

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – UNIOESTE
CAMPUS DE CASCAVEL
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

ÍNDICE DE VEGETAÇÃO EVI PARA ESTIMATIVA DE ÁREA DE MILHO 2.^a safra
E LAVOURAS DE INVERNO

RAFAELA FERNANDES NICOLAU

CASCAVEL - PR

2017

RAFAELA FERNANDES NICOLAU

**ÍNDICE DE VEGETAÇÃO EVI PARA ESTIMATIVA DE ÁREA DE MILHO 2.^a safra
E LAVOURAS DE INVERNO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Erivelto Mercante
Coorientador: Jerry A. Johann

CASCADEL – PARANÁ – BRASIL

2017

Dados Internacionais de Catalogação-na-Publicação (CIP)

548i

Nicolau, Rafaela Fernandes

Índice de vegetação EVI para estimativa de área de milho 2ª safra e lavouras de inverno.
Cascavel, 2017.
76 f.

Orientador: Prof. Dr. Erivelto Mercante

Coorientador: Prof. Dr. Jerry Adriani Johann

Tese (Doutorado) – Universidade Estadual do Oeste do Paraná, Campus de
Cascavel, 2017.

Programa de Pós-Graduação em Engenharia Agrícola

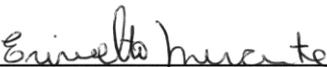
1. Milho - Pesquisa. 2. Sensoriamento remoto. I. Mercante, Erivelto. II. Johann,
Jerry Adriani. III. Universidade Estadual do Oeste do Paraná. IV.
Título.

CDD 20.ed. 633.15
CIP-NBR 12899

RAFAELA FERNANDES NICOLAU

Índice de Vegetação EVI para Estimativa de Área de Milho 2ª Safra e Culturas de Inverno

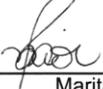
Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutora em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:


Orientador(a) - Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)


Marcus Metri Correa

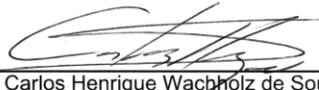
Universidade Federal Rural de Pernambuco (UFRPE)


Maritane Prior

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)


Marcio Furlan Maggi

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)


Carlos Henrique Wachpólz de Souza

Universidade Estadual de Maringá (UEM)

Cascavel, 15 de fevereiro de 2017

BIOGRAFIA

Rafaela Fernandes Nicolau, nascida no dia 22 de agosto 1985 na cidade de Santarém, PA. Filha de Magali Maria Fernandes Nicolau e Metri Nicolau Filho. Em 2009 concluiu o curso de Engenharia Agrícola pelo Centro Universitário Luterano de Santarém (CEULS - ULBRA) e em 2013 finalizou o Mestrado e iniciou o Doutorado no curso de Pós-Graduação em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, na Universidade Estadual do Oeste do Paraná. Nos anos de 2013 e 2014 ministrou aulas no curso tecnológico de Manutenção Industrial no SENAI (Serviço Nacional de Aprendizagem Industrial) na cidade de Cascavel/ PR. Participou do Projeto MAPAGRI (Embrapa Informática Agropecuária).

“Faça aquilo que gosta e não terá de trabalhar um único dia na sua vida”

Confúcio

A
DEUS,
Pelo dom da vida.

Aos meus pais,
Metri e Magali Nicolau, pela oportunidade, força e fé nos momentos difíceis e pela confiança
para seguir meus sonhos.

A minha querida irmã,
Nathália Nicolau pela amizade.

Aos meus avós,
pelo apoio, amizade e carinho nos momentos de dificuldades,
especialmente ao meu avô “Demetrinho”.

Ao meu marido,
Darlisson Bentes, pelo companheirismo, amizade e força para superar os obstáculos do dia
a dia.

AGRADECIMENTOS

À Universidade Estadual do Oeste do Paraná – UNIOESTE, e Ao Programa de Pós-Graduação em Engenharia Agrícola/ UNIOESTE pela oportunidade em participar do programa de pós-graduação e pela utilização de suas instalações;

Ao Professor Dr. Erivelto Mercante, pela orientação, a oportunidade, a confiança, a amizade e o apoio para a realização deste trabalho;

Ao professor Doutor Jerry A. Johann, pela coorientação, sugestões neste e em outros trabalhos, pelo apoio em assuntos acadêmicos e pela amizade do dia a dia;

Aos demais professores, pelas ajudas acadêmicas, conversas; saibam o quanto esses momentos foram importantes.

Aos meus colegas do GeoLab e LEA, pelas ajudas, principalmente nesse último ano, pelos momentos de conversas e descontração.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro;

Aos amigos Eloi, Cristiane, Bruna, Ariane, Kelyn, Suzana, Vanderléia pelo auxílio e amizade compartilhados ao longo desses quatro anos;

E a todos que de alguma forma contribuíram para a realização deste trabalho, eu agradeço de coração.

À Embrapa Informática Agropecuária, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação Araucária.

ÍNDICE DE VEGETAÇÃO EVI PARA ESTIMATIVA DE ÁREA DE MILHO 2.^a SAFRA E LAVOURAS DE INVERNO

RESUMO

A obtenção de tecnologias eficazes para a previsão e o acompanhamento de safras agrícolas ressalta a busca de metodologias que disponibilizem essas informações antes da colheita. Atualmente, o acompanhamento da produção agrícola é ainda em parte realizado por meio de técnicas subjetivas e onerosas por órgãos oficiais brasileiros. O estudo do monitoramento agrícola e/ou estimativa de safras das culturas de inverno, utilizando índices de vegetação extraídos de imagens multitemporais do sensor MODIS, é uma realidade que tem sido testada por diversos autores na busca de maior objetividade para os valores gerados. Nesse contexto, esta pesquisa tem por objetivo mapear e estimar áreas com as lavouras de inverno e de milho safrinha, utilizando séries temporais do índice de vegetação EVI, provenientes do sensor MODIS dos satélites Terra e Aqua, nas safras 2012, 2013 e 2014 para o estado do Paraná. Como forma de ajustar o mapeamento por meio do sensor MODIS (250 metros), foi realizada uma análise visual em que foram utilizadas imagens de média resolução espacial (30 metros) para identificação das culturas desejadas. No Artigo 1 foram geradas composições coloridas utilizando imagens do período de pré-plantio até o desenvolvimento inicial e imagens que representam o pico vegetativos das lavouras. Posteriormente, foi realizada a extração de áreas cultivadas com as lavouras de interesse para que pudessem ser comparadas com dados oficiais por meio de estatísticas e correlações, como também análises de acurácia. No Artigo 2 foram geradas composições coloridas utilizando somente as imagens que representam os picos vegetativos das lavouras para serem classificadas, utilizando o algoritmo SAM (*Spectral angle mapper*). Posteriormente, as máscaras foram comparadas com dados oficiais por meio de estatísticas e correlações, como também análises de acurácia. No Artigo 1 foi verificada subestimação para o milho 2.^a safra nas safras 2012 e 2013 e superestimação em 2014 e, para lavouras de inverno, superestimação. Pelas análises de acurácia, as máscaras foram classificadas com excelência. No Artigo 2 foi verificado que os dados de áreas foram superestimados para o milho 2.^a safra e subestimados para as lavouras de inverno. As análises de acurácia foram classificadas como excelentes em relação à imagem de média resolução.

Palavras-chave geral: Sensor MODIS; Sensoriamento remoto; série temporal.

EVI VEGETATION INDEX FOR AREA ESTIMATING OF SECOND HARVEST CORN AND WINTER CROPS

ABSTRACT

The acquisition of effective technologies for prediction and monitoring of agricultural crops highlights the search for methodologies that make this information available before harvesting. Currently, the monitoring of agricultural production is still partially carried out through subjective and onerous techniques by Brazilian official bodies. The study of the agricultural monitoring and/or estimation of winter crops yield, using vegetation indexes extracted from multitemporal images of the MODIS sensor, is a reality that has been tested by several authors, in the search for greater objectivity to the generated figures. In this context, this research aims to map and estimate areas with winter and maize crops, using temporal series of the EVI vegetation index from the MODIS sensor of the Terra and Aqua satellites, for the 2012, 2013, and 2014 harvests for the state of Paraná. As a way of adjusting the mapping through the MODIS sensor (250 meters), the visual analysis was performed in which images of medium spatial resolution (30 meters) were used to identify the chosen cultures. In article 1, color compositions were generated using images from the pre-planting period until the initial development and images representing the vegetative peak of the crops. Subsequently, the extraction of cultivated areas with the crops of interest was performed, so that these could be compared with official data through statistics and correlations, as well as accuracy analyzes. In Article 2, colored compositions were generated using only the vegetative peak images of the cultures to be classified using the Spectral Angle Mapper (SAM) algorithm. Subsequently, the masks were compared with official data through statistics and correlations, as well as accuracy analyzes. In Article 1, an underestimation of the safflower and winter crops areas was found for the 2012 and 2013 crops, and an overestimation for the 2014 safflower, and for the winter crops, overestimation. By the accuracy analyzes, the masks were classified with excellence. In Article 2, it was verified that the data of areas were overestimated for the safflower corn and underestimated for the winter crops. The accuracy analyzes were classified as excellent, in relation to the medium resolution image.

Keywords: MODIS sensor; Temporal series; Remote sensing.

SUMÁRIO GERAL

LISTA DE TABELAS	xi
LISTA DE FIGURAS	xiii
LISTA DE EQUAÇÕES	xiv
1 INTRODUÇÃO	1
2 OBJETIVOS	3
2.1 Objetivo geral	3
2.2 Objetivos específicos.....	3
3 REVISÃO BIBLIOGRÁFICA GERAL	4
3.1 Lavouras de inverno e milho 2. ^a safra.....	4
3.2 Zoneamento e calendário agrícola	6
3.2.1 Milho 2. ^a safra	7
3.2.2 Lavouras de inverno	8
3.3 Imagens de sensoriamento remoto orbital.....	10
3.3.1 O sensor MODIS e seus produtos	12
3.4 Índices de vegetação.....	14
3.5 Imagens multitemporais no estudo da vegetação.....	16
3.6 Classificação supervisionada utilizando o <i>Spectral angle mapper</i>	18
3.7 Análises estatísticas	20
3.7.1 Índices de acurácia.....	20
3.7.2 Análise de comparação de áreas	21
REFERÊNCIAS	23
ARTIGOS	31
ARTIGO 1: MAPEAMENTO DAS LAVOURAS DE INVERNO E MILHO 2.^a SAFRA NO ESTADO DO PARANÁ, UTILIZANDO IMAGENS MULTITEMPORAIS DO SENSOR MODIS	31
1 INTRODUÇÃO	31
2 MATERIAL E MÉTODOS	32
2.1 Área de estudo e aquisição dos dados	35
2.2 Seleção de pixels puros	36
2.3 Geração das imagens de mínimo e máximo EVI	37
2.4 Composição colorida e extração RGB.....	37

2.5	Índices de acurácias.....	38
2.6	Análises de comparação de áreas.....	38
3	RESULTADOS E DISCUSSÃO	39
3.1	Análises de acurácia das máscaras	42
3.2	Comparação das áreas mapeadas com os dados oficiais	43
4	CONCLUSÕES	46
5	AGRADECIMENTOS	Erro! Indicador não definido.
	REFERÊNCIAS	47
	ARTIGO 2: ESTIMATIVA DE ÁREAS DE MILHO 2.^a SAFRA E INVERNO, UTILIZANDO O ALGORITMO DE CLASSIFICAÇÃO SAM E IMAGENS DOS SATÉLITES TERRA E AQUA, PARA O ESTADO DO PARANÁ.....	49
1	INTRODUÇÃO	49
2	MATERIAL E MÉTODOS.....	51
2.1	Área de estudo e aquisição dos dados	52
2.2	Seleção de pixels puros e extração dos perfis temporais de EVI.....	53
2.3	Composição colorida RGB	53
2.4	Classificação supervisionada <i>Spectral angle mapper</i>	53
2.5	Índices de acurácia.....	54
2.6	Análises de comparação de áreas.....	54
3	RESULTADOS E DISCUSSÃO	55
3.1	Análises de acurácia das máscaras	57
3.2	Comparação das áreas mapeadas com os dados oficiais	58
4	CONCLUSÕES	60
5	AGRADECIMENTOS	Erro! Indicador não definido.
	REFERÊNCIAS	61
	CONSIDERAÇÕES FINAIS.....	64

LISTA DE TABELAS

PARTE GERAL

Tabela 1	Produção das culturas de inverno em nível nacional e estadual.....	4
Tabela 2	Estimativa mensal acumulada de plantio e colheita do milho 2. ^a safra no estado do Paraná.....	8
Tabela 3	Estimativa mensal acumulada de plantio e colheita do trigo no estado do Paraná.....	8
Tabela 4	Estimativa mensal acumulada de plantio e colheita da aveia no estado do Paraná.....	9
Tabela 5	Estimativa mensal acumulada de plantio e colheita do centeio no estado do Paraná.....	9
Tabela 6	Estimativa mensal acumulada de plantio e colheita da cevada no estado do Paraná.....	10
Tabela 7	Estimativa mensal acumulada de plantio e colheita do triticale no estado do Paraná.....	10
Tabela 8	Qualidade de classificação associada aos valores do Kappa	21

ARTIGO 1

Tabela 1	Datas das imagens dos satélites Terra e Aqua utilizadas no estudo.....	35
Tabela 2	Datas das imagens utilizadas para geração das imagens de mínimo e máximo para milho 2. ^a safra.....	39
Tabela 3	Datas das imagens utilizadas para geração das imagens de mínimo e máximo para lavouras de inverno	40
Tabela 4	Área das máscaras de milho 2. ^a safra, lavouras de inverno e sobreposição de áreas, estado do Paraná	42
Tabela 5	Análise de acurácia das máscaras na safra 2012, estado do Paraná	42
Tabela 6	Análise de acurácia das máscaras na safra 2013, estado do Paraná	42
Tabela 7	Análise de acurácia das máscaras na safra 2014, estado do Paraná	43
Tabela 8	Informações de área oficial (IBGE) e obtidas pelas máscaras de milho 2. ^a safra e lavouras de inverno para o estado do Paraná.....	44
Tabela 9	Estatísticas obtidas entre os dados de área oficial (ha) e obtidas pelas máscaras (ha) de milho 2. ^a safra e lavouras de inverno para o estado do Paraná.....	45

ARTIGO 2

Tabela 1	Áreas que compõem as máscaras de milho 2. ^a safra, lavouras de inverno e sobreposição de áreas, estado do Paraná.....	56
Tabela 2	Análise da acurácia das máscaras	57
Tabela 3	Informações de área oficial (IBGE) e obtidas pelas máscaras (ha) de milho 2. ^a safra e lavouras de inverno para o estado do Paraná.....	58
Tabela 4	Estatísticas obtidas entre os dados de área oficial (ha) e as obtidas pelas máscaras (ha) de milho 2. ^a safra e lavouras de inverno para o estado do Paraná	59

LISTA DE FIGURAS

PARTE GERAL

Figura 1	Representação esquemática do aumento do tamanho do pixel em função do ângulo de visada.	13
Figura 2	Exemplo do mapeador de ângulo espectral.	19

ARTIGO 1

Figura 1	Fluxograma de trabalho.	34
Figura 2	Localização das mesorregiões do estado do Paraná.	35
Figura 3	Identificação do milho 2. ^a safra nas imagens MODIS e <i>Landsat 8</i>	36
Figura 4	Identificação de lavouras de inverno nas imagens MODIS e <i>Landsat 8</i>	37
Figura 5	Distribuição espacial das culturas de interesse no estado do Paraná.	41

ARTIGO 2

Figura 1	Fluxograma do trabalho.	51
Figura 2	Mapa de localização das mesorregiões do estado do Paraná.	52
Figura 3	Exemplo da composição colorida utilizada.	53
Figura 4	Imagens <i>Landsat 8</i> (2013), com distribuição dos pontos aleatórios (pontos verdes na cultura e vermelhos não cultura).	54
Figura 5	Distribuição espacial de milho 2. ^a safra e lavouras de inverno no estado do Paraná.	55
Figura 6	Perfil espectro temporal.	56

LISTA DE EQUAÇÕES

Equação 1 Normalized difference vegetation index	15
Equação 2 Enhanced vegetation index.....	15
Equação 3 Exatidão global	20
Equação 4 Índice Kappa.....	21
Equação 5 Coeficiente de correlação por postos Spearman	22
Equação 6 Erro médio.....	22
Equação 7 Raiz do erro médio quadrático.....	22
Equação 8 Coeficiente de concordância aprimorado.....	22

1 INTRODUÇÃO

O Brasil está em pleno crescimento agrícola destacando-se no cenário mundial pela produção de alimentos, e também atendendo o mercado interno, principalmente, por possuir grandes áreas agricultáveis, aliadas ao avanço tecnológico no campo. O país se destaca na produção de soja (cultura de verão), sendo os estados do Mato Grosso, Rio Grande do Sul e Paraná os maiores produtores. Contudo, as culturas de inverno se destacam na região sul do Brasil, onde o clima favorece o cultivo do trigo, cevada, aveia, triticale e o milho (conhecido como safrinha ou 2.^a safra), principalmente no estado do Paraná.

Assim, o conhecimento prévio da produção dessas principais *commodities* é importante para o controle eficiente das importações e exportações, tanto para a balança comercial como para o abastecimento do mercado interno. Por isso, a importância da obtenção de tecnologias eficazes que quantifiquem as áreas cultivadas, ao longo de todo o desenvolvimento da cultura. Atualmente, o acompanhamento da produção agrícola é realizado por meios de questionários, de maneira subjetiva e onerosa por órgãos oficiais brasileiros como o Instituto Brasileiro de Geografia e Estatística (IBGE), a Companhia Nacional de Abastecimento (CONAB), a Secretaria da Agricultura e Abastecimento do Paraná (SEAB) e o seu Departamento de Economia Rural (DERAL) (MERCANTE, 2007).

Nesse contexto, o sensoriamento remoto orbital se evidencia como uma ferramenta de grande valia na coleta de dados de maneira rápida, com um custo relativamente baixo e pela periodicidade de obtenção desses dados (LIMA et al., 2014), associado ao uso de imagens de satélites que disponibiliza a identificação e quantificação de dados precisos e ágeis, auxiliando no levantamento de informações agrícolas e no estudo da dinâmica ambiental, no que diz respeito à cobertura e ao uso da terra (LIMA et al., 2014). O sensor *Moderate resolution imaging spectroradiometer* (MODIS) se apresenta como uma ferramenta eficiente para coleta de dados por possuir moderada resolução espacial e alta resolução temporal, o que permite o mapeamento e monitoramento de culturas em escala regional (MENGUE; FONTANA, 2015).

Os índices de vegetação são bastante utilizados em pesquisas com sensoriamento remoto, indicando a condição da vegetação, por possuírem relação com a energia solar absorvida e refletida, definindo o crescimento e desenvolvimento da vegetação. Esses índices de vegetação, em diversos casos, associam-se de forma direta com a cobertura do solo, biomassa (acúmulo de matéria seca na planta), índice de área foliar e consequentemente com o rendimento (MERCANTE, 2007).

Nesse contexto, autores como Casady, Van Leeuwen e Reed (2013), Potgieter, Lawson e Huete (2013), Lobell et al. (2013), Pan et al. (2012), entre outros, estudaram o monitoramento agrícola e/ou estimativa de safra de lavouras de inverno utilizando índices de vegetação extraídos de imagens multitemporais do sensor MODIS. Apesar de obterem resultados satisfatórios, as variáveis agroclimáticas bem como as especificidades das variedades das culturas tornam-se desafios para o desenvolvimento de modelos mais precisos para tais objetivos.

A região escolhida para o desenvolvimento deste trabalho foi o estado do Paraná, por possuir, aproximadamente, 26,7% da produção de milho 2.^a safra e produzir, aproximadamente, 46,9% de lavouras de inverno da produção total brasileira no ano de 2016 (IBGE, 2017), destacando o potencial agrícola do estado aliado à utilização da tecnologia. Por isso, sugere-se o mapeamento das lavouras de inverno e milho 2.^a safra utilizando séries temporais de imagens do sensor MODIS, buscando validar a metodologia proposta com as análises de acurácia e comparação com dados oficiais.

2 OBJETIVOS

2.1 Objetivo geral

Estimar áreas com as lavouras de inverno e milho 2.^a safra, a partir de séries temporais de imagens do sensor MODIS satélites Terra e Aqua.

2.2 Objetivos específicos

- Mapear lavouras de inverno e milho 2.^a safra para o estado do Paraná, utilizando as mesorregiões, para definir as datas para as imagens de mínimo e máximo.
- Analisar o ciclo fenológico de cada lavoura de interesse, a fim de realizar o mapeamento individual do milho 2.^a safra e lavouras de inverno.
- Mapear as lavouras de inverno e milho 2.^a safra para o estado do Paraná, com base nos perfis temporais de índices de vegetação, nas safras 2012 a 2014.
- Realizar a análise do mapeamento das lavouras (máscaras) para as três safras, pela comparação com imagens de média resolução espacial.
- Estimar as áreas cultivadas com as lavouras de inverno e milho 2.^a safra para o estado do Paraná, nas três safras monitoradas e confrontar com dados oficiais.

3 REVISÃO BIBLIOGRÁFICA GERAL

3.1 Lavouras de inverno e milho 2.^a safra

O estado do Paraná adota o sistema de sucessão de culturas, sendo que na metade sul e sudoeste (região subtropical) do Estado há o predomínio de soja no verão e de trigo no inverno e nas regiões norte e oeste (região de transição climática) predominam a soja no verão e o milho safrinha no inverno, seguindo o zoneamento climático das culturas (FRANCHINI et al., 2011). As principais regiões brasileiras produtoras de lavouras de verão, como Centro-Oeste e Sul plantam, aproximadamente, 73% de soja, contudo, há o cultivo expressivo de feijão, arroz e milho de primeira safra (CONAB, 2013). Logo, o cultivo do trigo, triticale, canola, centeio, cevada, milho safrinha contemplam as regiões brasileiras produtoras de lavouras de inverno (CONAB, 2014).

Em 2016, a produção nacional das lavouras de inverno totalizaram de 8 milhões de toneladas, sendo o estado do Paraná responsável por 46,9% dessa produção. Já a produção nacional de milho 2.^a safra foi de, aproximadamente, 40 milhões de toneladas e o estado do Paraná foi responsável por 26,7% dessa produção (IBGE, 2017). Na Tabela 1, apresenta-se a participação de cada lavoura de inverno e milho 2.^a safra na produção nacional, no ano de 2016, segundo o IBGE (2017).

