



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

sid.inpe.br/mtc-m21b/2015/02.12.20.29-TDI

DETECÇÃO E AVALIAÇÃO DE SECA AGRONÔMICA ATRAVÉS DA ANÁLISE DE SÉRIES TEMPORAIS DE DADOS MODIS E PERSIANN

Denis Araujo Mariano

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Maurício Alves Moreira, aprovada em 16 de março de 2015.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3HU5BP5>>

INPE
São José dos Campos
2015

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

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

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

Membros:

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

Dr. Amauri Silva Montes - Coordenação Engenharia e Tecnologia Espaciais (ETE)

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

Dr. Joaquim José Barroso de Castro - Centro de Tecnologias Espaciais (CTE)

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

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

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

BIBLIOTECA DIGITAL:

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

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

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

EDITORAÇÃO ELETRÔNICA:

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

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



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

sid.inpe.br/mtc-m21b/2015/02.12.20.29-TDI

DETECÇÃO E AVALIAÇÃO DE SECA AGRONÔMICA ATRAVÉS DA ANÁLISE DE SÉRIES TEMPORAIS DE DADOS MODIS E PERSIANN

Denis Araujo Mariano

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Maurício Alves Moreira, aprovada em 16 de março de 2015.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3HU5BP5>>

INPE
São José dos Campos
2015

Dados Internacionais de Catalogação na Publicação (CIP)

Mariano, Denis Araujo.

M337d Detecção e avaliação de seca agrônômica através da análise de séries temporais de dados MODIS e PERSIANN / Denis Araujo Mariano. – São José dos Campos : INPE, 2015.
xxiv + 86 p. ; (sid.inpe.br/mtc-m21b/2015/02.12.20.29-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.
Orientador : Dr. Maurício Alves Moreira.

1. Seca agrônômica. 2. MODIS. 3. PERSIANN. 4. Séries temporais. 5. Transformada wavelet. I.Título.

CDU 528.854:632.112

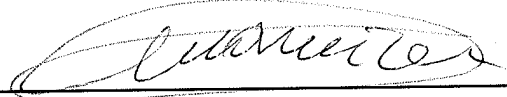


Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

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

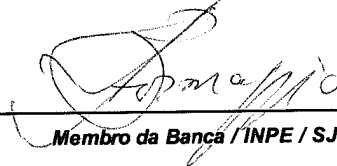
Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Mestre** em
Sensoriamento Remoto

Dr. Mauricio Alves Moreira



Presidente / Orientador(a) / INPE / SJCampos - SP

Dr. Antônio Roberto Formaggio



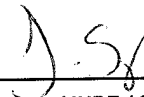
Membro da Banca / INPE / SJCampos - SP

Dra. Ieda Del' Arco Sanches



Membro da Banca / INPE / São José dos Campos - SP

Dr. Lênio Soares Galvão



Membro da Banca / INPE / SJCampos - SP

Dr. Jurandir Zullo Júnior



Convidado(a) / UNICAMP / Campinas - SP

Este trabalho foi aprovado por:

() maioria simples

() unanimidade

Aluno (a): **Denis Araujo Mariano**

São José dos Campos, 16 de Março de 2015

"Furious activity is no substitute for understanding."

H. H. WILLIAMS
in *Speaking of Science*, 2000

Dedico à família e amigos. Nem menos, nem mais.

AGRADECIMENTOS

Agradeço ao Instituto Nacional de Pesquisas Espaciais pelos maravilhosos estrutura e colaboradores. De forma mais pessoal, agradeço aos meus professores do INPE, Maurício Moreira, José Epiphânio, Flávio Ponzoni, Antônio Formaggio, Lênio Galvão e Bete Moraes, *tutti buona gente*. Vai um *danke!* para o Clement Atzberger, o qual me deu umas ideias boas sobre o trabalho.

Embora eu dedique este trabalho a minha família, tenho certeza que não lerão nada além dos agradecimentos, porém, fiz minha parte! *Mille grazie* à pessoinha Juju, que me impediu de trabalhar nos fins de semana. Como estamos falando de trabalho, melhor agradecer aos amigos que ajudaram, o William Foschiera com o Python, ao Jorge Jorge mestre cervejeiro, o Everton Baby, o Fabinho da terra dos edredons, o Édipo geomorfologista revelação de 2014, Vinícius que está tirando de malandro no Rio, os bixos de 2014 que são o puro creme do milho. Um agradecimento muito especial vai para o Sr. Sabil Mandala, o gajo de Tête - Moçambique, colecionador de *Plasmodium vivax*, enfim, um cara que minha família e eu admiramos muito.

Agradeço também aos amigos que só atrapalharam, ou seja, todos aqueles de Piracicaba, lá da Vaktôa... gosto de vocês porque não valem nada. Como me apego facilmente às coisas sem valor, vocês estão no meu coração.

Tem um cara que gostaria muito que apreciasse este trabalho, mas espero que daqui a muitos anos eu possa mostrar a ele tudo que aprendi e vivi. Mano, eu cresci muito, estou feliz, você sabe, agente se vê por aí.

Como dinheiro não vem em primeiro lugar, mas mesmo assim é importante, agradeço à CAPES pela ajuda financeira a mim e a meus colegas, com os quais sempre pude rachar a conta!

Se me esqueci de alguém, é porque não lembrei, agradeço mesmo assim.

RESUMO

Eventos de seca causam grande prejuízo para a agricultura brasileira, sendo a região Sul frequentemente castigada por esse fenômeno. Essas ocorrências prejudicam gravemente a cadeia agrícola nacional, o que causa oscilação de preços, onera produtores e empresas. Tais ocorrências evidenciam a necessidade de sistemas para monitorar e quantificar a seca com informações precisas e espacializadas. O presente trabalho objetivou mensurar em termos de intensidade e abrangência os eventos de seca agrônômica ocorridos no Paraná para as safras de verão de 2002 a 2013, considerando milho e soja. Foram utilizados dados dos espectros visível, infravermelho e termal do *Moderate Resolution Imaging Spectroradiometer* (MODIS) e de precipitação estimada por sensoriamento remoto (SR) oriundos do produto *Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks* (PERSIANN). Vários índices de vegetação (IV) foram avaliados, tendo estes em geral apresentado maior correlação com a precipitação de outubro para os anos secos e janeiro para os normais, indicando que, para o desempenho da vegetação, estes meses foram os mais relevantes para os respectivos tipos de anos. Foram criadas linhas de base para cada IV, considerando a mediana histórica para cada data fenológica. Os IVs foram então avaliados para caracterização da seca, tendo o *Land Surface Water Index* (LSWI) se destacado, apresentando maior correlação com métricas de precipitação e produtividade agrícola. Foram estudadas as relações entre o LSWI e *Land surface temperature* (LST), sendo detectada uma relação inversa entre as variáveis. Foram analisadas as transformadas de *wavelet* [wavelet transform (WT)] para cada variável e utilizado os métodos da WT cruzada (XWT) e coerência de WT (WCT). Não foi verificada relação de causa-efeito entre as variáveis, mas sim, uma relação de espelho, ou seja, outros fatores governam o comportamento de LSWI e LST. Segundo a literatura, o principal fator é a umidade do solo, a qual é bem correlacionada com o LSWI. Por fim, as diferenças acumuladas entre LSWI de cada safra e sua linha de base (LSWI-dif) foram espacializadas na forma de mapas para cada ano-safra, o que visualmente foi bastante coerente com os mapas de precipitação acumulada. O método de mensuração de seca agrônômica proposto se mostrou eficiente e potencialmente aplicável para fins de monitoramento agrícola, tendo como maior limitação a resolução espacial dos dados utilizados.

Palavras-chave: Seca agrônômica. MODIS. PERSIANN. Séries temporais. Transformada wavelet.

AGRICULTURAL DROUGHT DETECTION AND ASSESSMENT THROUGH MODIS AND PERSIANN TIME-SERIES DATA ANALYSIS

ABSTRACT

Drought events strike Brazilian agriculture causing yield losses, being the south region often stricken by this phenomenon. These occurrences lead to negative impacts in the agricultural chain by causing commodities prices fluctuation and hampering farmers and companies finances condition. A need for a system for monitoring and retrieving drought on time and spatialized information regarding the agriculture emerges in this context. The present study aimed at measuring and quantify the intensity and geographical spreading of the agricultural drought phenomena occurred in Paraná state between the 2002 and 2013 summer seasons, considering maize and soybean crops. Remote sensed reflectance and thermal data from Moderate Resolution Imaging Spectroradiometer (MODIS) sensors and precipitation from the Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks (PERSIANN) were used as input for the methods. Several vegetation indices (VI) were tested and generally, they were better correlated to accumulated precipitation in October for dry years and January for normal years, showing that these months are crucial for the vegetation condition regarding these kind of years. Using phenology and historical data, baselines for each index were created in a median basis. The VIs were then analyzed in order to better assess the agricultural drought occurrences being the Land Surface Water Index (LSWI) the most well suited for this task. LSWI showed better correlation to precipitation metrics and estimated yield. The relationships between LSWI and Land Surface Temperature (LST) were studied as well, showing an inverse correlation between them. The wavelet transform (WT) were used in each variable and the cross WT (XWT) and WT coherence (WCT) methods were applied for testing these relations. Cause-effect relationships were not found, instead, LST and LSWI simply mirrored each other, this means that other variables govern the LST and LSWI behavior, according to the literature, the main factor is the soil moisture which is also well correlated to LSWI. Finally, the accumulated differences between LSWI for each season and the baseline (*LSWI-dif*) were spatialized and mapped being possible to visualize the coherence between precipitation and *LSWI-dif* maps. The proposed method proved itself on being well suitable for agricultural monitoring needs, however, the main hurdle was the spatial resolution of the input data.

Keywords: Agricultural drought. MODIS. PERSIANN. Time series. Wavelet transform.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Índice de área foliar aproximado para os ciclos de milho e soja. No eixo das abscissas está representado o tempo na escala de dias julianos. A Figura (A) exhibe o comportamento de milho irrigado e de sequeiro, enquanto que a Figura (B) apresenta o mesmo para a soja.	5
2.2 Tipos de seca e seus impactos.	6
3.1 Região de estudo e mapa base de soja e milho para o ano-safra 2011/2012.	23
3.2 Classes texturais do solo e potencial agrícola.	24
3.3 Comportamento temporal hipotético de um índice de vegetação típico. A linha cheia corresponde ao IV, a pontilhada refere-se à magnitude e direção da variação do IV. Os pontos indicam os momentos de transição, os quais são coincidentes em ambas as curvas. O 1° ponto a partir da esquerda é o início da fase vegetativa, o 2° é aproximadamente o momento em que a planta atinge seu máximo de atividade fotossintética até o 3°, a partir do qual, inicia-se a senescência, o 4° ponto indica a fase de dormência, onde a atividade fotossintética aproxima-se a zero.	34
4.1 Mapa de precipitação acumulada anual média (mapa maior) e precipitação acumulada de setembro a janeiro (mapas menores). A legenda da direita inferior é referente aos mapas pequenos.	37
4.2 Séries temporais de SPI3 suavizadas por um filtro de MA_3	38
4.3 SPI3 acumulado de setembro a janeiro de cada ano-safra.	39
4.4 NDVI médio e desvio padrão por mesorregiões para as safras de 2002/2003 a 2005/2006.	43
4.5 NDVI médio e desvio padrão por mesorregião para as safras de 2006/2007 a 2009/2010.	43
4.6 NDVI médio e desvio padrão por mesorregiões para as safras de 2010/2011 a 2012/2013.	44
4.7 Função de autocorrelação do NDVI para a mesorregião Centro Ocidental. A região sombreada compreende o intervalo de confiança de 95 %.	45

4.8	Espectro de potência da transformada Wavelet (Morlet) para a série temporal de NDVI da microrregião OP-Toledo. A Figura A apresenta a série temporal original normalizada por $1/\sigma^2$ em preto e a WT em cinza. A Figura B apresenta o espectro de potência para a WT, a área não hachurada é delimitada pelo cone de influência; o contorno preto indica o setor do espectro de potência onde o nível de confiança de 95% é satisfeito. A Figura C indica o nível de potência para a toda a série, por isso chamado <i>Global Wavelet Spectrum</i> . A Figura D corresponde ao <i>2-8 year scale-averaged power</i> , demonstrando o comportamento da variância média ao longo do tempo.	46
4.9	Linhas de base para os índices de vegetação apresentadas em suas escalas originais.	48
4.10	Matriz de correlação de Pearson entre as linhas de base dos índices de vegetação. As estrelas indicam os níveis de confiança de 85%, 90% e 95% para *, ** e ***, respectivamente.	49
4.11	Comportamento da vegetação descrito pelos IVs na microrregião OP-Cascavel para o ano 2010 com SPI_{soma} de $-2,04$	52
4.12	Matriz de correlação de Pearson entre diferenças entre IVs de safra e base <i>versus</i> indicadores de SPI3.	54
4.13	Matriz de correlação de Pearson das diferenças entre IVs de safra e base <i>versus</i> indicadores de SPI3 para as mesorregiões COCP e OP.	55
4.14	Matriz de correlação de Pearson das diferenças entre IVs e safra <i>versus</i> indicadores de precipitação acumulada.	57
4.15	Matriz de correlação de Pearson das diferenças entre IVs e safra <i>versus</i> indicadores de precipitação acumulada para os anos mais secos da série (2003, 2004, 2005, 2007, 2008 e 2012).	58
4.16	Comportamento dos IVs para a microrregião de OP-Toledo no ano de 2005.	59
4.17	Matrizes de correlação de Pearson entre diferenças entre IVs e safra <i>versus</i> indicadores de produtividade estimada (IBGE) de soja e milho para as mesorregiões COCP e OP. A Figura (A) refere-se aos anos secos, já a (B), a todos os anos.	61
4.18	Regressões lineares entre os IVs e LST para a microrregião OP-Toledo.	63
4.19	Correlação cruzada entre NDVI-LST e LSWI-LST para a microrregião de OP-Toledo.	65
4.20	WT do LSWI e LST para a região de OP-Toledo. A escala representa a variância normalizada (potência) entre as séries.	66

4.21	XWT e WCT entre LSWI e LST para a microrregião OP-Toledo. A Figura (A) refere-se à XWT, sua escala é a da esquerda e representa a covariância. A Figura (B) refere-se à WCT e sua escala é a da direita, representando a covariação. Para ambas figuras, as setas apontadas para cima (norte) indicam que a relação está em fase (causa-efeito), sendo o contrário apontado para baixo (sul), ou seja, anti-fase (espelho). Setas apontando para a direita (leste) indicam que a relação LSWI/LST é positiva, enquanto que setas apontando para a esquerda indicam o contrário, ou seja, LSWI e LST tem relação inversa.	67
4.22	Mapas de <i>LSWI-dif</i> para a região de estudo de 2002/2003 a 2005/2006. . .	68
4.23	Mapas de <i>LSWI-dif</i> para a região de estudo de 2006/2007 a 2013/2014. . .	69

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Área plantada de soja em 10^3 <i>hectares</i> (IBGE) considerando safra e safrinha (IBGE, 2015a)	3
2.2 Área plantada de milho em 10^3 <i>hectares</i> (IBGE) apenas para a safra de verão (IBGE, 2015b).	4
2.3 Graus de severidade associados ao SPI.	8
2.4 Índices de vegetação	12
3.1 Área de agricultura mapeada e <i>pixels</i> utilizados nas análises	26
3.2 Bandas do MODIS e algumas especificações técnicas.	28
3.3 Resumo dos dados orbitais utilizados.	29
4.1 Resultados dos testes de Mann-Kendall para detecção de tendências	41
4.2 Correlação de Pearson para as séries de NDVI por mesorregião.	42
4.3 Média dos resultados da regressão entre IVs e LST por IV.	63
4.4 Média dos resultados das regressões entre IVs (LSWI, NDI7 e NDVI) e LST por microrregião.	64

LISTA DE ABREVIATURAS E SIGLAS

ACF	– Autocorrelation Function
ANA	– Agência Nacional de Águas
AVHRR	– Advanced Very High Resolution Radiometer
CC	– Carrying capacity
COCP	– Centro-Ocidental Paranaense
CWT	– Coherence of Wavelet transform
CONAB	– Companhia Nacional de Abastecimento
EOS	– End of the season
ETM+	– Enhanced Thematic Mapper Plus
EVI	– Enhanced Vegetation Index
GESER	– Grupo de Estudos em Seguros e Riscos
GOES	– Geostationary Operational Environmental System
GPP	– Gross primary production
IBGE	– Instituto Brasileiro de Geografia e Estatística
IRI	– International Research Institute for Climate and Society
IV	– Índice de vegetação
LAI	– Leaf area index
LST	– Land surface temperature
LSWI	– Land Surface Water Index
MA	– Moving average
MAE	– Mean absolute error
MM	– Moving median
MODIS	– Moderate Resolution Imaging Spectroradiometer
NCP	– Norte Central Paranaense
NDI7	– Normalized Difference Water Index 7
NDVI	– Normalized Difference Vegetation Index
NDWI	– Normalized Difference Water Index
NIR	– Near infrared
NP	– Norte Pioneiro
OP	– Oeste Paranaense
PCA	– Principal Component Analysis
PCI	– Precipitation Condition Index
PERSIANN	– Precipitation Estimation from Remotely Sensed Information – Using Artificial Neural Networks
R	– Red
SDCI	– Scaled Drought Condition Index
SDI	– Synthesized Drought Index
SIG	– Sistema de Informações Geográficas
SNR	– Signal to noise ratio
SOS	– Start of the season

SPI	–	Standardized Precipitation Index
SR	–	Sensoriamento remoto
SWIR	–	Shortwave infrared
TIR	–	Thermal infrared
TM	–	Thematic Mapper
TRMM	–	Tropical Rainfall Measuring Mission
VCI	–	Vegetation Condition Index
VHI	–	Vegetation Health Index
VIR	–	Visible-Infrared
WCT	–	Wavelet coherence transform
WS	–	Whittaker smoother
WT	–	Wavelet transform
XWT	–	Cross wavelet transform

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2 REVISÃO DE LITERATURA	3
2.1 Culturas de soja e milho	3
2.2 Conceituação de seca	5
2.3 Estimativa da precipitação por meio do SR orbital	6
2.4 Índices de precipitação	7
2.4.1 <i>Standardized Precipitation Index</i> (SPI)	7
2.4.2 <i>Precipitation Condition Index</i> (PCI)	8
2.5 Índices de vegetação	8
2.5.1 Índices baseados no espectro visível e infra-vermelho (IV-VIR)	9
2.5.2 Índices de vegetação e temperatura	10
2.5.3 Índices de vegetação, temperatura e precipitação	11
2.6 Filtragem de dados de sensoriamento remoto	12
2.7 Tendências em séries temporais	14
2.8 Extração de parâmetros fenológicos a partir de dados de SR	15
2.9 Sensoriamento remoto na avaliação de secas	15
2.10 Ferramentas de análise	17
2.10.1 Padronização	17
2.10.2 Correlação de Pearson	17
2.10.3 Função de autocorrelação	18
2.10.4 Teste de Mann-Kendall para detecção de tendências	18
2.10.5 Transformada <i>wavelet</i>	19
2.10.6 Análise das anomalias relativas às linhas de base	21
3 MATERIAIS E MÉTODOS	23
3.1 Área de estudo	23
3.2 Ferramental utilizado	24
3.3 Conjunto de dados	24
3.3.1 Mapa-base de agricultura anual do Paraná	24
3.3.2 Dados agroeconômicos	26
3.3.3 Dados meteorológicos	27
3.3.3.1 Precipitação estimada por meio de sensoriamento remoto	27

3.3.3.2	<i>Standardized Precipitation Index (SPI)</i>	27
3.3.4	Dados MODIS	28
3.4	Metodologia	29
3.4.1	Filtragem de dados do MODIS	29
3.4.1.1	Combinação entre dados do Terra e Aqua	29
3.4.2	Cálculo de índices de vegetação	30
3.4.2.1	Filtragem das séries-temporais de imagens	31
3.4.3	Extração de estatísticas regionais	32
3.4.4	Análise de tendências	33
3.4.5	Extração de métricas fenológicas	33
3.4.6	Análise de métricas fenológicas no domínio da frequência	34
3.4.7	Criação das linhas de base	34
3.4.8	Análises de correlações entre indicadores	35
3.4.9	Relação de coerência entre IV e LST	35
4	RESULTADOS E DISCUSSÃO	37
4.1	Análise do regime de chuvas	37
4.2	Resposta dos IVs	40
4.2.1	Análise de tendências	40
4.2.2	Fenologia	42
4.2.2.1	Métricas fenológicas derivadas de séries de NDVI	42
4.2.2.2	Autocorrelação de séries temporais de NDVI no estudo da fenologia	43
4.2.2.3	Transformada <i>wavelet</i> para uma série de NDVI	45
4.2.3	Linhas de base para os índices de vegetação	47
4.2.4	Comportamento dos IVs	51
4.2.5	Correlações entre indicadores	53
4.2.5.1	IVs vs. SPI3	53
4.2.5.2	IVs vs. precipitação acumulada	56
4.2.5.3	IVs vs. produtividade estimada pelo IBGE	60
4.2.5.4	IVs vs. LST	62
4.3	Relações de causa e efeito entre LSWI e LST	65
4.4	Espacialização da seca	68
5	CONCLUSÕES	71
	REFERÊNCIAS BIBLIOGRÁFICAS	75

1 INTRODUÇÃO

A seca é um fenômeno climático recorrente ao redor do planeta e suas características e impactos variam de região para região. No Brasil, um país em que grande parte da constituição do Produto Interno Bruto é decorrente da cadeia agrícola, a seca é um fenômeno que frequentemente atua negativamente neste balanço. Como exemplo, dados levantados pela Companhia Nacional de Abastecimento (CONAB) apontaram que, na safra de 2011/2012, os estados do Paraná e Rio Grande do Sul apresentaram declínio de até 30% na produtividade das lavouras de milho e soja (CONAB, 2012).

