out/publicacoes/pdf/asp-1-05-6.pdf>. Acesso em: 11 jan. 2014.

WARDLOW, B. D.; EGBERT, S. L. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. **Remote Sensing of Environment**, n. 112, p. 1096-1116, 2008. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2007.07.019>>. Acesso em: 10 jan. 2014.

ZHANG, X.; FRIEDL, M. A.; SCHAAF, C. B.; STRAHLER, A. H.; HODGES, J. C. F.; GAO, F.; HUETE, A. Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, n. 84, p. 471-475, 2003. Disponível em: <[http://dx.doi.org/10.1016/S0034-4257\(02\)00135-9](http://dx.doi.org/10.1016/S0034-4257(02)00135-9)>. Acesso em: 12 jan. 2014.

ZHOU, O.; LI, B.; SUN, B. Modelling spatio-temporal pattern of land use change using Multitemporal remotely sensed imagery. The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**, n. 37-B, p. 729-734, 2008.

4 SPECTRAL SEPARATION OF MAIZE AND SOYBEAN CROPS USING LOGARITHMIC EQUATIONS APPLIED TO MODIS TIME-SERIES

Christiano L. Arraes, Rubens A. C. Lamparelli, Jansle V. Rocha, Julio C. D. M. Esquerdo, Pablo Salvador, Javier Rodríguez, José-Luis Casanova Roque & Julia Sanz Justo

Abstract – Remote sensing techniques are useful for the determination of agricultural areas, especially of commodities such as soybean [*Glycine max (L.) Merr.*], and maize (*Zea mays L.*). Nevertheless, not always the mapped areas correspond to the reality, due to spectral confusion, which occurs among these two crops. The objective of this study was to develop a methodology to distinguish these two crops, based on the angular coefficients of logarithmic equations, adjusted to Enhanced Vegetation Index (EVI) time-series, in municipalities of the State of Paraná, Brazil, during the 2007-08 cropping season. The results have shown that in areas with steep slopes it was impossible to distinguish them due to a strong spectral confusion. Nevertheless in flat areas it was possible to distinguish them. The spatially distributed results showed the municipalities separated in two different portions. The municipality located at the northern part of Paraná had its angular coefficients for soybean and maize statistically differentiated, and the average angular coefficient for maize was 0.61 and for soybeans 0.38, with a Kappa coefficient of 0.71 and overall accuracy of 81.2%. At the southern portion of Paraná, this perception was not possible because this area has hilly terrain and plantations in small fields, which precludes its distinction from sensor systems with a spatial resolution of 250 m like Modis/Terra.

Keywords: *Glycine max (L.)*; *Merr*; *Zea mays (L.)*; Equações logarítmicas; EVI; Modis

4.1 Introduction

Information about the dynamics of crops in Brazil is crucial, because the space occupied by crops changes constantly due to market conditions, environment issues, migrations and public policy. In Brazil, there are several Federal and State agencies responsible for the assessment of agricultural production. However, the usual methodologies, such as census and field sampling, are expensive and have a high degree of subjectivity.

Several studies demonstrated the potential of remote sensing as an alternative method to map crops and to estimate the planted area (DORAISWAMY et al., 2004; SAKAMOTO et al., 2005; KASTENS et al., 2005; CHANG et al., 2007; MORIONDO et al., 2007; INMAN et al., 2008; BOLTON; FRIEDL, 2013). Among the several characteristics of these techniques, one of the most important, their temporality, attends the needs of constant updating of such information, in the context of agricultural dynamics, subsidizing decision making with a higher reliability. Scientific studies using remote sensing, especially those employing vegetation indices, allow a more efficient use of the wavelengths with outstanding responses to certain bio-physical vegetation parameters. These studies demonstrated and reinforced the usefulness of this technique for the analysis of vegetation (JENSEN, 2000; MA et al., 2001; SAKAMOTO et al., 2010; LIU et al., 2010). Among the different vegetation indices available, two are more frequently used: the Normalized Difference Vegetation Index (NDVI) (ROUSE et al., 1973) and the EVI (DEFRIES; TOWNSEND, 1994; HUETE et al., 1997).

There is a worldwide tendency to use these indices in parallel with the crop vegetation cycle. To perform this task, the common basic aspect is to study the spectral profile generated along time-series which represents the variation of the vegetation indices (ESQUERDO et al., 2011; NUARSA et al., 2011; NGUY-ROBERTSON et al., 2012; ARRAES et al., 2013). Some local or regional studies (VIÑA et al., 2004; MARTINEZ; GILABERT, 2009; MKHABELA et al., 2011) tested the standard of vegetation indices throughout the cropping season, in order to identify and map annual crop types (WARDLOW et al., 2008; SARKER et al., 2012), as well as to identify the temporal profiles in different stages of crop growth. According to Fehr and Caviness (1981) and Ritchie et al. (1982), the development phases of soybean and maize can be

divided among the vegetative (V) and reproductive (R) stages. These two stages, however, occur at different periods, allowing the identification of the vegetative peaks through the vegetation indices, such as the EVI (WARDLOW et al., 2007).

Several studies have shown the possibility of identifying and discriminating the phenological stages of the crops through the analysis of temporal profiles of vegetation indices (TUCKER et al., 1978; ZHANG et al., 2003; SAKAMOTO et al., 2010).

According to Ritchie et al. (1982), six weeks after the plant emergence (approximately 40 days) maize is at stage V12, with 85% to 95% of leaf area, covering a large portion of the soil, differing from soybean, which reaches the maximum leaf area at stadium R5, approximately 90 days after sowing. However this condition depends on the variety climatic conditions, and mainly on the spacing used during sowing (HEIFFIG et al., 2006; HAN et al., 2006; ZHANG et al., 2009). The Modis sensor, used in this study, has a spatial resolution of 250-500 or 1000 m, depending on the wavelength or the product generated (HUETE et al., 1999; HUETE et al., 2002).

In this scenario, it is vital to analyze alternatives which would allow a systematic mapping, enabling the identification and discrimination of soybean and maize crops, considering also the cloud coverage occurring along the cropping seasons and the short growing cycle of the crop (3 to 4 months) (JACKSON et al., 2004; PETTORELLI et al., 2005; WARDLOW et al.; 2007; GITELSON et al., 2008; ARVOR et al., 2011). Therefore in spite of its low spatial resolution Modis, is an alternative, due to its high repeatability, attending the needs of coverage in regions with a high cloud frequency, to monitor targets with high spectral dynamics, such as agricultural areas.

For these reasons, the objective of this paper was to develop a methodology to spectrally discriminate soybean and maize crops, based on the angular coefficients of logarithmic equations adjusted to EVI time-series, obtained from Modis images in 62 municipalities from the agriculture belt in the State of Paraná, one of the main producers in Brazil, during the 2007-2008 cropping season.

4.2 Data and Method

4.2.1. Study Area

The study was carried out in 62 municipalities from the agriculture belt in the State of Paraná, including the Central-South, West and Central-West regions, between latitudes S $22^{\circ}29'30''$ to S $26^{\circ}42'59''$ and longitudes W $48^{\circ}02'24''$ to W $54^{\circ}37'38''$ (Figure 4.1). These regions are responsible for approximately 45% of the soybean and maize production in the State. According to the Köppen climate classification, this area belongs to Cfb class, sub-tropical humid climate, presenting average annual temperatures of 19°C, average temperature of the warmest month above 22°C and temperature of the coldest month below 18°C (KOPPEN, 1931). The main soil types in this region are Oxisols, Ultisols, Entisols and Alfisols (INSTITUTO DE TERRAS, CARTOGRAFIA E GEOCIÊNCIAS, 2008).

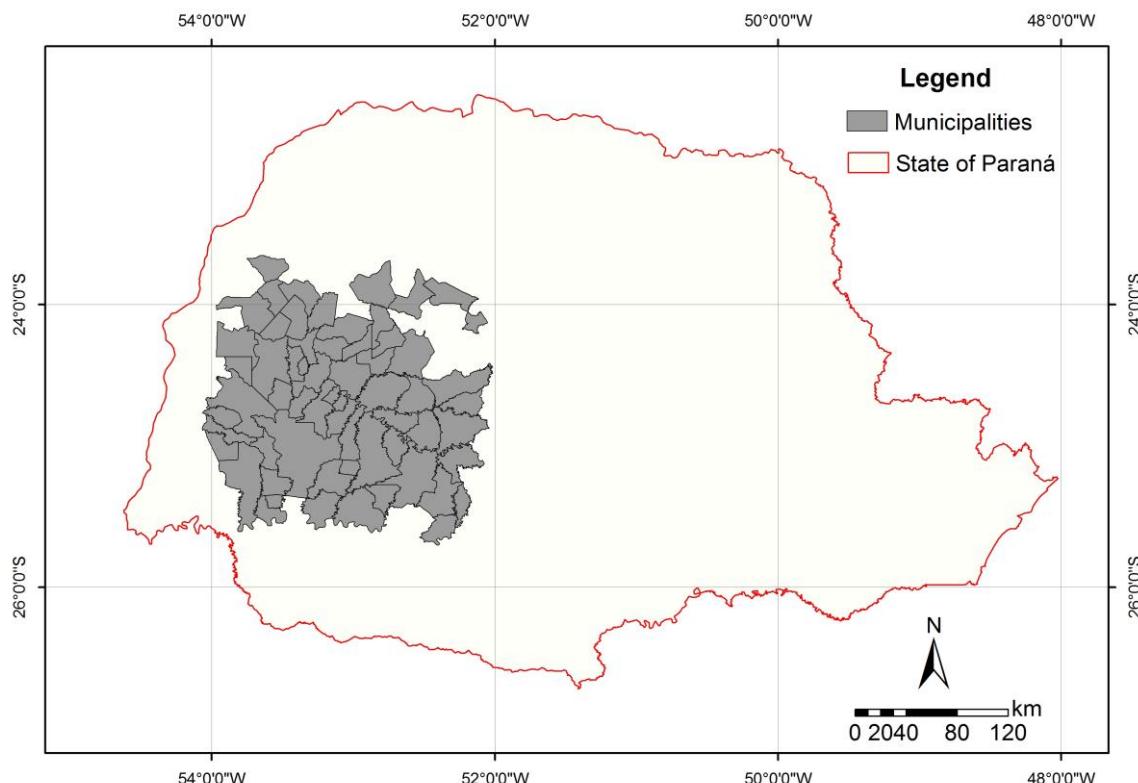


Figure 4.1: Municipalities studied in the State of Paraná.

4.2.2 Database

4.2.2.1 Acquisition of Modis/TERRA images

The spectral data were obtained from MODIS sensor, aboard TERRA satellite, product MOD13Q1 (HUETE et al., 1999), which has 12 products. In this study, the 16 days composition EVI was used, at “hdf” format and Sinusoidal projection. The 16-days EVI composition reduces chorus of cloud contamination, beyond the Quality Control product, which was also used to identify any possible cloud interference. These images are free-of-charge from the LP-DAAC/NASA (Land Processes Distributed Active Archive Center/National Aeronautics and Space Administration website).

4.2.2.2 Acquisition and re-projection of LANDSAT-TM 5 images

Landsat-5/TM images from Feb. 4th 2008, scenes 223/077 and 223/078, bands 3, 4 and 5 were gathered free-of-charge from INPE, the Brazilian National Institute for Space Research (INPE, 2011). Afterwards, they were re-projected to the Sinusoidal projection, the same of EVI products and converted to GeoTiff format.

4.3 Method

The methodology proposed to discriminate soybean and maize by the use of logarithmic equations fitted to temporal EVI profiles is based on the standard of these two crops, where they have different growth habits, vegetative structures and plant morphology.

Figure 4.2A shows the soybean and maize sown in the Cascavel region, one of the municipalities studied, with a time difference of sowing between both crops of approximately 20 days. Figure 4.2B, shows the soybean plantation at stage V2, 18 days after sowing, covering approximately 10% of the cultivated area. However, Figure 4.2C shows the vegetative stage of maize, at stage V8, with around 35 days after seeding. It

is possible to verify a clear differentiation among the leaf cover of soybean and maize, reinforcing the hypothesis that it is possible to discriminate them spectrally, supported by logarithmic equations adjusted to the initial stage of the EVI profiles. This information consisted of field collections in visited properties which grow soybeans and corn, as shown in Figure 4.2. The properties have size ranging from 50 to 200ha in the north and 20 to 100ha in Southern study area (62 municipalities).

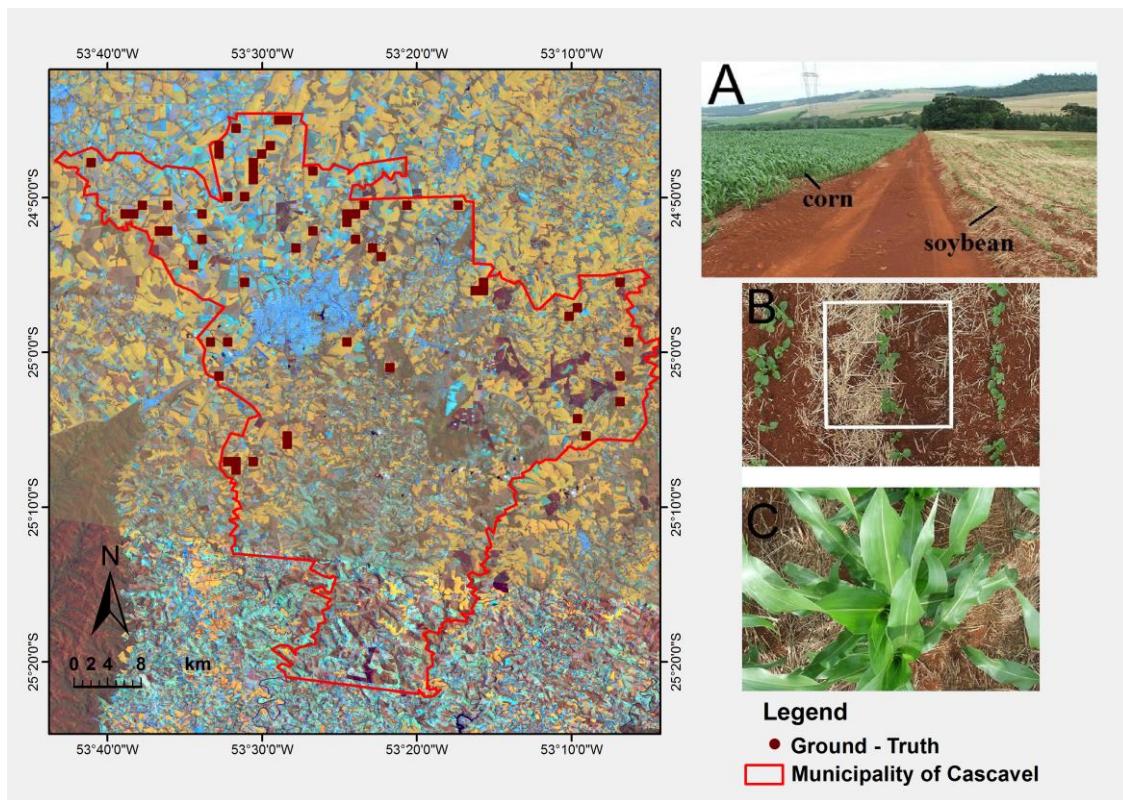


Figure 4.2: Area under study in the municipality of Cascavel – Paraná State (A) soybean and maize cultivated at the same time, (B) soybean sown at Oct. 22nd and (C) maize sown at Oct. 2nd.

Figure 4.3 illustrates a flowchart of the methodology, based on data obtained from low spatial resolution images (Modis/Terra) and medium spatial resolution images (Landsat-5/TM). The separation of maize and soybean crops using logarithmic equations, fitted to temporal EVI profile.

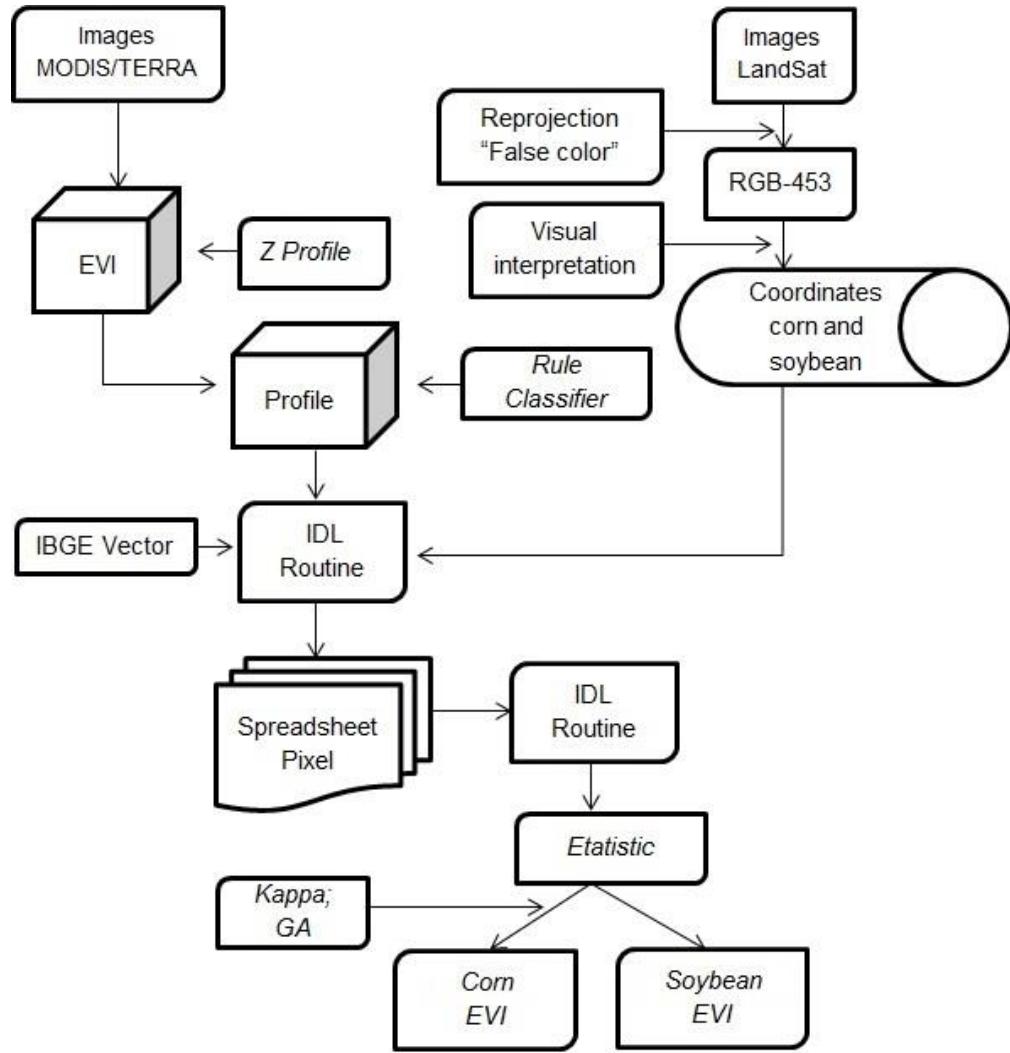


Figure 4.3: Flowchart of the methodology.

4.3.1 Generation of the angular coefficients of logarithmic equations

The logarithmic equations (Equation 1) were adjusted to the data, considering the average EVI values for each municipality, using an IDL routine, which runs over the entire time-series, and adjusts the equations to the data at the vegetative phase (VE to V5 – Figure 4.5). During this period we can observe differences in growing rate that are identified through the angular coefficients of those curves. It starts with the angular coefficients of the equations, considering every image pixel. Finally, the values of angular coefficients from maize and soybean crops were compared and statistically analyzed.

$$f(x) = \ell n(x) \quad (1)$$

4.3.2 Supervised classification of Landsat-5/TM images

For the soybean and maize samples selection, a color composite of bands 3, 4 and 5 (RGB453) was built, to facilitate the separation of these two crops (SANCHES et al., 2005). Afterwards, 50 training samples were collected for each crop, followed by a supervised classification, using the maximum likelihood algorithm and visual interpretation based on field knowledge. Figure 4.4 shows the control points of observation during the field survey on the classified image. Based on the Landsat classified image discriminating maize and soybean areas were chosen pixels in the Modis image and adjusted the logarithms equations which were used a posteriori as samples to differentiates maize from soybean during the vegetative phase.