Tabela 1 Produção das culturas de inverno em nível nacional e estadual

	Aveia	Centeio	Cevada	Milho 2.^a safra	Trigo	Triticale
Paraná	148.879	2.426	194.291	10.420.666	3.383.850	29.078
Brasil	865.628	6.409	366.110	39.030.779	6.719.519	52.125

Fonte: IBGE (2017).

O milho é originário da América, provavelmente da região onde hoje se situa o México. Os primeiros registros datam de 7 a 10 mil anos atrás (BULL; CANTARELLA, 1993). A cultura se espalhou para as regiões tropicais da América, como o Panamá e a América do Sul. No Brasil, o milho já era cultivado pelos índios antes da chegada dos portugueses, há pouco mais de 500 anos (EMBRAPA, 2008).

O milho (*Zeamays L.*) é uma planta que pertence à família *Gramineae poaceae*, subfamília *Panicoideae*, tribo *Maydea*, sub-tribo *Tripsacinae*. É uma herbácea anual, com um ciclo completo entre quatro a cinco meses (GOODMAN; SMITH, 1980) e, conforme o fotoperíodo, esse cereal é considerado planta de dias curtos (SILVA et al., 2006). Para um bom rendimento, a presença de algumas condições são importantes como umidade

(FANCELLI; DOURADO NETO, 2000) e radiação solar elevadas, temperatura variando entre 24 e 30°C e adequada disponibilidade hídrica no solo (SILVA, 2001). Sendo a falta de água no solo a principal causa de redução na produção desse vegetal, logo, o estresse hídrico na planta resulta da interação entre a disponibilidade de água no solo e a demanda evaporativa (BRUNINI et al., 2001). A deficiência hídrica durante o período vegetativo pode ocasionar atraso na ocorrência de alguns estádios fenológicos (BRUNINI, et al., 2001), sendo o período entre o pendoamento e a polinização considerado o mais importante, por ser a fase em que é determinado o número de óvulos a serem fecundados (FORNASIERI FILHO, 1992).

A aveia (*Avena* spp.) pertence à família *Poaceae*, tribo *Aveneae* e gênero *Avena*. É uma planta de clima temperado podendo ser cultivada em regiões subtropicais, porém, temperaturas acima de 32 °C no período de florescimento podem causar esterilidade ou acelerar a maturação dos grãos. O solo deve ser bem drenado, fértil, com altos teores de matéria orgânica e com pH variando entre 5,5 e 6,0 (PRIMAVESI; RODRIGUES; GODOY, 2000). A aveia é importante principalmente no sul do Brasil, podendo ser uma alternativa para o cultivo no inverno e em sistemas de rotação de culturas. É cultivada para diversas finalidades como para grãos que são utilizados na alimentação humana e animal, por possuírem alto valor nutritivo, como cobertura de solo e como forrageira. O ciclo da cultura varia de 120 a 200 dias, em função da cultivar e época de plantio (NUNES, 2014).

O centeio (*Secale cereale* L.) pertence à família *Gramineae*, sendo indicado como cultura de inverno, por adaptar-se a condições frias e secas (a atividade fisiológica de crescimento ocorre a partir de 0 °C). Assim, em ocasiões de invernos mais frios ou mais secos, a cultura se destaca pela maior produção de massa. É pouco exigente em disponibilidade hídrica, durante o desenvolvimento, e altamente sensível ao excesso de chuva (NASCIMENTO JUNIOR, 2014). O centeio é cultivado especialmente no centro e norte da Europa, principalmente na Rússia, Polônia, Alemanha, Belarus e Ucrânia, em climas frios ou secos, em solos arenosos e pouco férteis (EMBRAPA, 2014). Segundo Baier (1994), houve uma redução na produção do centeio no Brasil, provavelmente, em razão do subsídio estendido ao trigo, às poucas pesquisas sobre o cereal e à incidência de doenças. O estado do Rio Grande do Sul possui a maior área de cultivo de centeio no Brasil, totalizando, aproximadamente, 58% da área plantada (IBGE, 2017).

A cevada (*Hordeum vulgare*) pertence à família *Poaceae* e é uma planta anual cultivada no outono/inverno, com ciclo completo entre 130 e 150 dias, dependendo da época de semeadura, região e cultivar. No início do ciclo, o ideal são temperaturas baixas e temperaturas amenas no final do ciclo e a preparação do solo deve ser semelhante ao trigo (NUNES, 2014; DOTTO, 2014). A cevada é um cereal de inverno utilizado na industrialização de bebidas, composição de farinhas ou flocos para panificação, na produção de medicamentos e na alimentação animal. A produção brasileira do cereal concentra-se,

principalmente, na região Sul, contudo nos estados de Goiás, Minas Gerais e São Paulo também há registros do cultivo (EMBRAPA, 2014).

O trigo (*Triticum aestivum* L.) pertence à família *Poaceae*, tribo *Triticeae* (*Hordeae*), sub-tribo *Triticinae* e gênero *Triticum* (SLEPER; POEHLMAN, 2006). É uma espécie de cultivo em estação fria (inverno e primavera), de ciclo anual (FIOREZE, 2011). Segundo Osório (1982), o clima favorável para o trigo é descrito como tendo invernos suaves, verões quentes com alta radiação solar, sem chuvas fortes. A temperatura ideal para o crescimento do trigo tem relação ao estágio de desenvolvimento da planta, aceita-se que essa temperatura varie de 5 a 20 °C. Para o desenvolvimento foliar deve variar entre 20° e 25°C e para o perfilhamento entre 15° e 20°C. Após a mudança fisiológica para a iniciação da inflorescência e emissão da espiga, a resistência às geadas é pequena.

O desenvolvimento do trigo é complexo, pois, além de sua constituição genética, a planta é muito afetada por fatores externos à sua fisiologia. Segundo Machado, Lagoa e Ticelli (1993), sua produtividade está diretamente relacionada com a capacidade de manter elevada atividade fotossintética das folhas e intensidade de crescimento dos grãos durante o período reprodutivo. Brunetta et al. (2006) afirmaram que o trigo requer, além de elevados índices pluviométricos, uma boa distribuição durante o ciclo para alcançar produtividade em torno de 3,5 t.ha⁻¹ e Santos, Peluzio e Saito (2012) atestaram que as plantas que sofreram déficit hídrico no início do período de florescimento tiveram menor produção de grãos.

O triticale (*Triticosecale* Wittmack) é um cereal de inverno obtido pelo cruzamento artificial do trigo com o centeio. Caracteriza-se pela rusticidade do centeio e as qualidades panificáveis do trigo, além disso, pode ser usado para alimentação animal. A tecnologia de produção é semelhante à do trigo. Possui alta capacidade de produção e resistência a doenças fúngicas. É uma cultura indicada pela Comissão Sul-Brasileira de Pesquisa de Trigo para os estados do Rio Grande do Sul, Santa Catarina, Paraná e São Paulo (CSBPT, 2004).

3.2 Zoneamento e calendário agrícola

Os riscos decorrentes de fatores climáticos são alvos de estudos constantes de pesquisadores objetivando à determinação da variabilidade climática não prevista, sendo a principal fonte de risco à atividade agrícola (CUNHA; ASSAD, 2001; WAGNER, 2009), mesmo com os avanços tecnológicos e científicos (AYOADE, 1998). Segundo Possas et al. (2012), entre os elementos climáticos, a temperatura e a pluviosidade delimitam o plantio e a condução das lavouras em algumas regiões, assim, o zoneamento agroclimático se constitui como ferramenta importante para a escolha e implantação das mesmas.

Assim, a realização do zoneamento agrícola visa obter maiores informações sobre a adaptabilidade das culturas selecionadas e possibilitar o retorno de investimentos a médio e longo prazo para os produtores, auxiliando uma agricultura racional e sustentável (NUNES et al., 2007). São analisados parâmetros como clima, solo e ciclos de cultivares, a partir de uma metodologia validada pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) e adotada pelo Ministério de Agricultura, Pecuária e Abastecimento (MAPA). Assim, são quantificados os riscos climáticos envolvidos na condução das lavouras que podem ocasionar perdas na produção (BRASIL, 2011). Silva et al. (2011b) afirmaram que a época de semeadura e práticas culturais podem ser definidos como o resultado dos componentes biofísicos que influenciam no desenvolvimento e no crescimento das plantas. Nesse sentido, o potencial produtivo de grãos deve se adequar à época de semeadura, por ser a prática de manejo mais importante, devido à alteração das relações hídricas e a temperatura e radiação solar disponíveis à cultura ao longo do ciclo.

Segundo Souza et al. (2015), assim como o zoneamento agrícola é importante para que o agricultor possa fazer o planejamento e a escolha da cultura e/ou cultivar que melhor se adapte às condições edafoclimáticas de sua região, o calendário agrícola busca auxiliar na escolha do melhor período para implantação. Essa ferramenta é útil para assessorar o monitoramento do crescimento da lavoura e gerar informações para estimar o rendimento de grãos e o acompanhamento de quebras de safra.

Pinto e Fontana (2011) afirmaram que o calendário agrícola possui informações de porcentagens de área cultivada e facilita o acompanhamento do ciclo de desenvolvimento. O monitoramento do calendário agrícola e a previsão de safra de culturas no Brasil são realizados por entidades ligadas à agricultura, nas quais, os dados coletados por municípios são posteriormente agrupados a outros de toda extensão do território nacional (MOTTA; CYBIS; WEBER, 2003). A Secretaria de Estado da Agricultura e do Abastecimento (SEAB) disponibiliza uma planilha com informações importantes, como comparativo de área, produção e produtividade por anos/safra e por culturas e disponibiliza, também, o calendário agrícola com informações sobre a evolução de plantio e a colheita e comercialização a cada mês das últimas três safras para cada cultura (PARANÁ, 2014).

3.2.1 Milho 2.^a safra

O Ministério da Agricultura, Pecuária e Abastecimento publicou a Portaria nº 180, aprovando o Zoneamento Agrícola de Risco Climático do milho safrinha para o Estado do Paraná para o ano safra 2014 (FAEP, 2013). Por ser cultivada após uma lavoura de verão, a segunda safra ou safrinha, pode ter sua produtividade bastante afetada pelo regime de chuvas e por limitações de radiação solar e de temperatura na fase final de seu ciclo. O

calendário agrícola disponibilizado pela SEAB para a produção do milho 2.^a safra no Estado do Paraná pode ser visualizado na Tabela 2.

Tabela 2 Estimativa mensal acumulada de plantio e colheita do milho 2.^a safra no estado do Paraná

Safra 11/12	2012											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)	4	26	88	100								
Colheita (%)					1	4	26	83	99	100		
Safra 12/13	2013											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)	2	51	93	100								
Colheita (%)						3	29	84	99	100		
Safra 13/14	2014											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)	8	57	97	100								
Colheita (%)					1	5	46	87	100			

Fonte: Adaptado de Paraná (2014).

3.2.2 Lavouras de inverno

O Ministério da Agricultura, Pecuária e Abastecimento publicou a Portaria nº 196, aprovando o Zoneamento Agrícola de Risco Climático do trigo para o Estado do Paraná para o ano safra 2014 (FAEP, 2013). Nas regiões tradicionais de cultivo comercial de trigo, os maiores riscos de perda de produção estão relacionados com o excesso de chuvas na colheita, temperaturas elevadas e deficiência hídrica. O calendário agrícola disponibilizado pela SEAB para o cultivo do trigo no estado do Paraná pode ser visualizado na Tabela 3.

Tabela 3 Estimativa mensal acumulada de plantio e colheita do trigo no estado do Paraná

Safra 11/12	2012											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)				20	52	81	100					
Colheita (%)								9	56	78	100	
Safra 12/13	2013											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)				12	57	85	100					
Colheita (%)								3	26	60	95	100
Safra 13/14	2014											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)				26	61	82	100					
Colheita (%)								4	41	77	99	100

Fonte: Adaptado de Paraná (2014).

O calendário agrícola disponibilizado pela SEAB para o cultivo da aveia no estado do Paraná pode ser visualizado na Tabela 4.

Tabela 4 Estimativa mensal acumulada de plantio e colheita da aveia no estado do Paraná

		2012											
		jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Safr 11/12	Plantio (%)				20	64	90	100					
	Colheita (%)								10	45	79		
		2013											
		jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Safr 12/13	Plantio (%)				20	71	96	100					
	Colheita (%)								7	30	65	98	100
		2014											
		jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Safr 13/14	Plantio (%)				26	63	94	100					
	Colheita (%)								6	49	80	99	100

Fonte: Adaptado de Paraná (2014).

O calendário agrícola disponibilizado pela SEAB para o cultivo do centeio no estado do Paraná pode ser visualizado na Tabela 5.

Tabela 5 Estimativa mensal acumulada de plantio e colheita do centeio no estado do Paraná

		2012											
		jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Safr 11/12	Plantio (%)				14	44	64	100					
	Colheita (%)										23	100	
		2013											
		jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Safr 12/13	Plantio (%)				2	40	90	100					
	Colheita (%)									10	17	91	100
		2014											
		jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Safr 13/14	Plantio (%)					18	56	100					
	Colheita (%)									8	40	100	

Fonte: Adaptado de Paraná (2014).

O calendário agrícola disponibilizado pela SEAB para o cultivo da cevada no estado do Paraná pode ser visualizado na Tabela 6.

Tabela 6 Estimativa mensal acumulada de plantio e colheita da cevada no estado do Paraná

Safr 11/12	2012											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)					9	36	100					
Colheita (%)									2	20	100	
Safr 12/13	2013											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)					11	18	100					
Colheita (%)										3	70	100
Safr 13/14	2014											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)					3	23	100					
Colheita (%)										12	100	

Fonte: Adaptado de Paraná (2014).

O calendário agrícola disponibilizado pela SEAB para o cultivo do tritcale no Estado do Paraná pode ser visualizado na Tabela 7.

Tabela 7 Estimativa mensal acumulada de plantio e colheita do tritcale no estado do Paraná

Safr 11/12	2012											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)				12	38	65	99	100				
Colheita (%)								7	36	54	100	
Safr 12/13	2013											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)				7	42	66	100					
Colheita (%)									12	33	77	100
Safr 13/14	2014											
	jan.	fev.	mar.	abr.	mai.	jun.	jul.	ago.	set.	out.	nov.	dez.
Plantio (%)				7	34	55	100					
Colheita (%)									16	48	99	100

Fonte: Adaptado de Paraná (2014).

3.3 Imagens de sensoriamento remoto orbital

O sensoriamento remoto (SR) baseia-se na aquisição de informações de um objeto sem haver contato direto com ele por meio de sensores instalados em laboratório, campo ou órbita. Os sensores são dispositivos capazes de detectar e registrar a radiação eletromagnética em determinada faixa do espectro eletromagnético e gerar informações

passíveis de interpretação. Assim, trata-se de uma técnica rápida, não destrutiva das amostras e livre de qualquer reagente químico (FLORENZANO, 2002).

A aplicação do SR aliado às técnicas de geoprocessamento, para levantamentos de dados agropecuários, é mais preciso, rápido e, quando utilizado em larga escala, tem custo mais baixo, comparativamente a outras formas de levantamento (IPPOLITI-RAMIRO et al., 1999; FLORENZANO, 2011). As principais plataformas de sensores são os satélites ou aeronaves. Segundo Shimabukuro, Maeda e Formaggio (2009), o SR passou a ser largamente utilizado ao longo das últimas décadas por permitir o rápido monitoramento, a avaliação de variáveis ambientais e outros fatores relacionados com as atividades humanas. Para Florenzano (2011), as imagens de satélites possibilitam o estudo e o monitoramento de fenômenos naturais dinâmicos do meio ambiente, empregando-se no monitoramento da erosão do solo, inundações, áreas de queimada e desmatamento e nas dinâmicas agrícolas. Além disso, as imagens de satélites permitem o estudo de áreas extensas, com informações atualizadas (SOUSA et al., 2009).

Por isso, o emprego do sensoriamento remoto orbital tem sido amplamente utilizado. Becker et al. (2015) realizaram levantamentos de dados espaciais e temporais das culturas presentes no estado do Paraná, elaborando um Sistema de informação geográfica com a finalidade de subsidiar as metodologias de monitoramento de safras por meio de SR para o Estado. Sousa e Ferreira (2014) quantificaram as transformações ocorridas na bacia hidrográfica do Ribeirão João Leite, estado de Goiás, em quatro períodos distintos, utilizando imagens do programa americano de satélites *Landsat* e concluíram que o mapeamento multitemporal da cobertura e uso da terra constitui um importante subsídio às decisões voltadas à gestão territorial e reiteraram o enorme potencial e desempenho operacional das imagens *Landsat* para mapeamentos sistemáticos da cobertura e uso da terra em abordagens locais.

Ramos et al. (2015) utilizaram o SR para identificação e mapeamento de determinadas áreas para organização municipal e concluíram que é uma das ferramentas mais adequadas, quando se visa organizar, analisar, conhecer, gerir e visualizar a área de um município. Castillejo-González et al. (2009) testaram cinco métodos de classificação supervisionada para avaliar se a detecção remota oferece capacidade de identificação de culturas utilizando imagens QuickBird e verificaram que os métodos aplicados atingiram uma precisão geral superior a 85%, indicando o algoritmo máxima verossimilhança como o classificador mais preciso. Concluindo que os dados multiespectrais são eficientes para criação de um inventário de culturas, por oferecerem uma classificação detalhada, além de poderem ser usados como ferramenta precisa para influenciar decisões sobre medidas agroambientais.

Bezerra et al. (2014) avaliaram a dinâmica espaço-temporal por meio de técnicas e produtos de SR na Unidade de Conservação do Parque Nacional da Fuma Feia (RN) e

constataram o potencial das geotecnologias, na compreensão da dinâmica dos padrões espaciais e temporais dos processos biofísicos de interação solo-planta-atmosfera da caatinga no semiárido.

3.3.1 O sensor MODIS e seus produtos

O MODIS opera em 36 canais espectrais em comprimentos de onda que variam de 0,4 a 14,4 μm e resolução espacial que varia de 250 a 1000 metros (EMBRAPA, 2009). As 36 bandas espectrais desse sensor estão localizadas em função do comprimento de onda e foram escolhidas para observação de feições das propriedades das nuvens, dinâmica e propriedades da vegetação na cobertura terrestre, bem como para a temperatura da superfície dos oceanos no mundo (SALOMONSON; TOLL, 1990).

Segundo Mengue (2013), os dados do sensor MODIS possuem uma varredura de 55° para cada lado da órbita de 705 km de altura, resultando em uma faixa imageada de 2.330 km, com cobertura global de 2 dias e cobertura diária acima de 30° de latitude da superfície terrestre, permitindo a geração de imagens livres de nuvens por meio da composição de várias imagens obtidas em um período de 8 ou 16 dias (Figura 1). As imagens do sensor MODIS estão disponíveis ao usuário no Portal do Sistema de Informações e Dados do programa EOS, cerca de seis dias após a passagem do satélite ou do término do período, sem qualquer custo ao usuário. Essas imagens são disponibilizadas com correções atmosféricas e geométricas previamente realizadas, sem necessidade de correções posteriores (NASA/MODIS, 2003).

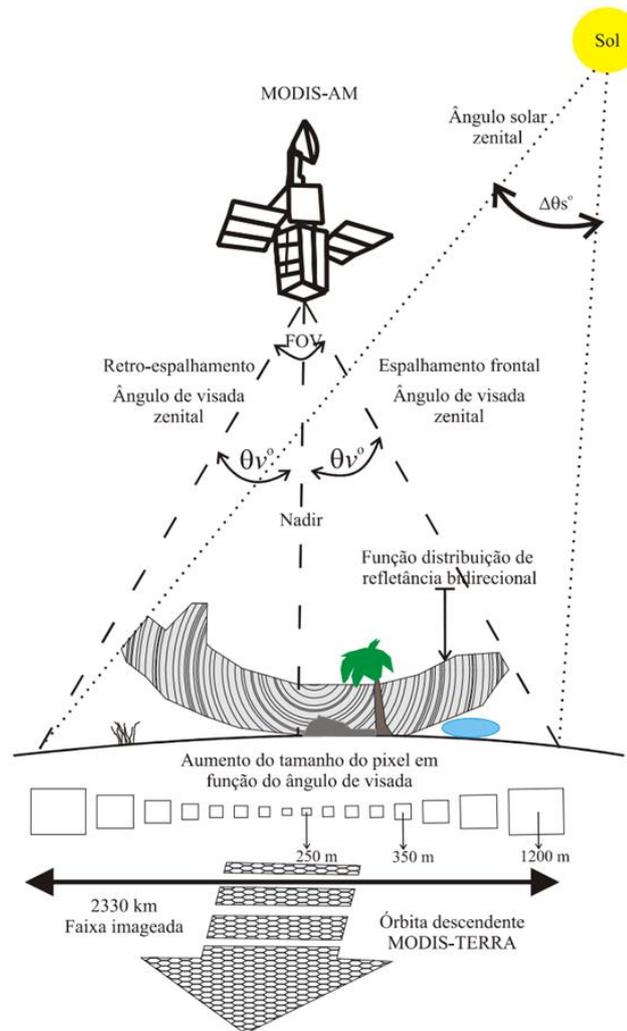


Figura 1 Representação esquemática do aumento do tamanho do pixel em função do ângulo de visada.

Fonte: Van Leeuwen, Huete e Laing (1999) adaptado por Adami (2010).

O MOD13 apresenta os produtos relativos aos índices de vegetação como o índice da diferença normalizada (NDVI) e o índice de vegetação melhorado (EVI) com composições de imagens de 16 dias (NASA/MODIS, 2003). Esses dois índices se complementam e fornecem comparações consistentes de dados temporais e espaciais das condições da vegetação global, de modo a monitorar a atividade fotossintética da vegetação em suporte à detecção de mudança e interpretações biofísicas e da fenologia (LATORRE et al., 2003). Segundo Anderson et al. (2003), os objetivos dos índices de vegetação do MODIS são gerar imagens sem nuvens, maximizar a cobertura global e temporal na resolução espacial mais fina possível, assegurar a qualidade e a consistência dos dados, descrever e reconstituir dados de variações fenológicas, entre outros.

O uso do sensor MODIS tem sido bastante utilizado por diversos autores, com os mais variados objetivos: Souza et al. (2015) utilizaram os perfis temporais provenientes dos índices de vegetação obtidos por meio de imagens do sensor MODIS para as culturas de milho e soja; Bolton e Friedl (2013) utilizaram dados do sensor MODIS associados aos dados do Departamento de Agricultura dos Estados Unidos (USDA) para desenvolver modelos de previsão do rendimento de milho e soja; Johann et al. (2016) estimaram datas do ciclo de desenvolvimento total da cultura da soja, utilizando séries temporais de EVI do sensor MODIS.