Informações mais precisas foram levantadas por Sousa et al. (2010) no Rio Grande do Sul, para os anos safras de 2005 e 2009. Foram observadas estiagens de alta intensidade em 40% e 37% da área do estado, respectivamente. No Paraná, no ano safra de 2005, ocorreu estiagem de baixa intensidade em 20% de sua área. Porém, em 2009, a intensidade foi alta e atingiu 34% da área. Levantar este tipo de informação só foi possível porque os pesquisadores recorreram a recursos de Sensoriamento Remoto (SR).

Monitorar a seca na agricultura consiste em mensurar sua intensidade e captar sua extensão espacial e persistência temporal (WARDLOW et al., 2012). Devido à grandiosidade geográfica do Brasil, levantar tal volume de informações em tempo hábil para tomada de decisões é uma tarefa inconcebível de ser realizada em campo, pois há limitações de capital humano, instrumental e financeiro. O SR orbital oferece uma perspectiva única para operacionalizar o monitoramento de seca, complementando os levantamentos feitos tradicionalmente em campo. As informações acerca das condições de lavouras, quando obtidas a tempo, têm grande importância na tomada de decisões. Para exemplificar: *i*) indício de quebra de safra em uma determinada região pode diminuir a oferta do produto, ocasionando flutuação de preços; *ii*) a mobilização de recursos financeiros para socorrer agricultores numa região atingida pela seca pode ser mais bem organizada quando se detêm este tipo de informação; *iii*) estatísticas de ocorrência de seca em termos de severidade e extensão também são de grande importância para a gestão de risco da cadeia agrícola. Para suprir essa demanda por informações, há grande disponibilidade de dados de SR gratuitos, de livre acesso e boa qualidade. No entanto, o Brasil carece de metodologias voltadas aos problemas regionais e, para avançar neste sentido, é necessário adaptar ou criar indicadores que respondam à ocorrência da seca em tempo hábil, com precisão e cobrindo toda área de interesse.

Um importante ciclo se forma quando sistemas de monitoramento de seca evoluem

conjuntamente com estratégias de gestão de risco, no qual, bom gerenciamento dos impactos da seca leva à busca por melhorias nos métodos de monitoramento e, em contrapartida, melhor monitoramento impulsiona a gestão de risco de forma mais eficiente (WILHITE et al., 2007). Daí surge a necessidade de se estabelecer um bom sistema de monitoramento da seca. No entanto, um primeiro passo é entender com que qualidade e prontidão os recursos de SR podem fornecer dados para alimentar este sistema.

O presente trabalho fundamentou-se na hipótese de que é possível detectar a ocorrência de seca em agricultura utilizando-se dados de SR aliados a diferentes métodos de análise. Assim, seria possível propor uma metodologia eficaz para caracterização e monitoramento da seca e seus efeitos na agricultura.

O objetivo principal do trabalho foi caracterizar, por meio de índices de vegetação, os eventos de seca agrônômica ocorridos no estado do Paraná entre dos anos-safra de 2002/2003 a 2013/2014. Para tal, os seguintes objetivos específicos foram delineados:

- i verificar a distribuição de precipitação e anomalias estimadas por SR para a região de estudo;
- ii estimar métricas da fenologia das culturas numa escala temporal, a partir de dados de SR;
- iii analisar a sensibilidade e resposta de diversos índices às anomalias na vegetação, elegendo o melhor índice para caracterização de seca agrônômica;
- iv aplicar ferramentas matemáticas robustas para entender as relações entre o índice eleito e a variável ambiental mais relevante;
- v espacializar a ocorrência da seca ao longo do tempo utilizando o índice eleito.

2 REVISÃO DE LITERATURA

Para esse trabalho, convencionou-se utilizar as siglas em inglês, o que facilita a consulta nas bases de informações científicas e mantém o mesmo padrão dos trabalhos acadêmicos citados.

2.1 Culturas de soja e milho

As culturas agrícolas abordadas neste trabalho foram a da soja (*Glycine max* (L.) Merrill) e milho (*Zea mays* L.). No Paraná, a principal cultura de grãos para a safra de verão é a soja, tendo o milho relativa baixa ocorrência, concentrando seu cultivo de forma mais expressiva na safrinha¹. As Tabelas 2.1 e 2.2 apresentam a distribuição geográfica dessas culturas para as safras de verão entre 2002 e 2013.

Tabela 2.1 - Área plantada de soja em 10^3 hectares (IBGE) considerando safra e safrinha (IBGE, 2015a)

Ano-safra	Brasil	Sul	PR	COCP	NCP	NP	OP
2003-2004	18.528	7.498	3.649	563	670	288	864
2004-2005	21.601	8.310	4.011	586	705	332	914
2005-2006	23.427	8.689	4.155	600	737	355	922
2006-2007	22.083	8.132	3.932	577	704	329	888
2007-2008	20.571	8.284	4.007	577	673	319	919
2008-2009	21.253	8.147	3.969	573	677	311	924
2009-2010	21.762	8.286	4.077	594	661	319	940
2010-2011	23.339	8.942	4.480	583	744	383	1004
2011-2012	24.032	9.088	4.555	606	754	405	984
2012-2013	25.091	9.178	4.457	602	751	397	953
2013-2014	27.949	10.012	4.763	612	790	441	977

As cultivares de soja semeadas no Paraná apresentam ciclos que variam de aproximadamente 100 a 150 dias. Sua semeadura é dependente das condições climáticas, ocorrendo geralmente entre o final de outubro e metade de dezembro, sendo portanto, uma janela bastante ampla (GARCIA et al., 2000). Já para o milho no Paraná, segundo Caramori et al. (2000) e Wagner et al. (2011), a época ideal de semeadura compreende os meses de setembro à metade de novembro, historicamente menos

¹Para o presente trabalho, embora não abordada, a safrinha é frequentemente mencionada. Define-se como safrinha a safra semeada entre os meses de janeiro e fevereiro, ou seja, após a colheita das culturas semeadas entre setembro e novembro. O período típico de safrinha de grãos varia entre regiões e culturas, mas a definição dada é compatível com as culturas de soja e milho para o estado do Paraná.

sujeitos ao *déficit* hídrico, tendo seu ciclo oscilando entre 114 e 122 dias.

Segundo Camargo et al. (1974), soja e milho possuem exigências hídricas semelhantes, embora o milho seja um pouco menos exigente. Na soja, a deficiência hídrica durante o período vegetativo retarda o crescimento da planta. Os períodos mais sensíveis ao *déficit* hídrico são o florescimento, a formação de vagens e o enchimento de grãos. O suprimento inadequado nessas épocas causa aborto de flores, má formação de vagens e chochamento dos grãos, respectivamente. Já o milho é relativamente tolerante ao *déficit* hídrico durante a fase vegetativa e maturação. Contudo, suas fases onde o suprimento de água insuficiente incorre em grandes perdas são o florescimento, pendoamento, formação de espigas e enchimento de grãos. Esses fatores ocasionam a não formação de espigas, mal desenvolvimento das mesmas, menor quantidade de grãos e baixa qualidade destes últimos, respectivamente. Dada sua maior tolerância à seca se comparado à soja, o milho é dominante na época de safrinha, na qual a disponibilidade de água é menor.

Nguy-Robertson (2013) caracterizou em termos de índice de área foliar [Leaf Area Index (LAI)] as culturas da soja e milho de sequeiro e irrigado, para o estado do Nebraska, nos EUA. A caracterização espectro-temporal foi feita com estimador de LAI por sensoriamento remoto *in situ*, o que fornece alta precisão nos resultados. A Figura 2.1 exhibe o comportamento das culturas, sendo que a escala de tempo foi adaptada às condições brasileiras para facilitar o entendimento do diagrama. Para o milho, *tassel*, *silk*, *kernel formation* e *dent stage* equivalem a pendoamento, formação de espiga, formação e enchimento dos grãos, respectivamente. Na soja,

Tabela 2.2 - Área plantada de milho em 10^3 hectares (IBGE) apenas para a safra de verão (IBGE, 2015b).

Ano-safra	Brasil	Sul	Paraná	COCP	NCP	NP	OP
2002-2003	10.068	3.745	1.471	49	130	106	120
2003-2004	9.831	3.476	1.357	45	115	106	101
2004-2005	9.024	3.291	1.288	39	97	95	100
2005-2006	9.639	3.716	1.510	62	125	128	158
2006-2007	9.883	3.369	1.309	53	127	111	130
2007-2008	9.652	3.484	1.383	56	117	122	123
2008-2009	8.829	3.456	1.421	99	122	103	188
2009-2010	7.139	2.631	897	26	67	64	71
2010-2011	7.653	2.419	777	20	60	65	53
2011-2012	7.596	2.617	972	38	63	82	92
2012-2013	6.663	2.382	864	36	49	70	85

flowers develop, pod and seed development e full seed to full maturity equivalem ao florescimento, formação de vagens e sementes, enchimento de grãos e maturação, respectivamente. Ainda sobre a Figura 2.1, vale lembrar que os patamares de LAI apresentados podem diferir significativamente das condições brasileiras.

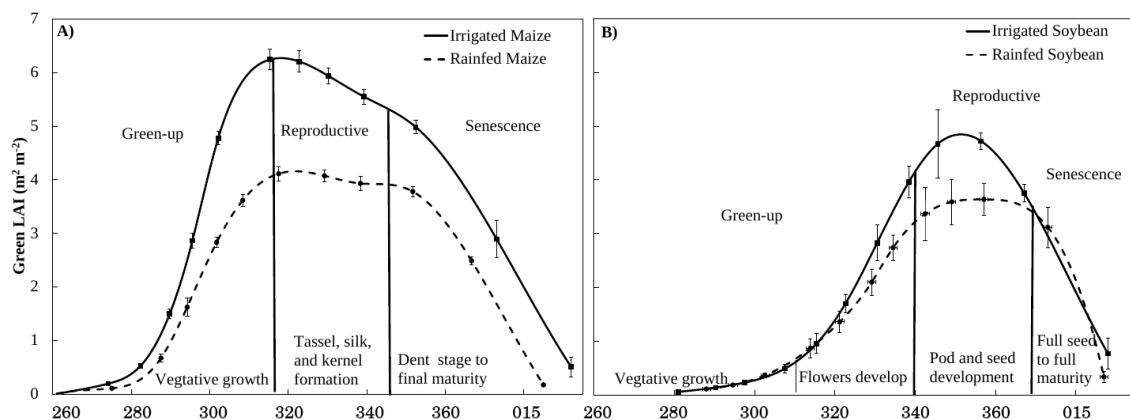


Figura 2.1 - Índice de área foliar aproximado para os ciclos de milho e soja. No eixo das abscissas está representado o tempo na escala de dias julianos. A Figura (A) exhibe o comportamento de milho irrigado e de sequeiro, enquanto que a Figura (B) apresenta o mesmo para a soja.

Fonte: Adaptado de [Nguy-Robertson \(2013\)](#).

2.2 Conceituação de seca

Seca é definida como um período de falta de água; uma condição em que a precipitação é insuficiente para suprir as necessidades humanas; uma anomalia negativa no nível de precipitação para um período; escassez de água na zona radicular do solo, dentre outras generalidades ([NAGARAJAN, 2010](#)). São comumente classificadas como secas meteorológicas quando os níveis de precipitação estão mais baixos que as médias anuais; secas hidrológicas são geralmente associadas a uma bacia hidrográfica ou rio, definidas como efeitos negativos na vazão de um rio, nível de reservatório, suprimento de água subsuperficial entre outros corpos d'água; já a seca agrônômica, a qual é o objeto deste estudo, é o impacto negativo na disponibilidade de água no solo no que tange ao suprimento para as plantas comprometendo sua produtividade ou condição; normalmente é ocasionada pelo *déficit* de precipitação, mas também podendo ser decorrente de manejo inadequado de recursos hídricos e edáficos ([WARDLOW et al., 2012](#)). A Figura 2.2 resume os tipos de secas, suas causalidades e efeitos no decorrer do tempo.

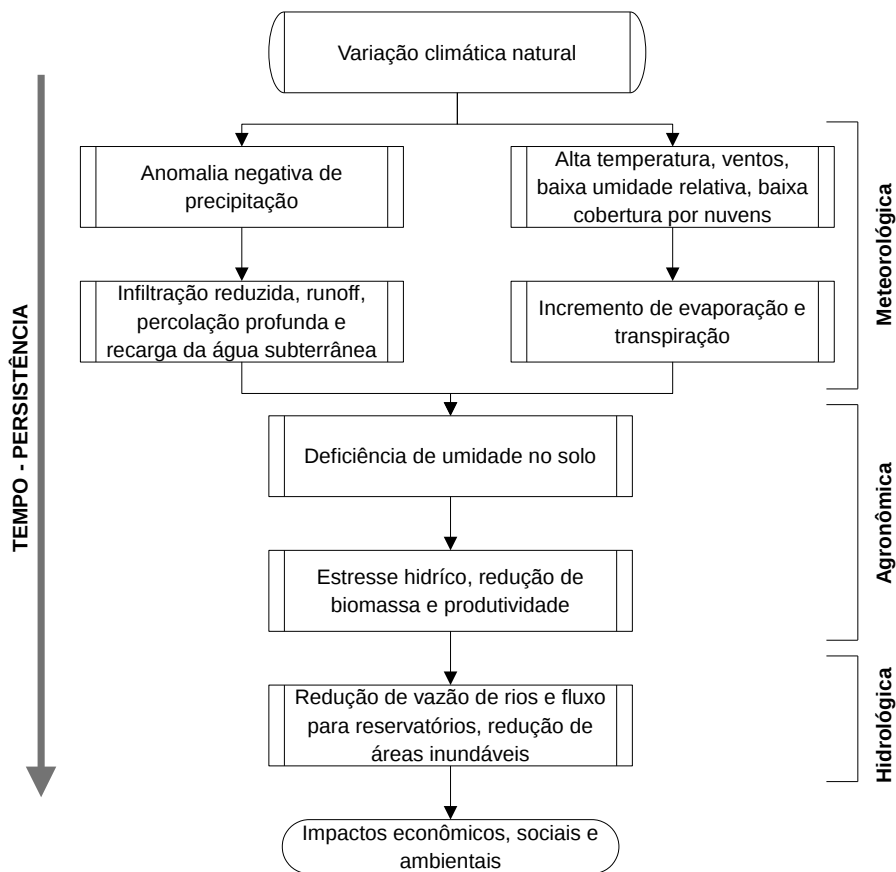


Figura 2.2 - Tipos de seca e seus impactos.

Fonte: Wilhite (2001)

2.3 Estimativa da precipitação por meio do SR orbital

Estimativas de precipitação por meio de sensores orbitais têm como um dos objetivos suprir a falta de dados provenientes de estações meteorológicas no solo, além de dinamizar a distribuição de informações. Os pesquisadores que necessitam de dados de precipitação geralmente enfrentam uma série de problemas, a saber: *i*) dificuldade de acesso aos dados, carência de plataformas de distribuição; *ii*) presença de lacunas nas séries e incoerências; *iii*) cobertura escassa, poucas estações meteorológicas; *iv*) demora na atualização dos dados. Na região sul do Brasil, por exemplo, a Agência Nacional de Águas (ANA), principal provedora de dados agrometeorológicos da própria ANA e outros órgãos, dispõe de, aproximadamente, 33 estações minimamente operantes, segundo consulta feita ao banco de dados da instituição (ANA, 2009).

Para superar estas dificuldades, além de oferecer muitas outras facilidades, diversos instrumentos e metodologias associadas foram desenvolvidos, com destaque para os

satélites da série *Geostationary Operational Environmental System* (GOES) que operam na faixa do infravermelho termal e também o *Tropical Rainfall Measuring Mission* (TRMM) que possui sensor ativo (COLLISCHONN et al., 2007). Os mesmos autores avaliaram a qualidade dos dados TRMM obtendo resultados bastante satisfatórios para a Bacia do Paraguai Superior.

No entanto, estimativas de precipitação por sensoriamento remoto baseadas apenas em um tipo de dado orbital tendem a ser tendenciosas e, portanto, de baixa precisão. Com o intuito de melhorar os produtos de estimativa de precipitação existentes e de fácil acesso, Hsu et al. (1997) propuseram um sistema que combina informações dos satélites GOES e TRMM, o que seguramente aumenta a qualidade das estimativas de precipitação. Este produto é denominado *Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks* (PERSIANN), desenvolvido pelo Departamento de Engenharia Civil e Ambiental da Universidade da Califórnia - Irvine. Sorooshian et al. (2000) avaliaram a acurácia do PERSIANN em estimar a precipitação diária sobre os estados do Texas e Flórida, obtendo correlações de 0,77 a 0,90 entre o estimado pelo sistema e o medido nas estações meteorológicas, o que é bastante satisfatório para os propósitos deste trabalho.

2.4 Índices de precipitação

2.4.1 *Standardized Precipitation Index* (SPI)

Dados de precipitação podem ser sintetizados na forma de índices, como por exemplo, o SPI (MCKEE et al.,), o qual possibilita a comparação entre áreas distintas e, capacidade de aferir seca meteorológica, agrícola e hidrológica de forma simples. O SPI para um dado período é seu *Z - score*, também conhecido como anomalia, o que permite a escolha da escala de tempo a ser periodizada. O cálculo do SPI é relacionado unicamente às probabilidades, tendo como base para tal a série histórica de precipitação para um determinado período. O SPI ajusta os dados de precipitação a uma distribuição *gamma* para que sejam trabalhados em função de probabilidades. A saída do SPI apresenta distribuição normal, a qual é então normalizada em termos de escala, o que possibilita a comparação entre locais e condições diferentes. Os limiares de SPI definem as classes de seca (Tabela 2.3).

O SPI foi elaborado para quantificar as anomalias de precipitação em escalas temporais múltiplas. Para eventos de seca meteorológica, pode ser utilizada a escala de 1 a 3 meses, porém, para a seca agrícola, escalas de 3 a 9 meses foram consideradas mais apropriadas (ROUAULT; RICHARD, 2003). Os dois tipos de seca citados

Tabela 2.3 - Graus de severidade associados ao SPI.

2,0 ou mais	Extremamente úmido
1,5 a 1,99	Muito úmido
1,0 a 1,49	Moderadamente úmido
-0,99 a 0,99	Normal
-1,0 a -1,49	Moderadamente seco
-1,5 a -1,99	Muito seco
-2 ou menos	Extremamente seco

são considerados como sendo de curto período, o que justifica o uso de escalas de tempo reduzidas (CACCAMO et al., 2011). O período de 3 meses (SPI3) é o adequado para os cultivos agrícolas anuais tropicais, pois estes têm ciclo mais curto que os avaliados por Rouault e Richard (2003). Neste contexto, pode se considerar como seco o período onde o *SPI* esteja abaixo de -1 . Esta abordagem será utilizada nas análises deste trabalho. Instruções mais detalhadas acerca do cálculo e interpretação do SPI estão disponíveis em WMO (2012).

2.4.2 *Precipitation Condition Index (PCI)*

Outro índice, utilizado por Du et al. (2013), é o *Precipitation Condition Index*, o qual considera os níveis máximos e mínimos de precipitação mensais para uma série temporal, em que o valor 0 representa estado de seca e o valor 1 situações de alta umidade. Em suma, o PCI desvia em 0,5 em um dado mês ao passo que a precipitação se aproxima do patamar máximo ou mínimo em uma série histórica (Equação 2.1). No entanto, este só pode ter aplicação local, o que impossibilita a comparação entre regiões. Ao consultar a literatura, ficou claro que o PCI não é amplamente utilizado, porém, é um dado de entrada para um índice de vegetação composto, o qual será descrito adiante.

$$PCI = \frac{Prec.acumulada - \text{Mínimo}}{Máximo - \text{Mínimo}} \quad (2.1)$$

em que: *Prec.acumulada*, *Mínimo* e *Máximo* são os valores de precipitação acumulada mensalmente, mínimo e máximo para determinado mês ao longo da série, respectivamente. Todas variáveis são referentes a um *pixel*. Os mínimos e máximos consideram toda a série temporal para o referido mês.