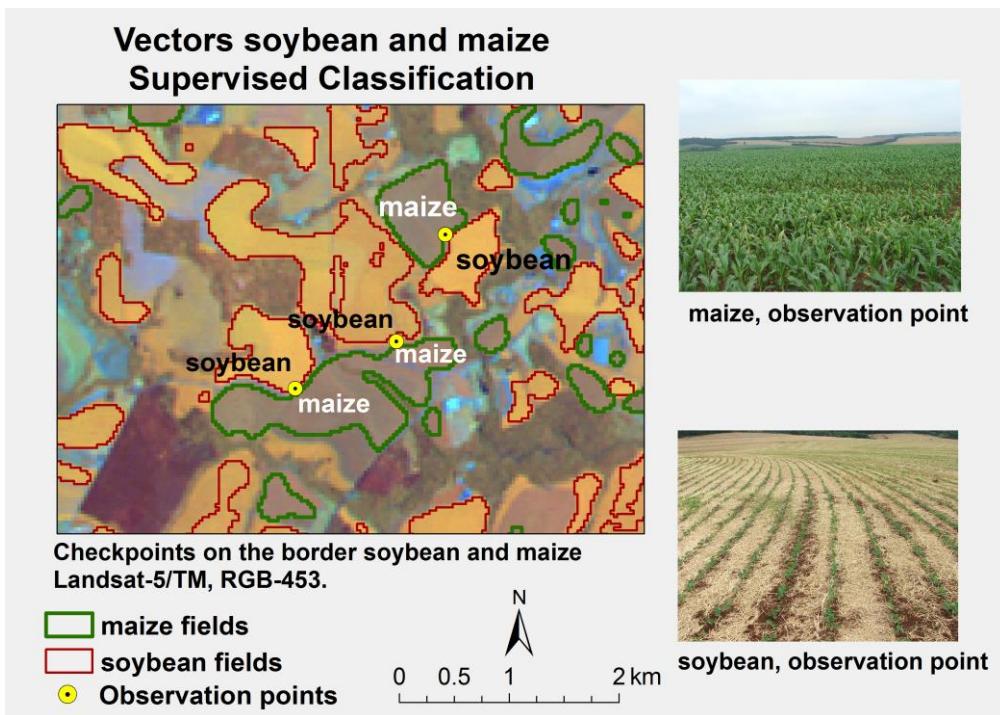


Figure 4.4: Supervised classification and fields in the municipality of Cascavel, in the State of Paraná.

4.3.3 Acquisition of soybean and maize fields geographic position

On the classified image, a median filter was applied in order to eliminate undesirable noise as well as the borders of soybean and maize fields. Such borders, constituted by mixed pixels, are interferences from other non-investigated targets and so the need to apply this filter, with a 3x3 window. Later, soybean and maize classes were extracted and converted to vector points, representing the center of the crop pixels, and exported to ASCII format.

4.3.4 Visualization of the EVI temporal profile of soybean and maize at MODIS images

The temporal profiles of EVI for the agricultural cropping season under analysis were processed with ENVI 4.5, using 14 maximum values composites (16 days), of 14 September 2007 to 27 March 2008 (Julian day: 257/2007; 273/2007; 289/2007; 305/2007; 321/2007; 337/2007; 353/2007; 001/2008; 017/2008; 033/2008; 049/2008; 065/2008; 081/2008 end 097/2008) to tile: h13v11, totaling 224 days, covering the entire cycle of these summer crops, independently of the sowing time.

4.3.5 Identification of the crops starting period and vegetative peak, in the temporal profile of EVI

In the temporal profile, these important stages of the vegetative cycle from both crops were identified, observing changes of vegetation phenology (Figure 4.5). In order to define the growth period, sections were generated in the temporal profiles, considering the lowest and highest vegetation development. This task was performed using the Rule Classifier from ENVI 4.5. This tool identifies the date (band) with the lowest and highest values of vegetation index in the temporal profile. Such values were considered here as the beginning and vegetative peak, respectively agreeing with the study performed by Zhang et al. (2003), which identified different phenological stages in the temporal profiles.

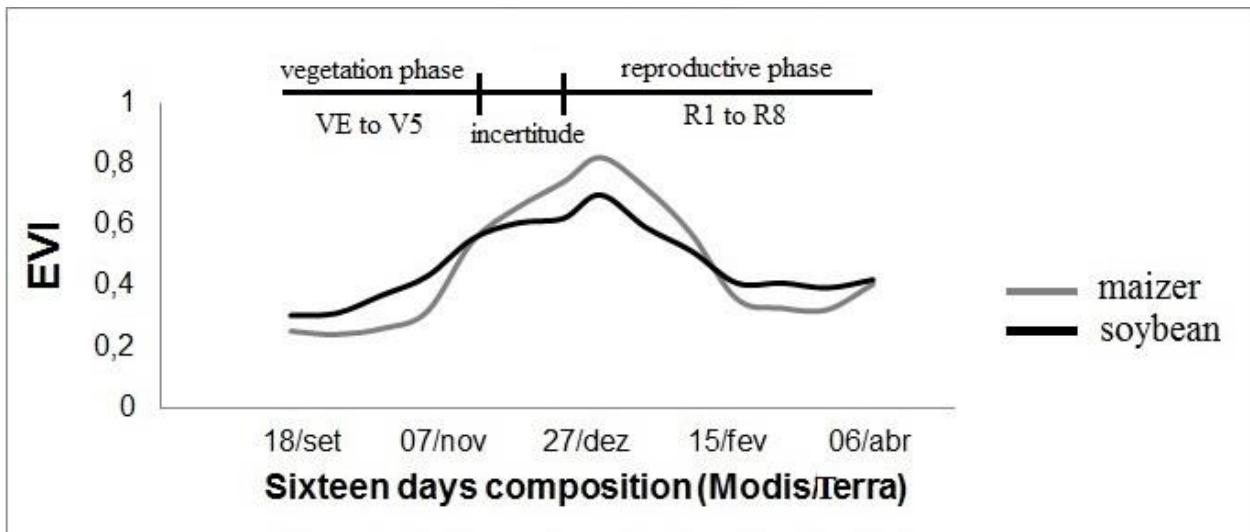


Figure 4.5: Representation of the temporal profile of EVI medium for the cultivation of maize and soybean, with the vegetative stages (VE to V5) and reproductive (R1 to R8).

4.4 Results and discussion

The methodology proposed to discriminate maize and soybean crops is based on its temporal standard in the field, once they have different vegetative development patterns. It is difficult to distinguish these two crops by the usual remote sensing techniques, especially due to the spectral confusion between them, once these crops are sown at the same period, according to Table 4.1 (PARANÁ, 2011). It shows the percentages of seeding in Paraná State during the 2007/08 cropping season. Furthermore, it must be considered that when using coarser spatial resolution sensors, such as Modis, this confusion is more intensive than higher spatial resolution sensors, such as LANDSAT-5/TM.

Table 4.1: Proportion of sowing and harvesting activities for soybean and maize in the State of Paraná.

Crop year	Condition	Aug.	Sept.	Oct.	Nov.	Dec.	%						
							Jan.	Feb.	Mar.	Apr.	May	June	July
Crop 2007/08	Sowing maize	1	14	55	27	3	-	-	-	-	-	-	-
	Harvesting maize	-	-	-	-	-	1	13	36	33	13	3	1
Crop 2007/08	Sowing soybean	-	-	23	63	14	-	-	-	-	-	-	-
	Harvesting soybean	-	-	-	-	-	-	11	45	34	10	-	-

While adjusting the logarithmic equations, it was verified that the municipalities were separated into northern and southern blocks. At the northern block, soybean was better discriminated from maize. This did not occur at the southern municipalities which presented, in general, distinct angular coefficients. However, when considering the respective standard deviations, it was verified for 31 municipalities that for both summation and subtraction generated a conflict zone, in contrast to the other 31 municipalities at the northern section, whose maize angular coefficient was differentiated from the soybean. This standard can be observed in Figure 4.6 and Figure 4.7.

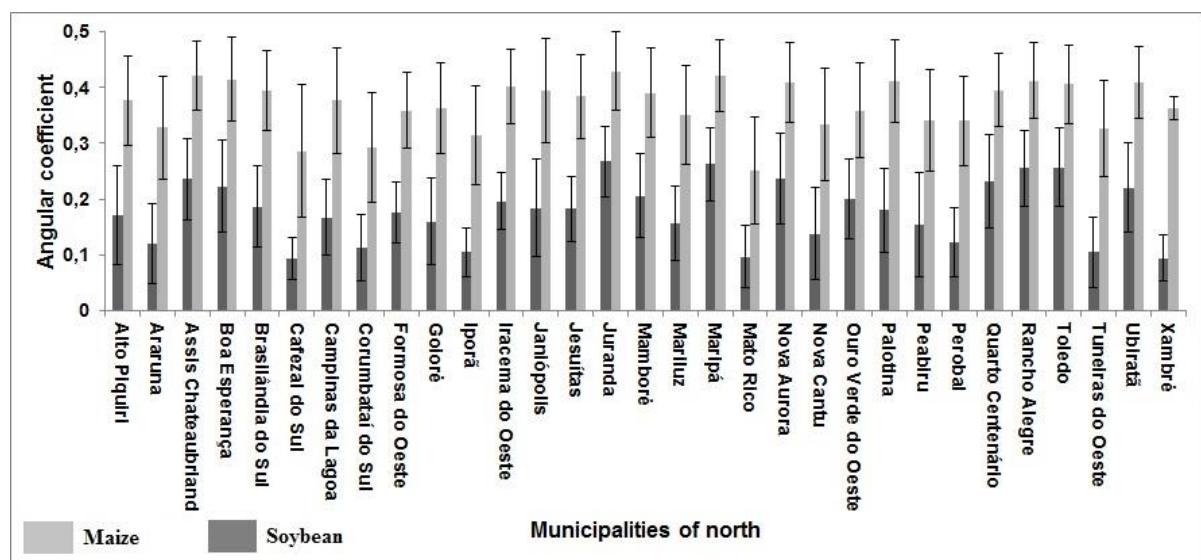


Figure 4.6: Angular coefficient and standard deviation for the 31 municipalities of north.

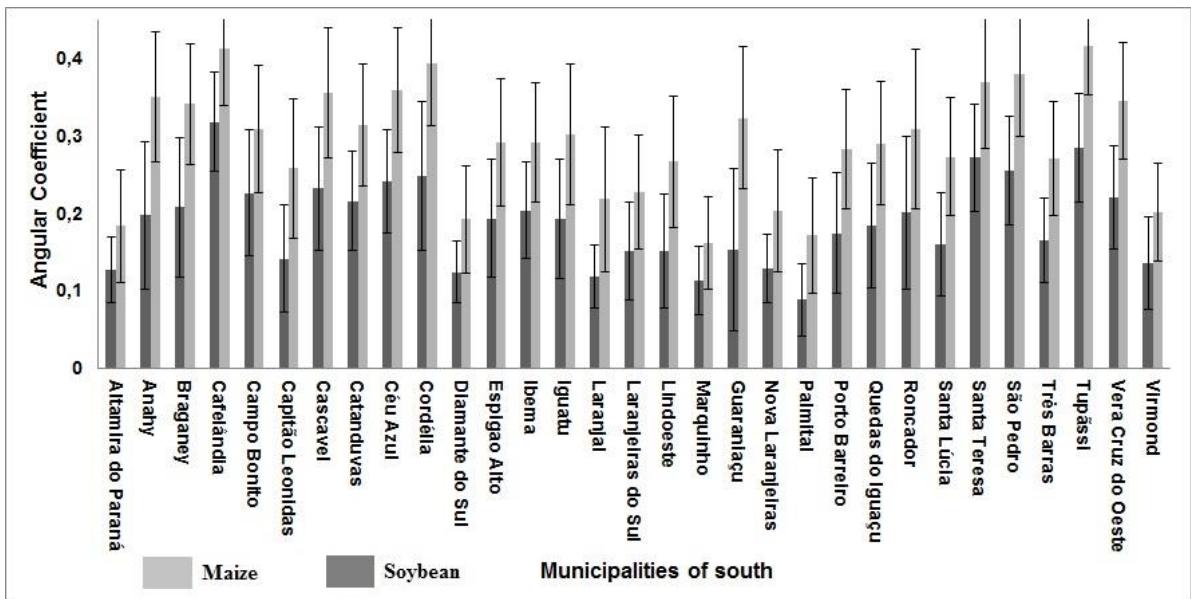


Figure 4.7: Angular coefficient and standard deviation for the 31 municipalities of south.

Spatial distribution of the results (Fig. 4.8) shows the separation of the 62 municipalities in two zones, the northern and southern, as mentioned earlier. The zone located at the southern region occupies soils in terrains with steeper slopes as compared to the northern zone. This could be partially explained by the lower degree of discrimination between soybean and maize. The most segmented agrarian structure of these areas, with small fields, gives a higher spectral confusion in low spatial resolution images, such as at Modis data (RUDORFF et al., 2007; CLARK et al., 2010).

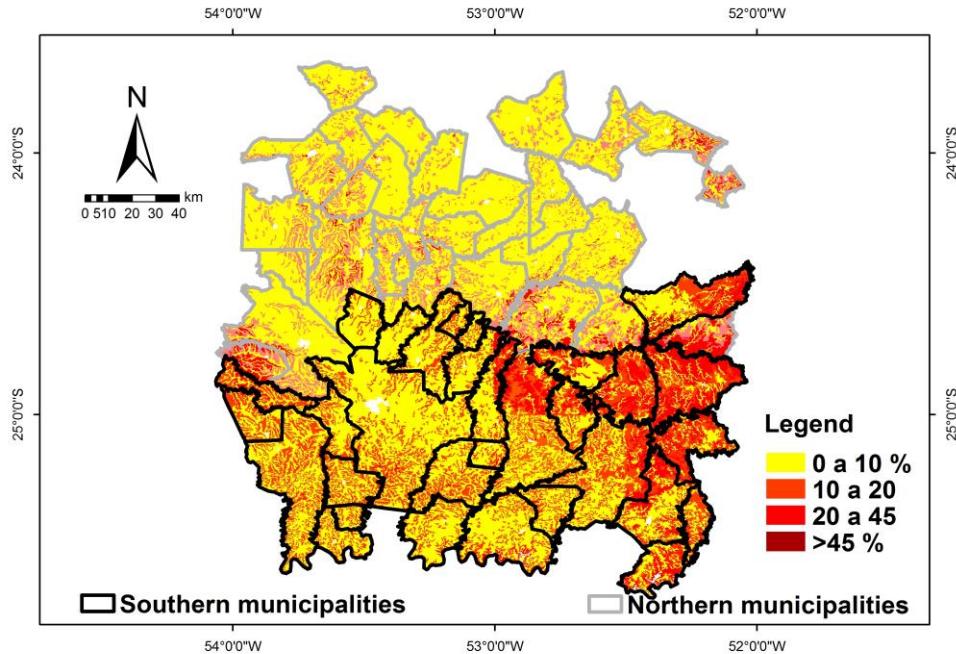


Figure 4.8: Slope map of the municipalities from the Paraná State.

Rudorff et al. (2007) evaluated the spectral-temporal reflectance of Modis images for the classification of a soybean area, and observed that, in sections with less segmented agrarian structure, where the fields are large and relatively homogeneous, this classification was quite satisfactory, contrasting with regions with relatively smaller extensions. The authors also emphasize that maize was included in the soybean class and that it was not discriminated because these crops are sown timely close to each other, precluding their temporal separation as mentioned earlier.

The Figures 4.9, 4.10, 4.11, and 4.12 shows the adjustment of logarithmic equations to the initial stage of the EVI temporal profile, for maize and soybean crops at both northern and southern regions, that can be seen in Figure 4.8. It is possible to observe that the average adjustment for all regions had a determination coefficient R^2 above 0.89. Potgieter et al. (2012) adjusted three Gaussian models of EVI temporal profiles to differentiate seasonal crop types and estimate agricultural areas, and obtaining a determination coefficient higher than 0.86. However, the angular coefficients from maize and soybean for the southern region present similar average statistical values, respectively 0.48 for maize and 0.33 for soybean. These values inhibit more

precise differentiation as compared to average angular coefficients found in the northern region (0.61 for maize and 0.38 for soybean), which allow higher accuracy for differentiation.

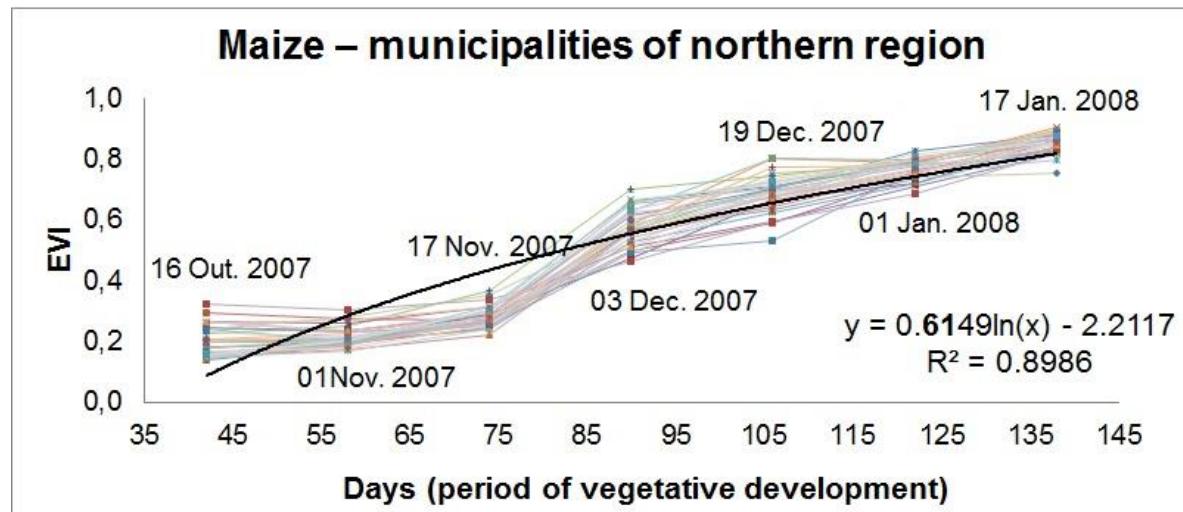


Figure 4.9: Adjustment of logarithmic equations at the initial phase of maize development, for each of the 31 municipalities of the northern, during harvest 2007/2008.

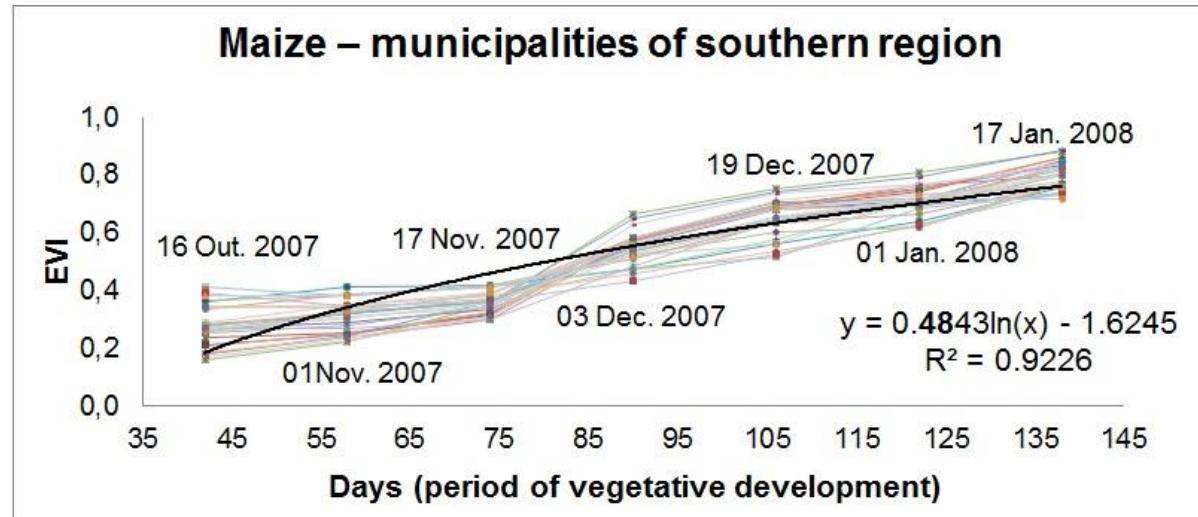


Figure 4.10: Adjustment of logarithmic equations at the initial phase of maize development, for each of the 31 municipalities of the southern region, during harvest 2007/2008.