Victoria et al. (2012) mapearam áreas agrícolas no estado do Mato Grosso, utilizando séries temporais do sensor MODIS e verificaram a possibilidade de utilizar essas séries para estimativas de áreas cultivadas, mostrando melhor concordância na comparação com os dados do IBGE. Santos et al. (2014) utilizaram o perfil espectro-temporal do sensor MODIS/NDVI para estimar área cultivada de soja e os resultados indicaram que as estimativas foram satisfatórias.

3.4 Índices de vegetação

Os índices de vegetação (IVs) derivados de satélites têm sido largamente utilizados para diversas aplicações, por exemplo, monitoramento e caracterização da cobertura vegetal (HILL, 2013). Os IVs espectrais são combinações matemáticas de bandas espectrais, principalmente na região do visível e infravermelho próximo do espectro eletromagnético, ou seja, são resultantes da combinação dos valores de reflectância em dois ou mais intervalos de comprimento de onda e possuem relação com a quantidade e o estado da vegetação presente em uma determinada área da superfície terrestre (VIÑA et al., 2011; RIZZI, 2004).

São medidas robustas da atividade da vegetação na superfície terrestre (ECKERT et al., 2015). Além do mais, são projetados para aumentar a contribuição das propriedades da vegetação e permitir comparações espaciais e temporais confiáveis da atividade fotossintética terrestre, variações estruturais do dossel e, em longo prazo, da estrutura fenológica e biofísica da vegetação (HUETE et al., 2002). De acordo com Govaerts et al. (1999), os IVs constituem uma abordagem conveniente para extração de informações de dados, por sua facilidade de utilização, o que contribui para o processamento e análise de grandes quantidades de dados adquiridos por plataformas de satélites.

O *Normalized difference vegetation index* (NDVI) (Equação 1) é uma transformação normalizada das bandas do infravermelho próximo (NIR) e vermelha (RED), projetada para

padronizar valores de IV de modo que estejam entre -1 e +1. Sendo que o 0 representa “sem vegetação”, os valores positivos “vegetação” e os valores negativos “superfícies sem vegetação” tais como água e neve (SILLEOS et al., 2006). Contudo, com o NDVI, há a possibilidade de saturação, ou seja, ele se torna insensível ao aumento da biomassa, mesmo havendo aumento da densidade do dossel, segundo Gamon et al. (1995).

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

em que:

ρ_{IVP} = banda do infravermelho próximo;

ρ_{V} = banda do vermelho.

Outro índice bastante utilizado é o *Enhanced vegetation index* (EVI) (Equação 2), proposto para melhorar o sinal da vegetação, pois ele é mais resistente às variações dos efeitos do solo e da atmosfera e é mais sensível à variação da estrutura, arquitetura do dossel e fisionomia da planta, mostrando ser adequado para o monitoramento agrícola (HUETE; JUSTICE; LIU, 1994). O EVI é um NDVI modificado, é a relação de reflectância de superfície do infravermelho próximo (NIR) para a vermelha (RED), levando em consideração o fator de ganho (ajuste) do solo ($G = 2.5$), coeficiente de ajuste para o efeito de aerossóis da atmosfera no vermelho ($c1 = 6$), coeficiente de ajuste para efeito de aerossóis da atmosfera no azul ($c2 = 7.5$) e a reflectância de superfície na banda do azul (ρ_{azul}):

$$\text{EVI} = 2.5 \frac{(\rho_{\text{IVP}} - \rho_{\text{V}})}{(1 + \rho_{\text{IVP}}) + (6\rho_{\text{V}}) - (7.5\rho_{\text{azul}})} \quad (2)$$

em que:

ρ_{IVP} = banda do infravermelho próximo;

ρ_{V} = banda do vermelho;

ρ_{Azul} = banda do azul.

Borges e Sano (2014) estudaram a utilização das séries temporais de EVI da plataforma Terra MODIS para mapear o uso e a cobertura vegetal do oeste da Bahia, o que demonstrou o potencial de séries temporais do sensor MODIS para discriminar classes de uso e cobertura vegetal representativas do oeste da Bahia. Johann et al. (2012) mapearam áreas com as culturas de soja e milho, no Paraná, utilizando imagens multitemporais EVI/MODIS e constataram que esses dados podem ser utilizados para o mapeamento dessas culturas.

Em estudos realizados por Zhang, Feng e Yao (2014), o índice de vegetação EVI/MODIS foi utilizado para estimar a área de milho cultivada em grande escala no

nordeste da China. Souza et al. (2015) analisaram os padrões de perfis temporais provenientes dos índices de vegetação EVI, NDVI e *Wide dynamic range vegetation index* (WDRVI) obtidos por meio de imagens do sensor MODIS, para culturas do milho e soja, nos anos safra 2010/2011 e 2011/2012, para o estado do Paraná, e verificaram que esses dados podem ser utilizados no mapeamento das lavouras para estimar a área estadual.

3.5 Imagens multitemporais no estudo da vegetação

O uso de perfis espectro-temporais para identificação de culturas por dados de satélite foi proposta na década de 1980 e apresentaram um perfil característico, utilizando índices de vegetação. O termo “perfil espectro-temporal” refere-se ao comportamento espectral ao longo do tempo de uma determinada cultura, assim, cada cultura possui um perfil espectral próprio.

A estimativa da área cultivada pode ser usada para fornecer informações para muitos tópicos relacionados com a agricultura, como por exemplo, o desenvolvimento de políticas de alimentação que são importantes para garantir a segurança alimentar e o planejamento agrícola nacional (MINGWEI et al., 2008). O monitoramento de área de plantio tem se tornado um desafio, devido às diversas dinâmicas agroclimáticas e à especificidade da variedade da cultura (ZHANG; FENG; YAO, 2014; CASADY; VAN LEEUWEN; REED, 2013). A utilização de modelos de regressão simples baseado com a correlação direta entre o rendimento e o índice de vegetação via imagens de satélites torna-se a abordagem mais básica para prever o rendimento em escala regional (BOLTON; FRIEDL, 2013).

O acompanhamento temporal para o monitoramento da prática agrícola é importante para o conhecimento do ciclo das lavouras, levando em consideração as fases fenológicas da planta. Assim, o uso do sensoriamento remoto torna-se uma ferramenta eficaz para o monitoramento e acompanhamento de grandes áreas (CASADY; VAN LEEUWEN; REED, 2013). A utilização de imagens de satélite de baixa resolução fornecem informações consistentes em grande frequência temporal e cobrem grandes áreas (VUOLO; ATZBERGER, 2012).

A utilização do sensor MODIS tem se mostrado útil para o acompanhamento de lavouras ao longo do ano, devido à alta frequência temporal dos dados coletados (CASADY; VAN LEEUWEN; REED, 2013). Vários autores utilizam essa ferramenta para acompanhar, monitorar e estimar as mais diversas culturas interanuais em escalas locais e estaduais (WALLACE; THOMAS, 2008; CASADY; VAN LEEUWEN; REED, 2013; VUOLO; ATZBERGER, 2012). O padrão de perfis adequados para séries temporais do IV reduz o volume de dados, fornecendo parâmetros quantitativos simples que se relacionam com a

fenologia (época de semeadura, floração) das culturas (POTGIETER; LAWSON; HUETE, 2013).

Sakamoto, Gitelson e Arkebauer (2013) desenvolveram um modelo de estimativa da produtividade de grãos de milho através de séries temporais MODIS, cuja principal característica foi a incorporação de um método de detecção da fenologia denominado *Shape model fitting* (SMF) capaz de revelar a distribuição espaço-temporal de fases de separação de pigmentos, assim, conclui-se que o método foi capaz de detectar as datas médias dos principais estádios fenológicos de séries temporais MODIS, estimando a produtividade com alta precisão. O emprego de conjunto de dados MODIS junto com dados de estatísticas oficiais foram utilizados por Becker-Reshef et al. (2010) para o desenvolvimento e avaliação de um modelo de regressão para previsão de produção de trigo. O modelo foi avaliado por seis semanas antes da colheita e apresentou um erro de 10% em relação às estatísticas oficiais lançadas após a colheita.

Kogan et al. (2013) avaliaram a eficiência relativa do uso de dados de satélites para a previsão de produtividade do trigo de inverno para a Ucrânia em nível regional, baseado em regressão empírica, utilizando dados temporais do MODIS/NDVI e modelos meteorológicos. Concluíram que o desempenho do modelo de regressão baseados em NDVI foi semelhante aos modelos meteorológicos na produção de trigo, de dois a três meses antes da colheita, comparando os resultados, posteriormente, com dados oficiais.

Lobell et al. (2013) utilizaram os índices de vegetação de produtos MODIS e SPOT em conjunto com Timesat (JÖNSSON; EKLUNDH, 2004) para estimar as datas de semeadura de mais de uma década, em todas as áreas de cultivo de trigo na Índia. Concluíram que o uso conjunto entre os dados de satélites e de campo confirmaram a confiabilidade das estimativas de satélite. Fontana et al. (2015) relacionaram o calendário agrícola da soja a perfis temporais de NDVI com intuito de validar uma tecnologia de baixo custo e adequada acurácia para fins de monitoramento e previsão de safras. Os resultados mostraram que os perfis temporais de NDVI permitiram acompanhar a evolução temporal da biomassa da soja e determinar a ocorrência dos subperíodos do ciclo.

Potgieter et al. (2010) determinaram a estimativa de área utilizando uma série temporal do sensor MODIS/EVI, em *Queensland* – Austrália, utilizando o classificador não supervisionado *k-means* e concluíram que o estudo de séries temporais pode ser utilizado com confiança no início da safra para previsão de um a dois meses antes da colheita. Potgieter, Lawson e Huete (2013) avaliaram três modelos Gaussianos para identificar e classificar diferentes tipos de lavouras de inverno nas principais áreas agrícolas de *Queensland* - Austrália, utilizando imagens multitemporais do sensor MODIS/EVI. Os resultados mostraram altas correlações significativas para as lavouras de inverno em geral, trigo e cevada, comprovando ser uma abordagem permitindo quase em data real as

estimativas de grandes áreas a um custo mínimo em comparação com censo ou métodos de pesquisa.

3.6 Classificação supervisionada utilizando o *Spectral angle mapper*

Uma metodologia bastante utilizada na elaboração de mapas de uso e ocupação do solo é a classificação digital de imagens de satélites (RODRIGUES, 2014). A classificação supervisionada é um procedimento usado na identificação de áreas espectralmente semelhantes dentro de uma imagem, ou seja, o usuário identifica as regiões de interesse na área terrestre e o algoritmo escolhido extrapola essas características espectrais para classificar outras regiões semelhantes na imagem (CASTILLEJO-GONZÁLEZ et al., 2009).

A classificação supervisionada refere-se à associação de pixels da imagem a uma “classe”, descrevendo um objeto real, por exemplo, vegetação, solo, água, etc. (DEMARCHI; PIROLI; ZIMBACK, 2011). Segundo Antunes et al. (2012), nas classificações digitais, as áreas são estimadas por contagem de pixels de toda a região em estudo, não havendo necessidade de amostragem, no entanto, os erros na classificação podem provocar em estimativas imprecisas.

Os métodos de classificação supervisionada são diversos, podendo ser baseados na distância, probabilidade ou mesmo por espectro angular. O *Spectral angle mapper* (SAM) rotula *pixels* pela similaridade angular entre o vetor padrão para uma determinada classe e o *pixel* a ser classificado (PETROPOULOS et al., 2010; SILVA et al., 2011a). O SAM é fundamentado na comparação do espectro da imagem com um espectro de referência, executada com um ângulo espectral, aceitável entre o vetor definido pelos espectros de referência fornecidos (amostras da classe) e o vetor definido pelo valor espectral do *pixel* que está sendo classificado no espaço n dimensão, em que n corresponde ao número de bandas da imagem (Figura 2).

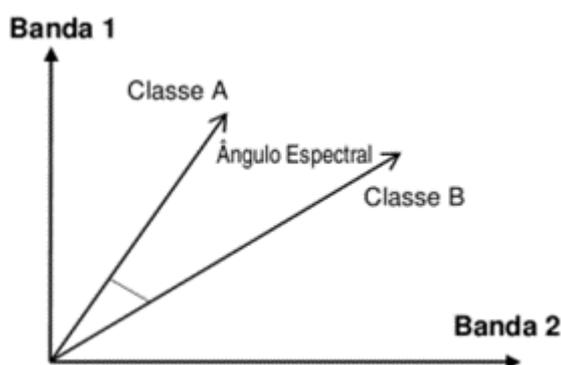


Figura 2 Exemplo do mapeador de ângulo espectral.

Fonte: SULSOFT (2014).

O algoritmo é particularmente eficiente quando se têm amostras selecionadas bem definidas espectralmente, mesmo que seja um número reduzido ou apenas uma única amostra (YI, 2005). Os ângulos menores representam relações mais próximas ao espectro de referência, além dos pixels fora do ângulo máximo definido não serem classificados (SULSOFT, 2014). Uma das vantagens de se utilizar esse método, encontra-se na capacidade de exploração de conhecimento das propriedades físico-químicas dos alvos, sumarizados pelos índices espectrais no tempo, o que fornece uma relação direta com os estádios fenológicos dos cultivos, em contraposição a outros componentes da cena, por meio da definição de diferentes espectros de referência (VICENTE et al., 2012). Outra vantagem desse algoritmo é que os espectros não são muito sensíveis aos efeitos da iluminação e do albedo. O SAM usa somente a direção dos vetores e não seu módulo, o que significa que todas as iluminações possíveis são tratadas da mesma maneira (SULSOFT, 2014).

Autores como Dalla Nora (2010), Vicente et al. (2012) e Borges e Sano et al. (2014) estudaram o uso do classificador SAM em produtos de diversos satélites. Yi et al. (2007) avaliaram a identificação e o mapeamento das áreas de milho no Rio Grande do Sul, a partir de dados multitemporais do sensor MODIS. Utilizando o algoritmo de classificação SAM, verificaram a aplicação para isolar ou complementar o mapeamento das áreas agrícolas, visando seu monitoramento a partir de IVs.

Borges e Sano (2014) utilizaram séries temporais de EVI/MODIS em conjunto com o algoritmo de classificação SAM para mapear o uso e cobertura vegetal do oeste da Bahia. E verificaram que os dados do mapeamento se mostraram coerentes quanto à vegetação e à identificação de classes antrópicas, demonstrando o potencial de séries temporais MODIS para discriminar classes de uso e cobertura vegetal. Já o estudo realizado por Grzegozewski et al. (2016) objetivou mapear, separar e estimar áreas de soja e milho no estado do Paraná, utilizando o EVI/ MODIS, empregando o algoritmo de classificação SAM e a validação do produto final o classificou como bom e excelente.

3.7 Análises estatísticas

3.7.1 Índices de acurácia

A técnica de matriz de erro ou matriz de confusão é uma das formas eficientes para validar uma classificação de dados de sensores remotos, pois permite calcular medidas de exatidão como os erros de omissão e inclusão, bem como o índice Kappa e a exatidão global (TINÓS et al., 2014). Segundo Silva Junior, Frank e Rodrigues (2014), essas métricas permitem avaliar melhor a classificação final.

A metodologia adotada para realizar a avaliação da exatidão das máscaras por meio das matrizes de erros é chamada de painel amostral (FOODY, 2002). Essa metodologia caracteriza-se pela distribuição aleatória de pontos amostrais dentro da região de interesse, com o objetivo de se realizar um levantamento das classes de uso do solo de cada ponto (LUIZ et al. 2002). São sorteados aleatoriamente pontos sobre os mapeamentos para balancear a análise dos erros de omissão e inclusão da análise da acurácia (GRZEGOZEWSKI et al., 2016; SOUZA et al., 2015).

A exatidão global (EG) (Equação 3) é calculada a partir da matriz de erros. Essa métrica significa o total de acertos em relação ao total de amostras da imagem classificada. De acordo com Foody (2002), o valor mínimo aceito que indica o sucesso da classificação foi padronizado em 85%.

$$EG = \frac{A}{n} * 100 \quad (3)$$

em que:

- EG = exatidão global;
- A = acerto geral (pontos amostrais com acerto);
- N = número de pontos amostrais.

O coeficiente Kappa (COHEN, 1960) (Equação 4) é obtido por meio da matriz de erros e é utilizado para expressar a precisão da classificação. Esse índice vem sendo recomendado, por apresentar vantagens sobre a EG ao incorporar todas as amostras classificadas de forma correta e incorreta da matriz dos erros ao invés de apenas utilizar aquelas que se situam na diagonal principal da mesma.

A avaliação da qualidade da classificação, proposta por Landis e Koch (1977), pode ser verificada na Tabela 8.

$$K = \frac{[n \cdot \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i \cdot x_j)]}{[n^2 - \sum_{i=1}^r (x_i \cdot x_j)]} \quad (4)$$

em que:

- K = coeficiente Kappa de concordância;
- n = número de pontos amostrais;
- r = número de linhas da matriz de erros;
- x_{ij} = observações da linha i e coluna j;
- x_i = total marginal da linha i;
- x_j = total marginal da coluna j.

Tabela 8 Qualidade de classificação associada aos valores do Kappa

Índice Kappa	Qualidade
< 0	Péssima
0,00 a 0,20	Ruim
0,21 a 0,40	Razoável
0,41 a 0,60	Boa
0,61 a 0,80	Muito boa
0,81 a 1,00	Excelente

Fonte: Landis e Koch (1977).

Outra maneira de se avaliar a acurácia do mapeamento é por meio da análise dos erros de inclusão (EI) e dos erros de omissão (EO) presentes na classificação. O erro de omissão consiste na exclusão de uma área da classe à qual ela pertence de fato, ou seja, refere-se à probabilidade de determinada classe ter sido corretamente classificada de acordo com os dados de referência. O erro de inclusão consiste na adição de uma área dentro de uma classe à qual ela não pertence na realidade, ou seja, são os pixels atribuídos a uma determinada classe oriundos de erros de classificação das outras classes (VIEIRA et al., 2011; CONGALTON; GREEN, 1999).

3.7.2 Análise de comparação de áreas

Segundo Andriotti (2010), o conceito de correlação refere-se a uma associação numérica entre duas variáveis, não implicando necessariamente uma relação de causa e efeito, podendo ser linear ou não. O coeficiente de correlação por postos de Spearman pode ser usado quando os dados não pertencem a uma escala de medida padrão, é um método não-paramétrico que usa somente os postos e não faz quaisquer suposições (SHIMAKURA,

2012); é robusto e não é insensível para relações que não sejam lineares entre as variáveis (ANDRIOTTI, 2010).

O teste não-paramétrico é aquele que não especifica condições sobre os parâmetros da população da qual a amostra foi obtida. Quando existem pressuposições, essas são mais brandas do que aquelas associadas aos testes paramétricos e, com isso, o emprego da estatística não-paramétrica constitui valiosa alternativa de trabalho dada a sua simplicidade e sua versatilidade (CAMPOS, 1983). O coeficiente de correlação por postos de Spearman é determinado pela Equação 5.

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2-1)} \quad (5)$$

em que:

d_i = a diferença entre cada posto de valor correspondente de X e Y;

n = número dos pares dos valores (equação x).

Como indicadores estatísticos foram utilizados o erro médio (*Mean error* - ME) (Equação 6), a raiz do erro médio quadrático (*Root mean square error* - RMSE) (Equação 7) e o coeficiente de concordância aprimorado de Willmott et al. (2012) (dr) (Equação 8); esse coeficiente determina a exatidão do método e indica o grau de afastamento dos valores estimados em relação aos observados. Esse índice varia de -1 a 1, com valores positivos e próximos de 1 indicando melhor concordância.

$$ME = \frac{1}{n} * \sum_{i=1}^n (O - E) \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (O - E)^2} \quad (7)$$

$$dr = 1 - \frac{\sum_{i=1}^n |E - O|}{2 \sum_{i=1}^n (|O - \bar{O}|)} \quad (8)$$

em que:

n = número de municípios;

O = área oficial da cultura;

E = área da cultura obtida pela máscara;

\bar{O} = área oficial média da cultura;

d_i = a diferença entre cada posto de valor correspondente de X e Y;

n = número dos pares dos valores.

REFERÊNCIAS

- ADAMI, M. **Estimativa da data de plantio da soja por meio de séries temporais de Imagens MODIS**. 2010. 135 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 2010.
- ANDERSON, L. O.; LATORRE, M. L.; SHIMABUKURO, Y. E.; ARAI, E.; CARVALHO JUNIOR, O. A. **Sensor MODIS: uma abordagem geral**. São José dos Campos, SP: Ministério da Ciência e Tecnologia; Instituto Nacional de Pesquisas Espaciais, 2003.
- ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística**. São Leopoldo: Unisinos, 2010.
- ANTUNES, J. F. G.; MERCANTE, E.; ESQUERDO, J. C. D. M.; LAMPARELLI, R. A. C.; ROCHA, J. V. Estimativa de área de soja por classificação de imagens normalizada pela matriz de erros. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p. 1288-1294, 2012.
- AYOADE, J. **Introdução à climatologia para os trópicos**. São Paulo: DIFEL, 1998. 332 p.
- BAIER, A. C. **Centeio**. Passo Fundo: EMBRAPA TRIGO, 1994. 29 p.
- BECKER, W. R.; PRUDENTE, V. H. R.; JOHANN, J. A.; RICHETTI, J.; MERCANTE, E. Obtenção de dados espaciais e temporais das culturas agrícolas no estado do Paraná. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17, 2015, João Pessoa/PB. **Anais...** João Pessoa, 2015.
- BECKER-RESHEF, I.; VERMOTE, E.; LINDEMAN, M.; JUSTICE, C. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. **Remote Sensing of Environment**, Amsterdam, v.114, p. 1312-1323, 2010.
- BEZERRA, J. M.; MOURA, G. B. A.; SILVA, B. B.; LOPES, P. M. O.; SILVA, E. F. F. Parâmetros biofísicos obtidos por sensoriamento remoto em região semiárida do estado do Rio Grande do Norte, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n. 1, p. 73-84, 2014.
- BOLTON, D. K.; FRIEDL, M. A. Forecasting crop yield using remote licensed vegetation indices and crop phenology metrics. **Agricultural and Forest Meteorology**, v.173, p. 74-84, 2013.
- BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, Curitiba, v. 20, n. 3, p. 526-547, 2014.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Zoneamento Agrícola**. Brasília, mai. 2011. Disponível em: <<http://www.agricultura.gov.br/politica-agricola/zoneamento-agricola>>. Acesso em: 9 jul. 2014.
- BRUNETTA, D.; BASSOI, M. C.; DOTTO, S. R.; SCHEEREN, P. L.; MIRANDA, M. Z.; TAVARES, L. C. V.; MIRANDA, L. C. Características e desempenho agrônomo da cultivar de trigo BRS 229 no Paraná. **Pesquisa Agropecuária Brasileira**, Brasília, v. 41, p. 889-892, 2006.