2.5 Índices de vegetação

Índices de vegetação (IVs) são definidos como a associação matemática de dados radiométricos provenientes de sensores remotos com as características espectrais da vegetação. Por serem intimamente relacionadas com fatores estruturais, teores de água e conteúdo de clorofila da vegetação, são variáveis com muitas aplicações para estudo e interpretação de dados de SR no que tange ao monitoramento fenológico e mapeamento sob diferentes escalas temporais e espaciais (ATZBERGER, 2013). Os índices mais amplamente empregados são obtidos a partir de dados das bandas do vermelho [*red* (R)] e infravermelho próximo [*near infrared* (NIR)]. Estes IVs evidenciam o contraste da alta absorvidade da radiação eletromagnética pela clorofila na banda do vermelho com a alta refletividade pelas estruturas e componentes foliares na região espectral do NIR (TUCKER, 1979). Embora exista uma multiplicidade de IVs, nesta revisão, serão abordados apenas os utilizados no trabalho. A Tabela 2.4, presente no final desta Seção, sintetiza a formulação dos índices abordados nesta revisão.

2.5.1 Índices baseados no espectro visível e infra-vermelho (IV-VIR)

O *Normalized Difference Vegetation Index* (NDVI) (ROUSE et al., 1974) é certamente o IV mais utilizado inclusive para caracterizar a seca, o que é evidenciado pelas inúmeras aplicações, sendo duas delas presentes neste trabalho: caracterização fenológica (ATZBERGER; EILERS, 2011) e detecção de seca agrônômica (GU et al., 2007). No entanto, o NDVI não considera os efeitos do solo, o que limita seu uso em situações onde o solo apresenta alta intensidade de brilho, contaminando a interpretação das condições da vegetação. Como forma de contornar algumas deficiências do NDVI, Huete et al. (2002) propuseram o *Enhanced Vegetation Index* (EVI), o qual incorpora fatores empíricos que consideram o brilho do solo no cálculo do índice, tendo sido este também aplicado em estudos de seca agrícola (SONG et al., 2013). Uma peculiaridade sobre o NDVI e EVI quando obtidos através de dados do MODIS, é que o primeiro é menos suscetível aos fatores direcionais da aquisição do dado, o que o torna mais coerente numa análise multi-temporal para dosséis contínuos, como soja e milho em estágio avançado de desenvolvimento (BREUNIG et al., 2012).

O *Normalized Difference Water Index* (NDWI), como proposto por Gao (1996), tem como principais características a não saturação quando obtidos em áreas agrícolas com alto LAI e a alta correlação com o teor de água nas folhas. Por isso, tem sido amplamente empregado na caracterização da seca agrícola (EZZINE et al., 2014).

Já o *Normalized Difference Water Index 7* (NDI7) (RUBIO; RIANO, 2006) é uma modificação do NDWI para o caso de dados do MODIS, pois a imagem da banda 5 (1240nm) apresenta baixa relação sinal-ruído [*Signal to Noise-Ratio* (SNR)]. No caso do satélite Terra, há uma falha sistemática que distorce os resultados. Desta forma, o NDI7 nada mais é que a substituição da imagem da banda 5 pela banda 7 (2130nm), o que produz resultados diferentes do NDWI, porém, ainda apresenta alta correlação com o teor de água nas folhas (CHEN et al., 2005), com maior peso do fator estrutural do dossel (TROMBETTI et al., 2008), o que é de interesse para o presente estudo.

Outro IV tido como boa aproximação para o teor de água nas plantas e solo é o *Land Surface Water Index* (LSWI), proposto por Xiao et al. (2004b). O LSWI relaciona as bandas do NIR e infravermelho próximo [*shortwave infrared* (SWIR)], de modo similar ao NDI7, porém, utilizando outras faixas do espectro. Os autores verificaram bom desempenho do LSWI na caracterização de floresta decidual para diferentes condições de umidade do solo, sendo assim, uma boa aproximação para esta variável. Nos últimos anos, tem tido seu uso intensificado, provando ser um índice bem correlacionado com variáveis biofísicas. Num trabalho recente, Wagle et al. (2015) utilizaram o LSWI para estimar a produtividade da soja em diversas situações de manejo de irrigação, tendo sido este índice eficiente em rastrear a seca e estimar o estresse hídrico. Isto é devido à alta absorbância da umidade foliar nos comprimentos de onda do SWIR1, e a reflectância sendo negativamente relacionada ao conteúdo de água na planta. O mesmo vale para o SWIR2² e, portanto, para o NDI7.

Com base na constatação de que os impactos da seca não podem ser facilmente detectados pelo NDVI se não houver uma referência de valores extremos, Kogan (1995b) desenvolveu o *Vegetation Condition Index* (VCI), de modo a captar as diferenças locais na produtividade do ecossistema e do clima. Para tal, empregou o conceito de capacidade de suporte intrínseca do ambiente [*Carrying capacity* (CC)] que é definida como a máxima população que um ambiente pode suportar (REINIGN, 1974). Para formalizar esta ideia em termos de SR, os NDVIs máximos e mínimos para cada data (ou intervalo) são determinados ao longo de uma série plurianual, de tal forma que as médias dos limites máximos e mínimos constituam a CC, enquanto que a variabilidade anual seja majoritariamente decorrente de anomalias climáticas. Dessa forma, a variação climática que impacta na vegetação será evidenciada pelo

²SWIR1 e SWIR2 são especificados para os canais 6 e 7 do MODIS, tendo suas faixas centralizadas em 1640nm e 2135nm, respectivamente.

VCI, exercendo, assim, sua potencialidade no monitoramento de seca agrícola. É, portanto, um indicador de seca melhor que o NDVI para este fim (DU et al., 2013).

2.5.2 Índices de vegetação e temperatura

A temperatura de superfície derivada do infravermelho termal [*Thermal infrared* (TIR)] pode auxiliar na detecção de seca em vegetação. Nesse sentido, serve como um fator auxiliar em estimativas de evapotranspiração, umidade do solo, déficit hídrico em vegetação e inércia termal. Mais especificamente sobre a vegetação, o aumento da temperatura foliar é um indicativo de estresse hídrico na planta e precede o início da seca. A resposta termal pode ocorrer mesmo quando as plantas estão verdes, pois elas fecham seus estômatos para minimizar a perda de água por transpiração diminuindo o fluxo de calor latente. Consequentemente, para manter o balanço de energia, haverá aumento do fluxo de calor sensível incorrendo em aumento de temperatura de superfície da folha (TANG; LI, 2014). Em termos de solo, maiores LST de dia podem servir de indicativo de menor umidade do solo, pois a água e vegetação são atenuantes nas trocas de calor entre solo e atmosfera, ou seja, em ambientes secos a troca é mais brusca. Por essa razão, regiões áridas apresentam grande amplitude térmica. Em síntese, NDVI e LST apresentam relação inversa e baseada em princípios físicos distintos.

A partir dessas ideias, Kogan (1995b) desenvolveram o *Temperature Condition Index* (TCI) como uma *proxy* para a condição termal da vegetação. O TCI é calculado também de forma normalizada a partir de máximos e mínimos, porém, de forma inversa, de tal modo que a relação com NDVI e VCI passe a ser colinear, permitindo a soma do TCI aos IVs baseados no espectro ótico. Combinando TCI e VCI, foi possível estabelecer um novo índice que demonstrasse os efeitos integrados da umidade e temperatura nas condições da vegetação. Daí surgiu o *Vegetation Health Index* (VHI) a partir da soma de VCI e TCI atribuindo-se pesos a cada um, acoplando aspectos termais e óticos (LIU; KOGAN, 1996). A distribuição das relações entre LST e NDVI apresentam correlações negativas em áreas secas e médias latitudes e correlações positivas nas áreas tropicais e altas latitudes (JULIEN; SOBRINO, 2009). Sendo assim, a relação oposta é esperada entre NDVI e TCI.

2.5.3 Índices de vegetação, temperatura e precipitação

Há uma tendência recente de incorporar dados de precipitação aos índices de vegetação como forma de caracterizar o fenômeno da seca de modo mais completo. Para tal, dados de estimativa de precipitação obtidos por meio de satélite têm ampla

aplicação neste sentido. Rhee et al. (2010), com o intuito de monitorar a ocorrência de seca em vegetação, tanto em regiões áridas quanto úmidas, propuseram o *Scaled Drought Condition Index* (SDCI), combinando NDVI e LST proveniente de dados MODIS e de precipitação estimada pelo TRMM. Para este índice, todas as variáveis foram então normalizadas para valores entre 0 e 1. Segundo os autores, o desempenho do SDCI foi superior ao NDVI e VHI na avaliação da vegetação nos estados áridos (Arizona e Novo México) e úmidos (Carolina do Norte e Carolina do Sul) dos Estados Unidos da América.

Ao utilizarem os mesmos elementos do SDCI, Du et al. (2013) analisaram conjuntamente os índices VCI, TCI e PCI propondo o *Synthesized Drought Index* (SDI), que reduz a redundância entre seus dados de entrada a partir de uma análise de componentes principais, sendo o SDI a primeira componente, contendo mais de 90% de toda variância dos índices de entrada. Os autores obtiveram resultados consistentes tendo captado com precisão os eventos de seca ocorridos na província de Shandong, China, apresentando alta correlação com o SPI3 e com a produtividade agrícola da área. Tanto o SDCI quanto o SDI foram aplicados apenas pelos próprios autores, não havendo na literatura registros da replicação do seu uso até o presente momento, o que de fato torna ainda mais interessante a análise destes índices.

A Tabela 2.4 resume os índices que foram abordados e avaliados neste trabalho. Os índices NDVI, EVI, NDWI, NDI7 e LSWI serão referidos como IV-VIR (Índices de vegetação baseados no Visível e Infravermelho) no decorrer do trabalho. Os outros, serão referidos como sendo derivados dos IV-VIR.

Tabela 2.4 - Índices de vegetação

Índice	Fórmula
NDVI (ROUSE et al., 1974)	$(NIR1 - Red)/(NIR1 + Red)$
EVI (HUETE et al., 2002)	$\frac{2,5*(NIR1-Red)}{NIR1+6*Red-7,5*Blue+1}$
NDWI (GAO, 1996)	$(NIR1 - NIR2)/(NIR1 + NIR2)$
NDI7 (RUBIO; RIANO, 2006)	$(NIR1 - SWIR2)/(NIR1 + SWIR2)$
LSWI (XIAO et al., 2004a)	$(NIR1 - SWIR1)/(NIR1 + SWIR1)$
VCI (KOGAN, 1995a)	$(NDVI - NDVI_{min})/(NDVI_{max} - NDVI_{min})$
TCI (KOGAN, 1995b)	$(BT_{max} - BT)/(BT_{max} - BT_{min})$
VHI (LIU; KOGAN, 1996)	$\alpha * VCI + (1 - \alpha) * TCI$
SDI (DU et al., 2013)	1ª PCA do conjunto VCI, PCI, TCI

BT = Temperatura de Brilho, α = peso para VCI no VHI.

2.6 Filtragem de dados de sensoriamento remoto

As séries temporais de IVs em agricultura são normalmente não-estacionárias, ou seja, apresentam diferentes componentes de frequência, como as variações sazonais, flutuações de longo (tendências) e curto prazo (anomalias). As variações sazonais são decorrentes do próprio ciclo da agricultura anual considerando safras e safrinhas. Flutuações de longo prazo ou tendências podem ser decorrentes de evolução tecnológica nos cultivos (caso positivo), empobrecimento do solo química ou fisicamente (negativa) e, até mesmo, a degradação dos sensores remotos, porém, não caracterizando alteração na vegetação, mas sim nos dados obtidos. Anomalias de curto prazo podem ser decorrentes de ataques de pragas e doenças ou de variações climáticas desfavoráveis para a planta, representadas principalmente pela seca. Nas três escalas, o ruído se faz presente, sendo, geralmente, mais impactante nas escalas de curto prazo. Para contornar essa gama de problemas e gerar séries temporais mais confiáveis e suavizadas, devem ser utilizados filtros, permitindo também extrair informações não observáveis numa série de dados brutos (CHANDLER; SCOTT, 2011).

Um dos métodos mais simples para remoção de ruídos em séries temporais é a aplicação do filtro de média móvel [*moving average* (MA)], o qual trabalha no domínio do tempo. Este é o filtro mais simples de entender e aplicar. Apesar de sua simplicidade, é bastante eficiente para as aplicações propostas neste trabalho, reduzindo o ruído e mantendo a forma da série. A simplicidade do filtro de MA também se reflete no seu baixo custo computacional, o que é mais um atrativo para processamentos de grande volume de dados. Um exemplo de aplicação pode ser visto em Gu et al. (2007). No entanto, um ponto negativo do filtro de MA é a susceptibilidade a dados extremos. No caso da filtragem de índices de vegetação, por exemplo, o NDVI obtido em presença de nuvens, apresenta o valor tendendo a 0, o que tendência para baixo o valor da média móvel local. A fórmula para um filtro de MA de janela 3³ é representada pela Equação 2.2.

$$y_{MA(3)} = \frac{1}{n} [x_1 + x_2 + x_3, x_2 + x_3 + x_4, \dots, x_{n-2} + x_{n-1} + x_n] \quad (2.2)$$

Um filtro menos susceptível a valores extremos é o de mediana móvel [*moving median* (MM)]. A mediana é outra medida de tendência central de uma série de dados, bem

³ Em filtragem, janela é definida como o número de observações anteriores e posteriores ao dado a ser filtrado na série temporal. Sendo assim, uma janela 3 determina a operação (no caso deste trabalho: média ou mediana) entre os 3 valores anteriores, o atual e os três posteriores, totalizando 7 observações.

menos susceptível que a média à presença de *outliers*. Uma filtragem por MM, no entanto, é menos eficiente em conservar a forma da série temporal. Um exemplo de aplicação pode ser visto em [Kovalsky et al. \(2012\)](#).

[Atzberger e Eilers \(2011\)](#) destacaram o potencial do filtro *Whittaker smoother* (WS) na filtragem e suavização de séries de dados SPOT-VGT enfatizando também seu baixo custo computacional se comparado a outros seis métodos estudados por [Hird e McDermid \(2009\)](#). O WS é um procedimento iterativo que diminui o peso das observações negativamente tendenciosas e *outliers*, o que leva a uma suavização mais próxima ao patamar superior da série, que tendem a serem valores mais confiáveis segundo os autores.

Outro método interessante, e no qual o usuário tem maior controle sobre o processo, permitindo melhor customização, é a filtragem por *wavelets*, o qual se mostrou mais eficiente que o Savitzky-Golay e a transformada de Fourier, como observado por [Lu et al. \(2007\)](#). O método foi empregado para dados do MODIS e consiste em decompor as séries temporais em diversas escalas (períodos) por meio da transformada *wavelet* de Daubechies (dbN), encontrando o período e ordem de decomposição que resultem na função de maior correlação com a série original. Os autores concluíram que a *wavelet db3* (Daubechies de terceira ordem) apresentou os melhores resultados para as composições de 8 dias do MODIS. Uma descrição mais detalhada em relação às *wavelets* será dada na Seção 2.10.5.

Em resumo, filtros que trabalham no domínio da frequência (*Wavelet*, *Whittaker* e *Fourier*) são complexos e computacionalmente bastante exigentes. Filtros que trabalham com ajuste de polinômios locais, como é o caso do Savitzky-Golay, são menos exigentes que os que trabalham no domínio da frequência. De acordo com [Smith \(2003\)](#), muitos cientistas e engenheiros sentem-se culpados por utilizar filtros MA ou MM, devido à simplicidade se comparados aos polinomiais e os do domínio da frequência. Mesmo tendo seu problema resolvido, continuam imaginando que algo mais poderia ser feito. Desta forma, o mais ideal é aliar a capacidade do filtro em resolver o problema da remoção de ruído e a viabilidade computacional.

2.7 Tendências em séries temporais

Em séries temporais, tendência é a mudança lenta e gradual em alguma propriedade da série ao longo do período analisado. Em outras palavras, é a mudança da média local também neste caminho gradual. Tradicionalmente, séries temporais são decompostas em componentes periódicos ou sazonais, ruídos e tendências, sendo cada

parte analisada separadamente, cada qual com técnicas específicas.

Antes de analisar os efeitos da seca na vegetação através das séries temporais de dados orbitais obtidos, é necessário fazer um estudo de detecção de tendências. Alguns fatores, tais como, desgaste dos sensores do MODIS, ganho tecnológico na agricultura, empobrecimento de solos podem representar uma tendência de subida ou queda nos IVs. Em caso positivo, este comportamento pode mascarar os efeitos da seca, que é o objeto de estudo deste trabalho. [Martínez e Gilabert \(2009\)](#), ao analisarem séries temporais de NDVI, dentre outras conclusões, puderam detectar tendência através de análise por *wavelet* aplicada a séries temporais de IVs para lavouras de arroz. A existência de tendências pode comprometer o cálculo de estatísticas de longo prazo, sendo, em determinados casos, necessário realizar um procedimento de remoção de tendências (*detrending*) ([CHANDLER; SCOTT, 2011](#)). A importância de se detectar a existência de tendências se sustenta na necessidade de removê-las, sendo considerado um pré-processamento para preparar as séries para métodos de análises que assumem estacionariedade ([FENSHOLT; PROUD, 2012](#)).

2.8 Extração de parâmetros fenológicos a partir de dados de SR

Em séries temporais de índices de vegetação, fenologia é uma métrica capaz de subsidiar questões acerca do impacto das mudanças ou anomalias climáticas na planta, ainda mais quando associada à capacidade geoespacial do sensoriamento remoto. Caracterizar temporalmente a fenologia das culturas agrícolas é um procedimento chave para análises temporais. A partir de valores do NDVI obtidos de imagens MODIS, [Zhang et al. \(2003\)](#) propuseram a utilização do algoritmo denominado método logístico, para extrair os parâmetros Início da estação [*Start of the Season* (SOS)] e Fim da estação [*End of the Season* (EOS)], obtendo erros menores de 10 dias para ambos. A escolha do método para extração de parâmetros tem forte impacto nos resultados, como observado por [Vrieling et al. \(2008\)](#), após comparar diferentes algoritmos, destacando-se a facilidade em implementar o método logístico.

Os estádios de desenvolvimento nos quais as culturas agrícolas anuais são mais sensíveis ao *déficit* hídrico são as fases: vegetativa, florescimento e enchimento de grãos ([DOORENBOS; KASSAM, 1979](#)), pois, nelas, o suprimento restringido de água afeta mais negativamente a produtividade final. No contexto da soja e do milho, o SOS geralmente coincide com o início da fase vegetativa, aproximadamente 20 dias após a semeadura considerando agricultura tropical/subtropical. Para as mesmas condições, o EOS ocorre até quatro semanas após o pico de NDVI ([ROJAS et al., 2011](#)), que coincide com o fim do período de enchimento de grãos.

2.9 Sensoriamento remoto na avaliação de secas

Avaliar a seca de forma geograficamente ampla é possibilitada, hoje em dia, por meio da utilização das mais variadas técnicas de sensoriamento remoto. Kogan (1995b), ao utilizar séries temporais de valores de NDVI do sensor *Advanced Very High Resolution Radiometer* (AVHRR), caracterizou os eventos de seca ocorridos nos Estados Unidos durante o período de 1985 a 1990. Neste mesmo trabalho, foi proposto o VCI, o qual teve boa concordância com a precipitação e as anomalias de produtividade das culturas agrícolas.

Sousa et al. (2010) realizaram um amplo trabalho no qual caracterizaram secas para toda a região sul do Brasil entre os anos de 2000 a 2009 por meio de dados EVI provenientes do sensor MODIS. Neste trabalho, destacou-se a potencialidade da metodologia no monitoramento de anomalias negativas de condição da vegetação, o que é grande indicativo de estiagem. Os autores concluíram também que os estados do Paraná e Rio Grande do Sul foram severamente castigados pela seca nos verões de 2005 e 2009.

Song et al. (2013) realizaram um estudo semelhante, porém, incorporando elementos de fenologia vegetal em suas análises e propondo uma metodologia que focasse nos impactos da seca na vegetação do Mt. Kenya, na África. Para tal, utilizaram séries temporais de valores de EVI obtidos de imagens do MODIS e dados de precipitação de estações meteorológicas. Os autores concluíram que, com a utilização de métricas fenológicas associadas aos dados de precipitação, uma boa caracterização das anomalias na vegetação pôde ser alcançada. Em outro trabalho nessa mesma linha, Wagle et al. (2015) avaliaram a produtividade primária bruta [*Gross primary production* (GPP)] de lavouras de soja sob diferentes níveis de manejo hídrico. Para tal, utilizaram índices de vegetação derivados do sensor MODIS, associando-os aos dados de fluxo de carbono estimados por uma torre de fluxo (*eddy flux tower*), obtendo resultados com desempenho satisfatório dos IVs em captar os efeitos da seca na GPP.