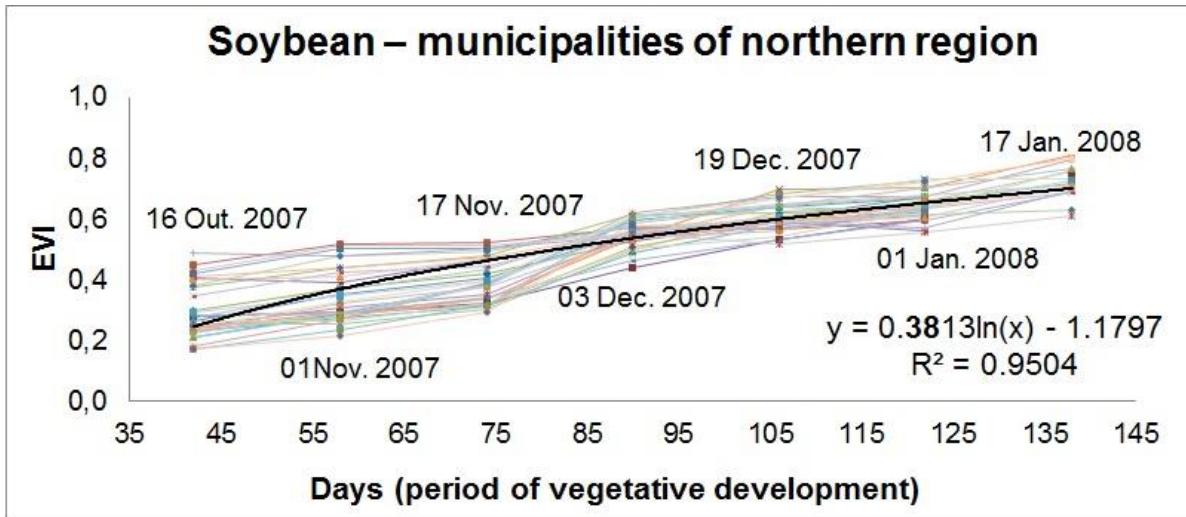


Figure 4.11: Adjustment of logarithmic equations at the initial phase of soybean development, for each of the 31 municipalities of the northern region, during harvest 2007/2008.

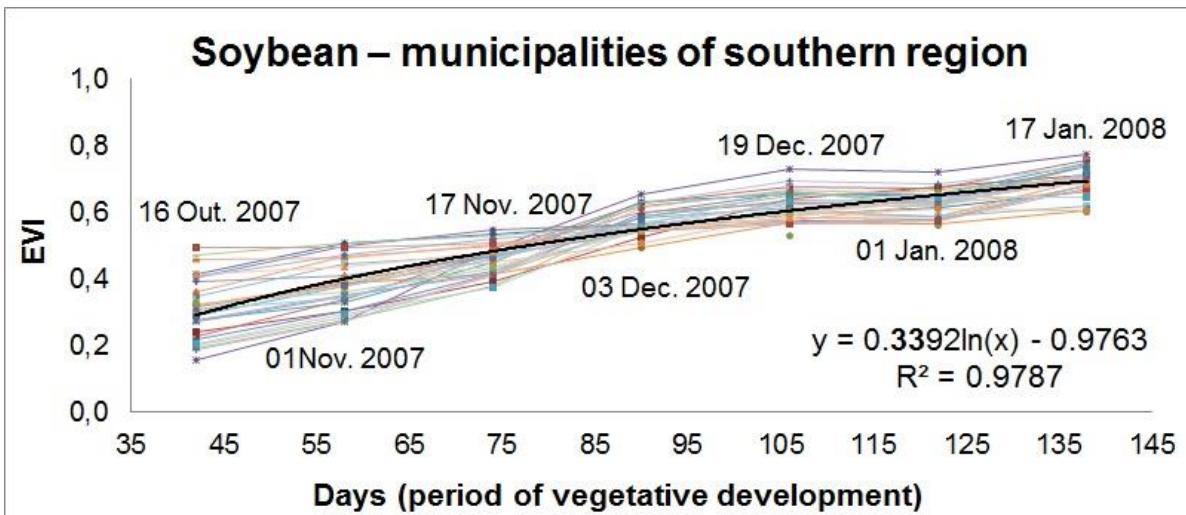


Figure 4.12: Adjustment of logarithmic equations at the initial phase of soybean development, for each of the 31 municipalities of the southern region, during harvest 2007/2008.

Table 4.2 shows the error matrix between the Landsat-5/TM reference image, and the maize and soybean crop mask at the southern region. Kappa values of 0.32 and global accuracy of 54.6% are below those recommended by Landis and Koch (1977) and Foody (2002), indicating that it was impossible to distinguish the targets precisely,

probably due to the field size, the hilly terrain, which can interfere in their spectral response, or the low spatial resolution of the sensor (250m) used.

Table 4.2: Error matrix between the reference (Landsat-5/TM, “false color” R4G5B3) and the soybean and maize crop masks for the southern region, harvest 2007/2008.

South Crop Mask	Reference Images (Landsat-5/TM)			Total	Commission Error ----%----
	Maize	Soybean	Non-summer crop		
Maize	24	16	10	50	52
Soybean	16	29	5	50	42
Non-summer crop	13	8	29	50	42
Total	53	53	44	150	KI = 0.32
Omission Error (%)	54.7	45.3	34.1	-	GA = 54.6%

Table 4.3, however, shows the error matrix between the reference Landsat-5/TM and the soybean and maize map for the northern region. The Kappa index of 0.71 and the global accuracy of 81.2% indicated that soybean and maize in these municipalities were discriminated with higher accuracy, according to Figure 4.13, which shows the separability mask of soybean and maize for the 62 municipalities.

Table 4.3: Error matrix between the reference (Landsat-5/TM, “false color” R4G5B3) and the separability mask of soybean and maize for the northern region, harvest 2007/2008.

North Crop Mask	Reference Images (Landsat-5/TM)			Total	Commission Error ----%----
	Maize	Soybean	Non-summer crop		
Maize	35	11	4	50	30
Soybean	4	45	1	50	10
Non-summer culture	0	5	28	33	15
Total	30	36	27	133	KI = 0.71
Omission Error (%)	10.3	26.2	15.2	-	GA = 81.2%

Nevertheless it is observed high commission errors (30%) for the maize class, as well as high values of omission errors for soybean class (26.2%), as a consequence of the slope difference at each one of the regions analyzed.

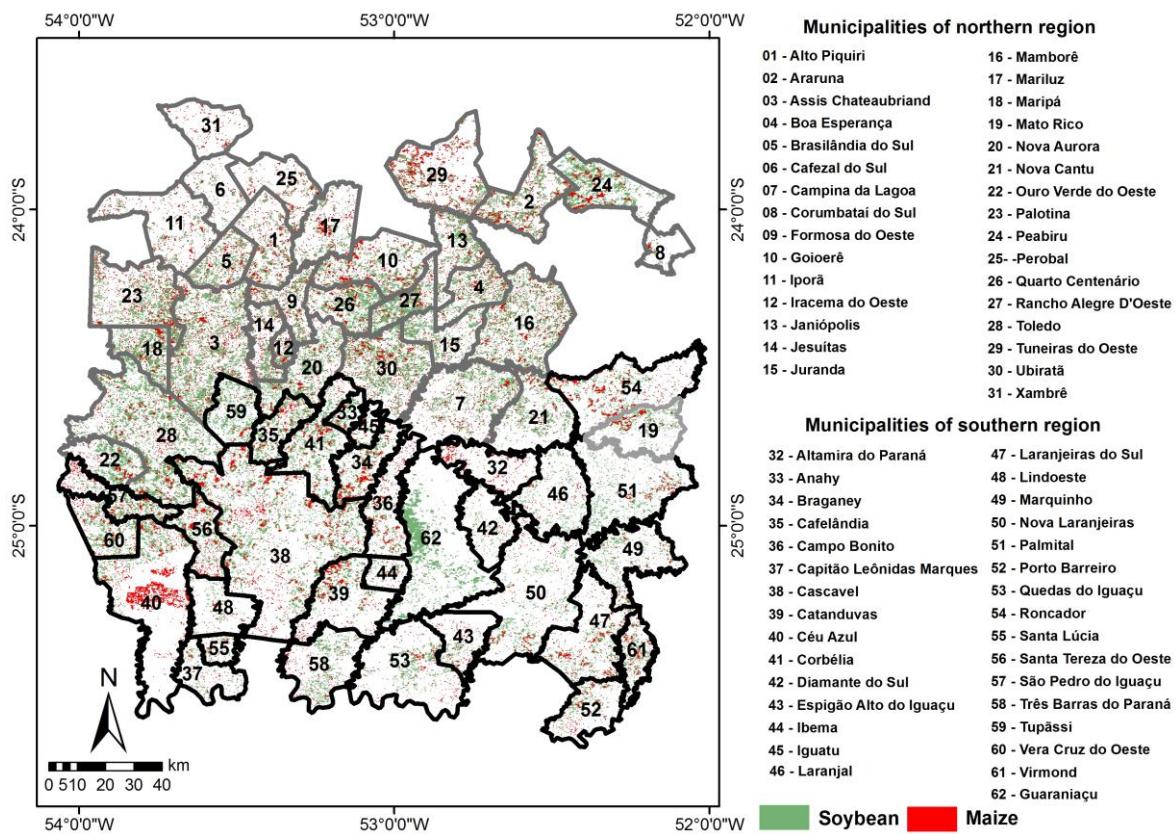


Figure 4.13: Soybean and maize mask for the 62 municipalities from the agriculture belt of Paraná State, harvest 2007/2008.

Table 4.4 shows the maize cultivated area in the northern and southern regions. A larger omission error is verified at the southern region, where the area difference for both crops as compared to the official figures by IBGE, were 31.7% and 34.4% respectively. Nevertheless, maize and soybean crop areas at the northern region presented a smaller omission error, in accordance with statistical results of Kappa and Global Accuracy. In this region, differences of 22.2% for maize and 23.3% for soybean were found, whose estimates are closer to the official IBGE data.

Table 4.4: Maize and soybean crop areas using the methodology proposed compared to official IBGE data for the crop year 2007/08.

Southern Region	Production 2007/08
Maize area by IBGE (ha)	237.264
Maize mask area (ha)	162.026
Difference (IBGE – Maize mask) (ha)	75.238
Difference (%)	- 31.7
Soybean area by IBGE (ha)	387.930
Soybean mask area (ha)	254.540
Difference (IBGE – Soybean mask) (ha)	133.390
Difference (%)	- 34.3
Northern Region	Production 2007/08
Maize area by IBGE (ha)	505.855
Maize mask area (ha)	393.564
Difference (IBGE – Maize mask) (ha)	112.291
Difference (%)	- 22.2
Soybean area by IBGE (ha)	707.703
Soybean mask area (ha)	542.568
Difference (IBGE – Soybean mask) (ha)	165.135
Difference (%)	- 23.3

4.5 Conclusions

The EVI product, generated by MODIS sensor, allows plotting temporal profiles for soybean and maize crops and correlating them with its initial stage of the phenological development, enabling the adjustment of logarithmic equations to this phase.

The methodology for discrimination of soybean and maize crops adjusted to temporal EVI profiles, at the initial stage of its development, presented highest accuracy in 31 municipalities, all located at the northern section of the area under study, with an average angular coefficient of 0.61 for maize and 0.38 for soybean and an average R^2 of 0.89 for maize and 0.93 for soybean.

The results indicate that the methodology proposed presented a higher potential for the discrimination of these two crops in flat terrains, with a Kappa index of 0.71 and a Global Accuracy of 81.2%. However, in areas with hilly terrain or where the agrarian structure is more segmented or diversified, this discrimination is not possible, due especially to the spectral confusion among these two crops.

Acknowledgements

We thank CNPq Scientific Initiation Scholarship as well as my sincere gratitude to CAPES/PDSE programscholarship for doctoral foreign stay and FAPESP for finance the project number: 2011/13748-8.

REFERENCES

- ARRAES, C. L.; LAMPARELLI, R. A. C.; ROCHA, J. V.; ESQUERDO, J. C. D. M.; SALVADOR, P.; RODRIGUEZ, J.; ROQUE, J. L.C.; JUSTO, J. S.; BENATTI, B. G. Reliability of Summer Crop Masks Derived from Second Order Polynomial Equations. **Journal of Agricultural Science**. v. 5, n. 3, p. 64-75, 2013.
- BOLTON, D. K.; FRIEDL, M A. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. **Agr. Forest Meteorol.** N. 173, p. 74-84, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.agrformet.2013.01.007>>. Acesso em: 15 dez. 2013.
- CHANG, J.; HANSEN, M.C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the United States using MODIS time-series data sets. **Agron. J.** n. 99, p. 1654-1664, 2007.
- CLARK, M. L.; AIDE, T. M.; GRAU, H. R.; RINER, G. A. Scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America. **Remote Sens. Environ.** n. 114, p. 2816-2832, 2010.
- DEFRIES, R.S.; TOWNSHEND, J.R.G. NDVI derived land cover classifications at a global scale. **Int. J. Remote Sens.** V. 15, n. 17, p. 3567-3586, 1994.
- DORAISWAMY, P.C.; HATFIELD, J.L.; JACKSON, T.J.; AKHMEDOVA, B.; PRUEGER, J.; STERNA, A. Crop condition and yield simulations using Landsat and MODIS. **Remote Sens. Environ.** n. 92, p. 548-559, 2004.
- ESQUERDO, J.C.D.M.; ZULLO JUNIOR, J.; ANTUNES, J.F.G. Use of NDVI/AVHRR time series profiles for soybean crop monitoring in Brazil. **Int. J. Remote Sens.** V. 32, n.13, p. 3711-3727, 2011.
- FEHR, W. R.; CAVINESS, C. E. **Stages of soybean development**. Ames: Iowa State University of Science and Technology, 1981. (Special report, 80.)
- FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sens. Environ.** n. 80, p. 185–201, 2002.
- GITELSON, A. A.; VIÑA, A.; MASEK, J. G.; VERNMA, S. B.; SUYKER, A. E. Synoptic Monitoring of Gross Primary Productivity of Maize Using Landsat Data. **IEEE Geosci. Remote.** S. v. 5, n. 2, p. 133-137, 2008.
- HAN, T.; WU, C.; TONG, Z.; MENTREDDY, R. S.; TAN, K., GAI, J. Postflowering photoperiod regulates vegetative growth and reproductive development of soybean.

Environ. Exp. Bot. N. 55, p. 120–129, 2006.

HEIFFIG, L. S.; CÂMARA, G. M. de S.; MARQUES, L. A.; PEDROSO, D. B.; PIEDADE, S. M. de S. Fechamento e índice de área foliar da cultura da soja em diferentes arranjos espaciais. **Bragantia**. v. 65, n. 2, p. 285-295, 2006. Disponível em: <<http://dx.doi.org/10.1590/S0006-87052006000200010>>. Acesso em: 10 dez. 2013.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sens. Environ.** n. 83, p. 195–213, 2002.

HUETE, A.; JUSTICE, C.; LEEUWEN, W. V. **Modis vegetation index (mod 13) Algorithm theoretical basis document version 3**. University of Arizona, 1999. Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf>. Acesso em: 03 nov. 2013.

HUNTE, A.D.L.; LIU, H.Q.; BATCHILY, K.; J.-VAN L. A. Comparation of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sens. Environ.** n. 59, p. 440-451, 1997.

INMAN, D.; KHOSLA, R.; REICH, R.; WESTFALL, D. G. Normalized Difference Vegetation Index and Soil Color-Based Management Zones in Irrigated Maize. **Agron.** J. n. 100, p. 60–66, 2008.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Banco de Dados Agregados**: Sistema IBGE de Recuperação Automática – SIDRA, 2012. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 13 nov. 2013.

INSTITUTO NACIONAL DE PESQUISAS ESPECIAIS. Catálogo de imagens **LANDSAT**. São José dos Campos, SP, 2012. Disponível em: <<http://www.inpe.br>>. Acesso em: 18 dez. 201.

INSTITUTO DE TERRAS, CARTOGRAFIA E GEOCIÊNCIAS. **Dados Cartográficos do Paraná**, 2008. Disponível em: <<http://www.itcg.pr.gov.br>>. Acesso em: 18 jan. 2014.

JACKSON, T. J.; CHEN, D.; COSH, M.; LI, F.; ANDERSON, M.; WALTHALL, C.; DORIASWAMY, P. RAY, H. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. **Remote Sens. Environ.** n. 92, p. 475–482, 2004.

JENSEN, J.R. **Remote Sensing of the Environment**: An Earth Resource Perspective, Upper Saddle River. New Jersey: Prentice- Hall, 2000.

KASTENS, J. H.; KASTENS, T. L.; KASTENS, D. L.A.; PRICE, K. P.; MARTINKO, E. A.; LEE, Re-Y. Image masking for crop yield forecasting using AVHRR NDVI time series imagery. **Remote Sens. Environ.** n. 99, p. 341-356, 2005.

- KOPPEN, W. **Grundriss der Klimakunde**. Berlin: Walter de Gruyter, 1931.
- LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**. n. 33, p. 159–174, 1977.
- LIU, J.; PATTEY, E.; MILLER, J. R.; MCNAIM, H.; SMITH, A.; HU, B. Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model. **Remote Sens. Environ.** n. 114, p. 1167-1177, 2010.
- MA, B. L.; DWYER, Lianne M.; COSTA, Carlos; COBER, Elroy R.; MORRISON, Malcolm J. Early Prediction of Soybean Yield from Canopy Reflectance Measurements. **Agron. J.** n. 93, p.1227–1234, 2001.
- MARTINEZ, B.; GILABERT, M.A. Vegetation dynamics from NDVI time series analysis using the wavelet transform. **Remote Sens. Environ.** n. 113, p. 1823-1842, 2009.
- MKHABELA, M.S.; BULLOCK, P.; RAJ, S.; WANG, S.; YANG, Y. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. **Agr. Forest. Meteorol.** n. 151, p. 385-393, 2011.
- MORIONDO, M.; MASELLI, F.; BINDI, M. A. Simple model of regional wheat yield based on NDVI data. **Eur. J. Agron.** n. 26, p. 266-274, 2007.
- NGUY-ROBERTSON, A.; GITELSON, A.; PENG, Y.; VIÑA, A.; ARKEBAUER, T.; RUNDQUIST, D. Green Leaf Area Index Estimation in Maize and Soybean: Combining Vegetation Indices to Achieve Maximal Sensitivity. **Agron. J.** n. 104, p. 1336–1347, 2012.
- NUARSA, I. W.; NISHIO, F.; HONGO, C. Relationship between Rice Spectral and Rice Yield Using Modis Data. **J. Agr. Sci.** n. 3, n. 2, p. 80-88, 2011.
- PARANÁ. Secretaria da Agricultura e do Abastecimento. Departamento de Economia Rural. Banco de dados da Produção Agropecuária. **Situação mensal de plantio, colheita e comercialização de produtos agrícolas no Paraná**. 2001. Disponível em: <<http://www.agricultura.pr.gov.br/arquivos/File/deral/pss.xls>>. Acesso em: 13 fev. 2013.
- PENG, Y.; GITELSON, A. A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sens. Environ.** n. 117, p. 440-448, 2012.
- PETORELLI, N.; VIK, J.O.; MYSTERUD, A.; GAILLARD, J.M.; TUCKER, C.J.; STENSETH, N.C. Using the satellite-derived NDVI to assess ecological responses to environmental change. **Trends. Ecol. Evol.** v. 20, n. 9, p. 503-510, 2005.