BRUNINI, O.; ZULLO JR., J.; PINTO, H. S.; ASSAD, E.; SAWAZAKI, E.; DUARTE, A. P.; PATTERNIANI, M. E. Z. Riscos climáticos para a cultura de milho no estado de São Paulo. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 519-526, 2001.

BUL, L. T.; CANTARELLA, H. **Cultura do milho**: fatores que afetam a produtividade. Piracicaba: Potafos, 1993. 301 p.

CAMPOS, H. **Estatística experimental não-paramétrica**. Piracicaba, SP: Nobel, 1983, 332 p.

CASADY, G. M.; VAN LEEUWEN, W. J. D.; REED, B. C. Estimating winter annual biomass in the Sonoran and Mojave deserts with satellite and ground based observations. **Remote Sensing**, Basel, v. 5, p. 909-926, 2013.

CASTILLEJO-GONZÁLEZ, I. L.; LÓPEZ-GRANADOS, F.; GARCÍA-FERRER, A.; PEÑA-BARRAGÁN, J. M.; JURADO-EXPÓSITO, M.; ORDEN, M. S.; GONZÁLEZ-AUDICANA, M. Object – and pixel- based analysis for mapping crops and their agro-environmental associated measures using Quick Bird imagery. **Computers and Electronics in Agriculture**, v. 68, p. 207-215, 2009.

COHEN, J. A. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, p. 37-46, 1960.

COMISSÃO SUL-BRASILEIRA DE PESQUISA DE TRIGO – CSBPT. **Indicações técnicas da Comissão sul-brasileira de pesquisa de trigo – 2004**. 1. ed. Passo Fundo: Embrapa Trigo, 2004. Disponível em: <<http://www.cnpt.embrapa.br/culturas/trigo/rcsbpt04/trigo2004-1.pdf>>. Acesso em: 25 ago. 2014.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira de grãos**. Companhia Nacional de Abastecimento, Brasília, v. 1, n. 1, mar. 2014. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/14_03_12_08_41_24_boletim_graos_marco_2014.pdf>. Acesso em: 14 mar. 2014.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Boletim de monitoramento agrícola**: culturas de verão. Safra 2012/ 2013. Companhia Nacional de Abastecimento, Brasília, v. 2, fev. 2013. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_03_07_09_50_03_boletimmonitoramentoculturasveraofev2013v02.pdf>. Acesso em: 13 mar. 2014.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC Press, 1999. 160 p.

CUNHA, G. R.; ASSAD, E. D. Uma visão geral do número especial da RBA sobre zoneamento agrícola no Brasil. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 377-385, 2001.

DALLA NORA, E. L. Detecção e monitoramento da soja no Rio Grande do Sul: Uma abordagem baseada na dinâmica espectral e fenológica da cultura. **Perspectiva**, Erechim, RS, v. 34, n. 127, p. 63-71, 2010.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo – SP usando imagens *Landsat-5*. **Ra'ega**, Curitiba, v. 21, p. 234-271, 2011.

DOTTO, S. R. **Sistemas de produção**: cultivo do cevada. Passo Fundo – RS: Embrapa Trigo, 4. ed. 2014. Disponível em: <https://www.spo.cnptia.embrapa.br/conteudo?p_p_id=conteudoportlet_WAR_sistemasdeproducao16_1ga1ceportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&p_r_p_-76293187_sistemaProducaoId=3709&p_r_p_-996514994_topicId=3105>. Acesso em: 26 ago. 2014.

ECKERT, S.; HUSLER, F.; LINIGER, H.; HODEL, E. Trend analysis of MODIS NDVI time series for detecting land degradation and regeneration in Mongolia. **Journal of Arid Environment**, v. 113, p. 16-28, 2015.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA Milho e Sorgo. **Milho**: história e arte. Sete Lagoas: Embrapa Milho e Sorgo, 7ª ed., mai. 2008. Disponível em: <http://www.cnpms.embrapa.br/grao/7_edicao/grao_em_grao_materia_03.htm>. Acesso em: 03 jul. 2014.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA Monitoramento por Satélite. **Sistemas orbitais de monitoramento e gestão territorial**. Campinas: Embrapa Monitoramento por Satélite, 2009. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 15 jul. 2014.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA Trigo. **Sistemas de produção**. 2. ed. Passo Fundo: Embrapa Trigo, abr. 2014. Disponível em: https://www.spo.cnptia.embrapa.br/conteudo?p_p_id=conteudoportlet_WAR_sistemasdeproducao16_1ga1ceportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-2&p_p_col_count=1&p_r_p_-76293187_sistemaProducaoId=3704&p_r_p_-996514994_topicId=3044. Acesso em: 01 jul. 2014.

FEDERAÇÃO DA AGRICULTURA DO ESTADO DO PARANÁ - FAEP. **Mapa divulga zoneamento agrícola de diversas culturas no Paraná**. Curitiba: FAEP, dez. 2013. Disponível em: <<http://www.sistemafaep.org.br/mapa-divulga-zoneamento-agricola-de-diversas-culturas-parana.html>>. Acesso em: 09 jul. 2014.

FANCELLI, A. L.; DOURADO NETO, D. **Produção de milho**. Guaíba: Agropecuária, 2000. 360 p.

FIOREZE, S. L. **Comportamento produtivo do trigo em função da densidade de semeadura e da aplicação de reguladores vegetais**. 2011. 86 f. Dissertação (Mestrado em Agronomia) - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, SP, 2011.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina, 2002. 97 p.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina, 2011. 128 p.

FONTANA, D. C.; PINTO, D. G.; JUNGES, A. H.; BREMM, C. Inferências sobre o calendário agrícola a partir de perfis temporais de NDVI/MODIS. **Bragantia**, Campinas, v. 74, n. 3, p. 350-358, 2015. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0006-87052015000300350&lng=pt&nrm=iso&tIng=en>.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, Amsterdam, v. 80, n. 1, p. 185-201, 2002.

FORNASIERI FILHO, D. **A cultura do milho**. Jaboticabal: FUNEP, 1992. 273 p.

FRANCHINI, J. C.; COSTA, J. M.; DEBIASI, H.; TORRES, E. **Importância da rotação de culturas para a produção agrícola sustentável no Paraná**. Documentos/ EMBRAPA Soja, Londrina, jun. 2011. Disponível em: <http://www.cnpso.embrapa.br/download/Doc_327-VE.pdf>. Acesso em: 13 mar. 2014.

GAMON, J. A.; FIELD, C. B.; GOULDEN, M. L.; GRIFFIN, K. L.; HARTLEY, A. E.; JOEL, G.; PEÑUELAS, J.; VALENTINI, R. Relationships between NDVI, canopy structure, and photosynthesis in three Californian vegetation types. **Ecological Applications**, v. 5, p. 28-41, 1995.

GOODMAN, M.M.; SMITH, J. S. C. Botânica. *In*: PATERNIANI, E.; VIEGAS, G. P. (orgs). **Melhoramento e produção do milho no Brasil**. Campinas: Fundação Cargill, 1980. p.32-70.

GOVAERTS, Y. M.; VERSTRAETE, M. M.; PINTY, B.; GOBRON, N. Designing optimal spectral indices: A feasibility and proof of concept study. **International Journal of Remote Sensing**, n. 20, p. 1853-1873, 1999.

GRZEGOZEWSKI, D. M.; JOHANN, J. A.; URIBE-OPAZO, M. A.; MERCANTE, E.; COUTINHO, A. C. Mapping of the soya bean and corn crops in the State of Paraná using EVI images from the MODIS sensor. **International Journal of Remote Sensing**, v. 37, n.6, p. 1257-1275, 2016.

HILL, M. Vegetation index suites as indicators of vegetation state in grassland and savanna: an analysis with simulated sentinel 2 data for a North American transect. **Remote Sensing of Environment**, Amsterdam, v. 137, p. 94-111, 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 Sensing of Environment**, Amsterdam, v. 83, p. 195-213, 2002.

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

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Levantamento sistemático da produção agrícola**. 2017. Disponível em:<<http://www.sidra.ibge.gov.br>>. Acesso em 12 jan. 2017.

IPPOLITI-RAMILO, G.A.; EPIPHANIO, J.C.N.; SHIMABUKURO, Y.E.; FORMAGGIO, A.R. Sensoriamento remoto orbital como meio auxiliar na previsão de safras. **Agricultura em São Paulo**, São Paulo, v. 46, n. 1, p. 89-101, 1999.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital MODIS na estimação de datas do ciclo da cultura da soja para o estado do Paraná – Brasil. **Engenharia Agrícola**, Jaboticabal, v. 36, n.1, p. 126-142, 2016.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/MODIS. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p. 1295-1306, 2012.

JÖNSSON, P.; EKLUNDH, L. Timesat – a program for analyzing time-series of satellite sensor data_ 1. **Computers & Geosciences**, v. 30, n. 8, p. 833–845, 2004.

KOGAN, F.; KUSSUL, N.; ADAMENKO, T.; SKAKUN, S.; KRAVCHENKO, O.; KRYVOBOK, O.; SHELESTOV, A.; KOLOTII, A.; KUSSUL, O.; LAVRENYUK, A. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical

models. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 192-203, 2013.

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

LATORRE, M. L.; ANDERSON, L. O.; SHIMABUKURO, Y. E.; CARVALHO JUNIOR, O. A. Sensor MODIS: características gerais e aplicações. **Espaço e Geografia**, Brasília, v. 6, n. 1, p. 91-121, 2003.

LOBELL, D. B.; ORTIZ-MONASTERIO, J. I.; SIBLEY, A. M.; SOHU, V. S. Satellite detection of earlier wheat sowing in India and implications for yield trends. **Agricultural Systems**, v. 115, p. 137-143, 2013.

LUIZ, A. J. B.; OLIVEIRA, J. C.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Auxílio das imagens de satélite aos levantamentos por amostragem em agricultura. **Agricultura em São Paulo**, São Paulo, v. 49, p. 41-54, 2002.

MACHADO, E. C.; LAGÔA, A. M. M. A.; TICELLI, R. Relações fonte-dreno em trigo submetido a deficiência hídrica no estágio reprodutivo. **Revista Brasileira de Fisiologia Vegetal**, Campinas, v. 5, n. 2, p. 145-150, 1993.

MENGUE, V. P. **Avaliação da dinâmica espectro-temporal visando o mapeamento da soja e arroz irrigado no Rio Grande do Sul**. 2013. 122 f. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

MENGUE, V. P.; FONTANA, D. C. Assessment of spectral-temporal dynamics for mapping the main summer crops in the Rio Grande do Sul State. **Bragantia**, Campinas, v. 74, n.3, p. 331-340, 2015.

MINGWEI, Z.; QINGBO, Z.; ZHONGXIN, C.; JIA, L.; YONG, Z.; CHONGFA, C. Crop discrimination in Northern China with double cropping systems using Fourier analysis of time-series MODIS data. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, p. 476-485, 2008.

MOTTA, J. L. G.; CYBIS, D.; WEBER, E. Evolução temporal do NDVI/NOAA em áreas cobertas por pixels com proporções variáveis de soja. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 11, n. 2, p. 353-369. 2003.

NASCIMENTO JUNIOR, A. **Sistemas de produção: cultivo do centeio**. 3. ed. Passo Fundo: Embrapa Trigo. 2014. Disponível em: <https://www.spo.cnptia.embrapa.br/conteudo?p_p_id=conteudoportlet_WAR_sistemasdeproducao16_1ga1ceportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-1&p_p_col_count=1&p_r_p_-76293187_sistemaProducaoId=3702&p_r_p_-996514994_topicId=3014>. Acesso em: 25 ago. 2014.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION – NASA. Moderate resolution imaging spectroradiometer - MODIS. **Technical specifications**, 2003. Disponível em: <<https://modis.gsfc.nasa.gov/>>. Acesso em: 10 nov. 2016.

NUNES, E. L.; AMORIM, R. C. F.; SOUZA, W. G.; RIBEIRO, A.; SENNA, M. C. A.; LEAL, B. G. Zoneamento agroclimático da cultura do café para a bacia do rio Doce. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 22, n. 3, p. 297-302. 2007.

NUNES, J. L. S. **Cereais de inverno: aveia**. Agrolink. Disponível em: <<http://www.agrolink.com.br/cereaisdeinverno/InformacoesTecnicasAveia.aspx>>. Acesso em: 25 ago. 2014.

OSÓRIO, E. **Trigo no Brasil**. Campinas: Fundação Cargill, 1982. 287 p.

PARANÁ. Secretaria de Estado da Agricultura e do Abastecimento - SEAB. Departamento de Economia Rural – PR. **Comparativo de área, produção e produtividade**. Calendário agrícola. Secretaria de Estado da Agricultura e do Abastecimento, Curitiba. Disponível em: <www.agricultura.pr.gov.br/arquivos/File/deral/pss.xls>. Acesso em: 12 jul. 2014.

PETROPOULOS, G. P.; VADREU, K. P.; XANTHOPOULOS, G.; KARANTOUNIAS, G.; SCHOLZE, M. A comparison of spectral angle mapper and artificial neural network classifiers combined with *Landsat TM* Imagery analysis for obtaining burnt area mapping. **Sensors**, v.10, p. 1967-1985, 2010.

PINTO, D. G.; FONTANA, D. C. Inferências sobre o calendário agrícola da soja a partir de perfis temporais de NDVI em imagens MODIS. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15, 2011, Curitiba/PR. **Anais...** São José dos Campos: INPE, 2011. p. 148-153.

POSSAS, J. M. C.; CORREA, M. M.; MOURA, G. B. A.; LOPES, P. M. O.; CALDAS, A. M.; FONTES JÚNIOR, R.V. Zoneamento agroclimático para a cultura do pinhão-mansão no Estado de Pernambuco, **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 16, n. 9, p. 993-998, 2012.

POTGIETER, A. B.; APAN, A.; HAMMER, G.; DUNN, P. Early-season crop area estimates for winter crops in NE Australia using MODIS satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 380-387, 2010.

POTGIETER, A. B.; LAWSON, K.; HUETE, A. R. Determining crop acreage estimates for specific winter crops using shape attributes from sequential MODIS imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 254-263, 2013.

PRIMAVESI, A. C.; RODRIGUES, A. A.; GODOY, R. **Recomendações técnicas para o cultivo de aveia**. São Carlos: Embrapa Pecuária Sudeste, 2000. 38 p. (Boletim Técnico, 6).

RAMOS, R. P. S.; DEUS, R. A. S.; COSTA, S. O. S.; GOMES, D. D. M. O Sensoriamento remoto aplicado ao mapeamento, identificação e análise do uso do município de Garanhuns-PE. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, Santa Maria, RS, v. 19, n. 2, p. 559-567, 2015.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja**: estudo de caso no Rio Grande do Sul. 2004. 212 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.

RODRIGUES, M. T.; POLLO, R. A. P.; RODRIGUES, B. T.; MALHEIROS, J. M.; CAMPO, S. Sensoriamento remoto e geoprocessamento aplicado ao uso da terra para avaliação entre classificadores a partir do índice Kappa. **Revista Científica Eletrônica de Engenharia Florestal**, Garça, SP, v. 23, n. 1, p. 60-70, 2014.

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

SALOMONSON, V. V.; TOLL, D. L. Execution phase (C/D) spectral band characteristics of the EOS Moderate Resolution Imaging Spectrometer (MODIS-N) facility instrument. **Advances in Space Research**, v. 2, n. 3, p. 231-236, 1990.

- SANTOS, A. R.; PELUZIO, T. M. O.; SAITO, N. S. **Spring 5.1.2 passo a passo**: aplicações práticas. Alegre, ES: Caufes, 2012.
- SANTOS, J. S.; FONTANA, D.C.; SILVA, T. S. F.; RUDORFF, B. F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n.1, p.54-63, 2014.
- SHIMAKURA, S. **Bioestatística avançada I**. Departamento de Estatística – UFPR. Disponível em: <<http://leg.ufpr.br/~shimakur/CE701/node80.html>> Acesso em 24 nov. 2012.
- SHIMABUKURO, Y. E.; MAEDA, E. E.; FORMAGGIO, A. R. Sensoriamento remoto e sistemas de informações geográficas aplicados ao estudo dos recursos agronômicos e florestais. **Revista Ceres**, v. 56, n. 4, p. 399-409, 2009.
- SILLEOS, N. G.; ALEXANDRIDIS, T. K.; GITAS, I. Z.; PERAKIS, K. Vegetation Indices: Advances made in biomass estimation and vegetation monitoring in the last 30 years. **Geocarto International**, n. 21, v.4, p. 21-28, 2006.
- SILVA JUNIOR, C. A.; FRANK, T.; RODRIGUES, T. C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande – PB, v. 18, n. 1, p. 44-53, 2014.
- SILVA, A. M.; MELLO, J. R. B.; BOSCHI, R. S.; ROCHA, J. V.; LAMPARELLI, R. A. C. Avaliação de classificadores para o mapeamento de uso da terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15, 2011b, Curitiba/PR. **Anais...** São José dos Campos: INPE, 2011. p. 7324-7331.
- SILVA, P. R. F. **Crescimento e desenvolvimento**. In: Indicações técnicas para a cultura de milho no estado do Rio Grande do Sul. Porto Alegre: Fepagro, Embrapa Trigo; Emater/ RS, Fecoagro/RS, n. 7, 2001. 135 p.
- SILVA, R. R.; BENIN, G.; SILVA, G. O.; MARCHIORO, V. S.; ALMEIDA, J. L.; MATEI, G. Adaptabilidade e estabilidade de cultivares de trigo em diferentes épocas de semeadura, no Paraná. **Pesquisa Agropecuária Brasileira**, Brasília, v. 46, n. 11, p. 1439-1447. 2011a.
- SILVA, W. J.; SANS, L. M. A.; MAGALHÃES, P. C.; DURÃES, F. O. M. Exigências climáticas do milho em sistema plantio direto. **Informe Agropecuário**, Belo Horizonte, v. 27, n. 233, p. 14-25, 2006.
- SLEPER, D. A.; POEHLMAN, J. M. **Breeding field crops**. Ames: Blackwell Pub Iowa, 2006. 424 p.
- SOUSA, M. A.; RIBEIRO, R. J. C.; CARNEIRO, P. J. R. Aplicações do sensoriamento remoto e do geoprocessamento. Estudo de caso: bacia do rio do Sono, TO – Brasil. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14, 2009, Natal/ RN. **Anais...** São José dos Campos: INPE, 2009. p. 2241-2248.
- SOUSA, S. B.; FERREIRA, L. G. Mapeamento da cobertura e uso da terra: Uma abordagem utilizando dados de sensoriamento remoto óptico multitemporais e provenientes de múltiplas plataformas. **Revista Brasileira de Cartografia**, v. 66, n. 2, p. 321-336, 2014.
- SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. **Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices**. **International Journal of Remote Sensing**, v.36, n.7, p.1809-1824, 2015.

SULSOFT – PROCESSAMENTO DE DADOS. **Guia do ENVI em português**. Versão 5.1. Porto Alegre. Disponível em: < <http://www.envi.com.br> >. Acesso em: jul. 2014.

TINÓS, T. M.; FERREIRA, M. V.; RIEDEL, P. S.; ZAINÉ, J. E. Aplicação e avaliação de metodologia de classificação automática de padrões de formas semelhantes do relevo. **Revista Brasileira de Geomorfologia**, v. 15, n. 3, 2014.

VAN LEEUWEN, W. J. D.; HUETE, A.R.; LAING, T.W. MODIS Vegetation Index Compositing Approach: A Prototype with AVHRR Data. **Remote Sensing of Environment**, Amsterdam, v. 69, n. 3, p.264-280. 1999.

VICENTE, L. E.; GOMES, D.; VICTORIA, D. C.; GARÇON, E. A. M.; BOLFE, É. L.; ANDRADE, R. G.; SILVA, G. B. S. Séries temporais de NDVI do sensor SPOT vegetação e algoritmo SAM aplicados ao mapeamento de cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, p. 1337-1345, 2012.

VICTORIA, D. C.; PAZ, A. R.; COUTINHO, A. C.; KASTENS, J.; BROWN, J. C. Cropland area estimates using MODIS NDVI time series in the state of Mato Grosso, Brazil. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p. 1270-1278, 2012.

VIEIRA, T. G. C.; ALVES, H. M. R.; VOLPATO, M. M. L.; BERNARDES, T.; SANTOS, E. R. dos. Avaliação de classificadores automáticos no mapeamento de áreas cafeeiras da região de Guaxupé, Minas Gerais. SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 6, 2009, Vitória - ES. **Anais...** Vitória – ES, 2011. *Online*.

VIÑA, A.; GITELSON, A. A.; NGUY-ROBERTSON, A. L.; PENG, Y. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. **Remote Sensing of Environment**, Amsterdam, v. 115, p. 3468-3478, 2011.

VUOLO, F.; ATZBERGER, C. Exploiting the classification performance of Support Vector Machines with multi-temporal moderate-resolution imaging spectroradiometer (MODIS) data in areas of agreement and disagreement of existing land cover products. **Remote Sensing**, n.4, p. 3143-3167, 2012.

WAGNER, M. V. **Características hidroclimáticas para a cultura do milho em Guarapuava - PR**. 2009. 68 f. Dissertação (Mestrado em Agronomia) - Universidade Estadual do Centro-Oeste, UNICENTRO-PR, Guarapuava, PR, 2009.

WALLACE, C. S. A.; THOMAS, K. A. An annual plant growth proxy in the Mojave Desert using MODIS-EVI data. **Sensors**, v. 8, p. 7792-7808, 2008.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, v. 32, n. 13, p. 2088-2094, 2012.

YI, J. L. R. **Dados do sistema sensor MODIS – TERRA para avaliação e monitoramento de áreas agrícolas na Região Sul do Brasil**. 2005. 181 f. Tese (Doutorado em Engenharia de Transportes) – Universidade De São Paulo, São Paulo, 2005.

YI, J. L. R.; SHIMABUKURO, Y. E.; QUINTANILHA, J. A. Identificação e mapeamento de áreas de milho na região Sul do Brasil utilizando imagens MODIS. **Engenharia Agrícola**, Jaboticabal, v. 27, n. 3, p. 753-763, 2007.