Nos índices acima descritos, não se consideravam dados de variação de precipitação, o que é de grande relevância no estudo da seca. Num amplo estudo realizado por Jackson (2005), foram incorporados dados de precipitação estimados por meio de dados adquiridos pelo TRMM, conjuntamente com índices de vegetação, enfatizando, porém, a análise de umidade do solo. O estudo evidenciou o potencial de aplicação dos dados estimados de precipitação em regiões de baixa densidade de estações meteorológicas.

Estudos mais recentes propuseram a criação de índices que incorporassem elementos de temperatura e precipitação além dos IVs tradicionais, abrangendo informações de valores de NDVI e de temperatura estimados a partir de imagens do MODIS e de precipitação obtido de imagens TRMM (DU et al., 2013; RHEE et al., 2010). Em ambos os trabalhos, os resultados demonstraram alta correlação entre os índices propostos e o SPI3 e SPI6. Ficou assim demonstrada a potencialidade da integração de várias plataformas e tipos de dados para caracterizar e monitorar a seca. No entanto, os trabalhos mais recentes citados não levaram em consideração os aspectos fenológicos da vegetação, o que tende a limitar a aplicabilidade destes índices no monitoramento da seca agrônômica. A fenologia é uma métrica de grande importância quando se analisam os efeitos do clima na agricultura, pois a susceptibilidade ao estresse hídrico difere entre as fases (CONFALONE; DUJMOVICH, 1999).

2.10 Ferramentas de análise

Nessa seção são descritas algumas ferramentas de análise empregadas neste trabalho, as quais têm como base os dois primeiros momentos estatísticos⁴. Vale ressaltar também que as ferramentas aqui descritas têm seu foco em análise de séries temporais. Uma série temporal é basicamente uma sequência de observações no tempo, em que uma premissa deve ser satisfeita: deve haver ao menos um valor que seja maior ou menor que seu vizinho anterior e posterior, ou seja, deve existir ao menos um pico ou um vale, respectivamente.

2.10.1 Padronização

Um problema comum em análise de dados é a escala. Se variáveis estão sendo comparadas e suas escalas são consideravelmente diferentes, uma prática comum é a padronização dos dados, ou seja, todas variáveis passam a ter mesma escala (ZUUR et al., 2007). Um dos métodos mais comuns é a centralização dos dados ao redor de zero utilizando a transformação apresentada pela Equação 2.3.

$$Y_i^{novo} = (Y_i - \bar{Y}) / \sigma_y \quad (2.3)$$

em que: Y_i^{novo} é a variável padronizada, \bar{Y} é a média amostral de Y , i é a i -ésima observação e σ_y é o desvio padrão da amostra.

As séries de dados transformados passam a não ter unidade e a padronização faz

⁴ Os momentos estatísticos são: 1º - média, 2º - desvio padrão, 3º - assimetria e 4º - curtose.

com que os dados tenham a mesma escala, mesmo que uma série tenha grandes flutuações enquanto que a outra tenha pequenas. O procedimento apenas remove a diferença nos valores absolutos entre as séries.

2.10.2 Correlação de Pearson

O coeficiente de correlação ou correlação de Pearson é a ferramenta estatística mais comum para se mensurar a associação entre duas variáveis. Definidos os pares de observações $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, temos a correlação de Pearson como apresentada na Equação 2.4.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.4)$$

em que: \bar{x} e \bar{y} são as médias amostrais de x e y , respectivamente. A significância de r é dependente do tamanho da amostra, o que restringe a aplicação dessa técnica em muitos casos. No presente trabalho, onde a correlação de Pearson foi utilizada extensivamente, atentou-se para esta restrição.

Vale lembrar que correlação não significa causalidade: se duas variáveis são fortemente correlacionadas, não significa necessariamente que uma determina o comportamento da outra, havendo a possibilidade de uma terceira ou n variáveis governarem as duas. A correlação de Pearson é apenas um indicativo para se associar o comportamento de duas séries, cabendo ao pesquisador interpretar essa relação tendo profundo conhecimento da natureza dos fenômenos envolvidos.

2.10.3 Função de autocorrelação

Autocorrelação é definida de forma simples como sendo a dependência entre observações sucessivas em uma série temporal. Os fenômenos da natureza quando analisados no tempo, quase sempre apresentam autocorrelação, o que é bastante nítido quando se trata de vegetação. Valores altos e baixos tendem a se agrupar próximos uns dos outros, e não uma oscilação como se observações sucessivas fossem independentes. A autocorrelação pode ser entendida também como a correlação de Pearson entre uma série e ela mesma deslocada no tempo (*lag*) (CHANDLER; SCOTT, 2011). Variando o *lag* para $k \geq 0$, teremos o coeficiente amostral de autocorrelação, como apresentado na Equação 2.5.

$$r(k) = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (2.5)$$

Calculando-se $r(k)$ para $k \geq 0$, obtém-se a função de autocorrelação [(*Autocorrelation function* (ACF))], a qual pode ser representada graficamente através do correlograma.

2.10.4 Teste de Mann-Kendall para detecção de tendências

O teste não paramétrico de Mann-Kendall tem sido aplicado em séries temporais de dados orbitais para detectar tendências, com destaque para as áreas da climatologia e hidrologia. O teste é baseado no ranqueamento dos dados e avalia a significância de uma tendência. Uma descrição detalhada pode ser encontrada em Hamed (2008), que aplica o teste de Mann-Kendall na detecção de tendências em séries de dados hidrológicos. O início do teste se dá pelo cálculo da estatística S , dada pela Equação 2.6:

$$S = \sum_{i=2}^n \sum_{j=1}^{i-1} \text{sign}(x_i - x_j) \quad (2.6)$$

em que: x_j é o dado em sequência (rankeado), n é o tamanho da série temporal e $\text{sign}(x_i - x_j) = -1$ se $(x_i - x_j) < 0$, $\text{sign}(x_i - x_j) = 0$ se $(x_i - x_j) = 0$ e $\text{sign}(x_i - x_j) = 1$ se $(x_i - x_j) > 0$. A hipótese nula H_0 é de que a amostra $X_t : t = 1, 2, \dots, n$ é independente e identicamente distribuída. A hipótese alternativa H_1 é de que existe uma tendência monotônica na amostra. O τ de Kendall é definido pela Equação 2.7:

$$\tau = 2 \frac{S'}{n(n-1)} \quad (2.7)$$

em que: S' é a soma de Kendall e é estimada a partir de $L - M$, onde L é o número de casos onde $(x_i - x_j) > 0$ e M é o número de casos onde $(x_i - x_j) < 0$. O teste retorna o coeficiente de correlação de Kendall (τ) que varia de -1 a $+1$, medindo o grau em que uma tendência é consistentemente crescente ou decrescente. Um valor de $+1$ indica uma tendência continuamente crescente e -1 indica exatamente o contrário. Valores próximos a 0 indicam tendências inconsistentes ou não-tendência. De forma complementar, o p -value também é fornecido, o que auxilia na interpretação da significância do teste (WESSELS et al., 2012). A estatística τ não pode ser confundida e

nem diretamente associada à inclinação da tendência, para tal tarefa existem outros métodos, como exemplo o método de Mínimos Quadrados Ordenados [*Ordinal Least Squares* (OLS)].

2.10.5 Transformada *wavelet*

A transformada *wavelet* [*Wavelet transform* (WT)] pode ser usada para analisar séries temporais de potência não estacionária em diferentes frequências. A WT retorna informações sobre o domínio da frequência (domínio de *Fourier*), porém, preservando a localização, que, no caso das séries temporais, é o tempo. A capacidade da WT para analisar variações nas potências em diferentes escalas de frequência e tempo fez com que tal ferramenta se tornasse amplamente empregada na análise de séries temporais. Quando se fala em potência, esta se refere à intensidade com que o sinal (série temporal) varia naquele ponto, enfim, o que causa variância na série. Desta forma, picos no periodograma ou espectrograma indicam quais frequências estão contribuindo mais para a variância de uma série, fazendo com que as sazonalidades e periodicidades, se existentes, sejam detectadas e evidenciadas (CAZELLES et al., 2008). Com foco em fenologia, Sakamoto et al. (2005) avaliaram vários tipos de *wavelet* mãe para extrair métricas fenológicas de vegetação a partir de séries temporais de dados MODIS. Já Martínez e Gilabert (2009) realizaram um excelente estudo sobre as potencialidades da WT em séries temporais de dados NDVI, tendo sido possível detectar tendências, métricas fenológicas, magnitude de mudanças e anomalias.

A WT consiste basicamente na decomposição de um sinal a diferentes escalas de tempo em uma série de funções básicas. Esse conjunto de funções básicas, $(\psi_{a,b}(t))$, pode ser gerado trasladando e escalonando a chamada *wavelet* mãe $\psi(t)$. A Equação 2.8 apresenta a forma genérica de uma *wavelet* mãe:

$$\psi_{a,b}(t) \equiv \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right), \quad a > 0, \quad -\infty < b < \infty, \quad (2.8)$$

em que: a é o parâmetro de escala que se ajusta à dilatação da *wavelet* e b determina a localização (no caso específico de séries-temporais, o tempo). A *wavelet* apresenta duas propriedades básicas: i) $\int_{-\infty}^{+\infty} \psi(t)dt = 0$ e ii) $\int_{-\infty}^{+\infty} \psi^2(t)dt = 1$, ou seja, a função tem média zero e intervalo finito. Por isso as séries são previamente normalizadas antes de proceder com a WT. A teoria de *wavelets* é densa e extensa, podendo se utilizar como ponto de partida para sua compreensão de modo prático o trabalho

desenvolvido por [Torrence e Compo \(1998\)](#), no qual analisaram séries temporais de índices oceânicos, porém, com o intuito principal de elucidar a teoria acerca das *wavelets*.

Outra aplicação das técnicas de *wavelets* é no estudo de duas séries, permitindo analisar a dependência entre elas. [Vargas et al. \(2010\)](#) utilizaram coerência de *wavelets* e também cruzadas (*cross wavelet transform* - XWT) para analisar a relação entre produção de CO_2 , vegetação e condições climáticas. A XWT é nada mais que a versão bivariada da WT, o que permite detectar a ocorrência de frequências de alta potência comuns às duas séries. Neste mesmo trabalho, encontram-se bem detalhadas as teorias acerca da coerência de *wavelets* e XWT. Uma abordagem mais didática é feita por [Grinsted et al. \(2004\)](#), podendo esta ser usado como um guia para aplicação da XWT. Define-se a XWT de duas séries temporais como sendo $W^{XY} = W^X W^Y *$, onde $*$ denota o complexo conjugado. Sendo assim, a $|W^{XY}|$ representa a potência da XWT, enquanto que a parte imaginária $arg(W^{XY})$ é interpretada como sendo o ângulo de fase entre as séries no domínio da frequência e tempo.

Por fim, um método para identificar frequências onde duas séries temporais são relacionadas é a coerência da transformada de *wavelet* [*wavelet coherency transform* (WCT)]. O método se baseia no fato que a WT, se bem adaptada à série, é capaz de conservar a variância, de tal forma que a WCT seja uma representação da covariância entre duas séries. Um maior detalhamento sobre a teoria acerca da WCT foi apresentado por [Torrence e Webster \(1999\)](#), onde há uma fundamentação teórica e um exemplo de aplicação.

2.10.6 Análise das anomalias relativas às linhas de base

A WT é muito poderosa para analisar oscilações nos padrões das séries temporais, em captar tendências e anomalias. No entanto, para mensurar estes desvios em termos absolutos, em relação à uma média local, a *wavelet* não é uma abordagem tão eficiente. Uma métrica bastante simples é adotada com este intuito, o erro médio absoluto (*Mean absolute error* - MAE). Este mesmo pode ser aplicado de forma móvel ao longo da série temporal, tratando cada trecho como uma pequena série. Isso possibilita mensurar desvios em diferentes estádios fenológicos da vegetação e traçar conclusões mais específicas. [Wagle et al. \(2014\)](#) utilizaram o MAE para quantificar diferenças entre a GPP estimada por uma torre de fluxo (*Eddy covariance tower*) e a GPP estimada por um modelo baseado em IVs. O MAE tem sua formulação apresentada na Equação 2.9.

$$MAE = \left[\frac{\left(\sum_i^j |IV_{base} - IV_{atual}| \right)}{j} \right] \quad (2.9)$$

em que: j é o número total de observações, i é o ponto inicial, IV_{base} é o valor do IV da linha de base para um dado período e IV_{atual} para o ano em análise. Como observado na Equação 2.9, o desvio é dado em módulo, o que pode não ser interessante para uma análise de anomalias em vegetação, já que valores negativos e positivos devem ser captados. No presente trabalho, o uso do módulo foi suprimido para que a direção dos desvios fosse representada.

3 MATERIAIS E MÉTODOS

3.1 Área de estudo

A área estudada compreende as quatro principais mesorregiões produtoras de soja e milho no estado do Paraná, a saber: Centro-Ocidental Paranaense (COCP), Norte-Central Paranaense (NCP), Norte Pioneiro (NP) e Oeste Paranaense (OP). Os solos são predominantemente argilosos, o que é de fato um dos fatores do desenvolvimento da agricultura de grãos na região, sendo esta a mais tradicional produtora de soja do Brasil. A Figura 3.1 exibe a região estudada e a as áreas de soja e milho para a safra de 2011/2012, baseada no mapa descrito na Seção 3.3.1.




Figura 3.1 - Região de estudo e mapa base de soja e milho para o ano-safra 2011/2012.

As áreas de soja e milho ocorrem, em sua maioria, sobre solos de textura argilosa e com bom potencial agrícola, como observado na Figura 3.2. Algumas regiões não contempladas na área de estudo também apresentam considerável área de soja e milho, tais como a Sudoeste Paranaense (SOP), Centro-Sul Paranaense (CSP) e Centro-Oriental Paranaense (CORP), porém, em áreas de menor potencial agrícola. Estas regiões não foram contempladas devido à menor densidade de área produtora e heterogeneidade de ambiente agrícola.




Figura 3.2 - Classes texturais do solo e potencial agrícola.

Fonte: EMBRAPA (1999).

3.2 Ferramental utilizado

Para realização desta pesquisa, foram utilizados apenas softwares livres, dados gratuitos e linguagem de programação. Há grandes vantagens nesta filosofia, tais como: maior possibilidade de reprodutibilidade do trabalho, custo baixo ou nulo, ampla comunidade de usuários dispostos a ajudar e desenvolver ferramentas. Foram utilizados os SIGs *SAGA GIS* e *Quantum GIS* (QGIS), em grande parte das operações. Também foi utilizada a *Orfeo Toolbox* para QGIS. Para alguns procedimentos específicos em série, utilizou-se linguagem de programação *Python*, incluindo os pacotes *GDAL*, *Numpy* e *Pandas*. Para armazenamento e organização de tabelas foi utilizado o formato HDF. Para o processamento de tabelas, elaboração de gráficos, análises matemáticas e estatísticas, recorreu-se aos pacotes *Pandas*, *Seaborn* e *Matplotlib*. A maioria dos *scripts* desenvolvidos para processamento de imagens encontra-se disponível no repositório que pode ser acessado em bitbucket.org/geopaitos/python-remotesensing, desenvolvido e mantido por Mariano e Foschiera (2014). O banco de dados de tabelas também pode ser acessado neste mesmo endereço.

3.3 Conjunto de dados

3.3.1 Mapa-base de agricultura anual do Paraná

Para o mapeamento das áreas de agricultura de soja e milho na região estudada, foram utilizadas imagens dos sensores *Thematic Mapper* (TM) e *Enhanced Thematic Mapper Plus* (ETM+) a bordo dos satélites Landsat-5 e 7, respectivamente. Foi tomado como base o ano-safra 2011/2012, tendo sido o mapeamento feito de

forma manual em conjunto com o Grupo de Estudos em Seguros e Riscos (GESER) da Universidade de São Paulo (USP), campus de Piracicaba (ESALQ). Os procedimentos para o mapeamento se basearam na metodologia descrita por [Ortiz et al. \(1997\)](#), consistindo, primeiramente, numa classificação automática pelo método da máxima verossimilhança (MaxVer) e, posteriormente, análise visual com edição dos polígonos gerados pelo MaxVer. Para o mapeamento utilizou-se a composição colorida RGB-453, de aplicação já consolidada na visualização de áreas agrícolas.

O mapa-base, embora referente à safra 2011/2012, foi utilizado para todo o período compreendido neste trabalho. Sabe-se que houve uma discreta expansão nas áreas de produção de grãos no Paraná no período em análise, no entanto, considerar a dinâmica espacial demandaria um grande esforço laboral na geração de máscaras de agricultura anual. O presente trabalho considerou a área total como estática ao longo do período, o que facilitou as análises de resultados, embora seja uma fonte de erro. Embora haja boas metodologias para gerar mapas de agricultura baseadas em imagens MODIS ([MARIANO et al., 2014](#); [WARDLOW; EGBERT, 2008](#)), ainda assim, a própria resolução das imagens é comumente incompatível com a distribuição geográfica da agricultura no Paraná, o que dificulta o uso de mapas anuais.

O resumo do mapeamento das áreas de soja e milho para a safra 2011/2012, realizado juntamente com o GESER¹, estão apresentados na Tabela 3.1.

¹ O trabalho de confecção do mapa foi em parte realizado pelo mesmo autor dessa dissertação, o qual fazia parte do GESER, tendo sido elaborado anos antes da idealização da dissertação. Sendo assim, não há uma referência formal para este mapa, assim como não se julgou necessária a análise estatística da qualidade do mesmo.

Tabela 3.1 - Área de agricultura mapeada e *pixels* utilizados nas análises

Meso	Micro	Área (ha)	<i>Pixels</i>	Analisada (ha)	Diferença (ha)
COCP	Campo Mourão	285.048	12.452	311.300	26.252
	Goioerê	221.858	9.729	243.225	21.367
NCP	Apucarana	63.052	2.760	69.000	5.948
	Faxinal	57.681	2.521	63.025	5.344
	Floraí	86.859	3.807	95.175	8.316
	Ivaiporã	124.869	5.507	137.675	12.806
	Londrina	137.201	6.000	150.000	12.799
	Maringá	53.270	2.279	56.975	3.705
	Porecatu	79.120	3.449	86.225	7.105
NP	Assaí	71.668	3.135	78.375	6.707
	Cornélio Procópio	109.314	4.767	119.175	9.861
OP	Cascavel	201.235	8.870	221.750	20.515
	Foz do Iguaçu	112.404	4.973	124.325	11.921
	Toledo	381.290	16.629	415.725	34.435

A coluna *Área (ha)* refere-se à área em hectares mapeada com base em imagens TM/Landsat-5 e ETM+/Landsat-7 (30 x 30 m²), *Pixels* refere-se ao número de *pixels* MODIS (500 x 500 m²) para cobrir a área mapeada, *Analisada (ha)* é o número de *Pixels* convertidos em área e *Diferença* é a comparação da *Área (ha)* com *Analisada (ha)*

Os polígonos que delimitam a área de agricultura são geralmente bastante irregulares e fragmentados, o que dificulta a análise dessas áreas com imagens de resolução espacial grosseira. Foi observada uma considerável diferença na área analisada em relação à mapeada, o que é certamente uma fonte de erro nos resultados apresentados no decorrer deste trabalho. Ao analisar a Tabela 3.1 conjuntamente com a Figura 3.1, optou-se por excluir das análises as microrregiões NP-Ibaiti, NP-Wenceslau Braz, NP-Jacarezinho e NCP-Astorga devido à baixa presença de áreas com agricultura anual e grande descontinuidade geográfica das mesmas, o que tende a dificultar qualquer análise baseada em MODIS. Sendo assim, das 18 microrregiões compreendidas nas mesorregiões consideradas, quatro foram descartadas por não serem representativas.

3.3.2 Dados agroeconômicos

As Tabelas 2.1 e 2.2 apresentam as áreas plantadas de soja e milho por mesorregião do Paraná para o período de 2002 a 2014, segundo estimativas do IBGE. Para a soja, não há discretização entre safra e safrinha, sendo o montante a soma de ambas. Porém, é sabido que há baixa ocorrência de soja em safrinha na região considerada. Sobre o milho, o IBGE disponibiliza tabelas distinguindo safra e safrinha,

portanto, os dados apresentados referem-se apenas às safras de verão. Está apresentada somente a variável "área plantada", no entanto, o IBGE disponibiliza também área colhida, produção e produtividade, tendo sido esta última utilizada em algumas análises do presente trabalho.