POTGIETER, A.B.; LAWSON, K.; HUETE, A.R. Determining crop acreage estimates for specific winter crops using shape attributes from sequential MODIS imagery. **Int. J. Appl. Earth. Obs.** v. 1, n. 1, p. 1-10, 2012.

RITCHIE, S.; HANWAY, J.J.; THOMPSON, H.E. **How a soybean plant develops**. Ames: Iowa State University of Science and Technology, 1982. (Special Report, 53).

RUDORFF, C. M.; RIZZI, R.; RUDORFF, B. F. T.; SUGAWARA, L. M.; VIEIRA, C. A. O. Superfícies de resposta espectro-temporal de imagens do sensor MODIS para classificação de área de soja no Estado do Rio Grande do Sul. **Cienc. Rural**. V. 37, n. 1, p. 118-125, 2007.

ROUSE, J. W.; HAAS JR, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: ERTS SYMPOSIUM, 3, 1973, São Paulo: **Annals...** São Paulo, 1973. p. 309–317.

SAKAMOTO, T.; YOKOZAWA, M.; TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N.; OHO, H. A Crop phenology detection method using time-series MODIS data. **Remote Sens. Environ.** n. 96, p. 366-374, 2005.

SAKAMOTO, T.; WARDLOW, B. D.; GITELSON, A. A.; VERMA, S. B.; SUYKER, A. E.; ARKEBAUER, T. J. A Two-Step Filtering approach for detecting maize and soybean phenology with time-series MODIS data. **Remote Sens. Environ.** n. 114, p. 2146-2159, 2010.

SANCHES, I.D.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Culturas agrícolas em imagens multitemporais do satélite Landsat. **Agric.** v. 52, n. 1, p. 83-96, 2005.

SARKER, M. H.; AKHAND, M. R.; RAHMAN, S. M. M. Temporal Monitoring of Aus Rice Using MODIS 16 Days Composite NDVI Data: A study over Barisal region of Bangladesh. **RJSITMt.**, n. 1, p. 11, 2012.

TUCKER, C. J.; ELGIN, J. H.; McMURTRY, J. E. Monitoring corn and soybean crop development by remote sensing techniques. **National Aeronautics and Space Administration**, v. 1, n. 1, p. 1-10, 1978. Disponível em: <<http://ntrs.nasa.gov>>. Acesso em: 01 out. 2013.

VIÑA, A.; GITELSON, A. A.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B.; SCHEPERS, J. Monitoring Maize (*Zea mays L.*) Phenology with Remote Sensing. **Agron. J.** n. 96, p. 1139-1147, 2004.

WARDLOW, B. D.; EGBERT, S. L.; KASTENS, J. H. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sens. Environ.** n. 108, p. 290-310, 2007.

WARDLOW, B. D.; EGBERT, S. L. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. **Remote Sens.**

Environ. n. 112, p. 1096-1116, 2008.

ZHANG, X.; FRIEDL, M. A.; SCHAAF, C. B.; STRAHLER, A. H.; HODGES, J. C. F.; GAO, F.; REED, B. C.; HUETE, A. Monitoring vegetation phenology using MODIS. **Remote Sens. Environ.** n. 84, p. 471-475, 2003.

ZHANG, J-Q.; ZHANG, L-X.; ZHANG, M-H.; WATSON, C. Prediction of Soybean Growth and Development Using Artificial Neural Network and Statistical Models. **Acta Agron. Sin.** v. 35, n. 2, p. 341-347, 2009.

5 RELAÇÃO ENTRE A RESPOSTA ESPECTRAL DE CULTURAS DE VERÃO E SUA PRODUÇÃO A PARTIR DE DADOS TST E NDVI DO SENSOR MODIS

Christiano L. Arraes, Rubens A. C. Lamparelli, Jansle V. Rocha, Julio C. D. M. Esquerdo, Pablo Salvador, Javier Rodríguez, José-Luis Casanova Roque & Julia Sanz Justo

Resumo – Técnicas de sensoriamento remoto são úteis na determinação de áreas cultivadas, principalmente das commodities soja [*Glycine max* (L.) Merr.] e milho (*Zea mays* L.). Considerando que a Temperatura de Superfície Terrestre (TST) e o índice de vegetação Normalized Difference Vegetation Index (NDVI) podem auxiliar nas estimativas da produção destas culturas, o presente trabalho objetivou correlacionar os valores dessas variáveis e a produção das culturas de verão para uma série histórica de 11 anos agrícolas, em microrregiões do Estado do Paraná. As máscaras de cultura de verão foram avaliadas por índice *kappa* e exatidão global encontrando valor médio superior a 0,68 e 84% respectivamente. A média da TST para os meses setembro, outubro e novembro indicaram que a temperatura tem maior influência nas fases iniciais do desenvolvimento vegetativo destas culturas, quando ainda apresentam solo exposto. As correlações lineares de Pearson entre os valores de TST e NDVI foram em média superior a -0,58 na série temporal de 11 safras agrícola. Os melhores coeficientes de determinação da regressão múltipla entre produção, NDVI e TST, retornado um valor médio entorno de 64%, sendo um bom indicativo do potencial da TST e do NDVI em auxiliar as estimativas agrícolas. No entanto, a baixa resolução espacial das imagens de TST se torna um empecilho no monitoramento de pequenas áreas agrícolas, principalmente quando essas estão acometidas de nuvens.

Palavras-chave: Soja; Milho; MODIS; TST; NDVI.

Abstract - Remote sensing techniques are useful in determining crop areas, mainly commodity crops as soybean [*Glycine max* (L.) Merr.] and corn (*Zea mays* L.). Considering that the Land Surface Temperature (LST) and the Normalized Difference Vegetation Index (NDVI) variables can estimate production of these crops, this study aimed to correlate the values of these variables and the production of summer crops for a historical series of 11 years at the State of Paraná, Brazil. Shades of summer crop were evaluated by Kappa coefficient and overall accuracy average value exceeding 0.68 and 84%, respectively. The mean of LST for the months of September, October and November indicated that the temperature has a greater influence in the early stages of vegetative development of these crops, while still present exposed soil. The Pearson linear correlation between LST and NDVI values returned an average value greater than -0.58 in the time series of 11 agricultural crops. The better determination coefficients of multiple regression between production, NDVI and LST returned an average value around 64%, being a good indicator of the potential of LST and NDVI in assisting agricultural estimates. However, the low spatial resolution images of the LST becomes an obstacle in monitoring small agricultural areas, especially when these are affected by clouds.

Keywords: Soybean; Corn; MODIS; LST; NDVI; Crop yield prediction model

5.1 Introdução

A alta variabilidade climática nas regiões tropicais torna-se um dos principais problemas a ser contornado quando se pretende trabalhar com estimativas de safras agrícolas. Deste modo, desenvolver ferramentas confiáveis para garantir maior acerto na estimativa das safras agrícolas é um desafio a ser superado.

Assim sendo, diversos pesquisadores como (QUIROGA; IGLESIAS, 2009; LV et al. 2013; THORP et al. 2012; CASA et al. 2012; TINGTING; CHUANG, 2010) utilizaram imagens de satélite como ferramenta nas estimativas de safras agrícolas, principalmente pelo seu baixo custo e alta disponibilidade. Outros pesquisadores, como Mkhabela et al. (2011), Nuarsa et al. (2011), Arvor et al. (2011) e Arraes et al. (2013)

utilizaram séries temporais de imagens de satélite para acompanhar o desenvolvimento de culturas em grandes extensões de terras, tendo como relação direta a biomassa das culturas com índices de vegetação, como por exemplo, o *Normalized Difference Vegetation Index* (NDVI) e o *Enhanced Vegetation Index* (EVI).

Sakamoto et al. (2010) desenvolveram uma metodologia para estimar as fases fenológicas das culturas de verão (soja e milho), melhorando os modelos de estimativas de safra agrícola. Os autores observaram que o modelo pode estimar as quatro fases fenológicas para o milho (V2 à V5 como sendo início vegetativo; R1 como sendo início da fase de florescimento; R5 formação de grão e R6 maturação) e para a soja (V1 a Vn estádio vegetativos; R5 formação das sementes; R6 enchimento de grãos e R7 como sendo o inicio da maturação), concluindo que, essa metodologia pode auxiliar na escolha da melhor época de se fazer os tratos culturais como adubação e manejo da irrigação.

Segundo Bhattacharya et al. (2011) a temperatura é outra variável importante que influencia no desenvolvimento da planta e, portanto, na produtividade final. Segundo Prasad et al. (2006), Jonna et al. (2007), Wu et al. (2011) e Cai e Sharma (2010), a Temperatura de Superfície Terrestre - TST pode ser correlacionada de forma direta ou indireta com os vários índices de vegetação, como por exemplo, o EVI e o NDVI, para as mais diferentes culturas, sendo que essas correlações podem contribuir de forma substancial nas estimativas das safras agrícolas.

Parida et al. (2008) observaram que a variação na TST é determinada, principalmente, pelos diferentes tipos de cobertura vegetal. Ao compararem valores de TST com dados de temperatura do ar, para as mais diferentes culturas, os autores encontraram correlação superior a 0,8, o que demonstra o potencial da TST em auxiliar nas estimativas de safras agrícolas. Li et al. (2008) mostram a possibilidade de utilização de dados orbitais no monitoramento do estresse hídrico, no Norte da China. Utilizaram dados de TST do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) combinado com valores de NDVI, para o cálculo do índice *Temperature vegetation dryness* (TVDI), o qual pode ser relacionado com as condições de umidade do solo (GOWARD et al., 2002; SONA et al., 2012; CHEN et al., 2011; BAJGIRAN et al., 2012; SUN et al., 2012).

Li et al. (2008) ressaltam que o TVDI não separou as diferentes condições de umidades, em áreas que estavam completamente tomadas pela vegetação, mostrando que esse índice foi válido para áreas com solo exposto ou em início de vegetação, o que impossibilitou fazer o acompanhamento de todas as fases do desenvolvimento vegetativo. Resultados similares também foram encontrados por Singh et al. (2003) e Gao et al. (2011) que comentam a importância dos índices de vegetação para o monitoramento da seca em áreas agrícolas, dando destaque para a aplicação da TST no cálculo destes índices, no entanto o TVDI não é indicado para monitorar secas severas.

Estudos realizados por Chang et al. (2007) nos Estados Unidos mostraram a importância da utilização de dados de sensoriamento remoto de baixa resolução espacial e alta resolução temporal no monitoramento de culturas agrícolas, devido à possibilidade de acompanhar as alterações fenológicas das culturas, assim como monitorar vastas áreas agrícolas. Os autores ainda desenvolveram modelos de estimativa de safra para as culturas de verão em nível nacional, estadual e municipal, utilizando dados de TST e dados de NDVI, ambos obtidos do sensor MODIS. Os autores encontraram coeficientes de correlação superiores a 0,9 quando comparados com os dados oficiais do governo. Prasad et al. (2006) e Sakamoto et al. (2013) também encontram valores superiores a 0,75 de correlação entre dados oficiais e dados obtidos por técnicas de sensoriamento remoto.

A metodologia proposta para correlacionar os dados de NDVI, TST e produção foi fundamentada nas necessidades térmicas destas culturas, visto que, segundo Embrapa Soja (2008), as culturas de verão necessitam de temperatura do solo entre 20 e 30°C na fase inicial do seu desenvolvimento vegetativo, sendo 25°C a temperatura ideal para uma emergência rápida e uniforme. Temperaturas inferiores a 10°C podem provocar retardamento no seu desenvolvimento vegetativo e acima de 40°C, ocorre redução da taxa de crescimento, principalmente durante os estádios vegetativos e reprodutivos, o que gera comprometimento na floração, diminui a capacidade de retenção de vagens, o que implica na redução da produtividade (WILHELM; WORTMANN, 2004; RATHKE et al., 2007).

Dentro deste contexto, este trabalho objetivou gerar modelos estatísticos capazes de explicar a relação existente entre a produção das culturas de verão e as variáveis espectrais NDVI e TST por microrregiões no Estado do Paraná para a série temporal de 2001 a 2011.

5.2 Material e Métodos

O estudo foi realizado em 39 microrregiões do Estado do Paraná, localizado na região Sul do Brasil (Figura 5.1), sendo responsável por 21,4% da área cultivada com soja e milho, referente à safra 2011, (IBGE, 2013). Foram avaliados dados agrícolas para as safras de 2001 a 2011.

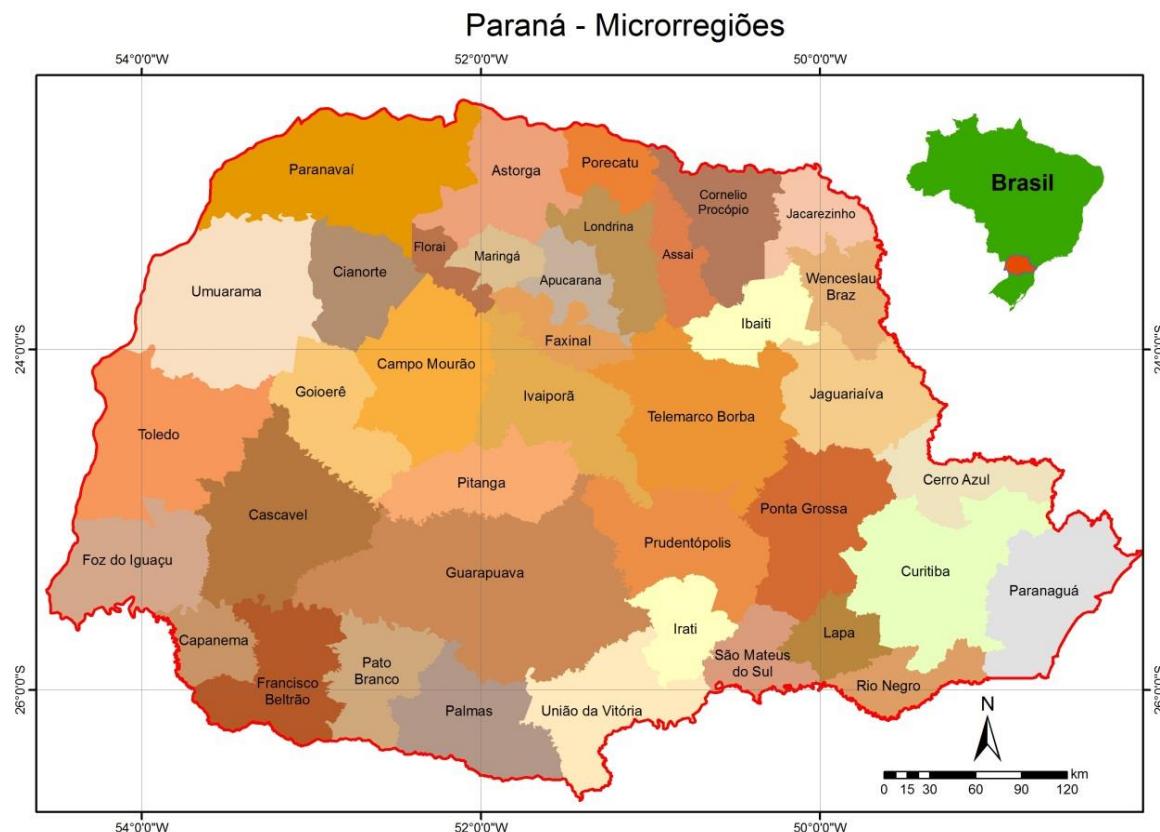


Figura 5.1: Microrregiões estudadas do Estado do Paraná.

De acordo com a classificação de Köppen, domina o clima do tipo C (mesotérmico) e, em segundo plano, o clima do tipo A (tropical chuvoso) e a amplitude térmica anual varia entre 12 °C e 13 °C, com exceção do litoral, onde as amplitudes

térmicas variam de 8 a 9 °C. (KÖPPEN, 1931). As principais ocorrências de solos da região são os Latossolos, Argissolos, Neossolos e Nitossolos (ITCG, 2008).

Para facilitar o entendimento da metodologia é apresentado na Figura 5.2 um fluxograma das principais etapas realizadas.

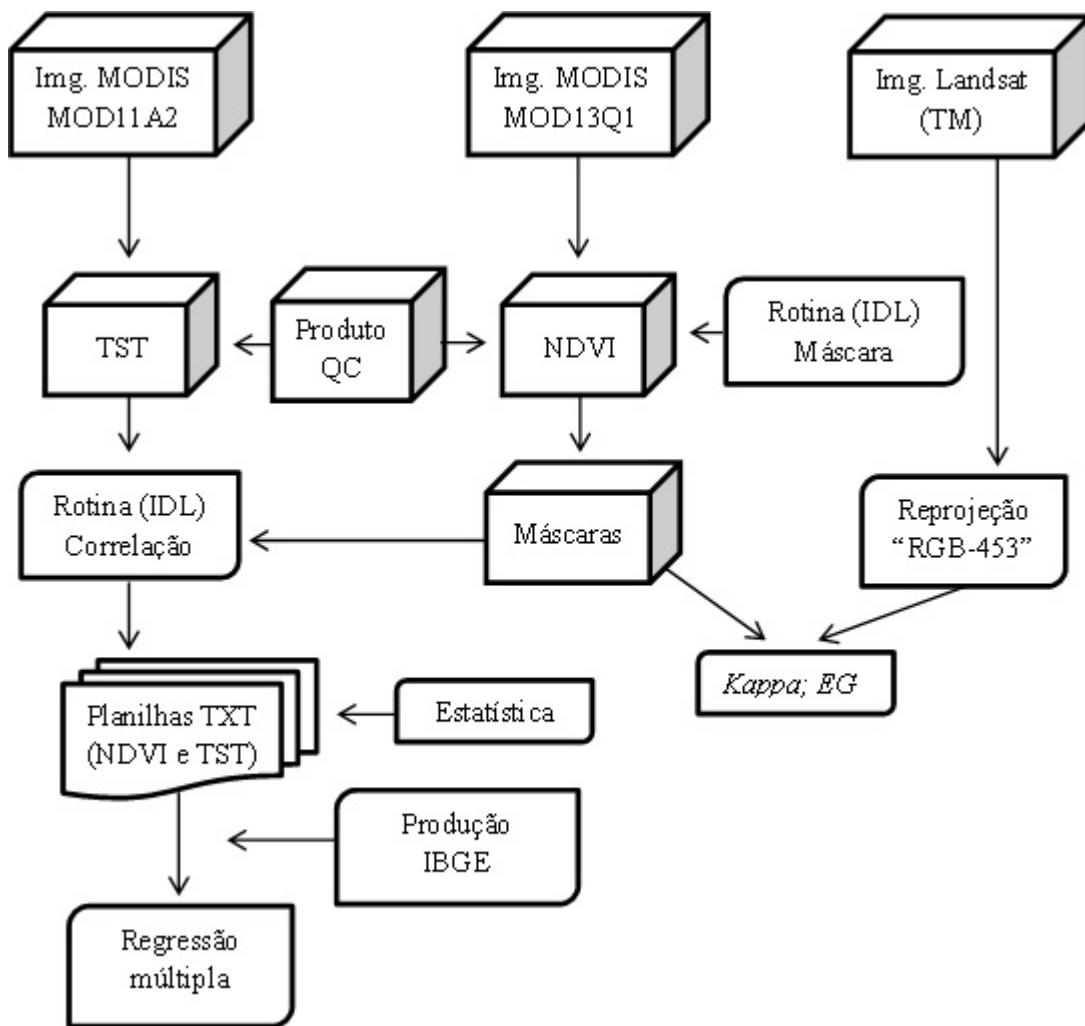


Figura 5.2: Fluxograma.