ZHANG, J.; FENG, L.; YAO, F. Improved maize cultivated area estimation over a large scale combining MODIS-EVI time series data and crop phenological information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.94, p. 102-113, 2014.

ARTIGOS

ARTIGO 1: MAPEAMENTO DAS LAVOURAS DE INVERNO E MILHO 2.^a SAFRA NO ESTADO DO PARANÁ, UTILIZANDO IMAGENS MULTITEMPORAIS DO SENSOR MODIS

Resumo: A obtenção de tecnologias eficazes para quantificar e estimar o monitoramento de lavouras agrícolas destaca a busca de metodologias que forneçam essa informação antes da colheita. O estudo do monitoramento e/ou estimativas de rendimento de lavouras de inverno usando índices de vegetação derivados de dados multitemporais a partir do sensor MODIS, está sendo estudado na busca de maior objetividade aos valores gerados. Nesse contexto, este estudo teve por objetivo mapear áreas com lavouras de inverno e milho 2.^a safra, utilizando séries temporais EVI/ MODIS dos satélites Terra e Aqua, para as safras 2012 a 2014 no estado do Paraná. No ajuste para o mapeamento foram utilizadas imagens de resolução espacial (30 metros) paralelamente às imagens MODIS (250 metros), para identificar as lavouras de interesse. A qualidade do mapeamento foi avaliada utilizando a análise da exatidão da matriz de erro como a Exatidão global, 87,5%; 79,5% e 82% nas safras 2012, 2013 e 2014 respectivamente e Índice Kappa, 0,81; 0,69 e 0,73, nas safras 2012, 2013 e 2014, respectivamente. As áreas obtidas pelas máscaras foram subestimadas para o milho 2.^a safra nas safras 2012 e 2013 e superestimada em 2014 e para as lavouras de inverno, foram superestimadas em média 1.874,85. A utilização do perfil espectral-temporal MODIS/EVI foi importante e eficaz na identificação e mapeamento do milho 2.^a safra e lavouras de inverno.

Palavras-chave: EVI; Índice de vegetação; Terra & Aqua.

1 INTRODUÇÃO

O Brasil se destaca no cenário mundial na produção de alimentos, principalmente por possuir grandes áreas agricultáveis aliadas ao avanço tecnológico no campo. A produção de lavouras de inverno e o milho 2.^a safra são fortes na região sul do Brasil, principalmente no estado do Paraná, onde o clima favorece esse cultivo. A região escolhida para o desenvolvimento deste trabalho foi o estado do Paraná, por possuir, aproximadamente, 20% da produção de milho 2.^a safra e 59% da produção total da lavoura de inverno brasileira no ano de 2015 (IBGE, 2016).

O acompanhamento da produção agrícola, em grande parte, ainda é realizado por meio de questionamentos aos produtores rurais e/ou cooperativas, por amostragem, demorada e onerosa por órgãos oficiais brasileiros (PINO, 2001; MERCANTE, 2007; SILVA JUNIOR; FRANK; RODRIGUES, 2014). Para tanto, o conhecimento prévio da produção

agrícola é importante para o controle econômico nacional e para o abastecimento do mercado interno. Por isso, a importância da obtenção de tecnologias eficazes que quantifiquem a previsão de safras agrícolas e o conhecimento de informações a partir das áreas cultivadas.

As técnicas de sensoriamento remoto são muito utilizadas na agricultura, uma vez que o monitoramento agrícola se faz necessário, pois a dinâmica produtiva segue padrões sazonais fortes relacionados com o ciclo de vida biológico das plantas, ao tipo de solo, bem como as variações climáticas e práticas de gestão agrícola (ATZBERGER, 2013). A utilização de imagens de resolução espacial moderada e alta resolução temporal são características que auxiliam no mapeamento e no monitoramento de atividades agrícolas em grandes áreas, baseando-se na análise do comportamento espectro-temporal de índices de vegetação (MENGUE; FONTANA, 2015).

O sensor *Moderate resolution imaging spectroradiometer* (MODIS) é considerado uma ferramenta eficiente por possuir moderada resolução espacial, baixo custo de aquisição de dados e alta resolução temporal que viabiliza o mapeamento e monitoramento de culturas em escala regional e, por isso, tem sido utilizado com frequência em estudos agrícolas. Nesse contexto, autores como Casady, Van Leeuwen e Reed (2013), Potgieter, Lawson e Huete (2013), Lobell et al. (2013), Pan et al. (2012) entre outros estudaram o monitoramento agrícola e/ou estimativa de safra de lavouras de inverno utilizando índices de vegetação extraídos de imagens multitemporais do sensor MODIS. Apesar de obterem resultados satisfatórios, as variáveis agroclimáticas bem como as especificidades das variedades tornam-se desafios para o desenvolvimento de modelos mais precisos para tais objetivos.

O objetivo deste trabalho foi mapear as áreas com as culturas de inverno (aveia, centeio, cevada, trigo e triticale) e milho 2.^a safra no Estado do Paraná, Brasil, a partir de séries temporais de imagens do sensor MODIS, satélites Terra e Aqua, ao longo do ciclo de desenvolvimento para as safras de 2012 a 2014.

2 MATERIAL E MÉTODOS

As atividades foram realizadas no Laboratório de Topografia e Geoprocessamento (GeoLab) e no Laboratório de Estatística Aplicada (LEA) da Universidade Estadual do Oeste do Paraná – UNIOESTE, *campus* de Cascavel. Para a realização dos procedimentos foram utilizados os *software's Environment for visualizing images* (ENVI 5.0) (*Exelis visual information solutions*, Boulder, Colorado, Estados Unidos da América) e ARCGIS 10

(*Environmental Systems Research Institute*, Redlands, California, Estados Unidos da América). A linguagem de programação *Interactive data language* (IDL 5.0), foi utilizada no desenvolvimento de processamento automático das imagens MODIS, assim como na extração dos dados dos perfis temporais e na geração das imagens de mínimo e máximo (ESQUERDO, 2007). Na Figura 1 pode ser visualizado o fluxograma das atividades realizadas para esta pesquisa.

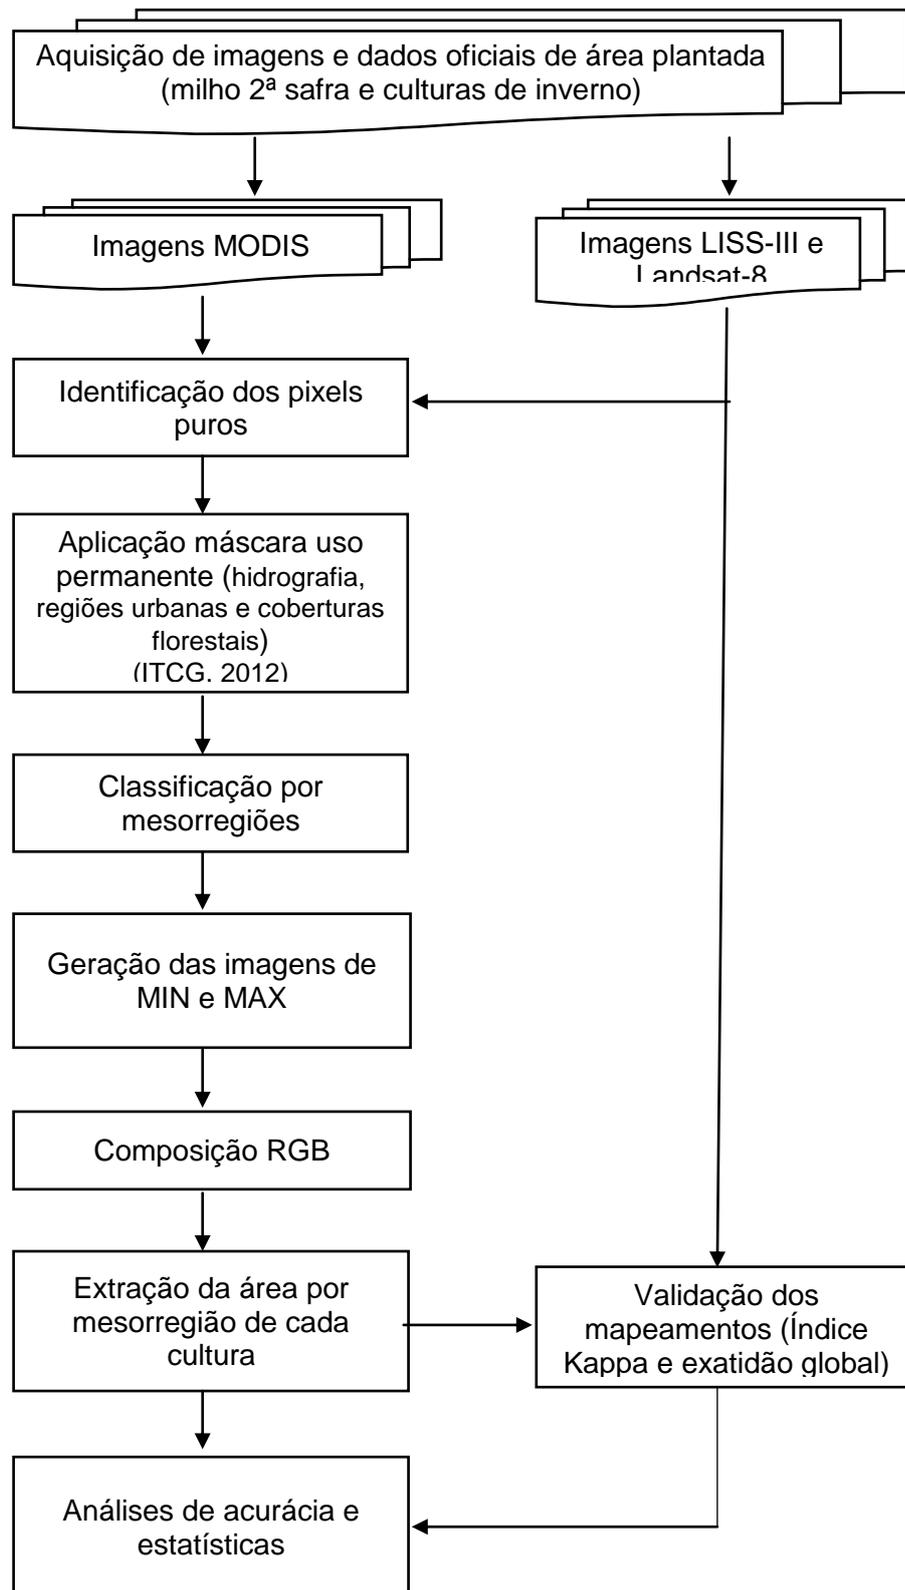


Figura 1 Fluxograma de trabalho.

2.1 Área de estudo e aquisição dos dados

O estudo compreende o estado do Paraná, região sul do Brasil, situado entre os paralelos 22°29'S e 26°43'S e os meridianos 48°2'W e 54°38'W e é constituído por 399 municípios. Como as datas de sementeiras diferem de acordo com as regiões por todo o estado, este foi dividido em dez mesorregiões, segundo o IBGE (2016): Norte Pioneiro, Norte Central, Noroeste, Centro Sul, Centro Oriental, Centro Ocidental, Oeste, Sudoeste, Sudeste e Metropolitana de Curitiba (Figura 2).

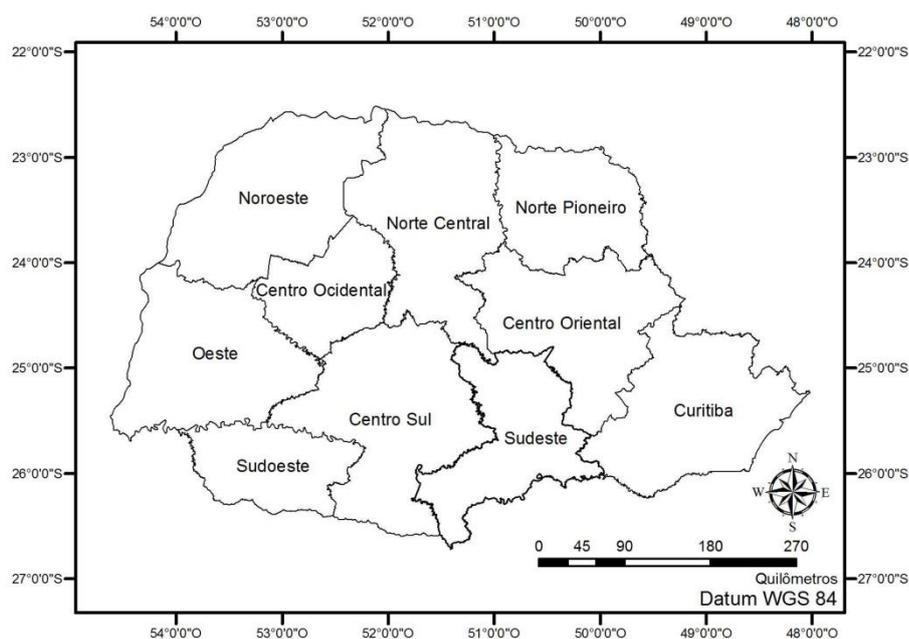


Figura 2 Localização das mesorregiões do estado do Paraná.

As imagens de satélite foram obtidas da base de dados da Embrapa Informática, e fazem parte do produto MOD13Q1.5 e MYD13Q1 do sensor MODIS a bordo dos satélites Terra e Aqua, respectivamente, que possuem produtos, como os índices de vegetação com resolução espacial de 250 metros e resolução temporal de 16 dias. Para o estudo atual foram utilizadas imagens do *tile* h13v11 do índice de vegetação melhorado (EVI), no período de todo o ciclo vegetativo das lavouras de inverno e milho 2.^a safra, para as safras de 2012, 2013 e 2014, apresentados na Tabela 1.

Tabela 1 Datas das imagens dos satélites Terra e Aqua utilizadas no estudo

	Milho 2. ^a safra		Lavouras de inverno	
	Satélite Terra	Satélite Aqua	Satélite Terra	Satélite Aqua
2012	01/01 a 27/07	09/01 a 19/07	06/04 a 31/10	14/04 a 08/11
2013	01/01 a 12/07	09/01 a 04/07	07/04 a 17/11	15/04 a 09/11
2014	01/01 a 26/06	09/01 a 18/06	07/04 a 17/11	15/04 a 09/11

As imagens do satélite *ResourceSat-1* (LISS-III), de média resolução espacial, foram obtidas da base de dados do Instituto Nacional de Pesquisas Espaciais (INPE) e as imagens do satélite *Landsat-8* foram obtidas da base de dados *U.S. Geological Survey* (USGS).

2.2 Seleção de pixels puros

Para contemplar o ciclo das culturas estudadas, foram utilizadas imagens LISS-III e *Landsat-8*. Adaptando as técnicas de interpretação visual de imagens, segundo Mercante et al. (2012), e avaliando o perfil temporal foi possível identificar talhões de lavouras de inverno (aveia, cevada, centeio, trigo e triticale) e milho 2.^a safra, que correspondem às dimensões dos pixels das imagens MODIS (250 x 250 m) selecionando somente os pixels que expressam unicamente o padrão espectral de cada cultura estudada, como pode ser verificado nas Figuras 3 e 4. Para cada pixel utilizado foi gerado um perfil temporal médio para cada cultura em estudo.

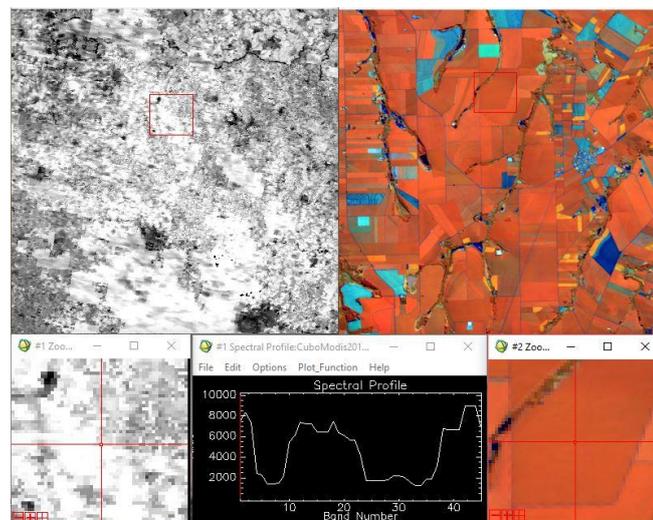


Figura 3 Identificação do milho 2.^a safra nas imagens MODIS e *Landsat 8*.

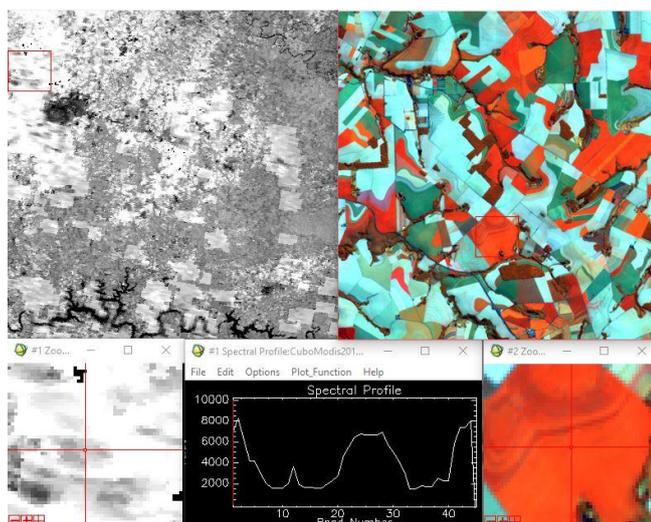


Figura 4 Identificação de lavouras de inverno nas imagens MODIS e *Landsat 8*.

2.3 Geração das imagens de mínimo e máximo EVI

Para gerar as máscaras de inverno e milho 2.^a safra, utilizou-se a metodologia proposta por Johann et al. (2012), que consiste na utilização de múltiplas imagens MODIS, para geração das “Imagens de mínimo” e a “Imagens de máximo” EVI. Foi utilizado um sistema de extração de dados de imagens desenvolvido por Esquerdo (2007) em linguagem IDL.

A “Imagem de mínimo EVI” representa a fase de pré-plantio até o desenvolvimento inicial das culturas e a “Imagem de máximo EVI” representa o pico vegetativo das culturas, ou seja, o final do desenvolvimento, florescimento e formação de colheita. Para a definição das datas, foram analisados os perfis temporais de EVI para cada cultura separadamente, verificando-se os períodos de semeadura e pico vegetativo em todas as regiões do estado, considerando-se que as épocas de cultivo são distintas.

2.4 Composição colorida e extração RGB

A composição colorida RGB foi realizada utilizando o *software* ENVI 5.0. As lavouras de inverno e milho 2.^a safra foram trabalhadas separadamente. Assim, a imagem de máximo EVI foi colocada no canal R e a imagem de mínimo EVI foi colocada nos canais G e B,

resultando em uma composição colorida em que as áreas em vermelho representam as culturas estudadas.

Posteriormente, os valores originais de EVI foram transformados para níveis de cinza (NC), e realizada a extração RGB, que se baseia na extração de áreas de interesse utilizando valores de cortes nos canais R e GB, resultando apenas na lavoura desejada (máscara) (JOHANN et al., 2012). Este sistema separa os valores de corte em NC, para o canal R e para os canais G e B, estabelecidos por testes pelo usuário.

Para cada teste, os pixels classificados foram os que tiveram valores maiores que o corte definido no canal R e valores menores que o corte definido para os canais G e B, resultando nas lavouras de inverno e milho 2.^a safra.

2.5 Índices de acurácias

Foram utilizados 400 pontos amostrais espalhados de forma aleatória sobre cada mapeamento, sendo 50% sorteados sobre o alvo de interesse (inverno ou milho 2.^a safra) e 50% fora do mapeamento. Esse procedimento visou balancear a análise dos erros de omissão e inclusão da análise da acurácia. A partir da matriz de erros, foi calculada a exatidão global (EG), o índice Kappa, erros de inclusão e omissão.

2.6 Análises de comparação de áreas

Os dados obtidos para as safras 2012, 2013 e 2014 pela extração de áreas das máscaras por mesorregiões foram comparados por meio do coeficiente de correlação por postos de Spearman com os dados oficiais da área colhida, disponibilizados pelo IBGE (2016). Os indicadores estatísticos erro médio (ME), raiz do erro médio quadrático (RMSE) e o coeficiente de concordância aprimorado de Willmott (d_r) também foram utilizados como parâmetros para avaliação das máscaras.

3 RESULTADOS E DISCUSSÃO

As datas para a geração das imagens de mínimo e máximo foram definidas pela análise dos perfis temporais de EVI para cada lavoura separadamente, verificando-se os períodos de semeadura e pico vegetativo em todas as mesorregiões do estado, levando em consideração que as épocas de cultivo de ambas as culturas são distintas. As datas para o milho 2.^a safra e lavouras de inverno podem ser verificadas nas Tabelas 2 e 3, respectivamente.