3.3.3 Dados meteorológicos

3.3.3.1 Precipitação estimada por meio de sensoriamento remoto

Os dados de estimativa de precipitação acumulada em 6 horas foram obtidos através do produto PERSIANN², os quais foram transformados para precipitação acumulada mensal. A grade é composta por células de $27 * 27km$, portanto, uma malha muito mais densa que a de estações meteorológicas. As imagens foram reamostradas para $500m$ através de interpolação pelo método bicúbico, com o objetivo de compatibilizar as resoluções espaciais de todos dados orbitais.

3.3.3.2 *Standardized Precipitation Index* (SPI)

O SPI é um índice que quantifica a anomalia de precipitação em relação a uma série histórica, como já visto na Seção 2.4.1. Para que o SPI seja confiável, a série histórica deve ser representativa, em geral, com mais de 30 anos de dados. Infelizmente, o produto de precipitação utilizado neste trabalho, o PERSIANN, não dispõe de uma série tão extensa. Foi então necessário recorrer a outra fonte de dados, neste caso, o *International Research Institute for Climate and Society* (IRI) da Universidade de Columbia - EUA, o qual fornece uma ampla e organizada base de dados climáticos através de seu portal (<http://iridl.ldeo.columbia.edu/>). Da base do IRI, foram adquiridos mapas de SPI3 para a região e período estudado com resolução espacial de $0,5^\circ$, o que equivale a, aproximadamente, $54km$ na latitude da região estudada.

Os mapas (*rasters* de SPI3) de resolução grosseira foram reamostrados para a mesma resolução das imagens MODIS, $500m$, utilizando interpolação bicúbica. A reamostragem não representa ganho de informação, porém, possibilita uma compartimentalização das informações nas regiões de forma mais adequada, além de uma melhor

² É importante mencionar que, na época da proposição desta dissertação, o sistema PERSIANN se encontrava operacional, tendo sido possível adquirir a série histórica dos dados para o período de 2000 a fevereiro de 2014. No entanto, atualmente, o sistema aparenta estar descontinuado, o que força o pesquisador que queira utilizar dados de precipitação estimada por satélite a buscar outras fontes. Felizmente, novos sensores disponibilizarão dados nos anos vindouros. Um exemplo concreto é a missão *Global Precipitation Measurement* (GPM) da NASA e *Japanese Aerospace Exploration Agency* (JAXA) com seu novo instrumento *GPM Microwave Imager* (GMI), sendo considerado o sucessor to TRMM.

compatibilidade com os dados espectrais utilizados.

3.3.4 Dados MODIS

O sensor MODIS esta presente nos satélites Terra e Aqua, lançados em 1999 e 2002 respectivamente. O sensor adquire individualmente imagens de uma mesma região praticamente a cada dois dias, ou quatro se consideradas as imagens termais noturnas. Isso faz com que o MODIS tenha uma alta resolução temporal. No entanto, esta alta frequência de aquisição de imagens é possível dado o largo campo de visada ($2.330km$) do sensor, o que acarreta em efeitos de distorção devido ao ângulo de aquisição, tendo estes sido descritos por [Breunig et al. \(2012\)](#) num estudo sobre os efeitos direcionais nos índices de vegetação aplicados à cultura de soja. De modo prático, esses problemas são em parte contornados através do uso de produtos compostos. Neste trabalho, foram utilizadas as composições de 8 dias, as quais consideram em sua elaboração o ângulo de visada e cobertura por nuvens. Em síntese, estes produtos agrupam em um pixel os melhores dados de uma série de 8 dias.

Os produtos MOD09A1 e MYD09A1 fornecem dados de reflectância de superfície para as bandas 1 a 7, com resolução espacial de $500m$ e temporal de 8 dias. Os dados do satélite Terra (MOD) são adquiridos por volta das 10:30 de cada dia enquanto que os do Aqua são obtidos aproximadamente às 13:30 do horário local. A Tabela 3.2 resume as bandas do MODIS presentes nos produtos utilizados neste trabalho. Um detalhe acerca do MODIS/Aqua é que sua banda 6 (SWIR1) apresenta-se comprometida, onde 15 dos 20 detectores ou não funcionam ou apresentam sinais ruidosos, gerando linhas brancas (sem dados) nas imagens ([RAKWATIN et al., 2009](#)).

Tabela 3.2 - Bandas do MODIS e algumas especificações técnicas.

	Banda	λ (nm)	Relação sinal-ruído	Resolução espacial (m)
1	Vermelho	620-670	128	250-500
2	NIR1	841-876	201	250-500
3	Azul	459-479	243	500
4	Verde	545-565	228	500
5	NIR2	1.230-1.250	74	500
6	SWIR1	1.628-1.652	275	500
7	SWIR2	2.105-2.155	110	500
31	Emissividade	10.780-11.280	-	1.000
32	Emissividade	11.770-12.270	-	1.000

Os dados termais foram fornecidos pelos produtos MOD11A2 e MYD11A2. Além das bandas de emissividade (31 e 32), o produto contém dados de temperatura de superfície [*Land Surface Temperature* (LST)], para o dia e para noite (LST-Day e LST-Night), com resolução espacial de 1000m e temporal de 8 dias. Segundo Wan (2008), os dados de LST apresentam erro médio de aproximadamente 1K, ou seja, um produto de alta qualidade. No presente estudo foram utilizados apenas os dados diurnos de LST. A Tabela 3.3 resume os dados orbitais utilizados neste trabalho.

Tabela 3.3 - Resumo dos dados orbitais utilizados.

Nome	M_D09A1	M_D11A2	PERSIANN	SPI3
Dados	Refl.	T	prec. (mm)	SPI3
Fornecedor	NASA	NASA	UCI	IRI
Formato I/O	hdf / tif	hdf / tif	bin / tif	ascii / tif
Resolução Espacial	500m	1000m	27km	54km
Resolução Trabalhada	500m	500m	500m	500m
Resolução Temporal	8 dias	8 dias	6 horas	mensal
Res. Temp. Trabalhada	8 dias	8 dias	mensal e 8 dias	mensal

Formato I/O refere-se aos dados de entrada (I - *input*) e saída (O - *output*), *Res.* é a resolução, *Temp.* é temporal e *Trab.* é trabalhada.

3.4 Metodologia

3.4.1 Filtragem de dados do MODIS

O processo de filtragem de dados de reflectância (MOD e MYD09A1) do sensor MODIS consistiu de duas etapas: combinação entre dados do MODIS/Terra e MODIS/Aqua (Seção 3.4.1.1) e filtragem das séries temporais (Seção 3.4.2.1).

3.4.1.1 Combinação entre dados do Terra e Aqua

Os produtos MOD09A1 e MYD09A1 foram combinados de modo a suprimir ou substituir dados contaminados por nuvens quando não coincidentes nas imagens provenientes dos sensores nos dois satélites. Este procedimento é baseado na abordagem utilizada por Sakamoto et al. (2013), a qual admite que a presença de nuvens pode ser facilmente identificada através da análise da banda do azul (B_3), assim, esta foi utilizada como parâmetro para comparação entre a qualidade das duas ima-

gens para uma mesma data. O programa escrito em Python executa o procedimento de fusão de dados, adicionalmente descartando pixels com valor incoerente, como em alguns casos da banda 6 do MODIS/Aqua. Estão descritos a seguir os passos executados pelo programa para esta filtragem:

- 1º Compara a banda azul das imagens dos dois sensores MODIS para uma mesma data, elegendo a de valor mais baixo;
- 2º Descarta *pixels* onde a refletância do azul é superior a 0,15;
- 3º Cria a máscara guia que indica de onde (MOD ou MYD) serão considerados os dados para o produto final;
- 4º Aplica-se a máscara guia para as sete bandas, gerando o produto MxD.

O produto final MxD é consideravelmente melhor que cada um dos originais individualmente, tendo assim, uma menor ocorrência de nuvens. Este produto é o dado de entrada para cálculo de todos os índices de vegetação, conforme consta na Seção 3.4.2. Não está no escopo deste trabalho a avaliação estatística da eficiência desta filtragem. No entanto, a análise visual dos resultados indicou um ganho de qualidade nas imagens.

3.4.2 Cálculo de índices de vegetação

Os dados MxD09A1 foram utilizados como entrada para cálculo dos IVs-VIR. Esses índices foram então filtrados utilizando o método descrito na Seção 3.4.2.1. Da série filtrada de NDVI, foram extraídos os parâmetros $NDVI_{min}$ e $NDVI_{max}$ para cada data referente a todos os anos. A partir destes parâmetros e da própria série de NDVI, foi calculado o VCI. Seguindo método semelhante ao VCI, foram calculados o TCI e PCI (*script* disponível em [Mariano e Foschiera \(2014\)](#)), porém, estes dois não foram submetidos ao processo de filtragem de séries temporais.

Para o cálculo do VHI foi utilizada a fórmula $VHI = \alpha VCI + (1 - \alpha)TCI$. A literatura acerca do valor de α é divergente, não estando claro se devem ser atribuídos pesos iguais para VCI e TCI ($\alpha = 0,5$) ou se isto pode ser flexibilizado. A decisão foi tomada com base na prática e na diminuição do σ ao longo das séries, porém, sem descartar totalmente um índice. É sabido que, dada sua natureza e resolução espacial, o TCI apresenta alto σ , o que insere variabilidade também no VHI, como demonstrado na Seção 4.2.3. Levando em consideração essas deficiências do TCI, foi estabelecido um $\alpha = 0,7$, portanto, dando apenas 30% de peso para o TCI e 70% para o VCI.

Finalmente, para o cálculo do SDI, foram agrupados os índices VCI, TCI e PCI

para cada data através de um processo simples de empilhamento (*layer stacking*). No entanto, o cálculo das PCAs pode ser imprevisível, pois seu resultado é totalmente dependente da imagem como um todo. Inicialmente, trabalhou-se com um *tile* inteiro do MODIS, o que inclui oceano e áreas muito diferentes da estudada, o que apresentou resultados incompreensíveis. Depois, foi calculada a PCA apenas para o estado do Paraná, mantendo-se inclusas áreas distintas da estudada, sendo possível identificar, ainda que precariamente, as áreas de agricultura. Optou-se finalmente por fazer um recorte apenas para a região de estudo, ou seja, as quatro mesorregiões de interesse, de onde foram calculadas as PCAs. O cálculo da PCA não foi restrito apenas às áreas de agricultura, mas sim, às quatro mesorregiões como um todo. O SDI é a 1ª componente principal, teoricamente contendo mais de 95% da variância dos dados de entrada.

3.4.2.1 Filtragem das séries-temporais de imagens

Mesmo após a filtragem descrita na Seção 3.4.1.1, a presença de ruídos ainda se manteve alta. Para contornar este problema, um procedimento de filtragem de séries-temporais foi realizado. Esta etapa se restringiu apenas aos índices de vegetação puramente ópticos (os IVs-VIR e VCI). A razão para tal é que o filtro descrito a seguir não se aplica aos dados termiais, cuja variação no tempo não segue um padrão típico como a da vegetação. Portanto, o TCI não foi filtrado e, conseqüentemente, o VHI também não foi. Quanto ao SDI, a filtragem tenderia a mascarar a característica principal da PCA, que é a variância ao longo do tempo, por isso, estas séries não foram submetidas a este procedimento.

Para elaborar o filtro, foram assumidos dois pressupostos: 1º) o índice de vegetação é reduzido devido à ocorrência de nuvens e contaminação atmosférica; 2º) crescimento abrupto e ou oscilações são inconsistentes em relação ao comportamento natural da vegetação. Isso permitiu desenvolver um filtro que preferencialmente eliminasse os efeitos dos valores inesperadamente baixos. Foi elaborado um filtro combinando MA e MM com janela de tamanho 7 (3 pontos antes e 3 após), ou seja, cada ponto foi filtrado a partir da média e mediana de 7 pontos. Neste trabalho, convencionou-se MA_n e MM_n , em que n é o tamanho da janela (e.g. MA_3 equivale a um filtro de média móvel de janela 3). O *script* em Python executa os seguintes procedimentos:

1º São desconsiderados inicialmente os valores de IV abaixo dos limiares estabelecidos como aceitáveis, em geral $-0,2$ para NDVI, EVI, NDI7, LSWI e NDWI. A estes valores é atribuído o código *NaN* (*not a number*), o que não entra no cômputo das médias e medianas, pois os SIGs e algoritmos computacionais ge-

almente compreendem o significado do NaN.

- 2º Calcula a média considerando a janela adotada ($3 + 1 + 3 = 7$);
- 3º Calcula a mediana considerando a mesma janela;
- 4º Considera como produto final a média móvel, porém, nos *pixels* onde a MA_3 for menor que $0,55 * MM_3$, considera-se a MM_3 ;
- 5º O processo é executado *pixel a pixel* para todas as imagens, reconstruindo todo o conjunto de dados e perdendo as três primeiras e últimas imagens.

Como resultado, foram obtidas imagens que, quando dispostas sequencialmente, apresentam séries temporais suavizadas, o que facilita sobremaneira a interpretação e possibilita análises mais aprofundadas. Este procedimento poderia ter sido executado diretamente sobre as bandas do MODIS e, posteriormente, os índices seriam calculados. No entanto, como os IVs apresentam em seu cômputo apenas entradas com expoente 1, a sequência de procedimentos é matematicamente indiferente. Além disso, nos trabalhos consultados (HIRD; MCDERMID, 2009; SAKAMOTO et al., 2010), os procedimentos de filtragem de séries temporais são executados diretamente sobre os IV. Portanto, optou-se por manter esta uniformidade.

3.4.3 Extração de estatísticas regionais

Devido ao grande volume de dados utilizados neste trabalho, é necessário se valer de ferramentas que os sintetizem, facilitando sua apresentação e análise. Para isso, frequentemente foram realizados procedimentos de extração de estatísticas descritivas de imagens com base em polígonos delimitadores de região, em geral, meso e microrregiões. As estatísticas mais comumente utilizadas foram a média, desvio padrão e tamanho da amostra (contagem).

O algoritmo utilizado para extração de estatísticas regionais considera em seus cálculos os *pixels* com ao menos 50% de sua área contida no polígono. Os polígonos base para extração de dados foram referentes às mesorregiões, microrregiões e agricultura anual por microrregiões, lembrando que este último é baseado em imagens TM e ETM+ do Landsat (30m). Portanto, é importante ter em mente que a análise de áreas agrícolas no Paraná é bastante comprometida pela baixa resolução espacial das imagens MODIS e quaisquer dados reamostrados para 500m, o que acarreta imprecisões nas medidas discutidas no decorrer do trabalho. Esse *script* desenvolvido foi utilizado em todas as etapas que envolveram extração de estatísticas de dados MODIS, SPI3 e PERSIANN por polígonos no decorrer do trabalho.

3.4.4 Análise de tendências

A partir das médias regionais extraídas por período de 8 dias para todos índices de vegetação, foram realizados testes estatísticos para detectar tendências nas séries temporais. O teste utilizado foi o de Mann-Kendall, o qual permitiu obter conclusões mais precisas em relação ao comportamento dos IVs para o período considerado de 11 anos. Os testes de Mann-Kendall foram aplicados às mesorregiões, de modo a simplificar as análises posteriores.

3.4.5 Extração de métricas fenológicas

A detecção de métricas fenológicas é uma etapa fundamental no estudo de séries temporais de condições de vegetação. O uso deste tipo de informação favorece a comparação de informações interanuais, o que é uma das propostas deste estudo. Como já mencionado na revisão de literatura, há diversos métodos para se detectar métricas fenológicas numa série temporal, porém, os métodos, em geral, apresentam resultados bastante similares se considerada uma frequência amostral de 8 dias. Sendo assim, no presente trabalho, optou-se pelo método mais simples, o de limiares (*thresholds*) (WHITE et al., 1997), porém, com as devidas adaptações.

A determinação da métrica SOS (*Start of the Season*) se deu em relação ao menor valor de NDVI a partir de setembro de cada ano-safra. Para isso, partiu-se do pressuposto de que, no Paraná, as safras não se iniciam antes de setembro, com isso, seguramente, o valor mínimo de NDVI será localizado nas proximidades do início da safra. Para se estabelecer uma margem de segurança, foi considerado como SOS o momento de oito dias antes do menor NDVI a partir do mês de setembro. A simplicidade do método é bem adaptada aos dados de oito dias. Porém, acredita-se que, ao trabalhar com dados diários, o método utilizado para detectar SOS pode ter grande influência nos resultados, sendo recomendado utilizar métodos mais robustos.

A Figura 3.4.5 apresenta uma série temporal idealizada para um índice de vegetação genérico. No presente trabalho, o 1º ponto será mais antecipado em comparação ao representado por Zhang et al. (2003), pois, considera-se hidrológicamente relevante o período imediatamente anterior ao início da ascensão do NDVI, o que é importante para estudos de seca agrônômica.

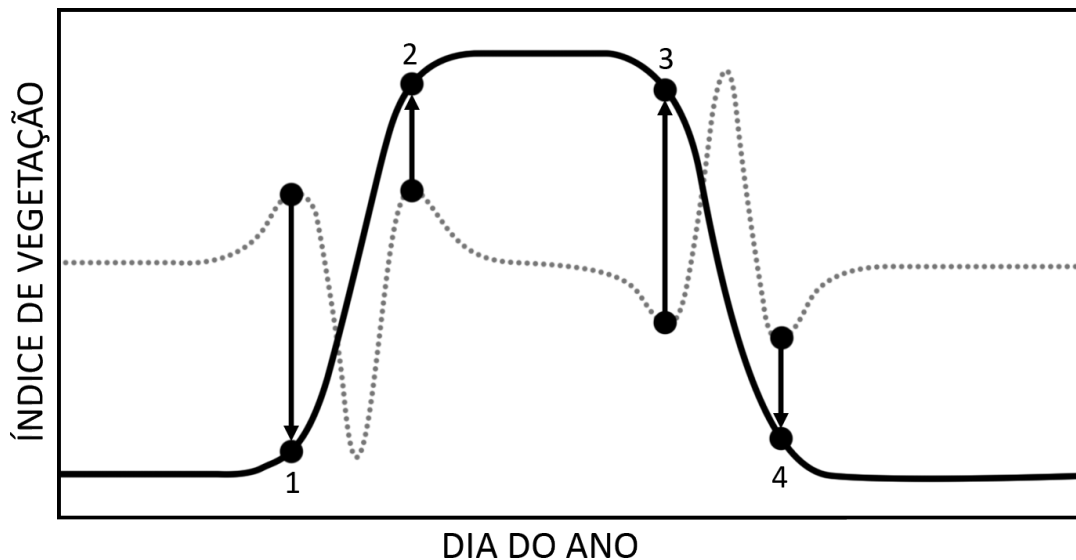


Figura 3.3 - Comportamento temporal hipotético de um índice de vegetação típico. A linha cheia corresponde ao IV, a pontilhada refere-se à magnitude e direção da variação do IV. Os pontos indicam os momentos de transição, os quais são coincidentes em ambas as curvas. O 1º ponto a partir da esquerda é o início da fase vegetativa, o 2º é aproximadamente o momento em que a planta atinge seu máximo de atividade fotossintética até o 3º, a partir do qual, inicia-se a senescência, o 4º ponto indica a fase de dormência, onde a atividade fotossintética aproxima-se a zero.

Fonte: Adaptado de Zhang et al. (2003).

3.4.6 Análise de métricas fenológicas no domínio da frequência

A análise de métricas fenológicas no domínio da frequência teve como objetivos, entender se houve variações consideráveis nas séries anuais e identificar padrões que auxiliassem nas análises da fenologia. Duas técnicas foram empregadas nesse sentido, a ACF e a WT, descritas nas Seções 2.10.3 e 2.10.5, respectivamente.

A aplicação da ACF e WT se restringiu apenas ao NDVI, por ser este extensivamente referenciado quanto à abordagem fenológica. No caso da WT, foram testadas várias *wavelets* mães de modo a detectar a que melhor se adequou ao padrão sazonal da vegetação.

3.4.7 Criação das linhas de base

As linhas de base são a média ou mediana histórica de um determinado índice de vegetação. Estas são o ponto de partida para a comparação anual entre um índice e seu histórico dentro do período compreendido. Para se obter uma medida

de tendência central (média ou mediana) histórica, é necessário que todas as safras sejam deslocadas para o mesmo ponto inicial, neste caso, o SOS.

No caso específico deste trabalho, é sabido que há anos bastante anômalos em relação à precipitação, o que levanta a hipótese de que também existam anomalias nos IVs. Neste ponto do trabalho, três caminhos poderiam ser tomados: 1^o) calcular a média histórica para cada data, o que seguramente será comprometida pelos anos ruins; 2^o) descartar os anos negativamente mais anômalos e calcular a média, gerando uma média mais elevada que a da opção 1, porém, perdendo representatividade com o aumento do σ ; 3^o) calcular a mediana sem descartar nenhum ano, gerando uma resposta localizada entre as opções 1 e 2. O critério adotado para a criação da linha de base foi o da robustez com menor sensibilidade a valores extremos, portanto, opção 3.