5.2.1 Aquisição e pré-processamento dos produtos Terra/MODIS

Os dados espectrais utilizados foram obtidos do sensor MODIS, a bordo do satélite Terra, produto MOD13Q1 que possui 12 subprodutos. O subproduto utilizado neste trabalho foi o NDVI, composição de 16 dias com resolução espacial de 250m, sendo que as imagens encontram-se em formato “hdf” e projeção sinusoidal. Também

foram adquiridas imagens de TST, composição de 8 dias, referente ao produto MOD11A2, com resolução espacial de 1km, em formato “hdf” com projeção sinusoidal (HUETE et al., 1999). Estas imagens foram obtidas do site da NASA (NASA, 2012). Os ruídos, segundo Huete et al. (1999), interferem negativamente no valor de radiância dos diferentes alvos. Para eliminar este efeito aplicou-se o produto controle de qualidade (QC) o qual fornece informações da qualidade do pixel, permitindo ao usuário uma análise qualitativa de cada pixel da imagem (GU et al., 2009). Para isso, as imagens QC foram transformadas em máscaras as quais eram multiplicadas por cada imagem TST e NDVI eliminando possíveis pixels com ruídos. Para transformar os valores de NDVI em escala de 0 a 1 foi utilizada a Equação 1. O produto TST apresenta valores que variam de 7.500 a 65.535 foram convertidas para graus Celsius, pela Equação 2. Todos esses procedimentos foram realizados em programação IDL.

$$NDVI = \frac{ND}{10.000} \\ (1)$$

$$TST(C) = (ND * 0,02) - 273,15 \quad (2)$$

NDVI = (Normalized Difference Vegetation Index);

TST = Temperatura de Superfície Terrestre em graus Celsius;

ND = Valor numérico digital do pixel da imagem.

5.2.2 Aquisição e pré-processamento das imagens Lansat-5/TM

Foram adquiridas imagens do satélite Landsat-5 sensor TM (Thematic Mapper) referente às bandas 3 (0,63 a 0,69 μm – vermelho), 4 (0,76 a 0,90 μm - infravermelho próximo) e 5 (1,55 a 1,75 μm - infravermelho médio) para as órbitas e pontos: 221/076; 223/077; 222/076; 223/078 e 223/076 (Figura 5.3), nas datas em que as culturas de verão encontravam-se no pico vegetativo. As imagens foram baixadas através do catálogo gratuito de imagens do Instituto Nacional de Pesquisas Espaciais – INPE (INPE, 2012) e, na sequência, foram reprojetadas para a projeção sinusoidal, a mesma dos produtos NDVI e TST. As composições coloridas “falsa cor” foram geradas com as bandas 3, 4 e 5 sendo elas posicionadas nos canais 4 (vermelho), 5 (verde) e 3 (azul).

Nessa composição, as culturas de verão podem ser diferenciadas conforme trabalho de Sanches et. al. (2005).

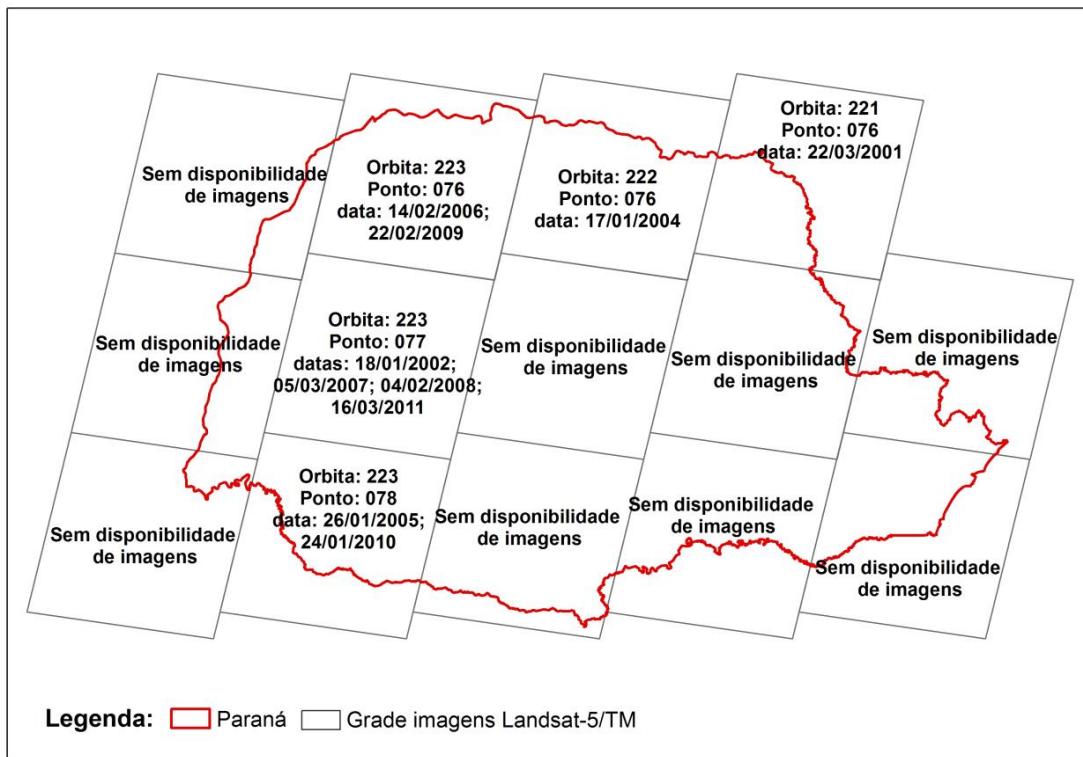


Figura 5.3: Grade de imagens Landsat-5/TM representando as imagens utilizadas no desenvolvimento desta pesquisa com datas, órbita e pontos.

5.2.3 Geração das máscaras de culturas de verão e avaliação de sua acurácia

Com as imagens de NDVI foram geradas máscaras das culturas de verão, metodologia descrita em Arraes et al. (2013), para as safras de 2001 a 2011, utilizando programação em linguagem IDL, em que os dados foram processados em três fases distintas, obedecendo à curva temporal de NDVI para as culturas de verão, conforme Figura 5.4, a qual representa, como exemplo, um perfil temporal médio de NDVI para a Microrregião de Cascavel-PR.

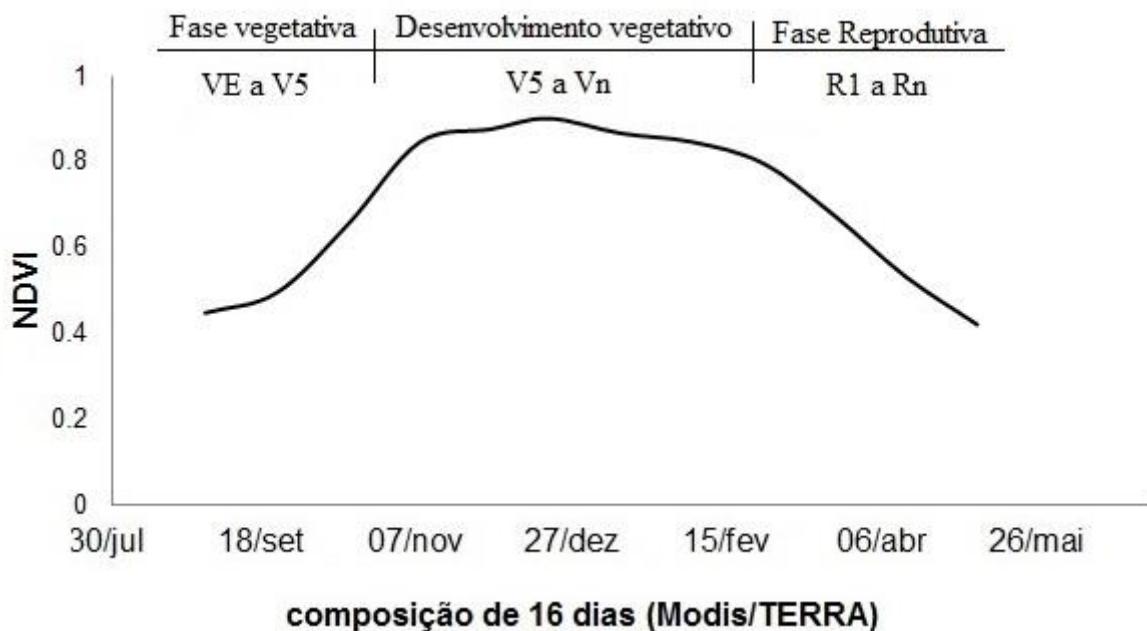


Figura 5.4: Representação do perfil temporal médio de NDVI para as culturas de verão, com as fases desenvolvimento vegetativo, maturação e senescência - Microrregião de Cascavel-PR.

Na primeira fase fenológica, denominada de vegetativa a qual se estende de VE a V5, os valores de NDVI partem de um patamar igual ou inferior a 0,3 e atingem valores entre 0,7 e 1,0, ou seja, partem de solo exposto ou coberto por palhada até a fase de pleno desenvolvimento vegetativo. Na segunda fase fenólica que se estende de V5 a Vn, denominada de pleno desenvolvimento vegetativo, os valores de NDVI seguem oscilando entre 0,7 e 1,0, até iniciar a terceira fase fenólica, denominada de fase reprodutiva que se estende de R1 a Rn, em que os valores de NDVI decaem deste patamar até um valor mínimo inferior a 0,3.

Pesquisadores, como Viña et al. (2004), Sakamoto et al. (2005), Wardlow et al., (2007) e Sakamoto et al. (2010), também identificaram as fases fenológicas do milho e soja a partir de séries temporais de índices de vegetação, mostrando assim ser possível traçar uma metodologia capaz de gerar máscaras de culturas de verão, partindo de suas fases fenológicas. Para verificar estatisticamente a acurácia da máscara, foram

aplicados três métodos: matriz de erro ou de contingenciamento, exatidão global (EG) e índice *Kappa*. Como referência, foram usadas as imagens Landsat-5/TM.

5.2.4 Extração dos valores de NDVI e TST

A extração dos dados de NDVI, com resolução de 250m, e os valores de TST, com resolução de 1 km, foi realizada por programação em linguagem IDL, trabalhando somente com pixels puros de TST, sobre as máscaras de culturas de verão. Para a realização da correlação linear múltipla, entre o valor médio dos quatro pixels centrais de NDVI com o valor do pixel puro de TST, aplicou-se a Equação 3 (Figura 5.5).

$$NDVI = \frac{[2;2] + [2;3] + [3;2] + [3;3]}{4} \quad (3)$$

NDVI = Normalized Difference Vegetation Index, médio.

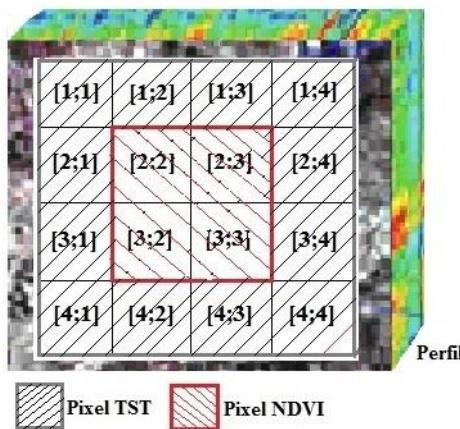


Figura 5.5: Matriz representando o pixel puro de TST e NDVI.

5.2.5 Análises estatísticas e estudo da relação múltipla do índice NDVI e valores da TST com a produção das culturas de verão

As correlações lineares de Pearson foram efetuadas para cada uma das 39 microrregiões do Estado do Paraná, em uma série temporal de 11 anos. Como também a normalidade dos dados foi verificada para as variáveis espectrais NDVI e TST por meio do teste de Kolmogorov - Smirnov, utilizando o software MINITAB 16.1.0 (2010).

Nas análises realizadas para avaliar a relação entre os dados espectrais, provenientes do NDVI e TST, com a produção das culturas de verão, foram avaliadas a força da relação pelo coeficiente de correlação linear de Pearson (r) e a forma da relação, pela regressão múltipla.

Partindo do pressuposto de normalidade, foram realizadas regressões múltiplas entre dados de produção (variável predita) e os dados espectrais TST e NDVI (variáveis preditoras) em nível de microrregião. Os dados de produção das culturas de verão, por microrregião, foram obtidos do Instituto Brasileiro de Geografia e Estatística (2013). Essas análises tiveram como objetivo determinar a porcentagem de explicação dos dados espectrais sobre a produção das culturas de verão.

5.3 Resultados e discussão

A Figura 5.6 mostra a TST média estimada pelos dados MODIS dos meses de setembro, outubro e novembro que, juntos, correspondem a quase 100% da semeadura, conforme dados fornecidos por Paraná (2012).

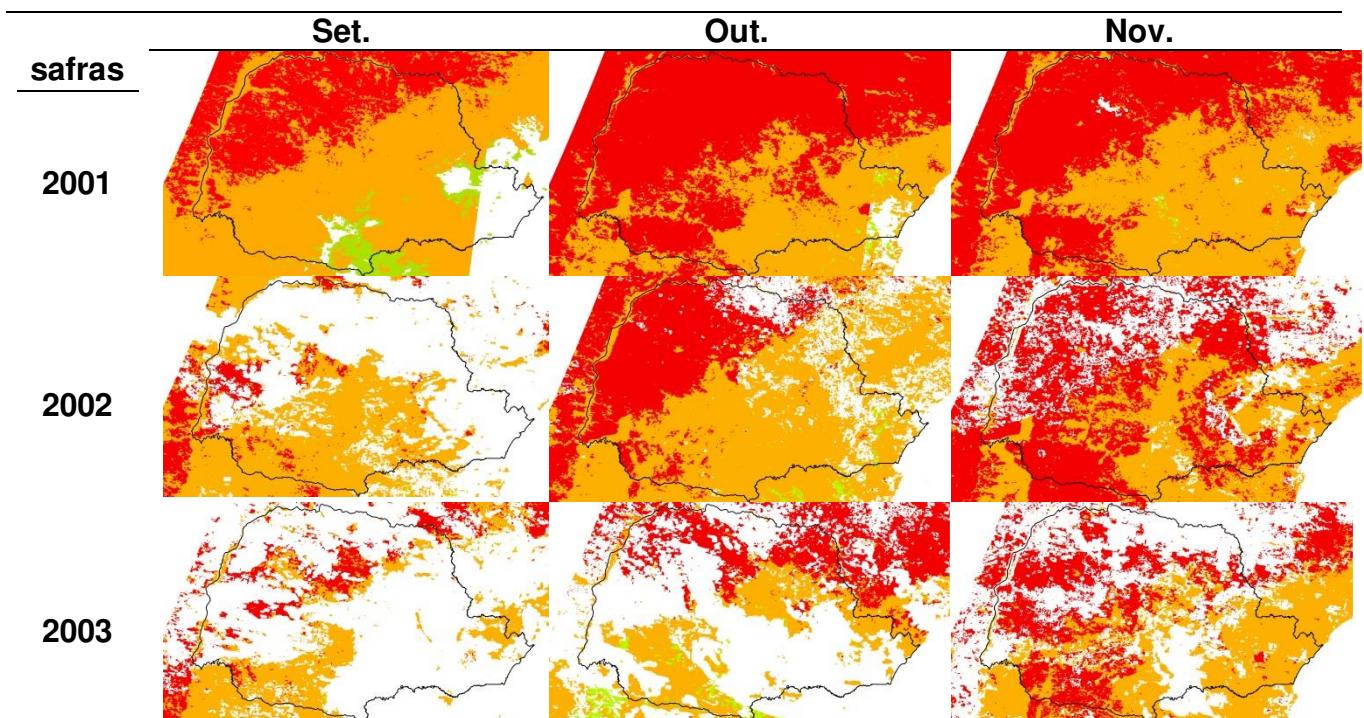
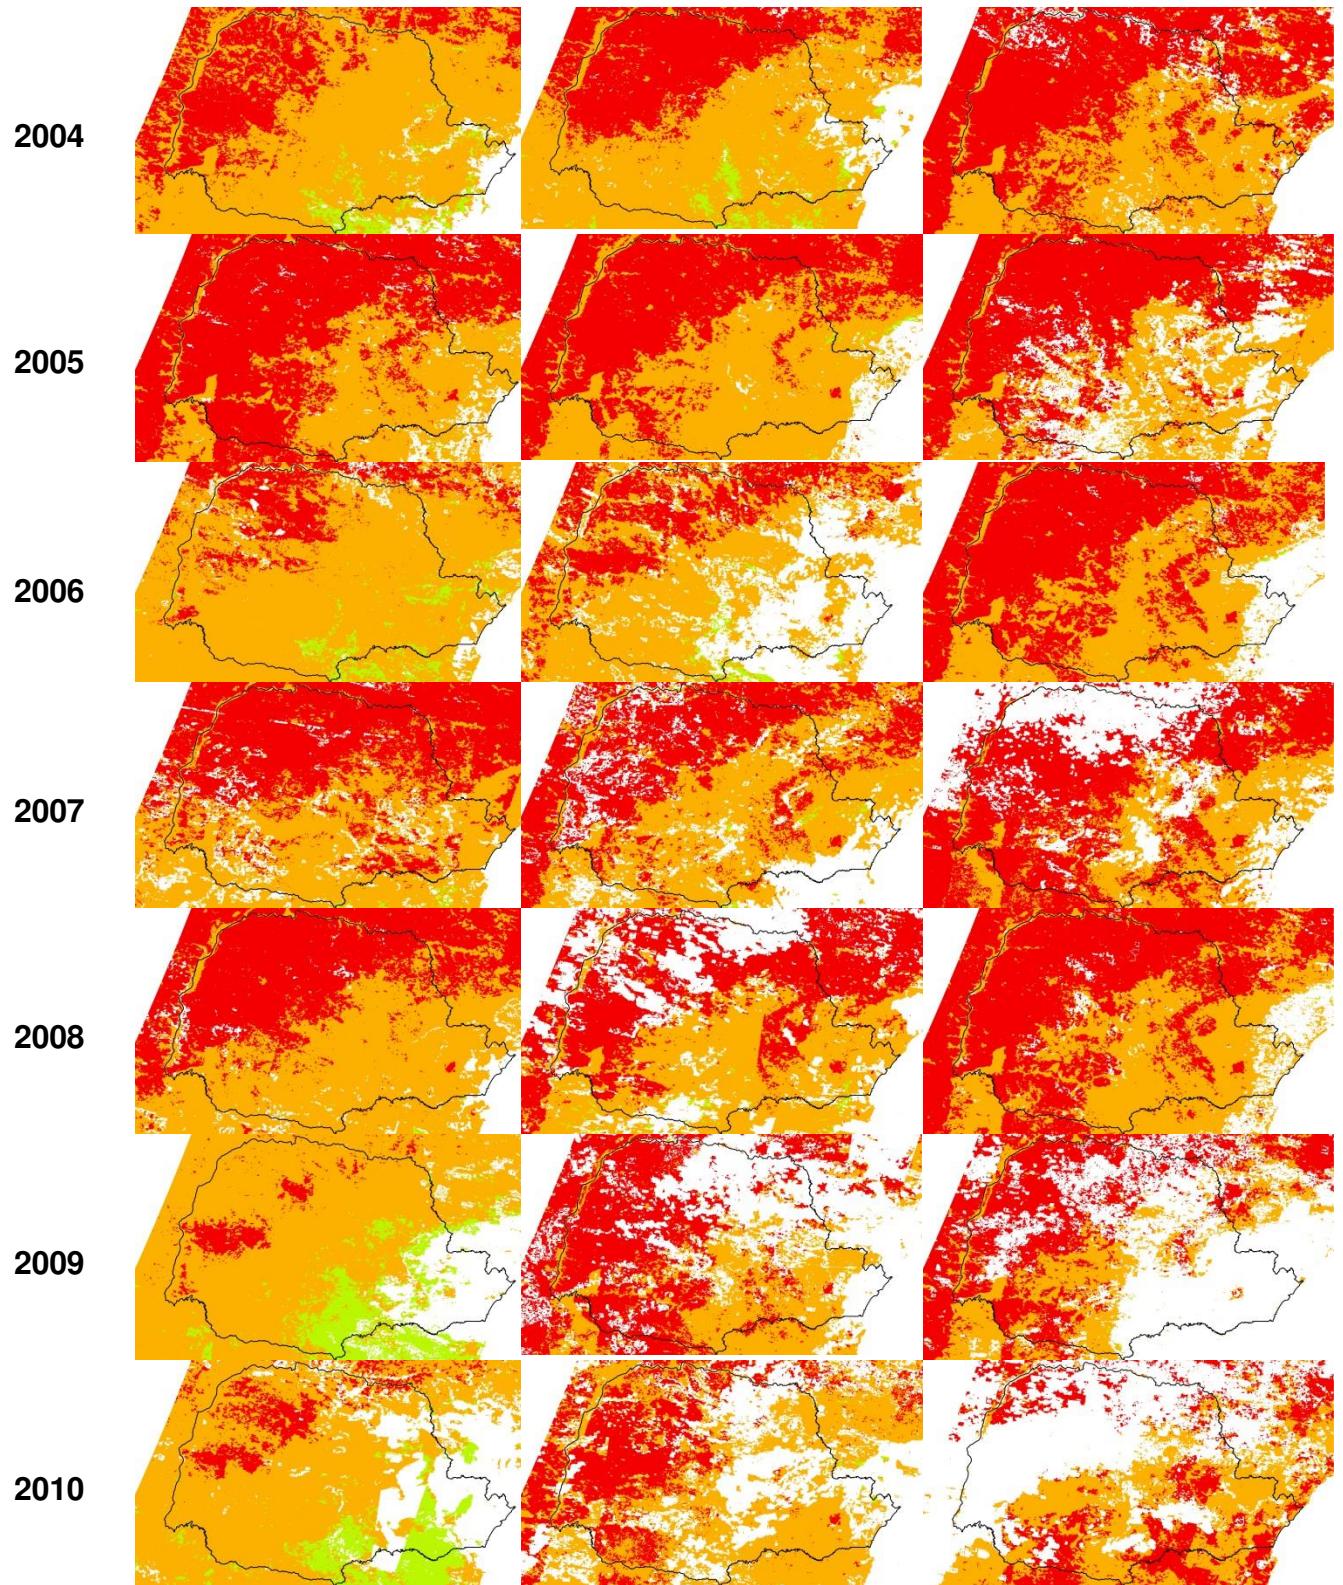
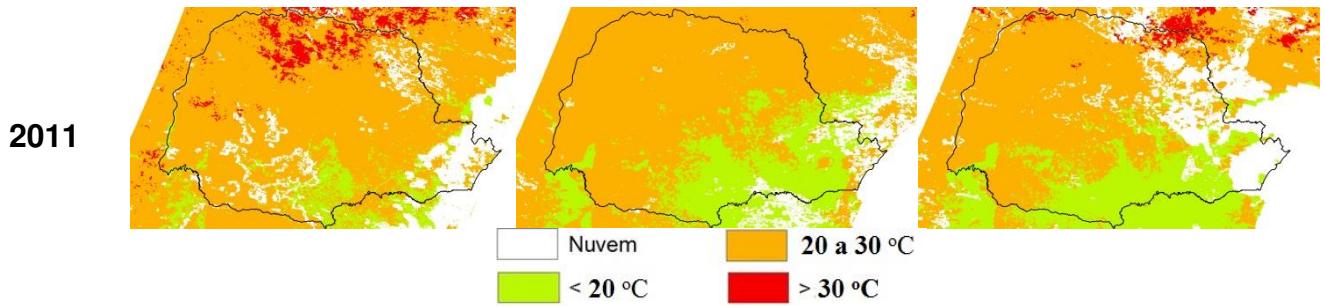