Tabela 2 Datas das imagens utilizadas para geração das imagens de mínimo e máximo para milho 2.^a safra

Mesorregiões		Safras		
		2012	2013	2014
Centro Ocidental	Imagem mínimo	01/01 a 06/04	01/01 a 30/03	01/01 a 07/04
	Imagem máximo	06/04 a 24/05	30/03 a 02/06	07/04 a 02/06
Centro Oriental	Imagem mínimo	01/01 a 29/03	01/01 a 14/03	01/01 a 14/03
	Imagem máximo	29/03 a 09/06	14/03 a 25/05	07/04 a 26/06
Centro Sul	Imagem mínimo	01/01 a 29/03	01/01 a 14/03	01/01 a 30/03
	Imagem máximo	29/03 a 04/08	22/03 a 10/06	30/03 a 18/06
Noroeste	Imagem mínimo	01/01 a 29/03	01/01 a 30/03	01/01 a 22/03
	Imagem máximo	29/03 a 01/06	30/03 a 12/07	22/03 a 25/05
Norte Central	Imagem mínimo	01/01 a 22/04	01/01 a 30/03	01/01 a 30/03
	Imagem máximo	22/04 a 01/06	30/03 a 02/06	30/03 a 25/05
Norte Pioneiro	Imagem mínimo	01/01 a 06/04	01/01 a 30/03	01/01 a 07/04
	Imagem máximo	14/04 a 16/05	30/03 a 10/06	07/04 a 25/05
Oeste	Imagem mínimo	01/01 a 13/03	01/01 a 06/03	01/01 a 14/03
	Imagem máximo	13/03 a 01/06	06/03 a 02/06	30/03 a 10/06
Sudeste	Imagem mínimo	01/01 a 06/04	01/01 a 14/03	01/01 a 07/04
	Imagem máximo	06/04 a 25/06	22/03 a 10/06	07/04 a 18/06
Sudoeste	Imagem mínimo	01/01 a 21/03	01/01 a 06/03	01/01 a 14/03
	Imagem máximo	21/03 a 19/07	06/03 a 25/05	30/03 a 10/06

Tabela 3 Datas das imagens utilizadas para geração das imagens de mínimo e máximo para lavouras de inverno

Mesorregiões		Safras		
		2012	2013	2014
Centro Ocidental	Imagem mínimo	06/04 a 01/06	07/04 a 18/06	07/04 a 10/06
	Imagem máximo	01/06 a 07/10	18/06 a 16/10	10/06 a 24/10
Centro Oriental	Imagem mínimo	06/04 a 17/06	07/04 a 18/06	07/04 a 10/06
	Imagem máximo	17/06 a 31/10	02/06 a 09/11	04/07 a 25/11
Centro Sul	Imagem mínimo	06/04 a 27/07	07/04 a 12/07	07/04 a 04/07
	Imagem máximo	12/08 a 08/11	12/07 a 17/11	04/07 a 17/11
Noroeste	Imagem mínimo	06/04 a 24/05	07/04 a 25/05	07/04 a 25/05
	Imagem máximo	04/08 a 15/10	05/08 a 08/10	13/08 a 08/10
Norte Central	Imagem mínimo	06/04 a 17/06	07/04 a 02/06	07/04 a 17/05
	Imagem máximo	17/06 a 07/10	10/06 a 24/10	02/06 a 24/10
Norte Pioneiro	Imagem mínimo	06/04 a 01/06	07/04 a 10/06	15/04 a 18/06
	Imagem máximo	01/06 a 07/10	18/06 a 08/10	26/06 a 24/10
Oeste	Imagem mínimo	06/04 a 01/06	07/04 a 02/06	07/04 a 10/06
	Imagem máximo	19/07 a 31/10	10/06 a 08/10	10/06 a 24/10
Sudeste	Imagem mínimo	06/04 a 19/07	07/04 a 02/06	01/05 a 20/07
	Imagem máximo	19/07 a 31/10	02/06 a 09/11	20/07 a 17/11
Sudoeste	Imagem mínimo	06/04 a 17/06	07/04 a 18/06	07/04 a 26/06
	Imagem máximo	17/06 a 29/09	05/08 a 01/11	04/07 a 24/10

O milho 2.^a safra e as lavouras de Inverno foram trabalhadas separadamente, logo, foram confeccionadas imagens de mínimo e máximo individuais. Na composição colorida, a imagem de máximo EVI foi inserida no canal R e a imagem de mínimo EVI foi posta nos canais G e B, resultando nas imagens (a), (b), (c), (g), (h) e (i), em que as áreas em vermelho representam as culturas de interesse (Figura 5).

Na geração das máscaras das lavouras de inverno e milho 2.^a safra, entre os vários testes realizados de cortes de NC para os canais da composição RGB, os melhores resultados obtidos para as lavouras de inverno, quando se definiu R165 GB 130 para a safra 2012 e R135 GB130 para as safras 2013 e 2014 e para o milho 2.^a safra, quando se definiu 140 como valor de corte para o canal R e 130 como valor de corte para os canais G e B para as três safras. A distribuição espacial das lavouras de inverno e milho 2.^a safra, para as safras no estado do Paraná, é ilustrada na Figura 5 ((d), (e), (f), (j), (l) e (m)). A região oeste é a maior produtora de milho 2.^a safra no estado e as regiões centro sul, centro ocidental e norte central destacam-se com os cultivos de inverno.

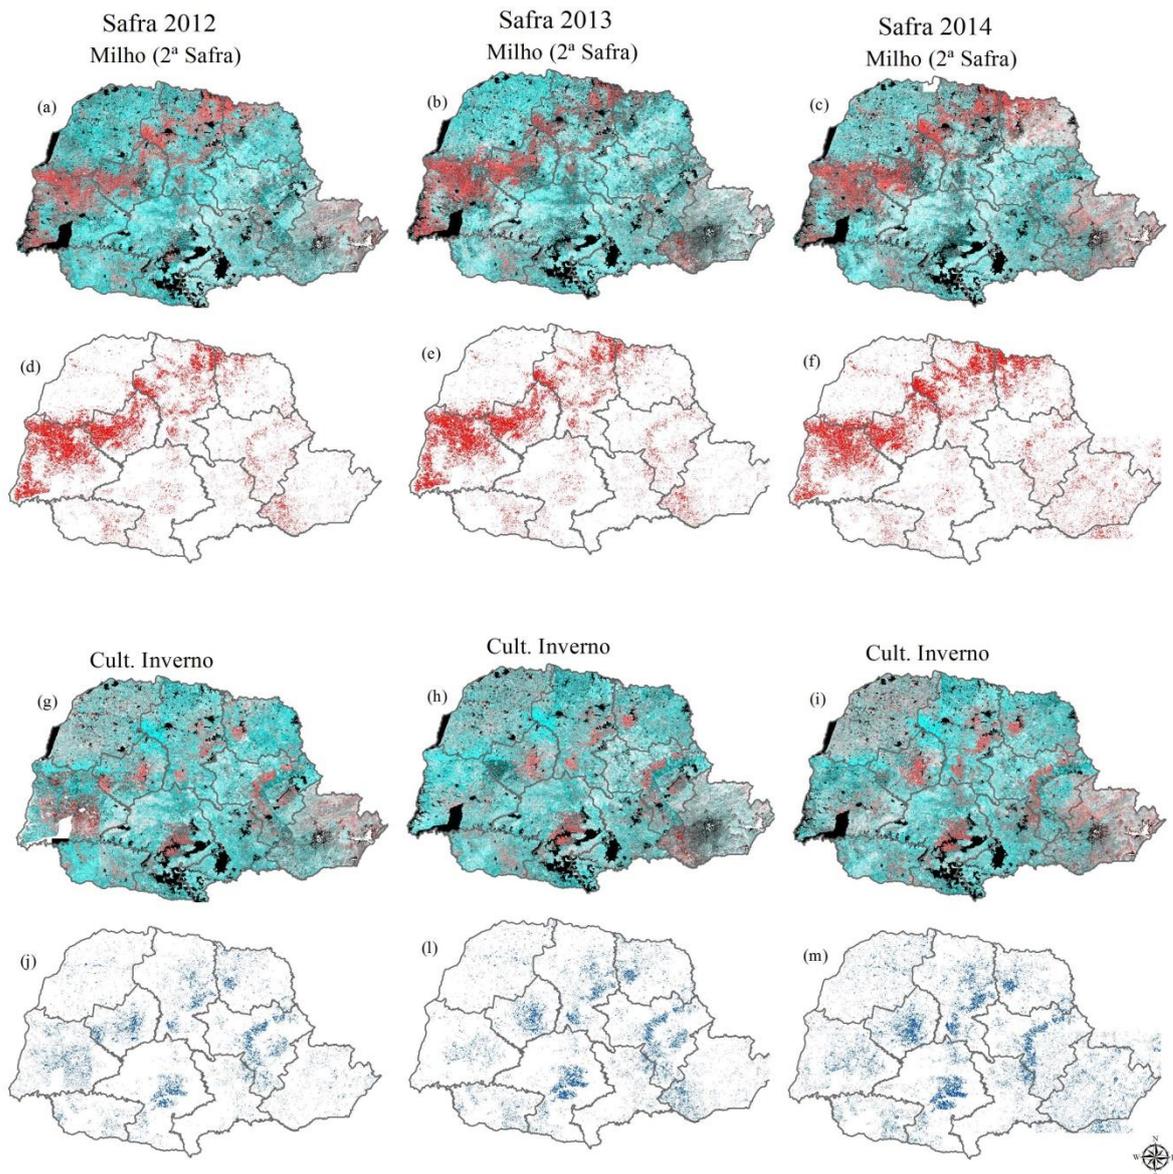


Figura 5 Distribuição espacial das culturas de interesse no estado do Paraná.

Com as máscaras de ambas as culturas, foi realizada uma operação matemática para avaliar se as áreas das lavouras de inverno e milho 2.^a safra estavam se sobrepondo, ou seja, se haviam áreas em comum às culturas estudadas. Na Tabela 4, pode-se observar as áreas de cada cultura e a sobreposição entre elas. Na safra de 2012 ocorreu a menor quantidade de áreas com sobreposição entre as lavouras e em 2014 a maior quantidade. Durante a verificação de pixels puros notou-se, principalmente na safra de 2014, áreas em que foram cultivados o milho 2.^a safra e posteriormente um cultivo de inverno.

Tabela 4 Área das máscaras de milho 2.^a safra, lavouras de inverno e sobreposição de áreas, estado do Paraná

Safras		Milho 2. ^a safra	Inverno	Sobreposição de áreas
2012	Área (ha)	2.620.350	938.018,8	284.118,8
	Sobreposição de áreas (%)	2,3	30,3	-
2013	Área (ha)	2.018.893,8	1.102.493,8	347.618,8
	Sobreposição de áreas (%)	17,2	31,5	-
2014	Área (ha)	2.396.550	1.615.281,3	595.150
	Sobreposição de áreas (%)	24,8	36,8	-

3.1 Análises de acurácia das máscaras

Os resultados das análises de acurácia como exatidão global, índice Kappa, erros de inclusão e omissão das máscaras confeccionadas a partir do índice de vegetação EVI podem ser verificadas nas Tabela 5, 6 e 7. Na safra 2012, a EG foi de 87,50%, atingindo o valor mínimo aceito de 85%, segundo Foody (2002), contudo, nas safras 2013 e 2014 os valores obtidos foram 79,50% e 82,00%. O ÍK, segundo a classificação descrita por Landis e Koch (1977), foi classificado como excelente para safra 2012 e como muito bom para as safras 2013 e 2014.

Tabela 5 Análise de acurácia das máscaras na safra 2012, estado do Paraná

Estimativa	Referência de campo			Total geral	Erro de inclusão
	Inverno	Milho	Não cultura		
Inverno	163	13	5	181	9,9%
Milho	7	177	10	194	8,8%
Não cultura	30	10	185	225	17,8%
Total geral	200	200	200	600	-
Erro omissão	18,5%	11,5%	7,5%	-	-

Nota: Índice Kappa = 0,81; Exatidão global = 87,50%.

Tabela 6 Análise de acurácia das máscaras na safra 2013, estado do Paraná

Estimativa	Referência de campo			Total geral	Erro de Inclusão
	Inverno	Milho	Não cultura		
Inverno	164	29	13	206	20,4%
Milho	6	146	20	172	15,1%
Não cultura	30	25	167	222	24,8%
Total geral	200	200	200	600	-
Erro omissão	18,0%	27,0%	16,5%	-	-

Nota: Índice Kappa = 0,69; Exatidão global = 79,50%.

Tabela 7 Análise de acurácia das máscaras na safra 2014, estado do Paraná

Estimativa	Referência de campo			Total geral	Erro de inclusão
	Inverno	Milho	Não cultura		
Inverno	158	30	8	196	19,4%
Milho	6	153	11	170	10,0%
Não cultura	36	17	181	234	22,6%
Total geral	200	200	200	600	-
Erro omissão	21,0%	23,5%	9,5%	-	-

Nota: Índice Kappa = 0,73; Exatidão Global = 82,00%.

Os resultados de acurácias encontrados por Potgieter, Lawson e Huete (2013), ao mapearem os tipos de culturas de inverno em *Queensland* (Austrália) utilizando imagens de EVI do MODIS, foram IK superior a 0,86 e EG de 96%; Li et al. (2014), mapeando os sistemas de cultivos na China, utilizando imagens de EVI do MODIS, observaram EG de 91%. Souza et al. (2015), mapeando culturas de verão utilizando EVI do sensor MODIS, encontraram valores de EG de 83,3% e 80,0% e IK 0,74 e 0,69 nas safras 2010/11 e 2011/12, respectivamente.

Outra maneira de avaliar a acurácia é por meio da análise dos erros de inclusão (EI) e dos erros de omissão (EO) presentes na classificação (CONGALTON; GREEN, 1999). Notou-se que as amostras sorteadas para as safras 2012, 2013 e 2014 foram, em média, 12,2%; 20,1% e 17,3% respectivamente de EI, indicando que a máscara classificou erroneamente esses locais como áreas de culturas de interesse e na realidade eram outros alvos. Os EO foram, em média, 12,5%; 20,5% e 18,0% para as safras 2012, 2013 e 2014, respectivamente, indicando a proporção de amostras que foram excluídas da classe à qual pertenciam.

3.2 Comparação das áreas mapeadas com os dados oficiais

A análise entre os dados da área estimada (máscara) e da área observada (IBGE) foi realizada para as três safras estudadas e pode-se ser observada na Tabela 8. Para o milho 2.^a safra, as áreas obtidas pelas máscaras foram inferiores às áreas oficiais do IBGE nas safras 2012 e 2013, com diferença percentual variando de 1% a 6,14% e na safra 2014 as áreas estimadas foram 22,40% maiores que as áreas oficiais. Nas lavouras de inverno, as áreas estimadas foram maiores que as áreas oficiais, com diferença percentual de 0,28%; 2,53% e 1,67% nas safras 2012, 2013 e 2014 respectivamente. No decorrer das safras, as áreas cultivadas com milho 2.^a safra foram reduzindo e as áreas de lavouras de inverno foram aumentando, indicando, provavelmente, a substituição do cultivo do milho pelos cultivos de inverno.

Tabela 8 Informações de área oficial (IBGE) e obtidas pelas máscaras de milho 2.^a safra e lavouras de inverno para o estado do Paraná

Lavouras	Variáveis	2012	2013	2014
Milho 2. ^a safra	Área IBGE (ha)	2.039.241	2.150.710	1.898.614
	Área Máscara (ha)	2.018.850	2.018.675	2.323.837
	Diferença (Máscara - IBGE)	-20.391	-132.035	425.223
	Diferença (%)	-1,00%	-6,14%	22,40%
Inverno	Área IBGE (ha)	935.230	1.125.265	1.510.138
	Área Máscara (ha)	937.825	1.153.752	1.535.301,3
	Diferença (Máscara - IBGE)	2.595	28.487	25.163,3
	Diferença (%)	0,28%	2,53%	1,67%

Fonte: IBGE (2016).

Crusiol et al. (2016) mapearam áreas agrícolas do município de Londrina em cinco safras de verão, confrontando os resultados obtidos com os dados oficiais IBGE e observaram percentual de 31,93% e 44,72% maiores que os dados oficiais nas safras 1998/1999 e 2000/2001, respectivamente; percentual variando de 3,96% a 14,80% menores que os dados oficiais nas safras de 2001/2002, 2006/2007 e 2008/2009. Com base no comportamento espectro-temporal EVI/MODIS, Mengue e Fontana (2015) mapearam lavouras de verão no estado do Rio Grande do Sul e, comparando os resultados obtidos com os dados oficiais do IBGE, notaram subestimação em 11,13% para a soja e superestimação de 16,72% para o arroz irrigado.

Na Tabela 9, são apresentados os índices estatísticos ME, RMSE e dr , sendo que o milho 2.^a safra apresenta melhores resultados, quando comparado com as lavouras de inverno. Analisando o ME, verificou-se que a área obtida pela máscara foi subestimada em média 7.621,26 ha nas safras 2012 e 2013 e superestimada em 42.522,34 ha em 2014 para milho 2.^a safra e superestimada, em média, 1.874,85 ha nas três safras de inverno. De acordo com o RMSE, que indica a acurácia do modelo, para todo o estado, houve variação média de 80.505,63 ha de erro para o milho 2.^a safra e 65.493,97 ha de erro para lavouras de inverno. Avaliando o r_s para o milho 2.^a safra, verificou-se uma variação de 0,72 a 0,75, indicando uma forte correlação entre os dados oficiais e os dados estimados; para as lavouras de inverno, variou de 0,40 a 0,60, indicando uma moderada correlação entre os dados oficiais com os dados obtidos pela máscara.

Tabela 9 Estatísticas obtidas entre os dados de área oficial (ha) e obtidas pelas máscaras (ha) de milho 2.^a safra e lavouras de inverno para o estado do Paraná

Lavouras	Estatísticas	2012	2013	2014
Milho 2. ^a safra	ME	-2.039,06	-13.203,46	42.522,34
	RMSE	77.709,30	88.230,90	75.576,70
	dr	0,85	0,83	0,84
	r_s	0,75	0,73	0,72
Inverno	ME	259,54	2.848,67	2.516,33
	RMSE	51.378,60	59.522,20	85.581,10
	dr	0,59	0,58	0,54
	r_s	0,60	0,60	0,40

Nota: ME: Erro médio; RMSE: Raiz do erro médio quadrático; dr: Coeficiente de concordância aprimorado de Willmott; r_s : Coeficiente de correlação por postos de Spearman.

A utilização de dados do sensor MODIS e seus produtos tem sido empregada por diversos autores, utilizando metodologias diferenciadas. Kogan et al. (2013) avaliaram o uso de dados do sensor MODIS para previsão da produtividade do trigo de inverno na Ucrânia, utilizando um modelo de regressão baseado em dados temporais de NDVI, dados meteorológicos e modelos biofísicos e verificaram que o modelo NDVI e o modelo biofísico foram superestimados no ano de 2010 e, em 2011, foram subestimados em relação às estatísticas oficiais. Mkhabela et al. (2011) estudaram a utilização do sensor MODIS – NDVI para previsão de safra em regiões canadenses e identificação do melhor momento para previsão de rendimento de culturas e observaram que o RMSE variou de 8 a 25% para a cevada, entre 10% e 58% para a canola e de 6% a 34% para o trigo. Li et al. (2014) propuseram um algoritmo para mapeamento agrícola utilizando uma série temporal do EVI sensor MODIS e este forneceu estimativas de área coerentes com os dados oficiais e a avaliação de acurácia indica uma precisão de 91% das áreas agrícolas.

De acordo com os resultados do mapeamento, verificou-se que os valores estimados (máscara) diferiram entre -6,14% e 22,40%, em relação aos dados oficiais. No entanto, essas estatísticas oficiais são realizadas a partir de pesquisas com produtores rurais e cooperativas e dados de financiamento agrícola, cujos valores são extrapolados, resultando em dados subjetivos e imprecisos (PINO, 2001; ANTUNES et al., 2012; JOHANN et al., 2012). Antunes et al. (2012) verificaram que as estimativas de órgãos oficiais como SEAB/DERAL são obtidas de forma subjetiva por meio de pesquisas de intenção de plantio realizadas por amostragens. Conforme Pino (2001), o IBGE utiliza informações municipais subjetivas baseadas em opiniões de agentes técnicos e econômicos, não permitindo uma análise quantitativa dos erros envolvidos, além de serem passíveis de manipulação.

Avaliando a acurácia das máscaras, em relação à referência (utilizando imagens de média resolução espacial – LISSIII e Landsat8), os resultados para a exatidão global e o Índice Kappa foram satisfatórios. Um fator que influencia no mapeamento são os tamanhos das áreas agrícolas, muitas vezes pequenas, confundindo o mapeamento, aumentando a

probabilidade da ocorrência de pixels mistos. Souza et al. (2015) mapearam culturas de soja e milho e concluíram que a cultura da soja foi melhor mapeada em relação ao milho, provavelmente devido às grandes áreas cultivadas no estado, o que facilita o mapeamento utilizando o sensor MODIS. O cultivo do milho é, geralmente, feito em áreas menores e mais dispersas, aumentando a probabilidade da ocorrência de pixels mistos.

Zhong et al. (2014), mapeando soja e milho no estado do Paraná, afirmaram que o efeito do pixel misto exerce relevante influência, em se tratando de precisão da classificação, e que esse efeito depende de diversos padrões de mistura de pixels entre as regiões do estado, logo, em regiões altamente cultivadas, muitos pixels mistos são dominados por culturas e foram classificados como áreas agrícolas devido a fortes sinais de vegetação das culturas, causando superestimação da área cultivada. Com isso, pode ocorrer o contrário, em regiões não muito cultivadas e/ou com pequenas áreas agrícolas, os pixels mistos podem ser dominados por áreas de pousio ou de outras lavouras, causando subestimação da área cultivada (LI et al., 2014). Outra possibilidade pode ser pela resolução espacial do sensor MODIS (250 m), pois, em pequenas áreas agrícolas (abaixo da resolução espacial do sensor), nota-se os efeitos da heterogeneidade espacial, desafios comuns para os estudos baseados no sensor MODIS de mudança da cobertura da terra (LI et al., 2014).

A utilização do MODIS favorece o mapeamento de áreas agrícolas, devido à resolução temporal, contudo, a dificuldade em mapear pequenas áreas utilizando esse sensor ainda gera alguns desacertos nos resultados finais, devido à resolução espacial das imagens. Novos estudos ainda precisam ser realizados a fim de minimizar esses entraves na utilização do sensor MODIS.

4 CONCLUSÕES

A utilização de imagens multitemporais do sensor MODIS mostrou-se uma ferramenta importante, permitindo o mapeamento do milho 2.^a safra e lavouras de inverno para as safras de 2012, 2013 e 2014, possibilitando a identificação, separação e o mapeamento de áreas para o estado do Paraná.

A comparação entre os valores estimados (máscaras) e os dados oficiais apresentaram resultados superestimados e subestimados das máscaras; a acurácia entre os dados da máscara e a referência foi satisfatória, evidenciando que a eficácia da metodologia utilizada.

O sensoriamento remoto é uma técnica importante que contribui para coleta ágil de informações e auxílio na complementação de pesquisas realizadas por instituições oficiais.

REFERÊNCIAS

ANTUNES, J. F. G.; MERCANTE, E.; ESQUERDO, J. C. D. M.; LAMPARELLI, R. A. C.; ROCHA, J. V. Estimativa de área de soja por classificação de imagens normalizada pela matriz de erros. **Pesquisa Agropecuária Brasileira**, Brasília, v.47, n.9, p.1288-1294, 2012.

ATZBERGER, C. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sensing**, Basel, v. 5, p. 949-981, 2013.

CASADY, G. M.; VAN LEEUWEN, W. J. D.; REED, B. C. Estimating winter annual biomass in the Sonoran and Mojave Deserts with satellite and ground based observations. **Remote Sensing**, Basel, v. 5, p. 909-926, 2013.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC Press, 1999. 160 p.