Para todos os índices, as imagens foram processadas para gerar as linhas de base a partir da mediana, no entanto, também foi calculado o desvio padrão da média como medida de dispersão, dando maior transparência aos resultados.

3.4.8 Análises de correlações entre indicadores

Como já apresentado, uma forma de se estudar a relação entre duas séries temporais é através da correlação de Pearson (ρ). Esta ferramenta tem o poder de mensurar a relação entre duas séries resumindo esta informação num único número. Baseado nisso, foram analisadas relações entre vários indicadores, dispondo-os em uma matriz, a qual denominou-se matriz de correlação de Pearson. Foi a forma encontrada de resumir um grande volume de informações e apresentá-las de forma compacta e inteligível. Esse procedimento foi utilizado para avaliar relações entre os próprios IVs e entre IVs e precipitação acumulada, SPI e estimativas de produtividade geradas pelo IBGE. Com isso, buscou-se identificar os IVs que apresentaram comportamento mais coerente com o esperado.

3.4.9 Relação de coerência entre IV e LST

As análises das relações entre o IV de melhor desempenho e a LST foram realizadas utilizando-se de métodos de WT para duas séries temporais. Primeiramente, foram calculadas a WT para cada série isoladamente. O próximo passo consistiu em gerar a XWT para o par IV-LST, identificando as frequências de alta potência em comum. Em seguida, foi calculada a WCT, identificando as frequências no tempo onde a covariância das séries é significativa.

A XWT e WCT retornam, além de aspectos de variância comum às duas séries e covariância, a diferença de fase entre as séries. O argumento complexo da XWT e WCT resulta no ângulo de fase (a parte imaginária de um número complexo). Relações simples de causa e efeito podem ser averiguadas a partir dos ângulos de fase resultantes da XWT e WCT. Estas análises proporcionaram um melhor entendimento acerca das relações entre IV e LST.

4 RESULTADOS E DISCUSSÃO

Nos gráficos apresentados, a convenção internacional foi forçadamente adotada, utilizando "." ao invés de ",", para separação de decimais. Ademais, em alguns casos, os textos foram apresentados em inglês devido à limitação de acentuação nos gráficos.

4.1 Análise do regime de chuvas

A área de trabalho foi caracterizada quanto ao seu regime de chuvas no período estudado. A Figura 4.1 apresenta a precipitação média anual e também as parciais para os períodos entre setembro e janeiro, quando se concentram as safras. Os mapas apresentados são baseados nos dados de precipitação estimados pelo modelo PERSIANN, evidenciando um gradiente de chuva acumulada de leste para oeste.

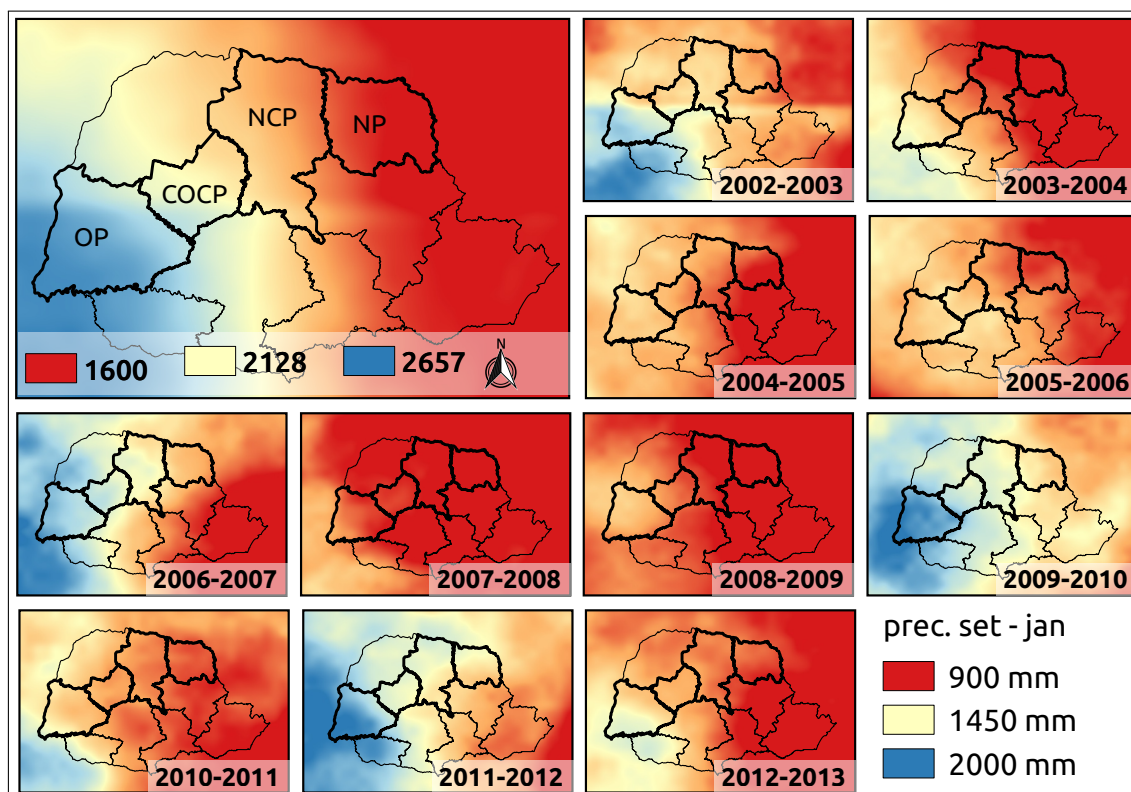


Figura 4.1 - Mapa de precipitação acumulada anual média (mapa maior) e precipitação acumulada de setembro a janeiro (mapas menores). A legenda da direita inferior é referente aos mapas pequenos.

Na Figura 4.1, foi possível notar a presença clara de artefatos, como a linha reta no ano-safra de 2002/2003. Adicionalmente, idealizava-se que as precipitações de setembro e fevereiro fossem de grande importância para a agricultura de verão nesta

região, o que será contrariado nas análises descritas na Seção 4.2.5.2.

O histórico de anomalias de precipitação foi representado pelos dados de SPI3 adquiridos junto ao banco de dados do IRI. A Figura 4.2 apresenta o perfil temporal do SPI3 ao longo do período estudado. Estão nela representadas as médias regionais e respectivos desvios padrão, tendo sido aplicado um filtro de MA_3 para facilitar a visualização. As barras verticais representam o desvio padrão das médias regionais, sendo estes bastante elevados, o que é consequência da grande variabilidade intra-regional, o que fica mais claro a partir da análise dos mapas apresentados na Figura 4.3.

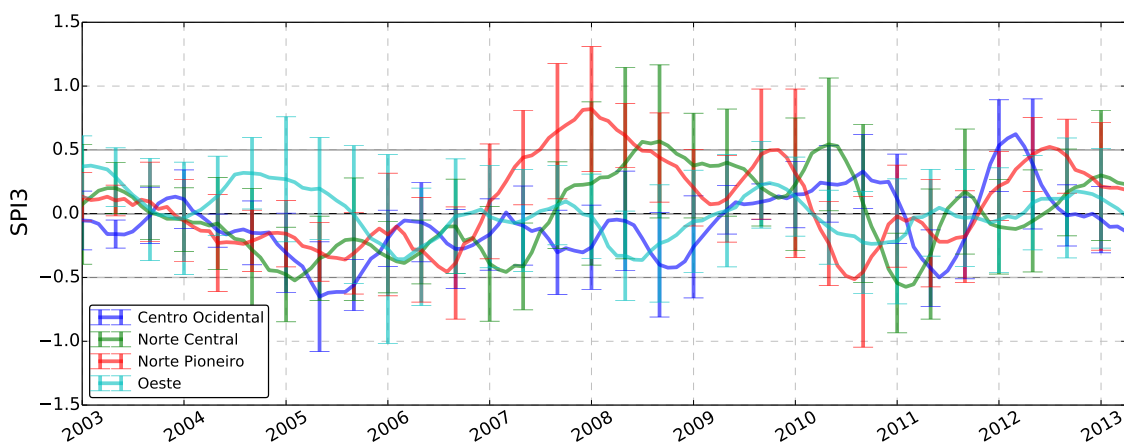


Figura 4.2 - Séries temporais de SPI3 suavizadas por um filtro de MA_3 .

De acordo com Mckee et al. (), uma definição mais precisa de seca pode ser dada baseada no SPI: seca é o período onde o SPI está abaixo de -1 , no entanto, esta definição pode ter diferentes impactos na avaliação de um cenário. No caso específico deste trabalho, foram considerados períodos de seca aqueles onde o SPI3 esteve abaixo de $-0,75$, pois, acreditou-se que o patamar de -1 seria muito extremo e pouco recorrente. Utilizando este conceito, foram analisados os anos de modo a detectar quais foram *muito secos*, *secos* e *normais*. O SPI3 foi acumulado de setembro a janeiro de cada ano-safra e a classificação se deu da seguinte forma: se $SPI3_{soma} < -3,0$ tem-se um *ano muito seco*, se $-0,5 > SPI3_{soma} > -3,0$ tem-se um *ano seco* e se $SPI3_{soma} > -0,5$ tem-se um *ano normal*. Essa abordagem permitiu caracterizar uma safra nessas categorias de seca descritas, pois considerou a persistência do evento entre os meses de setembro e janeiro. A Figura 4.3 apresenta os $SPI3_{soma}$ para cada ano.




Figura 4.3 - SPI3 acumulado de setembro a janeiro de cada ano-safra.

A análise dos mapas de SPI3 acumulado apresentados na Figura 4.3 permitiu visualizar espacialmente a ocorrência dos eventos de seca e suas intensidades. Foi notável que o cinturão da soja paranaense, ou seja, regiões NCP, COCP e OP foram frequentemente atingidas por secas de diversos graus de severidade. O SPI3 fornecido pelo IRI é proveniente de uma série de dados de precipitação de mais de 40 anos, o que permitiu afirmar que, no período estudado, as anomalias negativas foram bastante frequentes em relação à base de dados do IRI. Isso se fez evidente pela elevada ocorrência de valores negativos de SPI3 visto na Figura 4.3. No entanto, se considerando a área estudada como um todo, não foi possível classificar os anos-safra quanto à severidade da seca, porém, isso pôde ser feito localmente em termos de microrregiões. Estão listados a seguir os casos de ocorrência de *seca muito severa* e *severa*:

- Ano muito seco: $SPI3_{soma} < -3$;
 - 2004 - NCP-Ivaiporã;
 - 2005 - OP-Toledo;
 - 2006 - NCP-Porecatu;
 - 2010 - NP-Assaí, NCP-Londrina e Porecatu;
- Ano seco: $-3 < SPI3_{soma} < -2$;
 - 2002 - NCP-Ivaiporã;
 - 2004 - NCP-Porecatu;
 - 2005 - COCP-Goioerê, NCP-Londrina e Porecatu;
 - 2006 - NP-Assaí e Cornélio Procópio, NCP-Ivaiporã e Londrina;
 - 2007 - COCP-Goioerê;
 - 2008 - COCP-Goioerê;
 - 2010 - NCP-Apucarana, Faxinal e Ivaiporã, OP-Cascavel e Foz do Iguaçu.

4.2 Resposta dos IVs

Nessa Seção, discute-se primeiramente a análise de tendências para os IVs por mesorregião. Em seguida, a análise é focada em fenologia e neste ponto apenas o NDVI é abordado. Na sequência, o estudo se torna mais amplo, tendo sido avaliado o comportamento de cada IV em termos temporais, de frequências e espaciais, o que era um dos objetivos mais importantes do trabalho, ajudando a entender melhor as séries temporais. São, então, apresentadas as linhas de base e uma discussão sobre as mesmas. Avaliou-se o desempenho dos IVs em alguns casos selecionados e, utilizando-se o índice eleito, foram feitas análises aprofundadas quanto à relação do IV com uma variável ambiental de grande relevância.

4.2.1 Análise de tendências

A Tabela 4.1 resume os resultados dos testes de Mann-Kendall. O teste retorna a estatística τ e o p – *value* para cada série temporal. Considerando um nível de confiança de 95%, se o p – *value* estiver abaixo de 0,05 aceita-se a hipótese de que há tendência na série. Como pôde ser observado, indícios de tendência foram detectados em poucos casos (destacados em negrito). Os valores de *Kendall* τ próximos a 0, geralmente variando entre $-0,06$ a $0,06$, indicaram a inexistência de tendências.

Mesmo nas situações em que foi verificada a existência de tendência, estas foram fracas, sempre próximas aos limiares de não-tendência. A maioria das situações em que houve indícios de existência de tendências foram aquelas nas quais os IVs já apresentavam alto σ , como o SDI e o VHI, o que diminui a confiabilidade da análise para estes casos. Foram detectadas tendências também para apenas um caso de EVI e NDI7, ambos na mesma mesorregião NP.

Tabela 4.1 - Resultados dos testes de Mann-Kendall para detecção de tendências

IV	Região	Kendall τ	p-valor	IV	Região	Kendall τ	p-valor
EVI	COCP	0,0340	0,2420	LSWI	COCP	0,0142	0,6248
	NCP	0,0486	0,0938		NCP	0,0276	0,3444
	NP	0,0628	0,0306		NP	0,0469	0,1076
	OP	0,0033	0,9086		OP	-0,0004	0,9887
NDI7	COCP	0,0286	0,3244	SDI	COCP	-0,1756	0,0000
	NCP	0,0468	0,1069		NCP	0,0023	0,9373
	NP	0,0633	0,0292		NP	0,0920	0,0018
	OP	0,0075	0,7973		OP	-0,1483	0,0000
NDVI	COCP	0,0212	0,4649	VCI	COCP	-0,0148	0,6112
	NCP	0,0362	0,2124		NCP	0,0279	0,3385
	NP	0,0538	0,0639		NP	0,0557	0,0560
	OP	-0,0009	0,9748		OP	-0,0384	0,1876
NDWI	COCP	-0,0321	0,2686	VHI	COCP	0,0424	0,1478
	NCP	-0,0071	0,8064		NCP	0,0958	0,0011
	NP	0,0148	0,6090		NP	0,1182	0,0001
	OP	-0,0450	0,1210		OP	0,0135	0,6459

Tendo sido detectadas poucas situações de tendência e ainda considerando a incerteza inerente às mesmas, julgou-se desnecessário aplicar um procedimento para remoção delas (*detrending*). Desta forma, as análises das séries temporais puderam ser realizadas sem esta preocupação. Adicionalmente, a não ocorrência de tendências ao longo da série permitiu conjecturar as suposições a seguir:

- não houve degradação do sensor MODIS considerável ou não correção da mesma;
- não ocorreu avanço tecnológico agrícola que incrementasse os máximos de IVs;
- a degradação do ambiente de produção (solo) foi compensada pelas práticas de manejo físico e químico;
- o período de 11 anos não foi suficiente para apresentar tendência em nenhum dos casos supracitados.

4.2.2 Fenologia

A seguir é apresentada a Tabela 4.2 contendo a correlação de Pearson para as séries de NDVI entre as mesorregiões, indicando alta correlação entre as séries temporais. Isso permitiu realizar as análises de autocorrelação e WT (Seções 4.2.2.2 e 2.10.5, respectivamente) para apenas uma região, já que o comportamento nas outras é esperadamente o mesmo, dada as altas correlações positivas entre as regiões. Dentro da análise de fenologia, apenas a Seção 4.2.2.1 apresenta-se discretizada por regiões.

Tabela 4.2 - Correlação de Pearson para as séries de NDVI por mesorregião.

	Centro Ocidental	Norte Central	Norte Pioneiro	Oeste
Centro-Ocidental	1,000	0,959	0,885	0,948
Norte-Central	0,959	1,000	0,969	0,874
Norte Pioneiro	0,885	0,969	1,000	0,760
Oeste	0,948	0,874	0,760	1,000

4.2.2.1 Métricas fenológicas derivadas de séries de NDVI

Nessa Seção, são apresentados os resultados da análise de fenologia para as mesorregiões, seguindo a metodologia apresentada na Seção 3.4.5. As Figuras 4.4, 4.5 e 4.6 exibem o comportamento médio e desvio padrão do NDVI para cada mesorregião para as safras de 2002/2003 a 2012/2013. Também são apresentados os pontos de máximo e mínimo NDVI, sendo estes últimos, o parâmetro principal para determinar o SOS de cada safra. A partir das figuras foi possível notar que os pontos de mínimo ocorreram aproximadamente entre o final de setembro e metade de outubro para todas as safras. Ficou evidente também o elevado desvio padrão do NDVI, este decorrente de fatores do ambiente e de limitações do sensor MODIS em relação à resolução espacial nem sempre compatível com as áreas produtoras de grãos do Paraná. Uma discussão mais aprofundada sobre as medidas de dispersão encontra-se apresentada na Seção 4.2.3, compreendendo todos os IVs.

Nos gráficos apresentados também estão presentes as safrinhas, sendo que, estas não foram consideradas neste estudo e seus máximos e mínimos foram omitidos. Ainda assim, optou-se por representá-las para facilitar a visualização da diferença de amplitude de NDVI entre safra e safrinha além de uma melhor localização temporal dos ciclos agrícolas. Parte desta diferença pôde ser atribuída a uma maior relação entre milho e soja, em que a natureza erectófila do alvo milho proporciona menores

valores de NDVI se comparados à soja, que tem arquitetura planófila. Resultados semelhantes foram observados por Antunes e Esquerdo (), porém, os autores utilizaram dados do AVHRR. Uma análise rápida permitiu concluir que para todos os anos-safra, os SOS ocorreram sempre entre os dias 265 (22 de setembro) e 289 (16 de outubro), representando um intervalo de 24 dias ($3 * 8 = 24$).




Figura 4.4 - NDVI médio e desvio padrão por mesorregiões para as safras de 2002/2003 a 2005/2006.




Figura 4.5 - NDVI médio e desvio padrão por mesorregião para as safras de 2006/2007 a 2009/2010.

4.2.2.2 Autocorrelação de séries temporais de NDVI no estudo da fenologia

A análise da função de autocorrelação [*autocorrelation function* (ACF)] das séries temporais de NDVI buscou evidenciar alguns aspectos que não ficaram claros na seção anterior. A Figura 4.7 apresenta o correlograma para a série histórica de NDVI para a região Centro Ocidental. É possível notar que a ACF foi alta e decrescente com o tempo quando, a partir do 8º período, a ACF se inverteu, mantendo-se negativa até o 20º período, aproximadamente. A partir do 26º período, a ACF voltou a ser negativa até passar para um novo ciclo de forte intensidade a partir do 46º

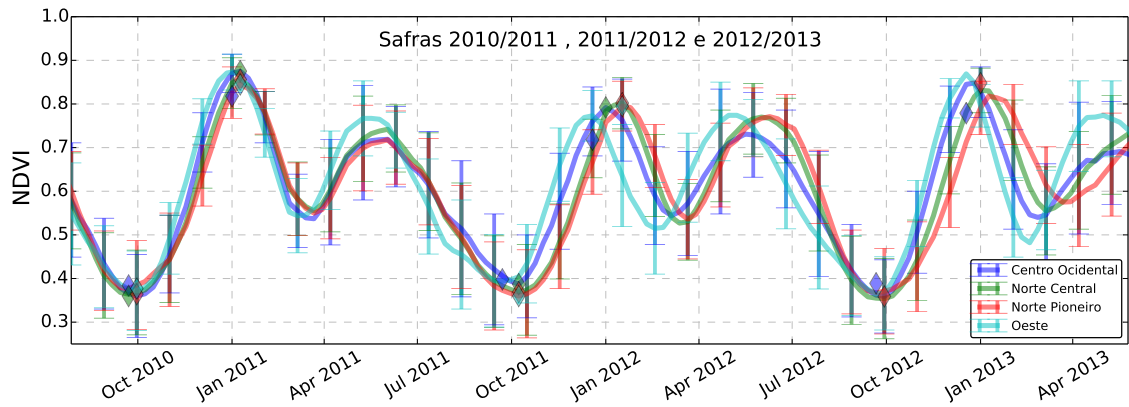


Figura 4.6 - NDVI médio e desvio padrão por mesorregiões para as safras de 2010/2011 a 2012/2013.

período. O ano é dividido em 46 períodos de 8 dias. Na ACF, é nítido que a cada aproximadamente 8 períodos, a concavidade da curvatura se inverte. Este intervalo de 8 períodos equivale a 64 dias, o que é, aproximadamente, metade do ciclo da soja e milho. Isso demonstra a alternância entre as safras de verão e inverno. Para as outras regiões estudadas, a ACF seria bastante semelhante dada a forte correlação entre as séries, como já visto na Tabela 4.2. Esta análise é uma abordagem alternativa para se detectar métricas fenológicas, sendo esperado que um ponto de mínimo NDVI diste 96 ($64 + 64/2$) dias de um de máximo NDVI. Uma prova deste comportamento é a evidenciação do ponto de maior anticorrelação (ACF mais negativa) no 12º período, equivalente a 96 dias. Finalmente, a ACF apresenta a vantagem de considerar a série histórica inteira, mostrando que ao longo do período estudado, a duração dos ciclos agrícolas não mudou.