Figura 5.6: TST médio, do Estado do Paraná, para os meses de setembro, outubro e novembro de 2000 a 2010.



Continuação da Figura 5.6: TST médio, do Estado do Paraná, para os meses de setembro, outubro e novembro de 2000 a 2010.



Continuação da Figura 5.6: TST médio, do Estado do Paraná, para os meses de setembro, outubro e novembro de 2000 a 2010.

Observando os mapas da Figura 5.6 com a produção do Estado do Paraná Tabela 5.1, verifica-se que para a safra de 2005, em que na série de 11 anos, mostrou a menor produção, aproximadamente 18 milhões de toneladas, as temperaturas médias ultrapassaram a faixa ideal para as culturas de verão (EMBRAPA SOLOS, 2008), principalmente nas regiões mais produtoras, as quais se localizam no Oeste do Estado do Paraná. Para a safra 2011, em que a produção atingiu aproximadamente 28 milhões de toneladas, os valores médios da TST para os meses de setembro, outubro e novembro encontram-se na faixa ideal de temperatura, para o plantio, o que pode ter favorecido produção.

Tabela 5.1: Produção, em milhões de toneladas, soja e milho para as safras de 2001 a 2011.

Safra	Cultura		
	Milho	Soja	Total
2001	12.646.564	8.615.187	21.261.751
2002	9.797.816	9.538.774	19.336.590
2003	14.390.104	11.009.946	25.400.050
2004	10.934.582	10.219.005	21.153.587
2005	8.572.364	9.492.153	18.064.517
2006	11.239.987	9.362.901	20.602.888
2007	14.258.086	11.876.790	26.134.876
2008	15.613.442	11.800.466	27.413.908
2009	11.261.704	9.408.991	20.670.695
2010	13.567.096	14.091.829	27.658.925
2011	12.472.720	15.457.911	27.930.631

Fonte: IBGE (2013)

Estudos realizados por Khalil et al. (2010) analisaram o grau de germinação de sementes de soja, sobre diferentes faixas de temperatura, concluindo que as maiores porcentagens de germinação ocorreram com temperaturas em torno dos 25°C, concordando com os resultados encontrados. A matriz de erros entre a imagem referência, Landsat-5/TM, e as máscaras de cultura de verão, para as 11 safras analisadas, apresentou os valores de *Kappa* em média superiores a 0,73, com exatidão global superior a 86% (Tabela 5.2).

Tabela 5.2: Índices *Kappa*, Exatidão Global e Erros de Omissão e Inclusão, para as 11 safras agrícolas.

Safra	Índices		Erros (%)	
	Kappa	Exatidão Global	Omissão	Inclusão
2001	0,72	86	17,8	8
2002	0,74	87	16,3	8
2003	**	**	**	**
2004	0,76	88	13,4	10
2005	0,68	84	18,5	12
2006	0,76	88	16	6
2007	0,74	87	15	10
2008	0,70	85	14	6
2009	0,76	88	14	8
2010	0,70	85	20	6
2011	0,76	88	16	6

** falta de imagens Landsat-5/TM para validação.

No entanto, por falta de imagens Landsat-5/TM que cobrisse todo o Estado do Paraná, a verificação sobre a referência terrestre foi efetuada somente sobre imagens disponíveis, que considerassem o pico vegetativo das culturas de verão. Os erros de omissão podem ser explicados pelo fato da necessidade de correlacionar os dados de NDVI e TST a partir de pixels puros, com mínima interferência de outros alvos. Segundo a metodologia proposta, o fundamental foi garantir que os alvos realmente fossem de culturas de verão e que sejam maiores que 1km², o que representa a resolução espacial da TST.

Considerando que o método de mapeamento adotado, foi mais conservador, ocorreram elevados erros de omissão, ou seja, as máscaras não foram capazes de identificar todas as áreas de culturas de verão, mas assegurou-se que elas não fossem contaminadas por outros alvos, de modo que a correlação linear de Pearson entre TST e NDVI fosse a mais fiel possível. Sendo assim, das 39 microrregiões estudadas, somente 32 apresentaram quantidade suficiente de pixels puros que pudessem realizar a correlações lineares de Pearson (Tabela 5.3 e Tabela 5.4).

Os dados de correlação mostram maiores valores para 10 microrregiões sendo: Florai com r superior a -0,592 (safra 2002), Francisco Beltrão superior a -0,655 (safra 2011), Goioerê superior a -0,608 (safra 2005), Ivaiporã superior a -0,644 (safra 2005), Londrina superior a -0,712 (safras 2005 e 2006), Maringá superior a -0,755 (safra 2011), Ponta Grossa superior a -0,659 (safra 2004), Porecatu superior a -0,614 (safra 2009), Telemarco Borba superior a -0,627 (safra 2001) e Umuarama sendo superior a -0,535 (safra 2002) todas significativas com 5% de probabilidade.

Se os maiores valores de correlação linear de Pearson para as Tabelas 5.3 e 5.4 foram encontrados para as regiões citadas consequentemente, os melhores coeficientes de determinação da regressão múltipla (Tabela 5.5) também foram obtidos com essas microrregiões. Florai apresentou $R^2 = 50,1\%$, Francisco Beltrão $R^2 = 77,5\%$, Goioerê $R^2 = 56,6\%$, Ivaiporã $R^2 = 59,4\%$, Londrina $R^2 = 68,2\%$, Maringá $R^2 = 86,7\%$, Ponta Grossa $R^2 = 68,3\%$, Porecatu $R^2 = 53,7\%$, Telemarco Borba $R^2 = 66,2\%$ e Umuarama $R^2 = 73,4\%$. Podendo assim, explicar, em torno de 64% da variabilidade da produção das culturas de verão nessas microrregiões, utilizando os dados NDVI e TST.

A TST apresenta maior influência na fase inicial do desenvolvimento das culturas de verão (Figura 5.7), pois o solo está parcialmente descoberto, e sendo assim absorve mais radiação eletromagnética elevando a sua temperatura. As principais consequências são a baixa germinação com pouca emergência da planta, afetando diretamente o desenvolvimento e a produtividade. Segundo a Embrapa (2007) temperaturas acima de 40°C provocam efeitos adversos na taxa de crescimento levando a estragos na floração e diminuição na retenção de vagens. Por outro lado, temperaturas do solo abaixo de 20°C também são prejudiciais provocando baixa germinação e emergência da planta.

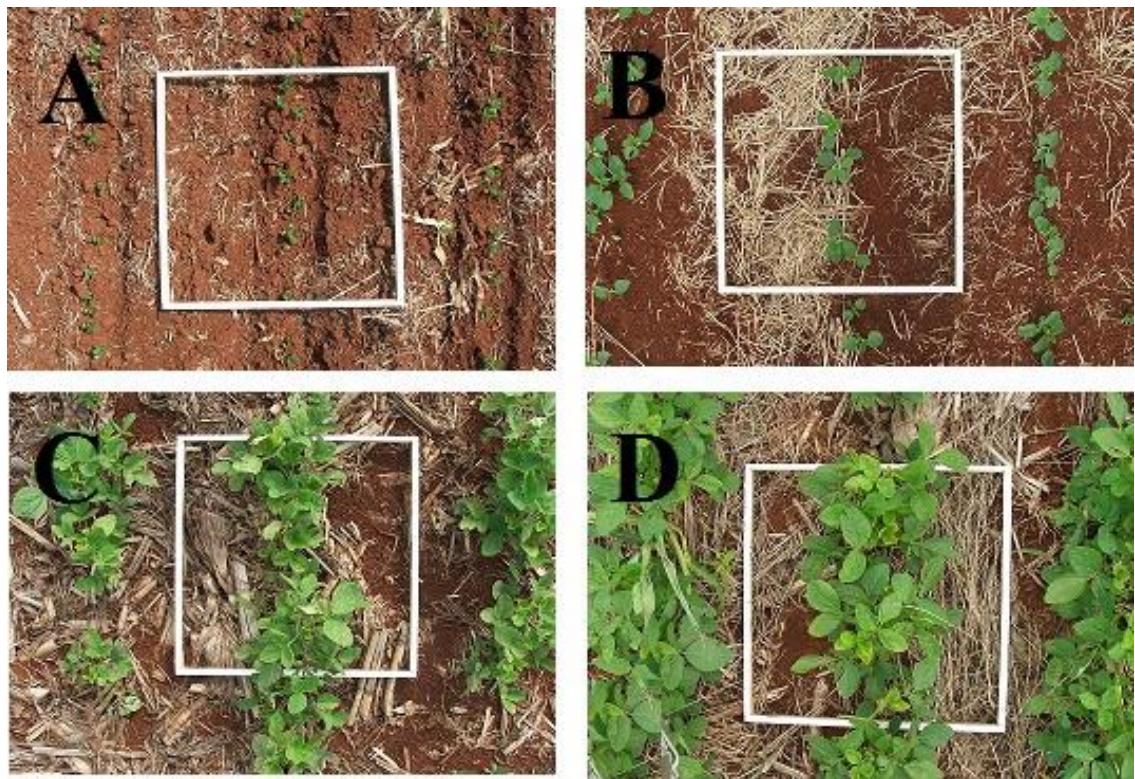


Figura 5.7: (A) Soja em estágio VE; (B) Soja em estágio V2; (C) Soja em estágio V4 e (D) Soja em estágio V6 com aproximadamente 50% da área foliar recobrindo o solo.

Tabela 5.3: Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para 39 microrregiões do Estado do Paraná, safra 2001 a 2006.

Microrregião	Safras																	
	2001			2002			2003			2004			2005			2006		
	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor
Apucarana	11	-0,720	0,002	1	-0,417	0,122NS	3	-0,55	0,034NS	4	-0,727	0,002	6	-0,528	0,043NS	2	-0,328	0,298NS
Assai	41	-0,819	0,000	16	-0,588	0,021NS	30	-0,657	0,008NS	37	-0,747	0,001	28	-0,636	0,011NS	16	-0,642	0,01NS
Astorga	49	-0,723	0,002	17	-0,459	0,085NS	17	-0,67	0,006NS	37	-0,768	0,001	38	-0,574	0,025NS	12	-0,497	0,06NS
Campo Mourão	237	-0,770	0,001	5	-0,522	0,046NS	130	-0,603	0,017NS	131	-0,805	0,000	120	-0,677	0,002	14	-0,572	0,026NS
Capanema	3	-0,339	0,216NS	10	-0,189	0,517NS	0	*	*	2	-0,688	0,005	0	*	*	0	*	*
Cascavel	82	-0,732	0,002	16	-0,478	0,072NS	16	-0,579	0,024NS	51	-0,802	0,000	11	-0,466	0,08NS	18	-0,389	0,151NS
Cianorte	69	-0,778	0,001	1	-0,499	0,058NS	30	-0,617	0,014NS	20	-0,803	0,000	106	-0,735	0,002	18	-0,488	0,077NS
Cornélio Procópio	160	-0,778	0,001	45	-0,819	0,000	114	-0,767	0,001	195	-0,757	0,001	121	-0,644	0,002	91	-0,668	0,002
Faxinal	11	-0,799	0,000	100	-0,756	0,001	4	-0,589	0,021NS	4	-0,656	0,008NS	3	-0,487	0,078NS	0	*	*
Florai	230	-0,723	0,002	120	-0,592	0,002	90	-0,785	0,001	145	-0,815	0,000	120	-0,815	0,000	156	-0,716	0,003
Foz do Iguaçu	158	-0,756	0,001	15	-0,379	0,164NS	10	-0,276	0,32NS	0	*	*	28	-0,454	0,089NS	27	-0,459	0,085NS
Francisco Beltrão	102	-0,731	0,002	76	-0,716	0,002	123	-0,714	0,002	155	-0,715	0,000	106	-0,735	0,002	85	-0,736	0,004
Goioerê	299	-0,780	0,001	85	-0,756	0,001	10	-0,647	0,002	120	-0,677	0,002	135	-0,608	0,002	85	-0,712	0,004
Guarapuava	7	-0,763	0,001	1	-0,233	0,403NS	17	-0,39	0,151NS	12	-0,548	0,034NS	0	*	*	7	-0,225	0,42NS
Ivaiporã	160	-0,724	0,002	114	-0,767	0,001	120	-0,647	0,002	131	-0,805	0,000	125	-0,644	0,002	3	-0,712	0,004
Jacarezinho	19	-0,664	0,007NS	7	-0,592	0,02NS	50	-0,733	0,002	21	-0,705	0,003	85	-0,694	0,004	0	*	*
Jaguariaíva	11	-0,721	0,002	5	-0,627	0,012NS	6	-0,205	0,465NS	3	-0,766	0,001	5	-0,525	0,044NS	7	-0,354	0,196NS

n – número de pixels; r – coeficiente de correlação linear de Pearson; NS – correlação não significativa com 5% de probabilidade; * - falta de dados (pixels puros de TST) para análise.

Continuação da Tabela 5.3: Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para 39 microrregiões do Estado do Paraná, safra 2001 a 2006

Lapa	1	0,172	0,541NS	4	0,342	0,231NS	0	*	*	0	*	*	0	*	*	0	*	*
Londrina	120	-0,669	0,002	149	0,820	0,000	68	-0,801	0,000	59	-0,814	0,000	54	-0,712	0,004	55	-0,712	0,004
Maringá	237	-0,870	0,000	89	-0,831	0,000	8	-0,786	0,001	85	-0,874	0,000	103	-0,794	0,001	170	-0,816	0,000
Palma	2	-0,583	0,029NS	17	-0,336	0,221NS	2	-0,314	0,274NS	1	-0,428	0,111NS	0	*	*	0	*	*
Paranavaí	11	-0,612	0,015	16	-0,246	0,377NS	1	-0,672	0,012NS	0	*	*	66	-0,692	0,004	0	*	*
Pato Branco	0	*	*	0	-0,181	0,519NS	0	*	*	0	*	*	0	*	*	0	*	*
Ponta Grossa	120	-0,669	0,002	140	-0,731	0,002	204	-0,812	0,000	56	-0,659	0,002	166	-0,682	0,003	120	-0,701	0,002
Porecatu	70	-0,762	0,001	55	-0,642	0,004	149	-0,82	0,000	224	-0,815	0,000	140	-0,640	0,001	123	-0,694	0,004
Prudentópolis	0	*	*	0	*	*	3	0,063	0,846NS	1	-0,239	0,41NS	0	*	*	0	*	*
Telemarco Borba	140	-0,627	0,002	89	-0,731	0,002	190	-0,657	0,002	85	-0,804	0,000	182	-0,698	0,003	120	-0,669	0,002
Toledo	471	-0,768	0,001	14	-0,546	0,035NS	59	-0,558	0,031NS	0	*	*	65	-0,554	0,032NS	19	-0,276	0,32NS
Umuarama	85	-0,778	0,001	120	-0,535	0,004	150	-0,599	0,004	58	-0,751	0,001	180	-0,606	0,003	170	-0,625	0,002
Wenceslau Braz	1	-0,212	0,466NS	4	-0,414	0,125NS	0	*	*	0	*	*	0	*	*	3	-0,437	0,155NS

n – número de pixels; r – coeficiente de correlação linear de Pearson; NS – correlação não significativa com 5% de probabilidade; * – falta de dados.

Tabela 5.4: Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para microrregiões 39 do Estado do Paraná, safra 2007 a 2011.