CRUSIOL, L. G. T.; NETO, O. C. P.; NANNI, M. R.; GUALBERTO, A. A. S.; FURLANETTO, R. H.; SILVA JUNIOR, C. A. Mapeamento de áreas agrícolas na safra de verão a partir de imagens *Landsat* frente aos dados oficiais. **Revista Agro@ambiente On-line**, Boa Vista RR, v. 10, n. 4, p. 287-298, 2016.

ESQUERDO, J. C. D. M. **Utilização de perfis multi-temporais do NDVI/AVHRR no acompanhamento da safra de soja no oeste do Paraná**. 2007. 186 f. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual de Campinas, Campinas. 2007.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, Amsterdam, v. 80, n. 1, p. 185-201, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Levantamento sistemático da produção agrícola**. 2016. Disponível em:<<http://www.sidra.ibge.gov.br>>. Acesso em 17 nov. 2016.

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

KOGAN, F.; KUSSUL, N.; ADAMENKO, T.; SKAKUN, S.; KRAVCHENKO, O.; KRYVOBOK, O.; SHELESTOV, A.; KOLOTII, A.; LAVRENYUK, A. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 192-203, 2013.

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

LI, L.; FRIEDL, M. A.; XIN, Q.; GRAY, J.; PAN, Y.; FROLKING, S. Mapping crop cycles in China using MODIS-EVI time series. **Remote Sensing**, Basel, v. 6, p. 2473-2493, 2014.

LOBELL, D. B.; ORTIZ-MONASTERIO, J. I.; SIBLEY, A. M.; SOHU, V. S. Satellite detection of earlier wheat sowing in India and implications for yield trends. **Agricultural Systems**, v. 115, p. 137-143, 2013.

MENGUE, V. P.; FONTANA, D. C. Assessment of spectral-temporal dynamics for mapping the main summer crops in the Rio Grande do Sul State. **Bragantia**, Campinas, v. 74, n.3, p. 331-340, 2015.

MERCANTE, E. **Dinâmica espectral da cultura da soja ao longo do ciclo vegetativo e sua relação com a produtividade na região do oeste do Paraná**. 2007. 241 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2007.

MERCANTE, E.; LIMA, L. E. P.; JUSTINA, D. D. D.; URIBE-OPAZO, M. A.; LAMPARELLI, R. A. C. Detection of soybean planted areas through orbital images based on culture spectral dynamics. **Revista Engenharia Agrícola**, Jaboticabal, v. 32, n. 5, p. 920-931, 2012.

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

PAN, Y.; LI, L.; ZHANG, J.; LIANG, S.; ZHU, X.; SULLA-MENASHE, D. Winter wheat area estimation from MODIS-EVI time series data using the Crop Proportion Phenology Index. **Remote Sensing of Environment**, Amsterdam, v. 119, p. 232-242, 2012.

PINO, F. A. Estimação subjetiva de safras agrícolas. **Informações Econômicas**, São Paulo, v. 31, n. 6, 2001.

POTGIETER, A. B.; LAWSON, K.; HUETE, A. R. Determining crop acreage estimates for specific winter crops using shape attributes from sequential MODIS imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 254-263, 2013.

SILVA JUNIOR, C. A.; FRANK, T.; RODRIGUES, T. C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n. 1, p. 44-53, 2014.

SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809-1824, 2015.

ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. Automated mapping of soybean and corn using phenology. **Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151-164, 2014.

ARTIGO 2: ESTIMATIVA DE ÁREAS DE MILHO 2.^a SAFRA E INVERNO, UTILIZANDO O ALGORITMO DE CLASSIFICAÇÃO SAM E IMAGENS DOS SATÉLITES TERRA E AQUA, PARA O ESTADO DO PARANÁ

Resumo: A importância da obtenção de tecnologias eficazes que quantifique a previsão de safras agrícolas, o conhecimento de informações a partir de áreas cultivadas que perdure durante todo o desenvolvimento da lavoura é importante para o planejamento econômico e de abastecimento interno nacional. Nesse contexto, o objetivo deste trabalho foi mapear as áreas com lavouras de inverno e milho 2.^a safra no estado do Paraná, a partir de séries temporais de imagens do sensor MODIS, satélites Terra e Aqua, para as safras de 2012 a 2014, utilizando o algoritmo de classificação SAM. As imagens de satélite foram obtidas da base de dados da Embrapa Informática, e fazem parte do sensor MODIS a bordo dos satélites Terra e Aqua, que possuem produtos, como os índices de vegetação com resolução espacial de 250 metros e resolução temporal de 8 dias. Para o atual estudo foram utilizadas imagens do Índice de vegetação melhorado (EVI), no período de todo o ciclo vegetativo das lavouras de inverno e milho 2.^a safra, para as safras de 2012, 2013 e 2014. As lavouras de inverno e milho 2.^a safra foram trabalhadas separadamente, assim, foi gerada uma composição colorida falsa cor. Logo, a imagem de máximo EVI de milho 2.^a safra e/ou lavouras de inverno foi inserida no canal R e a imagem de mínimo EVI de ambas culturas foi inserida nos canais G e B. O mapeamento foi realizado nas composições RGB, em que foi utilizado o algoritmo de classificação supervisionada *Spectral angle mapper* (SAM). A verificação da qualidade do mapeamento foi avaliada por meio de matrizes de erros, utilizando as análises de acurácia como a exatidão global e Coeficiente Kappa. A exatidão global para milho 2.^a safra e lavouras de inverno alcançou o valor mínimo aceitável de 85% e o coeficiente Kappa foi classificado como muito bom para lavouras de Inverno (2014) e classificado como excelente para as demais safras, bem como para o milho 2.^a safra nas três safras estudadas. Em comparação com os dados oficiais do IBGE, as máscaras de milho 2.^a safra foram superestimadas, em média 23,92% e as máscaras lavouras de inverno foram subestimadas, em média 30%.

Palavras-chave: Imagens multitemporais, MODIS, *Spectral angle mapper*.

1 INTRODUÇÃO

O conhecimento prévio da produção das principais *commodities* é importante para o controle eficiente das importações e exportações, tanto para a balança comercial como para o abastecimento do mercado interno. A busca de tecnologias capazes de quantificar a previsão de safras agrícolas e o conhecimento de informações a partir de áreas cultivadas que permaneça durante todo o ciclo vegetativo da lavoura.

O acompanhamento da produção agrícola e estatística oficial é realizado por meio de questionamentos aos produtores rurais e/ou cooperativas, bem como dados de financiamento agrícola, valores que são extrapolados, resultando em dados subjetivos e imprecisos (PINO, 2001; ANTUNES et al., 2012; JOHANN et al., 2012). Por isso, métodos alternativos estão sendo avaliados visando à redução de custos e da subjetividade na estimativa de safras, além de agilidade para aquisição de dados (ESQUERDO; ZULLO JÚNIOR; ANTUNES, 2009).

Nesse contexto, a utilização do sensoriamento remoto fornece informações sobre o uso e cobertura de áreas, monitoramento e mapeamento de culturas, na dinâmica dos sistemas agrícolas com elevada frequência de aquisição de dados, devido aos vários sensores orbitais (ESQUERDO; ZULLO JÚNIOR; ANTUNES, 2011). Assim, o uso de imagens de alta resolução temporal e moderada resolução espacial baseadas na análise do comportamento espectro-temporal de índices de vegetação produzem resultados mais ágeis e com baixo custo (MENGUE; FONTANA, 2015).

O sensor *Moderate resolution imaging spectroradiometer* (MODIS) tem sido bastante utilizado em estudos de áreas agrícolas e monitoramento da vegetação, em função da larga faixa de imageamento, resolução espectral e continuidade de imagens, desde o ano de 2000 (HUETE et al., 2002), bem como na distribuição gratuita das imagens ao usuário, na correção atmosférica e geométrica e na resolução temporal de 16 dias, minimizando problemas de cobertura de nuvens (JUNGES; FONTANA, 2011).

Diversos estudos têm sido realizados utilizando o sensor MODIS e seus índices de vegetação para mapeamento, monitoramento agrícola e vegetativo e estimativa de áreas e rendimentos (JOHANN et al., 2016; GRZEGOZEWSKI et al., 2016; GUSSO et al., 2014; SOUZA et al., 2015). Os estudos baseados nos índices de vegetação analisados pela dinâmica de séries temporais são vantajosos por minimizarem a variabilidade causada por fatores externos à vegetação, como também são indicadores de crescimento e vitalidade da vegetação, adequando-se para o monitoramento de áreas agrícolas e mudanças fenológicas (FONTANA; ALMEIDA; JACÓBSEN, 2007; RIZZI; RUDORFF, 2007; KUPLICH; MOREIRA; FONTANA, 2013).

A fim de solucionar a sobreposição de áreas de milho 2.^a safra e lavouras de inverno verificadas no estudo apresentado na seção anterior desta tese como Artigo 1, assim, fundamentado no trabalho realizado por Grzegozewski et al. (2016), o objetivo deste trabalho foi utilizar o algoritmo de classificação *Spectral angle mapper* (SAM) para caracterizar as áreas com as culturas de inverno (aveia, centeio, cevada, trigo e triticale) e milho 2.^a safra no estado do Paraná, Brasil, a partir de séries temporais dos satélites Terra e Aqua, para as safras de 2012 a 2014 e comparar as metodologias utilizadas nas duas etapas da pesquisa desta tese.

2 MATERIAL E MÉTODOS

As atividades foram realizadas no Laboratório de Topografia e Geoprocessamento (GeoLab) e no Laboratório de Estatística Aplicada (LEA) da Universidade Estadual do Oeste do Paraná – UNIOESTE, *campus* de Cascavel. Para a realização dos procedimentos foram utilizados os *softwares* *Environment for visualizing images* (ENVI 5.0) (*Exelis visual information solutions, Boulder, Colorado, Estados Unidos da América*) e *ARCGIS 10* (*Environmental Systems Research Institute, Redlands, California, Estados Unidos da América*). Na Figura 1 pode ser visualizado o fluxograma das atividades que foram realizadas para esta pesquisa.

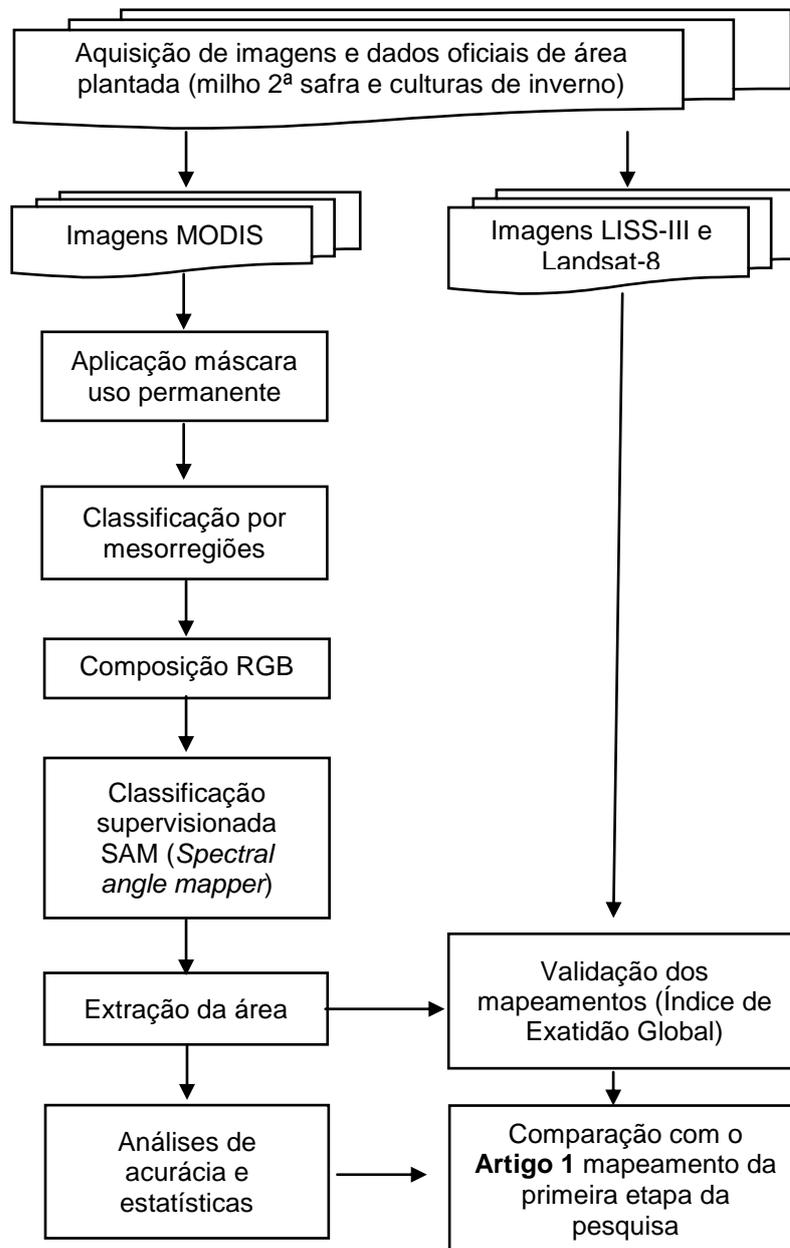


Figura 1 Fluxograma do trabalho.

2.1 Área de estudo e aquisição dos dados

O estudo compreende o estado do Paraná, região sul do Brasil, situado entre os paralelos 22°29'S e 26°43'S e os meridianos 48°2'W e 54°38'W e é constituído por 399 municípios. Como as datas de sementeiras diferem de acordo com as regiões por todo o estado, este foi então dividido em dez mesorregiões, segundo o IBGE (2016): Norte Pioneiro, Norte Central, Noroeste, Centro Sul, Centro Oriental, Centro Ocidental, Oeste, Sudoeste, Sudeste e Metropolitana de Curitiba (Figura 2).

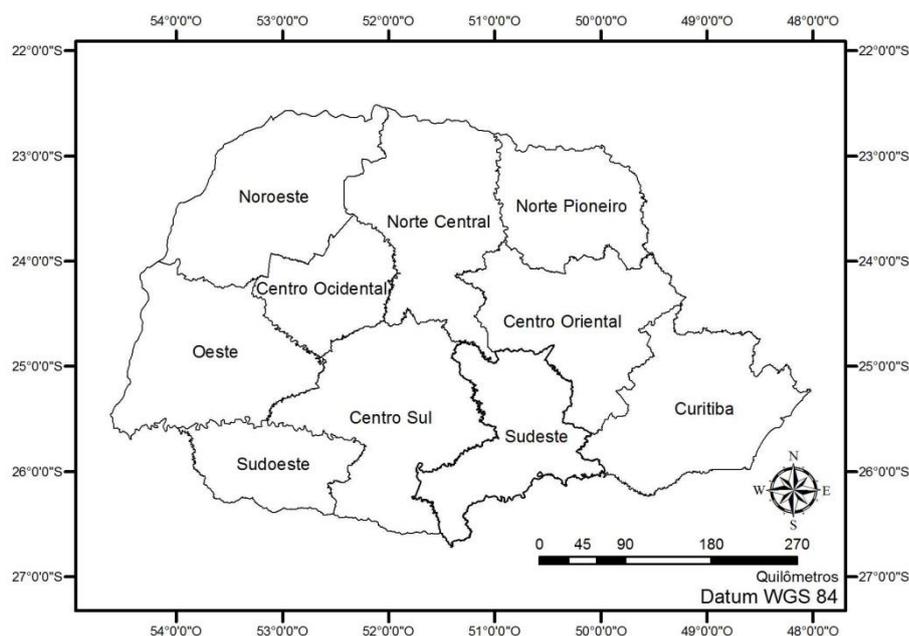


Figura 2 Mapa de localização das mesorregiões do estado do Paraná.

As imagens de satélite foram obtidas da base de dados da Embrapa Informática, e fazem parte do produto MOD13Q1.5 e MYD13Q1 do sensor MODIS a bordo dos satélites Terra e Aqua, respectivamente, que possuem produtos, como os índices de vegetação com resolução espacial de 250 metros e resolução temporal de 16 dias, ou seja, a resolução temporal utilizando os dois satélites foi de 8 dias. Para o estudo atual foram utilizadas imagens do *tile* h13v11 do índice de vegetação melhorado (EVI), no período de todo o ciclo vegetativo das lavouras de inverno e milho 2.^a safra, para as safras de 2012, 2013 e 2014. As imagens do satélite ResourceSat-1 (LISS-III), de média resolução espacial, foram obtidas da base de dados do Instituto Nacional de Pesquisas Espaciais (INPE) e as imagens do satélite *Landsat-8* foram obtidas da base de dados U.S. *Geological Survey* (USGS).

2.2 Seleção de pixels puros e extração dos perfis temporais de EVI

Para contemplar o ciclo das culturas estudadas, foram utilizadas imagens LISS-III e *Landsat-8*. Adaptando as técnicas de interpretação visual de imagens, segundo Mercante et al. (2012), e avaliando o perfil temporal foi possível identificar talhões de lavouras de inverno e milho 2.^a safra, que correspondem às dimensões dos pixels das imagens MODIS (250 x 250 m).

2.3 Composição colorida RGB

A composição colorida RGB foi realizada utilizando o *software* ENVI 5.0. As lavouras de inverno e milho 2.^a safra foram trabalhadas separadamente. Assim, para cada lavoura em estudo, foi gerada uma composição colorida falsa cor. Logo, a imagem de máximo EVI de milho 2.^a safra foi inserida no canal R e a imagem de mínimo EVI de ambas lavouras foi inserida nos canais G e B. Da mesma forma, foi feito para lavouras de inverno, resultando em uma composição colorida em que as áreas em vermelho representam as culturas estudadas (Figura 3).

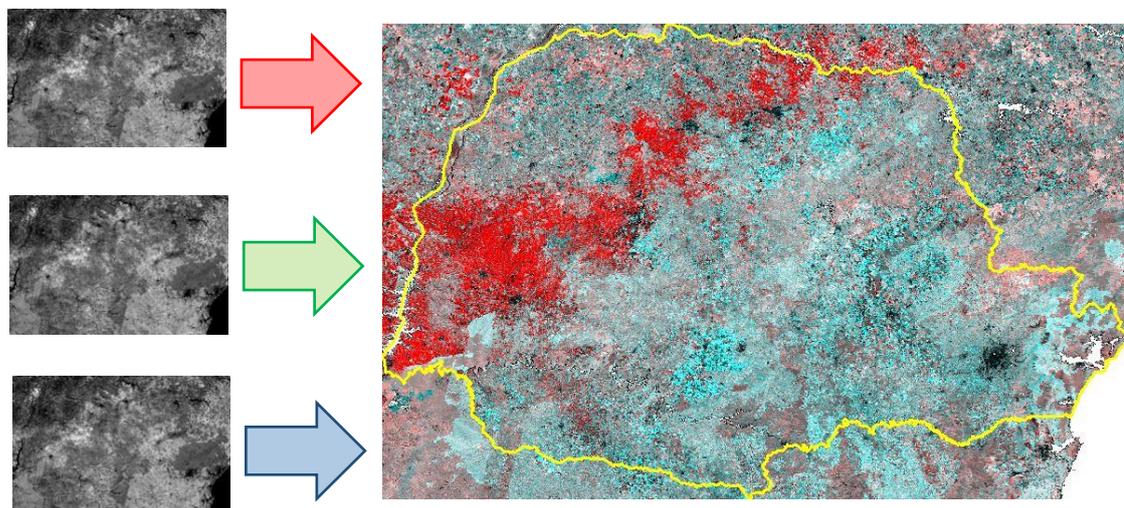


Figura 3 Exemplo da composição colorida utilizada.

2.4 Classificação supervisionada *Spectral angle mapper*

O mapeamento das culturas foi realizado nas composições RGB, utilizando o algoritmo de classificação supervisionada *Spectral angle mapper* (SAM). O SAM é um método de classificação que utiliza o ângulo entre as amostras de treinamento no espaço de n-dimensões para determinar os pixels para as classes, em que o algoritmo determina a proximidade espectral entre dois espectros e calcula o ângulo (vetores) entre eles (SULSOFT, 2014).

2.5 Índices de acurácia

Foram utilizados 400 pontos amostrais espalhados de forma aleatória sobre cada mapeamento, sendo 50% sorteados sobre o alvo de interesse (inverno ou milho 2.^a safra) e 50% fora do mapeamento (Figura 4). Este procedimento visou balancear a análise dos erros de omissão e inclusão da análise da acurácia. A partir da matriz de erros, foi calculada a exatidão global (EG), o índice Kappa, erros de inclusão e omissão.

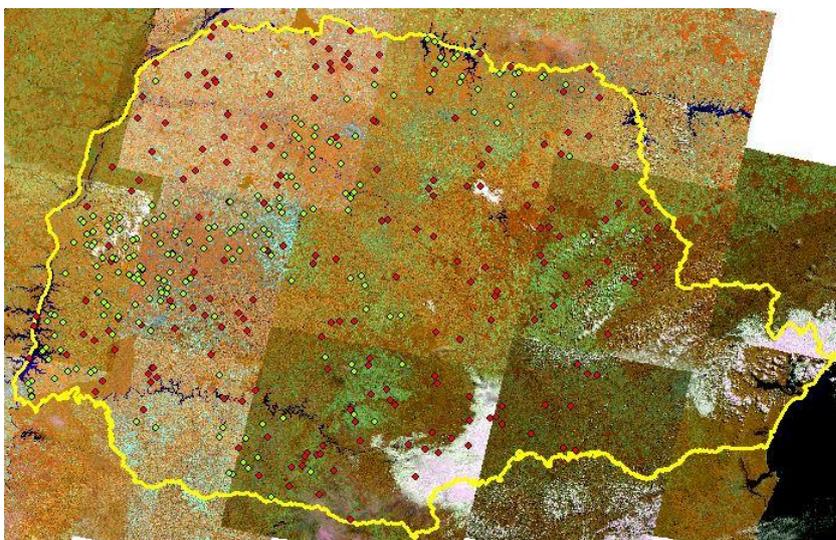


Figura 4 Imagens *Landsat 8* (2013), com distribuição dos pontos aleatórios (pontos verdes na cultura e vermelhos não cultura).

2.6 Análises de comparação de áreas

Os dados obtidos para as safras 2012, 2013 e 2014 pela extração de áreas das máscaras por mesorregiões foram comparados por meio do coeficiente de correlação por postos de Spearman com os dados oficiais da área colhida, disponibilizados pelo IBGE (2016). Os indicadores estatísticos erro médio (ME), raiz do erro médio quadrático (RMSE) e o coeficiente de concordância aprimorado de Willmott (d_r) também foram utilizados como parâmetros para avaliação das máscaras.