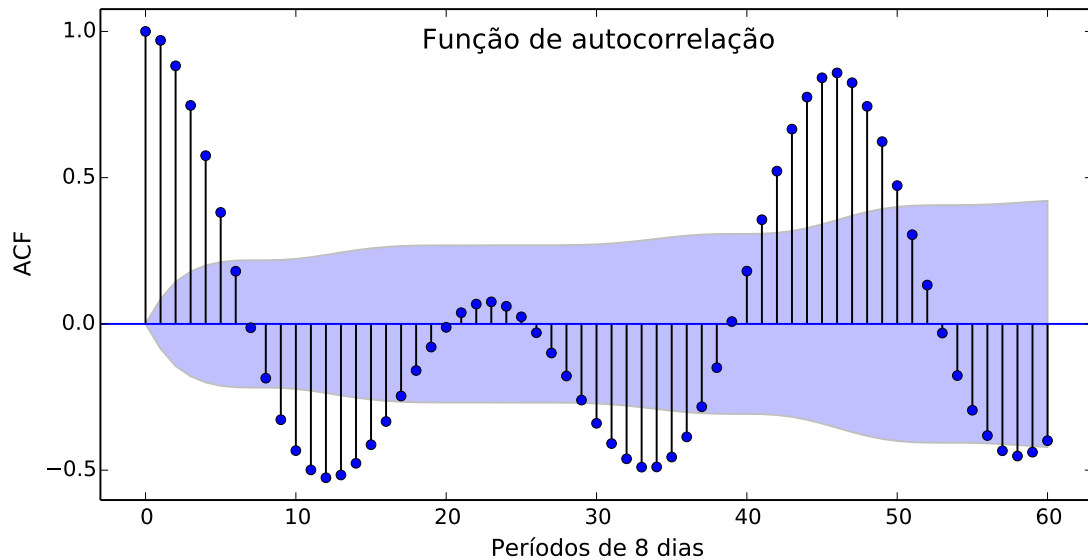


Figura 4.7 - Função de autocorrelação do NDVI para a mesorregião Centro Ocidental. A região sombreada compreende o intervalo de confiança de 95 %.

4.2.2.3 Transformada *wavelet* para uma série de NDVI

A análise da WT para uma série temporal de NDVI permitiu visualizar a ACF em uma perspectiva mais ampla, o que possibilitou estudar a variabilidade dos dados em diferentes escalas para todo o período considerado, sendo possível verificar a consistência da fenologia ao longo dos anos. A Figura 4.8 apresenta o espectro de potências da WT de Morlet para o NDVI da microrregião OP-Toledo. Várias *wavelets* mães foram testadas, tendo sido a de Morlet a que melhor se adaptou ao comportamento das séries temporais de NDVI. Esse modo de visualização da série permite identificar os períodos de potência mais intensada WT, ou seja, em que causa maior variabilidade na série temporal (áreas em vermelho). A área hachurada é delimitada pelo cone de influência, onde o espectro de potências é descartado em decorrência dos *end effects*, ou seja, o início e fim da série temporal. A região contornada em preto indica onde nível de confiança de 95 % foi satisfeito. O diagrama *Global Wavelet Spectrum* é simplesmente a média das potências por período ao longo de toda a série, evidenciando os picos nos períodos de maior potência, delimitados em sua base pela linha pontilhada indicando a região de significância. Por fim, o diagrama *2-8 year scale-averaged power* resume o comportamento da variância ao longo do tempo. Para um entendimento mais aprofundado dos detalhes da análise por *wavelet*, sugere-se os trabalhos de Torrence e Compo (1998) e Grinsted et al. (2004).

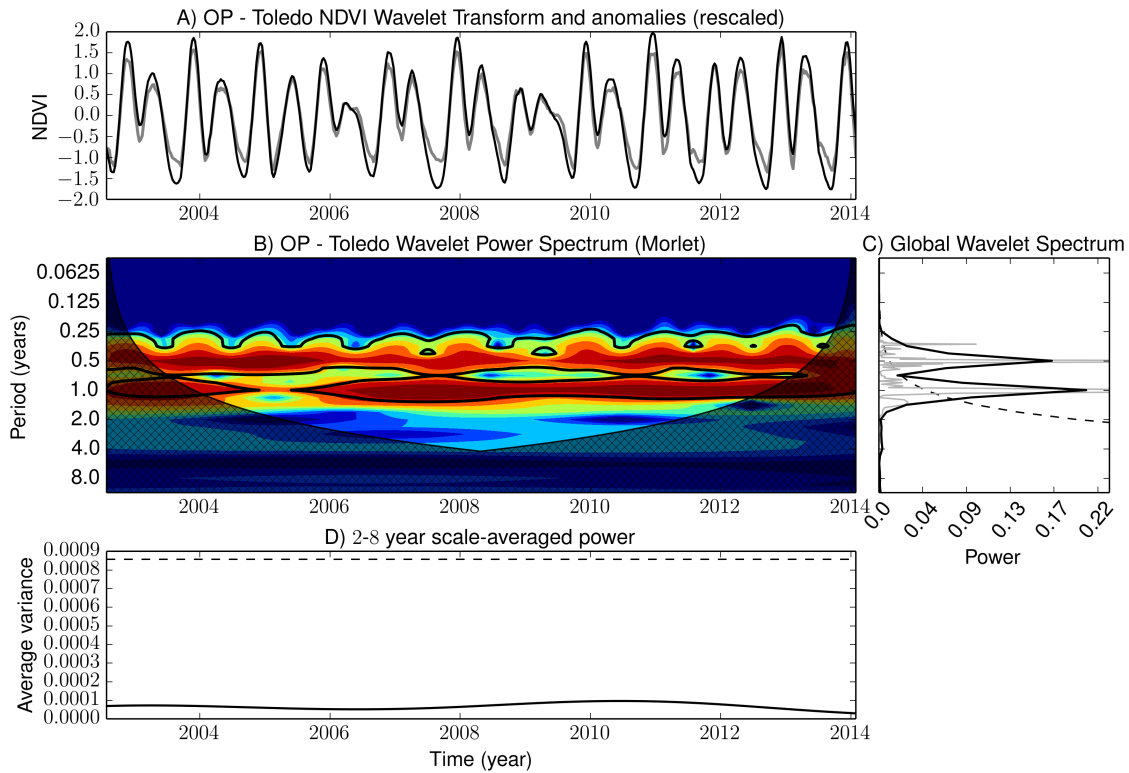


Figura 4.8 - Espectro de potência da transformada Wavelet (Morlet) para a série temporal de NDVI da microrregião OP-Toledo. A Figura **A** apresenta a série temporal original normalizada por $1/\sigma^2$ em preto e a WT em cinza. A Figura **B** apresenta o espectro de potência para a WT, a área não hachurada é delimitada pelo cone de influência; o contorno preto indica o setor do espectro de potência onde o nível de confiança de 95% é satisfeito. A Figura **C** indica o nível de potência para a toda a série, por isso chamado *Global Wavelet Spectrum*. A Figura **D** corresponde ao *2-8 year scale-averaged power*, demonstrando o comportamento da variância média ao longo do tempo.

Na Figura 4.8, são apresentadas, primeiramente, (A) as séries temporais originais e WT normalizadas, demonstrando a boa adaptação da WT de Morlet à série temporal de NDVI. Já o *NDVI Power Spectrum* (B) apresenta duas linhas vermelhas retas nos períodos de 0,5 e 1,0 ano. A linha de 0,5 ano é menos nítida que a de 1,0 ano, indicando que as safrinhas têm sua variabilidade centrada em 0,5, mas, com uma considerável margem, enquanto que a safra apresenta-se bem centrada em 1,0 ano. É da própria natureza da agricultura de grãos do Paraná esta maior flexibilidade na época da safrinha e mais rigidez na safra. Outra forma de visualizar esta diferença é a partir do *Global Wavelet Spectrum* (C), em que a base da curva de 0,5 ano é maior que a de 1,0 (considerando a linha de significância), indicando a amplitude da distribuição de potência. O gráfico D deixa claro que a variação dos valores da variância foi quase nula ao longo do tempo, o que está de acordo com as linhas

vermelhas presentes no gráfico B.

A análise da WT permitiu, em síntese, verificar como a variância se comportou na série temporal de NDVI, identificando como sendo os períodos de maior potência 0,5 e 1,0 ano, sendo estes padrões consistentes ao longo do período estudado. Também foi demonstrado que a WT de Morlet se adaptou bem à série temporal, o que permitiu uma boa caracterização da mesma e detecção precisa das variações de potência.

4.2.3 Linhas de base para os índices de vegetação

Na presente Seção foram apresentadas as linhas de base para cada IV considerado neste estudo. As séries anuais de cada índice foram deslocadas de modo a todas terem o mesmo ponto de partida, ou seja, o SOS. A partir daí, a numeração no tempo foi dada em números inteiros, sendo cada unidade corresponde a um período de oito dias. As linhas de base foram plotadas para o intervalo de 1 a 20 unidades, o equivalente a 160 dias. A Figura 4.9 apresenta as linhas de base para cada índice considerando os onze anos de dados. Os IVs tiveram também sua correlação de Pearson analisada entre os pares e apresentada na Figura 4.10.




Figura 4.9 - Linhas de base para os índices de vegetação apresentadas em suas escalas originais.




Figura 4.10 - Matriz de correlação de Pearson entre as linhas de base dos índices de vegetação. As estrelas indicam os níveis de confiança de 85%, 90% e 95% para *, ** e ***, respectivamente.

Como apresentado na Figura 4.9, os IVs-VIR apresentaram padrão bastante semelhante e baixo σ . No caso do VCI, que considera em seu cômputo dados referentes a série temporal inteira, o desvio padrão se mostrou bastante alto, o que levou à conclusão de que a introdução de métricas que representam dados de vários anos ($NDVI_{max}$ e $NDVI_{min}$) contribuíram negativamente para a confiabilidade do índice em termos de estatística descritiva. Além disso, as métricas de máximo e mínimo são puramente cronológicas, o que não considera a fenologia da vegetação agrícola, sendo este, portanto, um fator que compromete a qualidade desse tipo de índice.

A criação de linhas de base se deu utilizando séries de dados filtradas. Estas séries, apesar de apresentarem um comportamento bastante coerente com o que está presente na literatura, acabam por suavizar também eventos de interesse para este trabalho. Por exemplo, no caso de uma geada, praga ou doença muito severa, enfim,

fatores que representem rápido declínio no vigor da vegetação tendem a serem mascarados pelo processo de filtragem. Por essa razão, tanto as linhas de base quanto as séries das safras (como demonstrado nas Seções adiante) não apresentaram este aspecto em seu comportamento.

Como as linhas de base são produtos das séries temporais completas de cada IV, as correlações de Pearson entre as linhas são equivalentes às das séries completas. A partir da observação da Figura 4.10, ficou ainda mais evidente o comportamento das linhas de base entre pares, tendo como destaque a correlação negativa do SDI com os outros índices. Isso se explica pelo fato de que todos os IVs com exceção do SDI medem magnitude de parâmetros biofísicos do alvo enquanto que o SDI tem sua base na variabilidade, por isso, apresenta-se praticamente constante ao longo da safra tendo um decaimento após o fim da mesma (15^o período, 120 dias), onde a variação é abrupta.

Com relação ao TCI, analisada sua linha de base e sua baixa correlação de Pearson com outros IVs, verificou-se que este índice não tem relação forte com LAI [que é fortemente correlacionado com NDVI (CARLSON; RIPLEY, 1997; WANG et al., 2005)], devido à temperatura de superfície ser resultado da interação planta-atmosfera-solo-água. Desacoplar estes fatores dentro do TCI é uma tarefa que exigiria medições de campo bastante precisas, ou então, um melhor entendimento das variáveis adjuntas que exercem influência sobre o alvo. No trabalho de Kogan (1995a), criador do TCI, há pontos questionáveis acerca da eficiência do mesmo, pois realiza um procedimento de suavização dos dados de entrada. Sendo claro que a temperatura apresenta variabilidade de alta frequência (em períodos menores que uma semana), conseqüentemente, a filtragem de dados semanais pode incorrer em uma perda considerável de informação. Isso explica, em parte, o elevado desvio padrão ao longo da série temporal e também a não detecção de um padrão claro, uma vez que uma relação direta com os IV-VIR fosse esperada, segundo Karnieli et al. (2010). Resultados semelhantemente insatisfatórios foram encontrados por Bayarjargal et al. (2006), que compararam o desempenho de vários IVs, encontrando alta correlação entre os IVs-VIR, mas nada significativa entre qualquer IV-VIR e indicadores baseados em temperatura. Portanto, associar o TCI à condição de vegetação pareceu ser inviável, o que conseqüentemente colocou em dúvida a qualidade dos índices que utilizam o TCI em sua formulação (VHI e SDI).

O SDI, tendo como entrada VCI, TCI e PCI, apresentou, além de alto σ , parcialmente herdado do TCI, um comportamento totalmente diferente a partir do 15^o

período (120 dias), ou seja, o fim da safra de verão. O SDI é proveniente da 1ª PCA do conjunto, o que leva a crer que, após a colheita, a variância dos dados de entrada seja diminuída, pois não há mais presença do comportamento crescente ou decrescente da vegetação. O VHI, tendo sido dado um peso de 70% para VCI e 30% para TCI, assemelha-se ao VCI, mas herda a já comentada inconsistência do TCI.

De modo geral, os IVs-VIR apresentaram comportamento bem padronizado e correlacionado. Já os índices que carregam em seu cômputo dados referentes a uma série completa (VCI e TCI) apresentaram um σ mais alto. Por fim, índices que envolvem o TCI em sua formulação (VHI e SDI) apresentaram-se ainda mais inconsistentes, o que pôs em dúvida sua eficácia no monitoramento de seca em vegetação.

Por fim, um problema na construção das linhas de base foi referente à generalização do SOS. Este foi primeiramente calculado por microrregião e depois uniformizado para a área de estudo como um todo. As linhas de base foram produzidas *pixel a pixel*. Assim, o SOS generalizado foi, possivelmente, uma fonte de erro nas análises subsequentes. Trabalhos futuros podem ser idealizados no sentido de gerar as bases com SOS específico para cada microrregião ou até mesmo *pixel*. Como este trabalho teve uma abrangência geográfica bastante ampla, espera-se que análises realizadas em regiões mais homogêneas (ou menores) apresentem menor σ e, conseqüentemente, resultados mais confiáveis.

4.2.4 Comportamento dos IVs

Para melhor entender o comportamento dos IVs, foi escolhido como exemplo, um caso dentre uma gama de 154 possibilidades processadas (14 *microrregiões* * 11 *anos* = 154). O caso analisado foi o da região OP-Cascavel para o ano de 2010, com $SPI3_{soma}$ de $-2,04$, portanto, um ano de forte seca. A Figura 4.11 apresenta o perfil dos IVs comparados às respectivas linhas de base. Nos gráficos também estão representadas as somatórias dos IVs do 1º ao 15º período para a linha de base e a safra considerada. Também estão representadas as diferenças entre as mesmas (*dif*). A escolha do 15º se deveu ao fato de que, geralmente, a atividade fotossintética da planta já tenha cessado neste momento, estando a vegetação em senescência. À exceção do SDI, que foi normalizado em termos de desvio padrão, ou seja, centrado em 0, os outros IVs tiveram sua normalização limitada de 0 a 1. As somas foram calculadas em a partir dos dados normalizados, portanto, a comparação entre os índices pôde ser considerada justa (excetuado o SDI). A área em cinza escuro representa os momentos onde o IV da safra esteve abaixo da base, sendo o oposto representado pelas áreas em cinza claro. As linhas preta e cinza representam safra

e base, respectivamente. Esse padrão de apresentação foi mantido no decorrer do trabalho.




Figura 4.11 - Comportamento da vegetação descrito pelos IVs na microrregião OP-Cascavel para o ano 2010 com SPI_{soma} de $-2,04$.

Como observado na Figura 4.11, VCI, VHI e SDI apresentaram-se bastante incoerentes em relação aos demais. Como já discutido na Seção 4.2.3, VHI e SDI herdaram a inconsistência dos dados de temperatura. Quanto ao VCI, este apresenta-se semelhante ao VHI, porém, com um aspecto mais suavizado. Resumidamente, nenhum desses três IVs permitiu tirar conclusões sobre o caso OP-Cascavel-2010. Por outro lado, os IVs-VIR apresentaram comportamento bastante semelhante. NDVI e NDI7 captaram uma menor diferença entre base e safra, enquanto que EVI, LSWI e NDWI foram mais eficientes. O destaque ficou por conta do NDWI, que apresentou uma diferença de $-0,66$, a maior dentre os cinco índices tradicionais. Maior diferença representa um maior distanciamento da situação ideal (base), ou seja, neste caso analisado, os IVs puderam ser classificados quanto ao desempenho na seguinte ordem decrescente: NDWI, LSWI, EVI, NDI7 e NDVI, já desconsiderados VCI, VHI e SDI, para este caso.

O caso supracitado possui uma série de especificidades, a saber: $SPI3_{soma} = -2,04$, ano de 2010, microrregião OP-Cascavel, precipitação acumulada para os meses de outubro, novembro, dezembro e janeiro de $304mm$, $95mm$, $535mm$ e $268mm$, respectivamente. A tarefa de analisar oito IVs para esta situação foi realizada, no entanto, repetir o procedimento para todos casos existentes seria uma tarefa impraticável e a compilação de resultados seria muito onerosa. Felizmente, graças às poderosas ferramentas computacionais disponíveis, uma outra análise foi executada a fim de testar todas as possibilidades. A Seção 4.2.5 detalha os resultados.

4.2.5 Correlações entre indicadores

Nessa Seção estão apresentadas as correlações entre indicadores de vegetação, precipitação e agroeconômicos. Primeiramente, os indicadores relacionados à precipitação foram extrapolados para além do $SPI3_{soma}$, o qual era referente à soma de SPI3 de setembro a fevereiro. Foram criados novos indicadores semelhantes, mas com diferentes meses acumulados. A nomenclatura segue o esquema a seguir: $SPI3$ é seguido pela letra inicial de cada mês, ou seja, setembro, outubro, novembro, dezembro e janeiro. Resumindo, os indicadores testados foram $SPI3_{sondj}$ (era o antigo $SPI3_{soma}$), $SPI3_{ndj}$, $SPI3_{dj}$, $SPI3_n$, $SPI3_d$ e $SPI3_j$. De forma análoga, foram criados indicadores para a precipitação acumulada mensalmente, resultando em: p_o , p_n , p_d , p_j , p_{on} , p_{nd} , p_{dj} , p_{ndj} e p_{ondj} .

No que se refere aos IVs, foram testadas as diferenças entre safra e linha de base acumuladas nos 15 primeiros períodos, como já abordado na Seção 4.2.4. Por fim, a título ilustrativo, são correlacionados os indicadores de vegetação às produtividades estimadas pelo IBGE. Os resultados das análise estão apresentados nas Seções subsequentes.

4.2.5.1 IVs vs. SPI3

A Figura 4.12 apresenta a matriz de correlação das diferenças entre os IVs e suas linhas de base *versus* indicadores de SPI3 acumulado. Nessa Figura e nas similares apresentadas mais adiante, as correlações entre os próprios IVs e entre os indicadores meteorológicos não são o foco da discussão, mas sim, as relações entre IVs¹ e indicadores.

¹As relações entre os IVs apresentam-se discutidas na Seção 4.2.3, referente às linhas de base.