Microrregião	Safras														
	2007			2008			2009			2010			2011		
	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor	n	NDVI x TST r	p-valor
Apucarana	26	-0,818	0,001	83	-0,736	0,004	2	-0,443	0,098NS	28	-0,671	0,005	180	-0,744	0,002
Assai	26	-0,794	0,001	136	-0,576	0,005	13	-0,508	0,053NS	52	-0,587	0,035NS	68	-0,781	0,001
Astorga	45	-0,767	0,001	206	-0,601	0,002	20	-0,57	0,027NS	88	-0,833	0,000	91	-0,791	0,000
Campo Mourão	360	-0,748	0,001	383	-0,765	0,001	0	*	*	428	-0,757	0,001	141	-0,839	0,000
Capanema	5	-0,365	0,199NS	9	-0,685	0,005	1	-0,45	0,092NS	0	*	*	0	*	*
Cascavel	18	-0,605	0,022NS	135	-0,764	0,001	16	-0,313	0,255NS	164	-0,526	0,053NS	37	-0,837	0,000
Cianorte	32	-0,768	0,001	101	-0,756	0,001	5	-0,503	0,08NS	55	-0,678	0,003	45	-0,828	0,001
Cornélio Procópio	130	-0,806	0,000	401	-0,765	0,001	43	-0,432	0,108NS	182	-0,805	0,000	196	-0,787	0,000
Faxinal	26	-0,82	0,001	45	-0,794	0,000	0	*	*	16	-0,515	0,06NS	10	-0,767	0,004
Florai	150	-0,89	0,000	461	-0,643	0,001	58	-0,767	0,001	439	-0,809	0,000	260	-0,795	0,000
Foz do Iguaçu	0	*	*	166	-0,769	0,001	0	*	*	81	-0,68	0,001	120	-0,697	0,004
Francisco Beltrão	98	-0,719	0,002	98	-0,694	0,004	158	-0,867	0,000	82	-0,692	0,002	125	-0,655	0,002
Goioerê	445	-0,89	0,000	455	-0,765	0,001	121	-0,789	0,000	428	-0,758	0,001	41	-0,82	0,000
Guarapuava	7	-0,628	0,016NS	86	-0,729	0,002	0	*	*	0	*	*	59	-0,765	0,001
Ivaiporã	180	-0,769	0,001	50	-0,802	0,000	8	-0,403	0,136NS	15	-0,836	0,001	37	-0,702	0,004
Jacarezinho	85	-0,736	0,004	13	-0,605	0,022NS	1	-0,449	0,107NS	3	-0,645	0,013NS	13	-0,812	0,000
Jaguariaíva	22	-0,779	0,001	45	-0,794	0,000	0	*	*	0	*	*	16	-0,645	0,009NS
Lapa	1	-0,216	0,5NS	2	-0,585	0,022NS	0	*	*	0	*	*	0	*	*

n – número de pixels; r – coeficiente de correlação linear de Pearson; NS – correlação não significativa com 5% de probabilidade; * - falta de dados.

Continuação da Tabela 5.4: Correlação linear de Pearson obtida entre os parâmetros NDVI e TST para microrregiões 39 do Estado do Paraná, safra 2007 a 2011.

Londrina	98	-0,729	0,002	242	-0,804	0,000	232	-0,823	0,000	144	-0,791	0,001	130	-0,713	0,003
Maringá	44	-0,878	0,000	171	-0,805	0,000	103	-0,754	0,001	121	-0,789	0,000	106	-0,755	0,001
Palma	20	-0,242	0,405NS	7	-0,628	0,016NS	1	-0,492	0,063NS	0	*	*	0	*	*
Paranavaí	86	-0,715	0,003	93	-0,731	0,002	5	-0,327	0,275NS	23	-0,429	0,111NS	13	-0,775	0,001
Pato Branco	4	-0,627	0,012NS	4	-0,365	0,199NS	2	-0,327	0,275NS	4	0,017	0,953NS	0	*	*
Ponta Grossa	238	-0,757	0,001	51	-0,733	0,002	58	-0,767	0,001	13	-0,775	0,001	230	-0,632	0,002
Porecatu	170	-0,716	0,003	438	-0,757	0,001	74	-0,614	0,002	232	-0,823	0,000	210	-0,697	0,004
Prudentópolis	13	-0,553	0,032NS	12	-0,64	0,01NS	0	*	*	0	*	*	0	*	*
Telemarco Borba	65	-0,674	0,004	75	-0,654	0,003	123	-0,686	0,003	55	-0,697	0,002	160	-0,846	0,001
Toledo	12	-0,615	0,015NS	258	-0,756	0,001	0	*	*	583	-0,76	0,001	83	-0,718	0,004
Umuarama	35	-0,705	0,003	135	-0,768	0,001	103	-0,754	0,001	103	-0,754	0,001	60	-0,746	0,002
Wenceslau Braz	2	-0,504	0,079NS	7	-0,328	0,298NS	0	*	*	0	*	*	2	-0,567	0,035NS

n – número de pixels; r – coeficiente de correlação linear de Pearson; NS – correlação não significativa com 5% de probabilidade; * - falta de dados (pixels puros de TST) para análise.

Tabela 5.5 Regressões lineares múltiplas obtidas com produção e os valores médios dos pixels puros de NDVI e TST para Microrregiões do Estado do Paraná.

Microrregião	NDVI e TST	Coeficiente de determinação (%)
	Modelo	
Apucarana	$P = -811 + 117 \text{ NDVI} + 3,69 \text{ TST}$	2,90%
Assai	$P = -5577 - 434 \text{ NDVI} + 20,9 \text{ TST}$	49,5%
Astorga	$P = 5503 - 712 \text{ NDVI} - 15,0 \text{ TST}$	24,2%
Campo Mourão	$P = -18412 + 3929 \text{ NDVI} + 54,5 \text{ TST}$	32,6%
Capanema	$P = 14172 - 825 \text{ NDVI} - 43,5 \text{ TST}$	49,9%
Cascavel	$P = 36959 - 2862 \text{ NDVI} - 110 \text{ TST}$	26,6%
Cianorte	$P = -2783 - 283 \text{ NDVI} + 10,8 \text{ TST}$	40,8%
Cornélio Procópio	$P = -6801 - 1990 \text{ NDVI} + 30,9 \text{ TST}$	48,4%
Faxinal	$P = 1991 - 240 \text{ NDVI} - 5,20 \text{ TST}$	25,3%
Florai	$P = -926 - 564 \text{ NDVI} + 6,71 \text{ TST}$	50,1%
Foz do Iguaçu	$P = -13512 - 1082 \text{ NDVI} + 51,1 \text{ TST}$	41,2%
Francisco Beltrão	$P = 9075 - 2259 \text{ NDVI} - 20,4 \text{ TST}$	77,5%
Goióerê	$P = 171 - 2453 \text{ NDVI} + 10,6 \text{ TST}$	56,6%
Guarapuava	$P = -3375 - 695 \text{ NDVI} + 18,6 \text{ TST}$	24,6%
Ivaiporã	$P = -1284 - 766 \text{ NDVI} + 8,21 \text{ TST}$	59,4%
Jacarezinho	$P = 312.164 - 234.608 \text{ NDVI} + 0,214006 \text{ TST}$	10,3%
Jaguariaíva	$P = 5114 - 1299 \text{ NDVI} - 12,2 \text{ TST}$	47,2%
Lapa	$P = 2536 - 2773 \text{ NDVI} - 0,52 \text{ TST}$	44,2%
Londrina	$P = -1531 - 940 \text{ NDVI} + 9,8 \text{ TST}$	68,2%
Maringá	$P = -1344 - 937 \text{ NDVI} + 8,26 \text{ TST}$	86,7%
Palma	$P = 2276 - 76 \text{ NDVI} - 5,78 \text{ TST}$	7,3%
Paranavaí	$P = 1381 + 259 \text{ NDVI} - 4,78 \text{ TST}$	46,3%
Ponta Grossa	$P = -2730 - 1628 \text{ NDVI} + 17,2 \text{ TST}$	65,3%
Porecatu	$P = -2604 - 716 \text{ NDVI} + 12,4 \text{ TST}$	53,7%
Telemarco Borba	$P = 4932 - 1500 \text{ NDVI} - 9,69 \text{ TST}$	66,2%
Toledo	$P = 15248 - 6665 \text{ NDVI} - 23,6 \text{ TST}$	45,1%
Umuarama	$P = 17012 - 1053 \text{ NDVI} - 52,3 \text{ TST}$	73,4%
Wenceslau Braz	$P = -203 - 1026 \text{ NDVI} + 4,4 \text{ TST}$	36,0%

P – produção das culturas de verão

Quando avaliadas as relações entre os perfis médios de TST e NDVI para as 11 safras agrícolas, em todo o Estado do Paraná, observa-se uma relação inversa entre seus valores. Na medida em que o solo ganha massa vegetal, o que está diretamente relacionado ao aumento dos valores de NDVI, é observado reduções nos valores de TST, sendo que o inverso também é detectado (Figura 5.8a e 5.8b). Julien e Sobrino (2009) e Julien et al. (2011) mostraram a relação inversa entre os valores de TST e

NDVI para diferentes culturas, corroborando com os resultados aqui encontrados. Estudos realizados por Sun e Kafatos (2007), mostram e ressaltam que essa correlação só é inversa quando efetuada nas estações quentes do ano, como é o caso deste estudo.

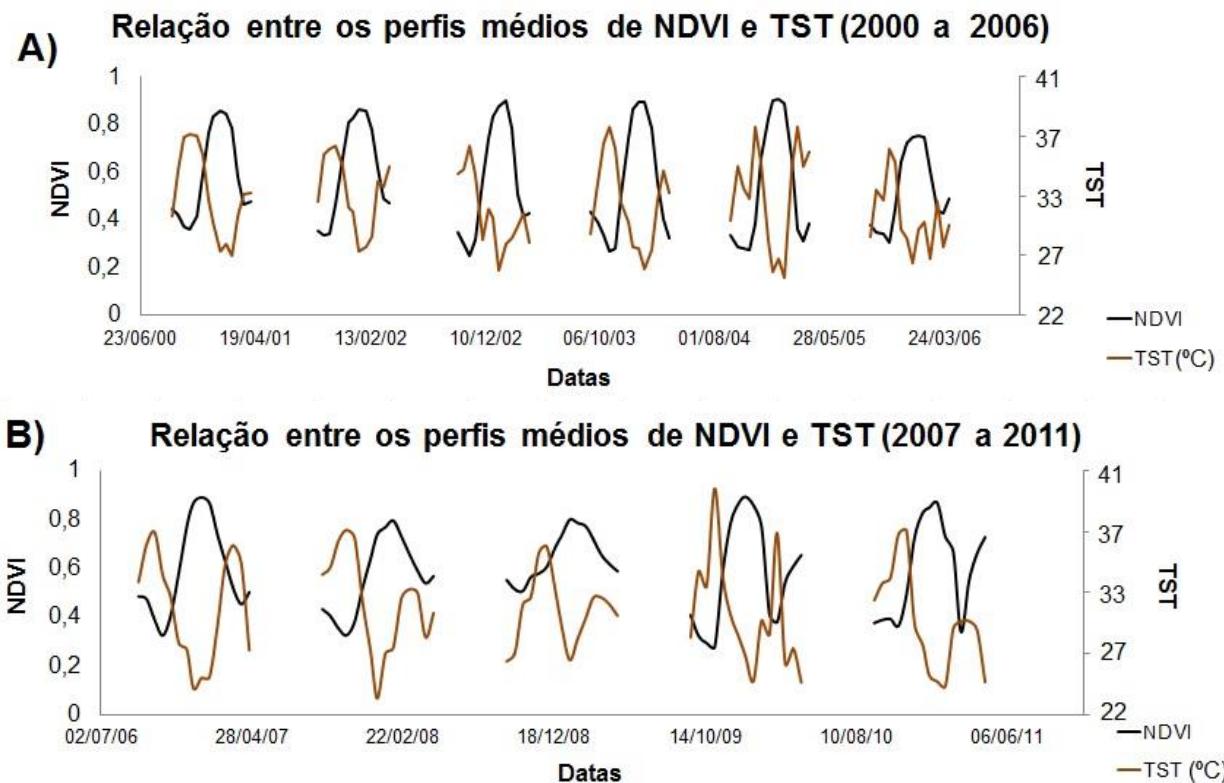


Figura 5.8: (a) Relações entre valores médios de NDVI e TST para as safras de 2000 a 2006 e (b) relações entre valores médios de NDVI e TST para as safras de 2007 a 2011.

Segundo Peng e Gitelson (2012) a TST é uma variável auxiliar na estimativa de safras agrícolas, uma vez que os autores afirmam que, a produtividade primária bruta pode ser calculada a partir de dados de temperatura de superfície. Os autores ainda encontraram correlação superior a 0,8 quando compararam os valores da produtividade primária bruta com os índices de vegetação EVI e NDVI.

5.4 Conclusão

Os produtos NDVI, composição de 16 dias, e TST, composição de 8 dias, gerados a partir das imagens do sensor MODIS permitiu traçar perfis temporais para as culturas de verão e correlacioná-los às fases do seu desenvolvimento fenológico, sendo verificado a relação inversa entre seus valores. A TST apresentou maior influência na fase inicial do desenvolvimento vegetativo das culturas de verão devido parte do solo ainda se encontrar sem vegetação.

As máscaras de cultura de verão apresentaram índice *Kappa* e exatidão global superiores a 0,68 e 84%, respectivamente, no entanto, os valores de erros de omissão foram inferiores a 20% e os de inclusão foram inferiores 10%. Os resultados mostram que mesmo com imagens de resolução de 1km, para a TST, foi possível trabalhar com agregados de 4 pixels puros de NDVI sobre pixel de TST .

As correlações lineares de Pearson entre os valores de TST e NDVI para cada uma das 32 microrregiões avaliadas tiveram 10 microrregiões com valor médio superior a -0,58 na série temporal de 11 safras agrícola. Os melhores coeficientes de determinação da regressão múltipla entre produção, NDVI e TST também foram obtidos com essas 10 microrregiões retornando um valor médio entorno de 64%, sendo um bom indicativo do potencial da TST e do NDVI em auxiliar as estimativas agrícolas.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP – projeto: 2011/13748-8) pelo apoio financeiro.

Ao Programa de Doutorando no Brasil com Estágio no Exterior – PDEE (Processo BEX: 4565/11-8) pelo apoio financeiro e incrível experiência oferecida.

REFERÊNCIAS

ARRAES, C. L.; LAMPARELLI, R. A. C.; ROCHA, J. V.; ESQUERDO, J. C. D. M.; SALVADOR, P.; RODRÍGUEZ, J.; ROQUE, J. L.C.; JUSTO, J. S.; BENATTI, B. G. Reliability of Summer Crop Masks Derived from Second Order Polynomial Equations. **Journal of Agricultural Science**. v. 5, n. 3, p. 64-75, 2013.

ARVOR, D.; JONATHAN, M.; MEIRELLES, M. S. P.; DUBREUIL, V.; DURIEUX, L.. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. **International Journal of Remote Sensing**, v. 3, n. 9, p. 1–25, 2011.

BAJGIRAN, P. R.; OMASA, K.; SHIMIZU, Y. Comparative evaluation of the Vegetation Dryness Index (VDI), the Temperature Vegetation Dryness Index (TVDI) and the improved TVDI (iTVDI) for water stress detection in semi-arid regions of Iran. **ISPRS Journal of Photogrammetry and Remote Sensing**, n. 68, p. 1–12, 2012.

BHATTACHARYA, B. K.; MALLICK, K.; NIGAM, R.; DAKORE, K.; SHEKH, A.M. Efficiency based wheat yield prediction in a semi-arid climate using surface energy budgeting with satellite observations. **Agricultural and Forest Meteorology**, n. 151, p. 1394–1408, 2011.

BROW, J. C.; KASTENS, J. H.; COUTINHO, A. C.; VICTORIA D. de C.; BISHOP, C. R. Classifying multiyear agricultural land use data from Mato Grosso using time-series MODIS vegetation index data. **Remote Sensing of Environment**, n.130, p. 39–50, 2013.

CAI, X.L.; SHARMA, B.R. Integrating remote sensing, census and weather data for an assessment of rice yield, water consumption and water productivity in the Indo-Gangetic river basin. **Agricultural Water Management**, n. 97, p. 309–316, 2010.

CASA, R.; VARELLA, H.; BUIS, S.; GUÉRIF, M.; SOLAN, B.; BARECT, F. Forcing a wheat crop model with LAI data to access agronomic variables: Evaluation of the impact of model and LAI uncertainties and comparison with an empirical approach. **Europ. J. Agronomy**, n. 37, p. 1–10, 2012.

CHANG, J.; HANSEN, M.C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the United States using MODIS time-series data sets. **Agronomy Journal**, n. 99, p. 1654-1664, 2007.

CHEN, C-F.; SON, N-T; CHANG, L.-Y. CHEN, C.-C. Monitoring of soil moisture variability in relation to rice cropping systems in the Vietnamese Mekong Delta using MODIS data. **Applied Geography**, n. 31, p. 463–475, 2011.

EMBRAPA SOJA. **Tecnologia de produção de soja**: Região Central do Brasil 2009 e 2010. Londrina-PR: Embrapa Soja, 2008. (Sistemas de Produção, n. 13).

EMBRAPA SOJA. **Ecofisiologia da soja**. Londrina-PR: Embrapa Soja, 2007. (Circular Técnico n. 48).

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, n. 80, p. 185– 201, 2002.

GAO, Z.; GAO, W.; NI-BIN, C. Integrating temperature vegetation dryness index (TVDI) and regional water stress index (RWSI) for drought assessment with the aid of LANDSAT TM/ETM+ images. **International Journal of Applied Earth Observation and Geoinformation**, n. 13, p. 495–503, 2011.

GOOWARD, S. N.; XUE, Y.; CZAJKOWSKI, K. P. Evaluating land surface moisture conditions from the remotely sensed temperature/vegetation index measurements An exploration with the simplified simple biosphere model. **Remote Sensing of Environment**, n. 79, p. 225–242, 2002.

GUA, J.; Li, X.; HUANG, C.; OKIN, G. S. A simplified data assimilation method for reconstructing time-series MODIS NDVI data. **Advances in Space Research**, n. 44, p. 501–509, 2009.

HUETE, A., JUSTICE, C., LEEUWEN, W. V. **Modis vegetation index (mod 13) Algorithm theoretical basis document version 3**. University of Arizona. 1999. Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf>. Acesso em: 06 jun. 2013.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Banco de Dados Agregados. **Sistema IBGE de Recuperação Automática - SIDRA**. 2013. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 10 ago. 2013.

INSTITUTO DE TERRAS, CARTOGRAFIA E GEOCIÊNCIAS. **Dados Cartográficos do Paraná**, 2008. Disponível em: <<http://www.itcg.pr.gov.br>>. Acesso em: 18 jan. 2013.

INSTITUTO NACIONAL DE PESQUISAS ESPECIAIS. **Catálogo de imagens LANDSAT**. São José dos Campos, SP, 2012. Disponível em: <<http://www.inpe.br/>>. Acesso em: 18 dez. 2013.

JOHANN, J. A.; ROCHA, J.V.; DUFT, D. G.; LAMPARRELLI, R. A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesq. agropec. bras.**, v. 47, n. 9, p. 1295-1306, 2012.

JONNA, S.; BADRINATH, K. V. S.; HANDRASEKHARG; AMMINEDU C. E.; CHAND, R. K. Crop surface temperature estimation in irrigated command areas using MODIS satellite data. **International Journal of Remote Sensing**, v. 28, n. 23, p. 5195–5205, 2007.

JULIEN, Y.; SOBRINO, J. A. The Yearly Land Cover Dynamics (YLCD) method: An analysis of global vegetation from NDVI and LST parameters. **Remote Sensing of Environment**, n. 113, p. 329–334, 2009.

JULIEN, Y.; SOBRINO, J. A.; J.-C.; JIMÉNEZ-MUÑOZ. Land use classification from multitemporal Landsat imagery using the Yearly Land Cover Dynamics (YLCD) method. **International Journal of Applied Earth Observation and Geoinformation**, n. 13, p. 711–720, 2011.

KHALIL, S. K.; MEXAL, J. G.; REHMAN, A.; KHAN, A. Z. Soybean mother plant exposure to temperature stress and its effect on germination under osmotic stress. **Pak. J. Bot.**, v. 42, n. 1, p. 213-225, 2010.

KOPPEN, W. **Grundriss der Klimakunde**. Berlin: Walter de Gruyter, 1931.

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

LIA, Z.; WANGA, Y.; ZHOUB, Q.; WUC, J.; PENGA, J.; CHANG, H. Spatiotemporal variability of land surface moisture based on vegetation and temperature characteristics in Northern Shaanxi Loess Plateau, China. **Journal of Arid Environments**, n. 72, p. 974–985, 2008.

LUNETTA, R. S.; SHAO, Y.; EDIRIWICKREMA, J.; LYON, J. G. Monitoring agricultural cropping patterns across the Laurentian Great Lakes Basin using MODIS-NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, n. 12, p. 81–88, 2010.

LV, Z.; LIU, X.; CAO, W.; ZHU, Y. Climate change impacts on regional winter wheat production in main wheat production regions of China. **Agricultural and Forest Meteorology**, v. 171, n. 172, p. 234– 248, 2013.

MINITAB INC. **Minitab For Windows**: Version Release 16.1.0. State College, PA, 2010. (Statistical Software).