3 RESULTADOS E DISCUSSÃO

O milho 2.^a safra e as lavouras de inverno foram trabalhados separadamente, logo, as máscaras de milho 2.^a safra (Figura 5), correspondem às imagens (5a), (5b) e (5c) e as máscaras correspondentes das lavouras de inverno estão identificadas nas imagens (5d), (5e) e (5f).

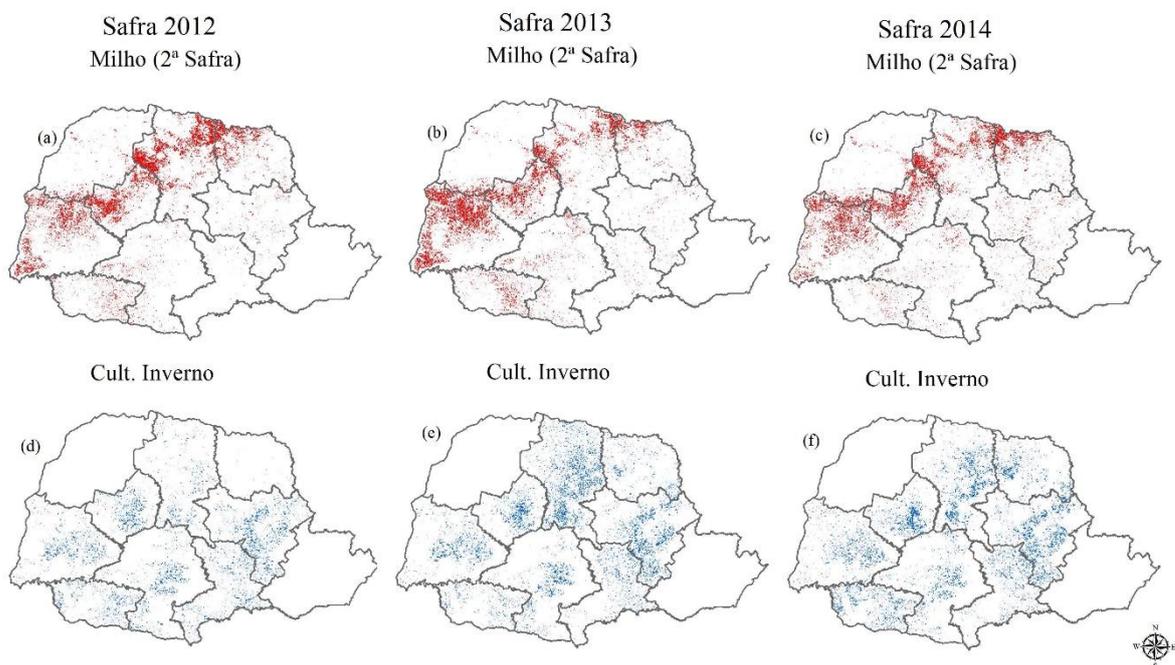


Figura 5 Distribuição espacial de milho 2.^a safra e lavouras de inverno no estado do Paraná.

Após a confecção das máscaras de cada lavoura estudada, foi realizada uma operação matemática para avaliar se as áreas das lavouras de inverno e milho 2.^a safra possuíam áreas em comuns. Na Tabela 1, observam-se as áreas de cada lavoura e as áreas sobrepostas. Ainda no mapeamento apresentado na secção anterior desta tese como Artigo 1, foi verificado que houve áreas de sobreposição de milho 2.^a safra e lavouras de inverno: 8%; 11,1% e 14,8% nos anos de 2012, 2013 e 2014, respectivamente, totalizando, em média, 408.962,5 hectares. Comparando os valores nas sobreposições utilizando o classificador SAM, constataram-se 979 hectares de sobreposições, em média, sendo que no ano de 2013 foi verificado o maior valor (2.256 ha).

Na verificação dos pixels puros, observaram-se que, em alguns talhões, havia o cultivo do milho 2.^a safra seguida de lavouras de inverno, justificando a sobreposição principalmente nas safras 2013 e 2014, conforme Figura 6. Observa-se no perfil espectro-temporal que, pela indicação 1, foi realizado o plantio em 10 de fevereiro do milho 2.^a safra e a colheita (2) foi em 10 de junho. Em seguida, foi realizado o plantio de inverno em 26 de junho e a colheita (3) foi realizada em 16 de outubro.

Tabela 1 Áreas que compõem as máscaras de milho 2.^a safra, lavouras de inverno e sobreposição de áreas, estado do Paraná

Lavouras	2012		2013		2014	
	Área (ha)	Sobreposição de áreas (%)	Área (ha)	Sobreposição de áreas (%)	Área (ha)	Sobreposição de áreas (%)
Milho 2. ^a safra	1.300.656	0,1%	1.309.056	1%	1.216.094	0,2%
Inverno	585.825	0,2%	938.175	1,5%	968.169	0,3%
Sobreposição de áreas	1.275	0,07%	14.100	0,63%	2.981	0,14%

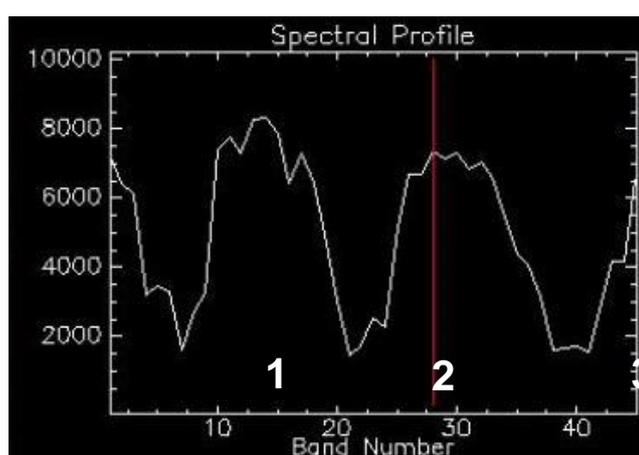


Figura 6 Perfil espectro temporal.

3.1 Análises de acurácia das máscaras

Os resultados das análises de acurácia como exatidão global e o índice Kappa, como também os erros de inclusão e omissão das máscaras confeccionadas a partir do índice de vegetação EVI podem ser verificadas na Tabela 2. Para a cultura de milho 2.^a safra, a exatidão global alcançou valores entre 92,50% e 96%; para lavouras de inverno, alcançou valores entre 87,7% e 93,7%, atingindo o valor mínimo aceito que é de 85% (FOODY, 2002). O Índice Kappa, segundo a classificação descrita por Landis e Koch (1977), para lavouras de inverno no ano de 2014 foi classificado como muito bom e para as demais a classificação foi excelente, logo, indica que a qualidade da classificação é semelhante à referência terrestre.

Tabela 2 Análise da acurácia das máscaras

Lavouras	Ano	EG	IK	EO		EI	
				Não Cultura	Cultura	Não Cultura	Cultura
Milho 2. ^a safra	2012	96,0%	0,92	3,0%	5,0%	4,9%	3,1%
	2013	93,0%	0,86	4,5%	9,5%	9,0%	4,7%
	2014	92,5%	0,85	3,0%	12,0%	11,0%	3,3%
Inverno	2012	93,7%	0,87	4,5%	8,0%	7,7%	4,7%
	2013	92,5%	0,85	3,5%	11,5%	10,6%	3,8%
	2014	87,7%	0,75	6,5%	18,0%	16,1%	7,3%

Nota: EG= Exatidão global; IK= Índice Kappa; EO= Erros de omissão; EI= Erros de inclusão.

Grzegozewski et al. (2016) observaram valores do IK de 0,84 e 0,79; 0,64 e 0,75 (safras 2012/13 e 2013/14) entre áreas estimadas de milho e soja, respectivamente, e a EG de 92,5% e 89,5%; 81,7% e 87,7% (safras 2012/13 e 2013/14), entre áreas estimadas de milho e soja, respectivamente, utilizando o algoritmo SAM em imagens multitemporais de EVI, sensor MODIS, juntamente com dados oficiais. Borges e Sano (2014) encontraram valor de EG de 95,33%, demonstrando uma alta correlação entre a distribuição espacial de soja obtida pelo algoritmo SAM em relação à distribuição espacial no campo.

Outra maneira de se avaliar a acurácia é por meio da análise das acurácias dos erros de inclusão (EI) e dos erros de omissão (EO) presentes na classificação (CONGALTON; GREEN, 1999). O EI variou entre 3,1% e 4,7%, ou seja, as amostras de milho 2.^a safra não foram classificadas pela máscara e para EO variou de 5% a 12%, indicando a proporção de amostras que foram excluídas da classe à qual pertenciam. O EI variou de 3,8% a 7,3%, representando as amostras de lavouras de inverno que a máscara classificou, erroneamente, como sendo lavouras de inverno e na verdade eram outros alvos, o EO variou de 8% a 18%, indicando a proporção de amostras que foram excluídas da classe à qual pertenciam.

Autores como Johann et al. (2012) estimaram e mapearam áreas com as culturas de soja e milho no estado do Paraná e verificaram EI variando de 3,5% a 7,5%, bem como EO variando de 4,6% a 7%. Souza et al. (2015) utilizaram o algoritmo SAM para mapear milho e soja para o estado do Paraná e constataram que os EI obtidos para o milho foram maiores, 40,3% em média, em relação aos erros obtidos para a soja. Borges e Sano (2014) mapearam o uso e a cobertura vegetal utilizando o algoritmo SAM e encontraram valores de EG 84%; IK classificado como muito bom; EO mais elevado para “campo sujo” 32,1% e EI de 33% para classe vegetação secundária.

3.2 Comparação das áreas mapeadas com os dados oficiais

A análise entre os dados da área estimada (máscara) e da área observada (IBGE) foi realizada para as três safras estudadas (Tabela 3). Para o milho 2.^a safra, as áreas obtidas pelas máscaras foram superiores às áreas oficiais do IBGE, em média 23,92% nas três safras, contudo, para lavouras de inverno, as áreas obtidas pela máscara foram inferiores às áreas oficiais do IBGE, em média 30%.

Tabela 3 Informações de área oficial (IBGE) e obtidas pelas máscaras (ha) de milho 2.^a safra e lavouras de inverno para o estado do Paraná

Lavouras	Variáveis	2012	2013	2014
Milho 2. ^a safra	Área IBGE (ha)	2.039.241	2.150.710	1.898.614
	Área Máscara (ha)	2.535.933	2.544.327	2.451.464
	Diferença (Máscara - IBGE)	496.692	393.617	552.850
	Diferença (%)	24,36%	18,30%	29,12%
Inverno	Área IBGE (ha)	935.230	1.125.265	1.510.138
	Área Máscara (ha)	585.057	938.044	968.076
	Diferença (Máscara - IBGE)	-350.173	-187.221	-542.063
	Diferença (%)	-37,44%	-16,64%	-35,89%

Fonte: IBGE (2016).

Na Tabela 4, observam-se as análises estatísticas calculadas entre os dados das máscaras e os dados oficiais. Analisando o ME, verificou-se que a área obtida pela máscara de milho 2.^a safra foi superestimada, em média, 1.205,65 ha e foi subestimada, em média, 901,80 ha nas safras de inverno. A RMSE foi calculada para verificar as divergências entre as áreas oficiais e as áreas obtidas pelo mapeamento e as menores divergências foram verificadas para as lavouras de inverno (em média 3.007,6), podendo ser constatado pelo

índice de concordância (em média, $dr = 0,75$) junto com o coeficiente de correlação ($r_s = 0,80$, em média).

Tabela 4 Estatísticas obtidas entre os dados de área oficial (ha) e as obtidas pelas máscaras (ha) de milho 2.^a safra e lavouras de inverno para o estado do Paraná

Lavouras	Estatísticas	2012	2013	2014
Milho 2. ^a safra	ME	1.244,84	986,51	1.385,59
	RMSE	18.039,3	18.189	18.122,1
	dr	0,53	0,52	0,49
	r_s	0,46	0,43	0,44
Inverno	ME	- 877,63	-469,22	-1.358,55
	RMSE	2.936,3	2.857,6	3.229,1
	dr	0,73	0,77	0,77
	r_s	0,73	0,77	0,89

Notas: Erro médio; RMSE: Raiz do erro médio quadrático; dr: Coeficiente de concordância aprimorado de Willmott; r_s : Coeficiente de correlação por postos de Spearman.

Junges, Fontana e Pinto (2013) verificaram áreas de cereais de inverno subestimadas em 38,5%, em relação aos dados oficiais no município de Ijuí (RS) (2003), contudo, no município de Santa Rosa (RS), no ano de 2001, a superestimação das áreas de cereais de inverno foi de 45,2%. Grzegozewski et al. (2016) utilizaram o algoritmo SAM para mapear áreas de soja e milho no estado do Paraná e verificaram superestimação média de 16% da máscara de milho e soja, em relação aos dados oficiais. Mengue e Fontana (2015) constataram valores de EG (90,56%) e IK (0,66) para arroz irrigado e EG (85%) e IK (0,61) para soja, quando mapearam culturas de verão no Rio Grande do Sul, a partir do comportamento imagens espectro-temporal de índices de vegetação.

Os resultados do mapeamento foram satisfatórios, pois os índices de acurácia estão dentro dos padrões aceitáveis (segundo diversos autores), embora tenha sido verificada a superestimação de 23,92%, em média, para o milho 2.^a safra e subestimação de 30%, em média, para o cultivo de inverno. Lobell e Asner (2004) estudaram a importância da heterogeneidade de subpixels em sistemas de cultivo no México e verificaram que a raiz do erro médio (RSME) diminuiu à medida que o tamanho da área analisada aumentava. Souza et al. (2015) relataram que a classificação supervisionada requer amostras que representem pixels para cada classe de interesse; a inserção de pixels que causam confusão espectral pode levar a erros na classificação.

A sobreposição de áreas entre as lavouras de inverno e milho 2.^a safra foram reduzidas em relação ao mapeamento apresentado na seção do Artigo 1, constatando que a associação das imagens multitemporais MODIS e o classificador SAM são eficientes para o mapeamento de lavouras agrícolas. O milho 2.^a safra foi melhor mapeado, segundo as análises de acurácia, provavelmente, pelo fato de as áreas cultivadas serem de tamanho maior, facilitando o mapeamento, pelo fato de o sensor MODIS possuir uma resolução

espacial de 250 metros. Junges et al. (2013) afirmaram que, na utilização de imagens MODIS, as culturas agrícolas abaixo da área mínima capturada pelo sensor (6,25 ha) podem não ser identificadas, devido a não uniformidade na maioria das imagens resultando na mistura espectral, ou seja, a resposta espectral do pixel é o resultado da combinação das respostas espectrais dos alvos que o compreendem.

Santos et al. (2014) justificaram a superestimação das áreas de soja pela resolução espacial das imagens MODIS, devido à agregação de pequenas áreas de soja vizinhas a grandes áreas de soja e a subestimação das áreas, justifica-se pela presença de pequenas áreas de soja que o sensor MODIS não pode detectar, em virtude da resolução espacial das imagens de 250 m. Mesmo assim, dados do sensor MODIS e seus produtos têm sido largamente empregados, justificando o baixo custo de aplicação, uma vez que as imagens MODIS são disponibilizadas gratuitamente aos usuários, além da facilidade de implementação em rotinas de processamento de imagens (JUNGES; FONTANA, 2009).

Souza et al. (2015), Grzegozewski et al. (2016), Yi, Shimabukuro e Quintanilha (2007) analisaram a associação das imagens do sensor MODIS e a utilização do classificador SAM e afirmaram que essa metodologia é viável, pela utilidade em se identificar, classificar e mapear culturas agrícolas, visando o monitoramento a partir de séries temporais.

A escassez de estudos que contabilizassem informações sobre o milho 2.^a safra e lavouras de inverno no estado do Paraná começaram a ser sanadas a partir desse trabalho. A utilização dessa metodologia, aplicada para separação do milho 2.^a safra e lavouras de inverno, auxiliou no mapeamento e abriu precedentes para que outros trabalhos possam ser realizados a fim de melhorar e contribuir com informações necessárias para o mapeamento dessas lavouras importantes para a economia do estado.

4 CONCLUSÕES

A utilização de imagens multitemporais do sensor MODIS/ EVI, aliada à utilização do algoritmo SAM mostrou-se uma ferramenta importante, permitindo a identificação, separação e o mapeamento mais acurado do milho 2.^a safra e lavouras de inverno para safras de 2012, 2013 e 2014 no estado do Paraná, proporcionando uma metodologia prática, de rápida implementação e com baixo custo de execução.

A comparação entre os valores estimados (máscaras) e os dados oficiais apresentou resultados superestimados das áreas de milho 2.^a safra e subestimados das áreas de

lavouras de inverno. A acurácia entre os dados da máscara e a “referência” foi classificada como excelente, evidenciando que a metodologia utilizada foi eficiente.

REFERÊNCIAS

ANTUNES, J. F. G.; MERCANTE, E.; ESQUERDO, J. C. D. M.; LAMPARELLI, R. A. C.; ROCHA, J. V. Estimativa de área de soja por classificação de imagens normalizada pela matriz de erros. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p. 1288-1294, 2012.

BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, Curitiba, v. 20, n. 3, p. 526-547, 2014. Disponível em: <<http://dx.doi.org/10.1590/S1982-21702014000200030>>. Acesso em: 2 jan. 2017.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC Press, 1999. 160 p.

ESQUERDO, J. C. D. M.; ZULLO JÚNIOR, J.; ANTUNES, J. F. G. Uso de perfis multitemporais de NDVI/AVHRR no acompanhamento da cultura da soja no oeste do Paraná. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14, 2009, Natal/RN, **Anais...** São José dos Campos: INPE, 2009.

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. **International Journal of Remote Sensing**, v.32, p. 3711-3727, 2011.

FONTANA, D. C.; ALMEIDA, T. S.; JACÓBSEN, L. O. Caracterização da dinâmica temporal dos Campos do Rio Grande do Sul por meio de imagens AVHRR/NOAA. **Revista Brasileira de Agrometeorologia**, v.15, p.69-83, 2007.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, Amsterdam, v. 80, n. 1, p. 185-201, 2002.

GRZEGOZEWSKI, D. M.; JOHANN, J. A.; URIBE-OPAZO, M. A.; MERCANTE, E.; COUTINHO, A. C. Mapping of the soya bean and corn crops in the State of Paraná using EVI images from the MODIS sensor. **International Journal of Remote Sensing**, v. 37, n.6, p. 1257-1275, 2016.

GUSSO, A.; ARVOR, D.; DUCATI, J.R.; VERONEZ, M. R.; SILVEIRA JUNIOR, L. G. Assessing the MODIS crop detection algorithm for soybean crop area mapping and expansion in the Mato Grosso State, Brazil. **The Scientific World Journal**. 9 p. 2014. Disponível em: <<http://dx.doi.org/10.1155/2014/863141>>. Acesso em: 27 dez. 2016.

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 Sensing of Environment**, Amsterdam, v. 83, p. 195-213, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Levantamento sistemático da produção agrícola**. 2016. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em 17 nov. 2016.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital MODIS na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná – Brasil. **Engenharia Agrícola**, Jaboticabal, v. 36, n. 1, p. 126-142, 2016.

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

JUNGES, A. H.; FONTANA, D. C. Desenvolvimento das culturas de cereais de inverno no Rio Grande do Sul por meio de perfis temporais do índice de vegetação por diferença normalizada. **Ciência Rural**, Santa Maria, v. 39, n. 5, p.1349-1355, 2009.

JUNGES, A. H.; FONTANA, D.C. Modelo agrometeorológico-espectral de estimativa de rendimento de grãos de trigo no Rio Grande do Sul. **Revista Ceres**, Viçosa, v. 58, n. 1, p. 9-16, 2011.

JUNGES, A. H.; FONTANA, D. C.; PINTO, D. G. Identification of croplands of winter cereals in Rio Grande do Sul State, Brazil, through unsupervised classification of normalized difference vegetation index images. **Engenharia Agrícola**, Jaboticabal, v. 33, n. 4, p. 883-895, 2013.

KUPLICH, T. M.; MOREIRA, A.; FONTANA, D. C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.17, n.10, p.1116-1123, 2013.

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

LOBELL, D. B.; ASNER, G. P. Cropland distributions from temporal a mixing of MODIS data. **Remote Sensing of Environment**, Amsterdam, v. 93, p. 412-422, 2004.

MENGUE, V. P.; FONTANA, D. C. Assessment of spectral-temporal dynamics for mapping the main summer crops in the Rio Grande do Sul State. **Bragantia**, Campinas, v. 74, n.3, p. 331-340, 2015.

MERCANTE, E.; LIMA, L. E. P.; JUSTINA, D. D. D.; URIBE-OPAZO, M. A.; LAMPARELLI, R. A. C. Detection of soybean planted areas through orbital images based on culture spectral dynamics. **Revista Engenharia Agrícola**, Jaboticabal, v. 32, n. 5, p. 920-931, 2012.

PINO, F. A. Estimação subjetiva de safras agrícolas. **Informações Econômicas**, São Paulo, v. 31, n. 6, 2001.

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

SANTOS, J. S.; FONTANA, D. C.; SILVA, T. S. F.; RUDORFF, B. F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n. 1, p. 54-63, 2014.

SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v.36, n.7, p.1809-1824, 2015.

SULSOFT – PROCESSAMENTO DE DADOS. **Guia do ENVI em português**. Versão 5.1. Porto Alegre. Disponível em:< <http://www.envi.com.br> >. Acesso em: jul. 2014.

YI, J. L. R.; SHIMABUKURO, Y. E.; QUINTANILHA, J. A. Identificação e mapeamento de áreas de milho na região Sul do Brasil utilizando imagens MODIS. **Engenharia Agrícola**, Jaboticabal, v. 27, n. 3, p. 753-763, 2007.

CONSIDERAÇÕES FINAIS

O uso de dados utilizando o índice de vegetação EVI do sensor MODIS, associado ao algoritmo de classificação SAM, proporcionou o mapeamento com a identificação, separação e estimativa das áreas cultivadas com as lavouras de inverno e milho 2.^a safra, para o estado do Paraná, torna-se uma alternativa eficaz, objetiva, ágil e de baixo custo de implementação, podendo ser utilizada por órgãos oficiais responsáveis pelas estatísticas de produção agrícola.

Em algumas regiões do estado, as áreas agrícolas são menores que a área mínima capturada pelo sensor MODIS, dificultando a identificação das lavouras, induzindo, assim, o usuário ao erro. Assim, para trabalhos futuros, sugere-se o desenvolvimento de estudos que possam ajustar melhor essa metodologia, visando às lavouras de inverno, principalmente na região Sul do Brasil.