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**, n. 151, p. 385-393, 2011.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **REVERB | ECHO**. NASA, 2012 Disponível em: <http://www.echo.nasa.gov/reverb/about_reverb.htm>. Acesso em: 21 set. 2013.

NUARSA, I. W.; NISHIO, F.; HONGO, C. Relationship between Rice Spectral and Rice Yield Using Modis Data. **Journal of Agricultural Science**, v. 3, n. 2, p. 80-88, 2011.

PARANÁ. Secretaria da Agricultura e do Abastecimento. Departamento de Economia Rural. Banco de dados da Produção Agropecuária. **Situação mensal de plantio, colheita e comercialização de produtos agrícolas no Paraná**, 2012. Disponível em: <<http://www.agricultura.pr.gov.br/arquivos/File/deral/pss.xls>>. Acesso em: 12 jul. 2013.

PARIDA, B. R.; OINAM, B.; PATEL, N. R.; SHARMA, N.; KANDAWL R.; HAZARIKA, M. K. Land surface temperature variation in relation to vegetation type using MODIS satellite data in Gujarat state of India. **International Journal of Remote Sensing**, v. 29, n. 14, p. 4219–4235, 2008.

PEÑA-BARRAGÁN, J.M.; NGUGI, M. K.; PLANT, R. E.; SIX, J. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, n. 115, p. 1301–1316, 2001.

PENG, Y.; GITELSON, A. A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sens. Environ.** n. 117, p. 440-448, 2012.

PRASAD, A. K.; CHAI, L.; SINGH, R. P.; KAFATOS, M. Crop yield estimation model for Iowa using remote sensing and surface parameters. **International Journal of Applied Earth Observation and Geoinformation**, n. 95, p. 2-8, 2006.

QUIROGA, S.; IGLESIAS, A. A comparison of the climate risks of cereal, citrus, grapevine and olive production in Spain. **Agricultural Systems**, n. 101 p. 91–100, 2009.

RATHKE, G.-W.; WIENHOLD, B.J.; WILHELM, W.W.; DIEPENBROCK, W. Tillage and rotation effect on corn–soybean energy balances in eastern Nebraska. **Soil & Tillage Research**, n. 97, p. 60–70, 2007.

ROCHA, J. **Crop Monitoring in South America MERCOSUR + BOLIVIA**. MARS-FOOD, AGRIFISH, IPSC, JRC-EC, TP266, 21020 - Ispra (VA), 2005.

SAKAMOTO, T. GITELSON, A. A. ARKEBAUER, T. J. MODIS-based corn grain yield estimation model incorporating crop phenology information. **Remote Sensing of Environment**, n. 131, p. 215–231, 2013.

SAKAMOTO, T.; WARDLOW, B. D.; GITELSON, A. A.; VERMA, S. B.; SUYKER, A. E.; ARKEBAUER, T. J. A Two-Step Filtering approach for detecting maize and soybean phenology with time-series MODIS data. **Remote Sensing of Environment**, n. 114, p. 2146-2159, 2010.

SAKAMOTOT.; YOKOZAWA, M.; TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N.; OHO, H. A Crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, n. 96, p. 366-374, 2005.

SANCHES, I.D.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Culturas agrícolas em imagens multitemporais do satélite Landsat. **Agricultura**, v. 52, n. 1, p. 83-96, 2005.

SINGH, R. P.; ROY, S.; KOGAN, F. Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India. **Int. J. Remote Sensing**, v. 24, n. 22, p. 4393–4402, 2003.

SONA, N.T.; CHENA, C.F.; CHENB, C.R.; CHANGA, L.Y.; MINHC, V.Q. Monitoring agricultural drought in the Lower Mekong Basin using MODIS NDVI and land surface temperature data. **International Journal of Applied Earth Observation and Geoinformation**, n. 18, p. 417–427, 2012.

SUN, L.; SUNA, R.; LI X.; LIANGB, S.; ZHANG, R. Monitoring surface soil moisture status based on remotely sensed surface temperature and vegetation index information. **Agricultural and Forest Meteorology**, v. 166, n. 167, p. 175–187, 2012.

SUN, D.; KAFATOS, M. Note on the NDVI-LST relationship and the use of temperature-related drought indices over North America. **Geophysical Research Letters**, n. 34, p. 1-4, 2007.

TIINGTING, L.; CHUANG, L. Study on extraction of crop information using time-series MODIS data in the Chao Phraya Basin of Thailand. **Advances in Space Research**, n. 45, p. 775–784, 2010.

THORP, K.R.; WANG, G.; WEST, A.L.; MORAN, M.S.; BRONSON, K.F.; WHITE, J.W.; MON, J. Estimating crop biophysical properties from remote sensing data by inverting linked radiative transfer and ecophysiological models. **Remote Sensing of Environment**, n. 124, p. 224–233, 2012.

VIÑA, A.; GITELSON, A. A.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B.; SCHEPERS, J. Monitoring Maize (*Zea mays* L.) Phenology with Remote Sensing. **Agronomy Journal**, n. 96, p. 1139-1147, 2004.

WARDLOW, B. D.; EGBERT, S. L.; KASTE, J. HS. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, n. 108, p. 290-310, 2007.

WILHELM, W. W.; WORTMANN, C. S. Tillage and Rotation Interactions for Corn and Soybean Grain Yield as Affected by Precipitation and Air Temperature. **Agronomy Journal**, n. 96, p. 425-432, 2004.

WU, C.; CHEN, J.M.; HUANG, Ni. Predicting gross primary production from the enhanced vegetation index and photosynthetically active radiation: Evaluation and calibration. **Remote Sensing of Environment**, n. 115, p. 3424–3435, 2011.

UDORFF, C. M., RIZZI, R.; RUDORFF, B. F. T.; SUGAWARA, L. M.; VIEIRA, C. A. O. Superfícies de resposta espectro-temporal de imagens do sensor MODIS para classificação de área de soja no Estado do Rio Grande do Sul. **Cienc. Rural**, v. 37: n. 1, p. 118-125, 2007.

6 CONCLUSÕES GERAIS

O Sensor MODIS, abordo do satélite Terra, mostrou ser uma ferramenta que pode auxiliar o governo nas tomadas de decisão e principalmente facilitar os levantamentos de safras agrícolas. Dentre os vários produtos oriundos do sensor MODIS, os índices de vegetação NDVI e EVI e a Temperatura de Superfície Terrestre (TST) mostraram-se capazes de auxiliar pesquisadores no monitoramento de culturas de verão, principalmente por poder correlacionar estes produtos com informações de produção.

A máscara de cultura de verão obtida por técnicas que conciliam dados provenientes de sensores remotos com equações polinomiais de segunda ordem possibilitou compreender de forma dinâmica as distintas fases fenológicas das culturas de verão. O que levou também a uma maior confiabilidade vista a agregação de parâmetros estatísticos como, por exemplo, o coeficiente de determinação oriundo dos ajustes das equações polinomiais aos perfis temporais das culturas de verão. A metodologia proposta apresentou uma exatidão global de 93%, sendo ligeiramente superior a exatidão global encontrada pela metodologia máximo-mínimo NDVI que foi de 91%, indicando ser mais uma ferramenta no auxílio das estimativas de safras agrícolas.

O produto EVI permitiu traçar perfis temporais tanto para a cultura da soja quanto para o milho, e correlacioná-los com a fase inicial do seu desenvolvimento fenológico, ajustando equações logarítmicas a esta fase inicial, sugerindo assim a possibilidade de distinguir essas duas culturas por técnicas de sensoriamento remoto. No entanto, os resultados indicaram que a metodologia proposta apresentou maior potencial de diferenciação, destas culturas, em áreas com maiores propriedades agrícolas, onde foi encontrado índice *Kappa* de 0,71 e exatidão global de 81,2%. Porém, deve-se considerar que em regiões onde as propriedades têm tamanhos menores, essa separação não foi possível, devido principalmente à ocorrência de confusão espectral entre estas duas culturas ou com outros alvos que não soja e milho, como provável consequência da baixa resolução espacial das imagens MODIS.

A correlação entre dados de TST, NDVI e produção mostrou ser possível, no entanto a TST apresentou maior influência na fase inicial do desenvolvimento vegetativo das culturas de verão devido parte do solo ainda se encontrar sem vegetação. Uma das maiores restrições nas análises foi o fato que as imagens de TST possuem resolução espacial de 1 km dificultando correlacioná-las com os dados de NDVI que possui resolução de 250m. No entanto, os resultados demonstraram que mesmo com imagens de resolução de 1 km foi possível trabalhar com agregados de pixels puros de NDVI bem como de TST para parte das 39 microrregiões estudadas, resultando assim em modelos matemáticos que podem auxiliar no acompanhamento das estimativas de produção.

REFERÊNCIAS

- ARRAES, C. L.; LAMPARELLI, R. A. C.; ROCHA, J. V.; ESQUERDO, J. C. D. M.; SALVADOR, P.; RODRIGUEZ, J.; ROQUE, J. L.C.; JUSTO, J. S.; BENATTI, B. G. Reliability of Summer Crop Masks Derived from Second Order Polynomial Equations. **Journal of Agricultural Science**. v. 5, n. 3, p. 64-75, 2013.
- ARVOR, D.; JONATHAN, M.; MEIRELLES, M. S. P.; DUBREUIL, V.; DURIEUX, L.. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. **International Journal of Remote Sensing**, v. 3, n. 9, p. 1–25, 2011.
- BAJGIRAN, P. R.; OMASA, K.; SHIMIZU, Y. Comparative evaluation of the Vegetation Dryness Index (VDI), the Temperature Vegetation Dryness Index (TVDI) and the improved TVDI (iTVDI) for water stress detection in semi-arid regions of Iran. **ISPRS Journal of Photogrammetry and Remote Sensing**, n. 68, p. 1–12, 2012.
- BHATTACHARYA, B. K.; MALLICK, K.; NIGAM, R.; DAKORE, K.; SHEKH, A.M. Efficiency based wheat yield prediction in a semi-arid climate using surface energy budgeting with satellite observations. **Agricultural and Forest Meteorology**, n. 151, p. 1394– 1408, 2011.
- CAI, X.L.; SHARMA, B.R. Integrating remote sensing, census and weather data for an assessment of rice yield, water consumption and water productivity in the Indo-Gangetic river basin. **Agricultural Water Management**, n. 97, p. 309–316, 2010.
- CASA, R.; VARELLA, H.; BUIS, S.; GUÉRIF, M.; SOLAN, B.; BARECT, F. Forcing a wheat crop model with LAI data to access agronomic variables: Evaluation of the impact of model and LAI uncertainties and comparison with an empirical approach. **Europ. J. Agronomy**, n. 37, p. 1– 10, 2012.
- CHANG, J.; HANSEN, M.C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the United States using MODIS time-series data sets. **Agronomy Journal**, n. 99, p. 1654-1664, 2007.
- CHEN, C-F.; SON, N-T; CHANG, L.-Y. CHEN, C.-C. Monitoring of soil moisture variability in relation to rice cropping systems in the Vietnamese Mekong Delta using MODIS data. **Applied Geography**, n. 31, p. 463–475, 2011.
- COMPANHIA NACIONAL DE ABASTECIMENTO. **GeoSafras**. CONAB, 2012. Disponível em: <<http://geoweb.conab.gov.br/conab/>>. Acesso em: 06 jul. 2013.
- CONGALTON, R. G. A review of assessing the accuracy classifications of remotely sensed data. **Remote Sensing of Environment**, n. 37, p. 35-46, 1991.

DEFRIES, R.S.; TOWSHEND, J.R.G. NDVI derived land cover classifications at a global scale. **Int. J. Remote Sens.** v.15, n. 17, p. 3567-3586, 1994.

DORAISWAMY, P. C.; HATFIELD, J. L.; JACKSON, T. J.; AKHMEDOVA, B.; PRUEGER, J.; STERNA, A. Crop condition and yield simulations using Landsat and MODIS. **Remote Sensing of Environment**, n. 92, p. 548-559, 2004.

EMBRAPA SOJA. **Tecnologia de produção de soja:** Região Central do Brasil 2009 e 2010. Londrina-PR: Embrapa Soja, 2008. Sistemas de Produção n.13.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. Rio de Janeiro: EMBRAPA, 1999.

ESQUERDO, J.C.D.M.; ZULLO JUNIOR, J.; ANTUNES, J.F.G. Use of NDVI/AVHRR time series profiles for soybean crop monitoring in Brazil. **Int. J. Remote Sens.** v. 32, n. 13, p. 3711-3727, 2011.

GAO, Z.; GAO, W.; NI-BIN, C. Integrating temperature vegetation dryness index (TVDI) and regional water stress index (RWSI) for drought assessment with the aid of LANDSAT TM/ETM+ images. **International Journal of Applied Earth Observation and Geoinformation**, n. 13, p. 495–503, 2011.

GOWARD, S. N.; XUE, Y.; CZAIKOWSKI, K. P. Evaluating land surface moisture conditions from the remotely sensed temperature/vegetation index measurements An exploration with the simplified simple biosphere model. **Remote Sensing of Environment**, n. 79, p. 225– 242, 2002.

GUA, J.; LI, X.; HUANG, C.; OKIN, G. S. A simplified data assimilation method for reconstructing time-series MODIS NDVI data. **Advances in Space Research**, n. 44, p. 501–509, 2009.

HUETE, A.; JUSTICE, C.; LEEUWEN, W. V. **Modis vegetation index (mod 13) Algorithm theoretical basis document version 3**. University of Arizona, 1999. Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf>. Acesso em: 05 maio 2013.

HUNTE, A.D.L.; LIU, H.Q.; BATCHILY, K.; J.-VAN L. A. Comparation of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sens. Environ.** n. 59, p. 440-451, 1997.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Banco de Dados Agregados**: Sistema IBGE de Recuperação Automática - SIDRA. 2013. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 10 ago. 2013.

INSTITUTO NACIONAL DE PESQUISAS ESPECIAIS. **Catálogo de imagens LANDSAT**. São José dos Campos, SP, 2012. Disponível em: <<http://www.inpe.br/>>.

Acesso em: 18 dez. 2013.

JENSEN, M.E. Water consumptions by agricultural plants. In: KOZLOWSKY, T.T.; (ed.) **Water deficits and plant growth**. New York: Academic Press, 1986. Cap.2, p1-22,

JONNA, S.; BADRINATT K. V. S.; HANDRASEKHARG; AMMINEDU, C. E.; CHAND, R. K. Crop surface temperature estimation in irrigated command areas using MODIS satellite data. **International Journal of Remote Sensing**, v. 28, n. 23, p. 5195–5205, 2007.

JUSTICE, C.O.; VERMOTE, E.; TOWSHEND. J. R.G.; DEFRIES, R.; ROY, P.D; HALL, D.K, SALOMONSON, V.; PRIVETTE, J.L.; RIGGS, G.; STRAHLER, A.; LUCHT, W.; MYNENI, B; KNYAZIKHIN, Y.; RUNNING, W.S.; NEMANI, R.R.; WAN, Z.; HUETE, A.R.; LEEUWEN, W.V.; WOLFE, R.E.; GIGLIO, L.; MULLER, J.P; LEWIS, P.; BARNSLEY, M. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, n.4, p.1228-1247, july, 1998.

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

LIA, Z.; WANGA, Y.; ZHOUB, Q.; WUC, J.; PENGA, J.; CHANGD, H. Spatiotemporal variability of land surface moisture based on vegetation and temperature characteristics in Northern Shaanxi Loess Plateau, China. **Journal of Arid Environments**, n. 72, p. 974–985, 2008.

LV, Z.; LIU, X.; CAO, W.; ZHU, Y. Climate change impacts on regional winter wheat production in main wheat production regions of China. **Agricultural and Forest Meteorology**, v. 171, n. 172, p. 234–248, 2013.

MARTINEZ, B.; GILABERT, M.A. Vegetation dynamics from NDVI time series analysis using the wavelet transform. **Remote Sens. Environ.** n. 113, p. 1823-1842, 2009.

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

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **REVERB | ECHO**, 2012. Disponível em: <http://www.echo.nasa.gov/reverb/about_reverb.htm>. Acesso em: 09 jul. 2013.

NUARSA, I. W.; NICHIO, F.; HONGO, C. Relationship between Rice Spectral and Rice Yield Using Modis Data. **J. Agr. Sci.** v. 3, n. 2, p. 80-88, 2011.

PARANÁ. Secretaria de Estado da agricultura e do Abastecimento. **Atlas do Estado do Paraná**. Curitiba, 1987.

PARIDA, B. R.; OINAM, B.; PATEL, N. R.; SHARMA, N.; KANDAWL, R.; HAZARIKA, M. K. Land surface temperature variation in relation to vegetation type using MODIS satellite data in Gujarat state of India. **International Journal of Remote Sensing**, v. 29, n. 14, p. 4219–4235, 2008.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos, SP: A. Silva Vieira, 2007.

PRASAD, A. K.; CHAI, L.; SINGH, R. P.; KAFATOS, M. Crop yield estimation model for Iowa using remote sensing and surface parameters. **International Journal of Applied Earth Observation and Geoinformation**, n. 95, p. 2-8, 2006.

QUIROGA, S.; IGLESIAS A. A comparison of the climate risks of cereal, citrus, grapevine and olive production in Spain. **Agricultural Systems**, n. 101, p. 91–100, 2009.

RAMME, F. L. P.; LAMPARELLI, R. A. C.; ROCHA, J. V. Perfis temporais NDVI MODIS, na cana-soca, de maturação tardia. **Engenharia Agrícola**, v. 30, n. 3, p. 480-494, 2010.

SAKAMOTO, T.; WARDLOW, B. D.; GITELSON, A. A.; VERMA, S. B.; SUYKER, A. E.; ARKEBAUER, T. J. A Two-Step Filtering approach for detecting maize and soybean phenology with time-series MODIS data. **Remote Sensing of Environment**, n. 114, p. 2146-2159, 2010.

SAKAMOTO, T.; GITELSON, A. A.; ARKEBAUER, T. J MODIS-based corn grain yield estimation model incorporating crop phenology information. **Remote Sensing of Environment**, n. 131, p. 215–231, 2013.

SANCHES, I.D.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Culturas agrícolas em imagens multitemporais do satélite Landsat. **Agricultura**, v. 52, n. 1, p. 83-96, 2005.

SINGH, R. P.; ROY, S.; KOGAN, F. Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India. **Int. J. Remote Sensing**, v. 24, n. 22, p. 4393–4402, 2003.

SONA, N.T.; CHENA, C.F.; CHENB, C.R.; CHANGA, L.Y.; MINHC, V.Q. Monitoring agricultural drought in the Lower Mekong Basin using MODIS NDVI and land surface temperature data. **International Journal of Applied Earth Observation and Geoinformation**, n. 18, p. 417–427, 2012.

SUN, L.; SUNA, R.; LI X.; LIANGB, S.; ZHANG, R. Monitoring surface soil moisture status based on remotely sensed surface temperature and vegetation index information. **Agricultural and Forest Meteorology**, v. 166, n. 167, p. 175–187, 2012.

THORP, K.R.; WANG, G.; WEST, A.L.; MORAN, M.S.; BRONSON, K.F.; WHITE, J.W.; MON, J. Estimating crop biophysical properties from remote sensing data by inverting linked radiative transfer and ecophysiological models. **Remote Sensing of**

Environment, n. 124, p. 224–233, 2012.

TINGTING, L.; CHUANG, L. Study on extraction of crop information using time-series MODIS data in the Chao Phraya Basin of Thailand. **Advances in Space Research**, n. 45, p. 775–784, 2010.

VIANELLO, L.R.; ALVES, A.R. Meteorologia básica e aplicações. Viçosa: UFV, 1991.

WARDLOW, B. D.; EGBERT, S. L. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. **Remote Sens. Environ.** n. 112, p. 1096-1116, 2008.

WU, C. CHEN, J.M.; HUANG, Ni. Predicting gross primary production from the enhanced vegetation index and photosynthetically active radiation: Evaluation and calibration. **Remote Sensing of Environment**, n. 115, p. 3424–3435, 2011.