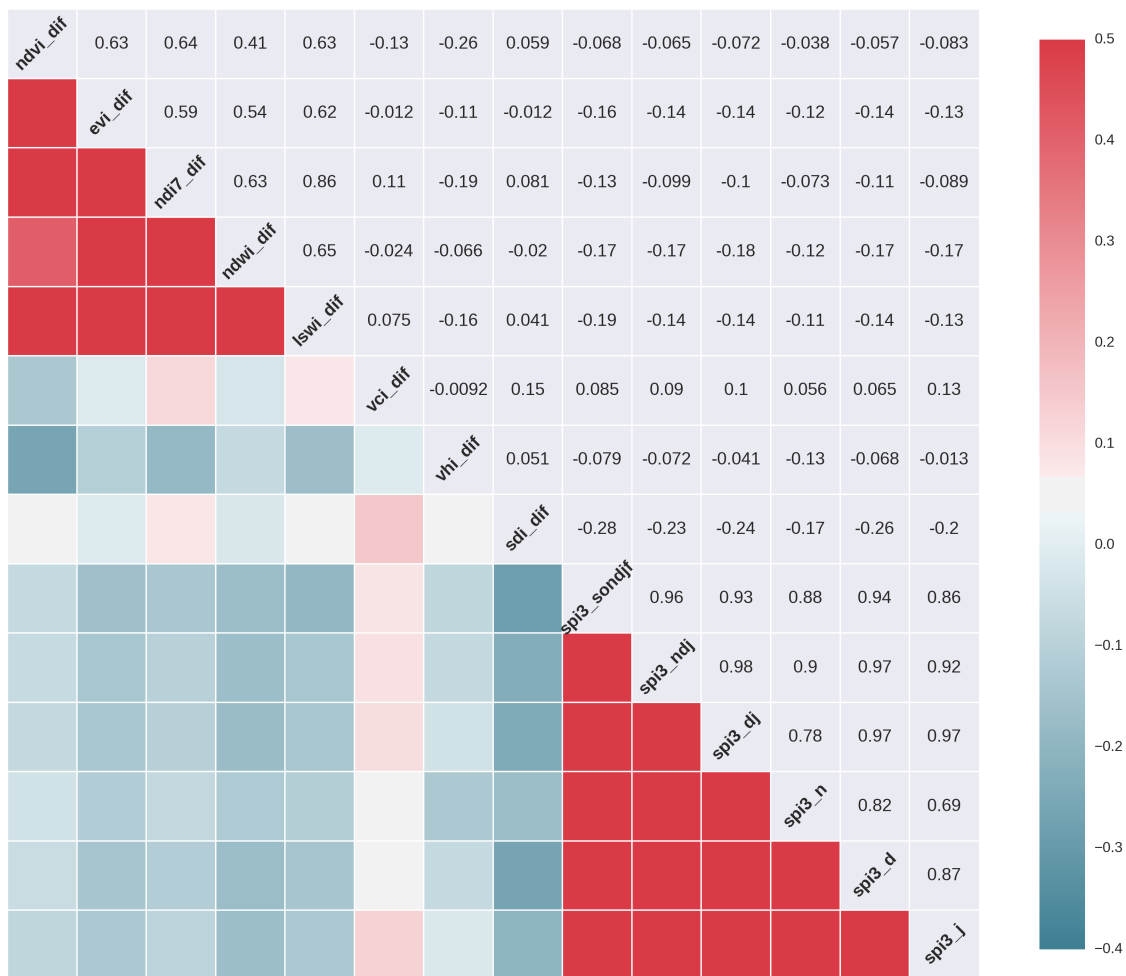


Figura 4.12 - Matriz de correlação de Pearson entre diferenças entre IVs de safra e base *versus* indicadores de SPI3.

Surpreendentemente, apenas o indicador VCI_{dif} se correlacionou positivamente com diferentes períodos de acúmulo de SPI3, sendo mais forte para o $SPI3_j$ e $SPI3_{dj}$, com r de 0,13 e 0,10, respectivamente. Embora esses valores sejam muito baixos, ainda assim apontaram que o SPI3 de janeiro (que refere-se a novembro, dezembro e janeiro) é o indicador de anomalia de precipitação que melhor explica o comportamento das diferenças entre safra e linha de base para o VCI. No entanto, esta análise lançou suspeitas sobre sua confiabilidade, dado o alto nível de incerteza (σ) inerente ao VCI, como já apresentado na Figura 4.9.

Fez-se necessário investigar essas relações de forma mais localizada geográfica e cronologicamente, tentando encontrar comportamentos mais coerentes com a teoria. A análise foi então refeita, estratificada por mesorregiões e anos-safra específicos,

porém, não isoladamente². A Figura 4.13 exibe a matriz de correlação considerando as regiões COCP e OP, duas das maiores produtoras de soja e milho do Paraná. Foi observado que o VCI ainda se manteve como sendo o IV mais positivamente correlacionado às anomalias de precipitação, porém, as análises ainda se mantiveram inconclusivas no que diz respeito aos IVs. Por outro lado, houve evidência de que as anomalias de precipitação para os meses de novembro, dezembro e janeiro ($SPI3_j$) demonstra que esse é o período crítico para a agricultura da região, no que diz respeito à precipitação.




Figura 4.13 - Matriz de correlação de Pearson das diferenças entre IVs de safra e base *versus* indicadores de SPI3 para as mesorregiões COCP e OP.

Por fim, a análise foi repetida, desta vez considerando apenas os anos onde os SPI3 de janeiro foram mais baixos, ou seja, os anos de anomalia negativa de precipitação

²A análise de correlações não pôde ter critérios tão rigorosos a ponto de reduzir drasticamente o tamanho da amostra, pois isso enfraqueceria a confiabilidade dos resultados.

mais relevantes dentro do período estudado, a saber: 2004, 2005, 2006, 2007 e 2011. Nesse caso, todas regiões foram consideradas. Não foi verificada nenhuma evidência que demonstrasse a eficácia dos IVs em se correlacionarem positivamente nesses cenários. Por esta razão, optou-se por não exibir a matriz de correlação.

O estudo do desempenho dos IVs considerando a diferença entre safra e linha de base e sua relação com o SPI3 mostrou-se em grande parte inconclusivo. As fracas correlações de Pearson não evidenciaram uma mudança de comportamento dos IVs de acordo com as classes de SPI3. Por outro lado, houve indícios de que os meses de novembro, dezembro e janeiro foram os mais relevantes para o comportamento da agricultura. Conjecturou-se que o principal fator responsável pelas fracas relações seja a baixíssima resolução espacial do SPI3 fornecido pelo IRI ($54 * 54km$). Na literatura, vários trabalhos apresentam coeficientes de determinação r bastante elevados entre SPI e índices de vegetação. Por exemplo, Caccamo et al. (2011) testaram uma gama de IVs para uma área imensa na bacia de Sydney-Austrália, obtendo r variando de 0,54 a 0,77.

4.2.5.2 IVs vs. precipitação acumulada

Essa Seção segue o mesmo padrão da anterior, porém, o enfoque foi nos dados de precipitação estimada pelo produto PERSIANN. A Figura 4.14 apresenta a matriz de correlação de Pearson entre as diferenças entre IVs e bases *versus* precipitação acumulada mensalmente.




Figura 4.14 - Matriz de correlação de Pearson das diferenças entre IVs e safra *versus* indicadores de precipitação acumulada.

O mês de janeiro mostrou-se o mais positivamente correlacionado com os IVs. Neste caso, o VCI, assim como na análise de SPI3, também foi o índice de melhor desempenho. No entanto, o mês de janeiro é determinante no desempenho de uma safra bem sucedida em termos de produtividade, ou seja, que tenha apresentado desenvolvimento satisfatório até então.

Foram analisadas as correlações considerando os anos mais secos, a saber: 2003, 2004, 2005, 2007, 2008 e 2012, para duas mesorregiões importantes (COCP e OP), a exemplo da Seção anterior. A matriz de correlação evidenciou uma aspecto chave na agricultura, a importância da chuva no mês de plantio ou anterior. Nos anos secos, o mês de outubro apresentou a maior correlação com as diferenças entre IVs das safras e suas bases. Notadamente, os meses posteriores tiveram pouca influência nos resultados. Isso indica que as culturas agrícolas analisadas, quando atingidas pela

seca nas fases iniciais ou de pré-plantio, pouco dependeram dos meses seguintes. Agronomicamente, um desenvolvimento inicial insatisfatório dificulta a criação de estrutura radicular para absorção de água, mesmo que essa seja abundante nos meses seguintes. A Figura 4.16 exemplifica essa situação, apresentando o caso de OP-Toledo para o ano de 2005. As escalas dos IVs são as originais, porém, os cálculos das diferenças são com base nos dados normalizados, portanto, comparáveis.

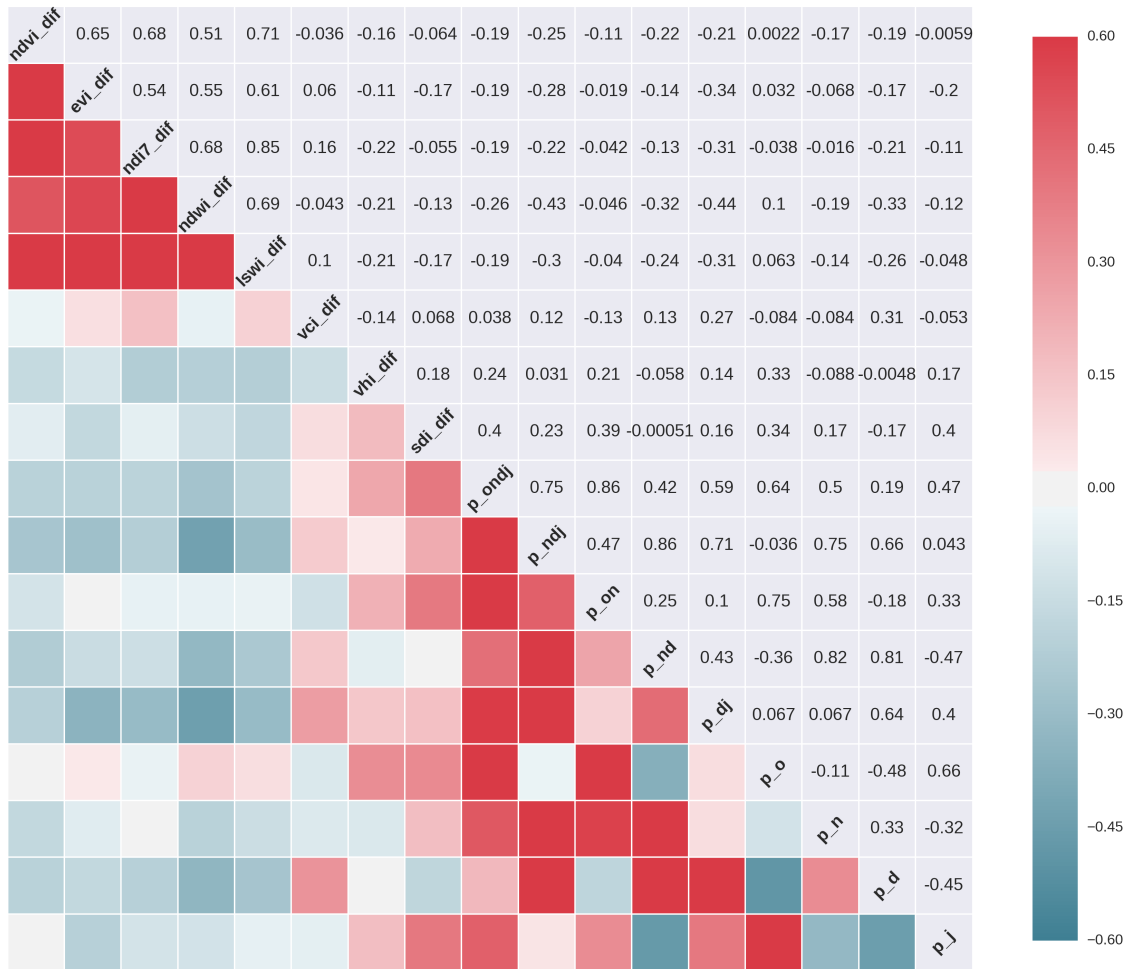


Figura 4.15 - Matriz de correlação de Pearson das diferenças entre IVs e safra *versus* indicadores de precipitação acumulada para os anos mais secos da série (2003, 2004, 2005, 2007, 2008 e 2012).

Embora ainda inclusos nas matrizes de correlação, as análises acerca dos índices derivados perdeu o sentido, dada a alta variabilidade e inconsistência dos mesmos. Portanto, a partir daqui, os índices VCI, VHI e SDI não foram contemplados nas discussões. Da análise das Figuras 4.15 e 4.16 conjuntamente, verificou-se indícios de que o EVI teria sido o IV mais eficiente em captar o impacto do fenômeno da seca

na vegetação, tendo sido o desempenho dos outros índices (NDWI, LSWI e NDVI) menos satisfatório. As séries temporais plotadas referem-se a um caso específico, já a matriz de correlação é mais abrangente. Nessa última, o EVI se mostrou menos correlacionado com a precipitação de outubro em relação ao NDWI e LSWI. Ao analisar vários casos separadamente (MESO-Micro-ano), verificou-se que, de modo geral, NDWI, LSWI e EVI apresentaram nessa ordem melhores resultados, como já observado na Figura 4.15.

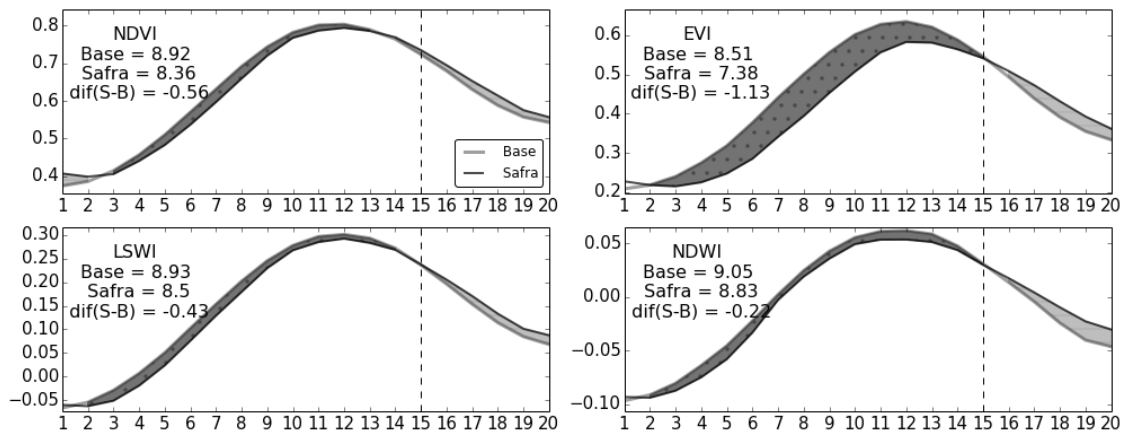


Figura 4.16 - Comportamento dos IVs para a microrregião de OP-Toledo no ano de 2005.

Em síntese, o desempenho dos índices é comparativamente bastante variável, sendo o NDWI ligeiramente superior ao LSWI seguido pelo EVI. No que diz respeito à precipitação, o mês de outubro exerceu maior influência sobre as diferenças entre safra e base para os anos secos, enquanto que, se considerados todos anos, janeiro é mais influente (Figura 4.14). Johnson (2014) também se viu decepcionado ao tentar relacionar IVs e indicadores de precipitação para as culturas da soja e milho, tendo verificado que a baixa qualidade dos dados de precipitação pode ter sido o principal fator para o desempenho aquém do esperado. O mesmo autor ainda levantou uma hipótese um tanto controversa, a de que a umidade no solo é estabelecida sobre um longo período, apresentando longa memória, de tal forma que a água consiga se manter nas camadas mais profundas e a planta seja capaz de alcançar esta camada, o que seria uma resistência à estiagem. No entanto, como observado na Figura 4.16, em anos secos, a falta de chuva nos meses de outubro foi determinante para o baixo desempenho das lavouras, o que vai contra a hipótese do autor, ou que a realidade dos ambientes seja suficientemente distinta a ponto de produzir resultados também distintos. Ainda que as correlações apresentadas sejam bastante baixas, muito

devido à limitação dos dados, exaustivas análises visuais dos gráficos caso-a-caso possibilitaram corroborar com os resultados apresentados na matriz de correlação de Pearson da Figura 4.15. Adicionalmente, em se comparando o desempenho dos IVs em relação a SPI3 e precipitação acumulada, esta última apresentou-se mais coerente com o comportamento dos IVs. Acredita-se que a resolução e qualidade dos dados PERSIANN foram determinantes para se verificar essa vantagem, uma vez que estes tem resolução espacial de $27km$ frente aos $54km$ do SPI3.

Não apenas as limitações dos dados de SPI e precipitação, mas a própria natureza da seca agrônômica faz com que estes indicadores apresentem dificuldade em rastrear tal fenômeno. Embora, com o intuito de detectar veranicos, o SPI e a chuva acumulada podem ser computados para períodos curtos, sua utilização ainda é limitada. Estes índices não levam em conta outros fatores do ambiente determinantes para o estabelecimento da seca, como as anomalias de temperatura, radiação solar e vento (OTKIN et al., 2013). A tentativa de englobar ao menos o fator temperatura nos índices se mostrou fracassada, como demonstrado pelos resultados das análises de VHI e SDI.

4.2.5.3 IVs vs. produtividade estimada pelo IBGE

Ainda dentro do escopo da correlação entre indicadores, uma terceira abordagem foi o estudo da relação entre os IVs e as produtividades estimadas pelo IBGE, ainda que estas sejam de natureza subjetiva. Foi mantida a estratégia de focar a análise na região mais relevante, ou seja, COCP e OP, diminuindo a heterogeneidade de ambientes de produção. A base de dados do IBGE não fornece informações sobre a safrinha de milho para os anos 2002 e 2013. Coincidentemente, estes anos não foram considerados secos e, aproveitando-se desse fato, optou-se por excluir os outros anos não secos, tendo sido a análise restringida aos anos secos: 2003, 2004, 2005, 2007, 2008 e 2012. A Figura 4.17 (A) apresenta a matriz de correlação de Pearson entre os IVs e a produtividade estimada de soja e milho pelo IBGE para os anos secos. A análise da matriz evidencia a boa correlação entre os IVs-VIR e a produtividade de soja, mas não de milho. Devido à subjetividade dos dados do IBGE, não foi possível concluir se, para o caso do milho, a baixa correlação é devido a alguma incoerência nas estatísticas agrícolas levantadas pelo instituto ou simplesmente pela baixa representatividade dessa cultura frente a soja na safra de verão. É sabido que, na região estudada, o milho é predominante na safrinha, ao contrário da soja, o que diminui sua amostragem e, portanto, dificulta a análise do mesmo.

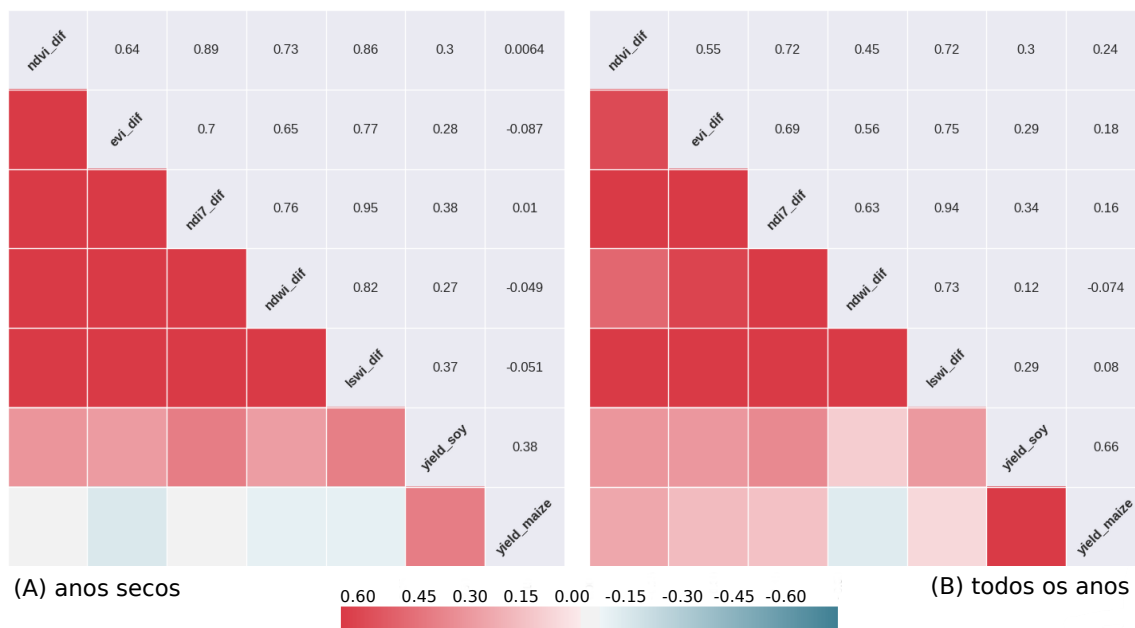


Figura 4.17 - Matrizes de correlação de Pearson entre diferenças entre IVs e safra *versus* indicadores de produtividade estimada (IBGE) de soja e milho para as mesorregiões COCP e OP. A Figura (A) refere-se aos anos secos, já a (B), a todos os anos.

A análise da Figura 4.17 (A) permitiu concluir que, considerando os anos secos, os índices LSWI e NDI7 tiveram destaque quando relacionados à produtividade de soja. A análise foi então repetida, desta vez, considerando todos os anos em que estivessem disponíveis os dados de soja e milho, ou seja, 2003 a 2012. Os resultados estão exibidos na Figura 4.17 (B), demonstrando ainda a boa correlação com a produtividade de soja e uma melhora considerável no desempenho dos IVs com o milho. Os IVs LSWI e NDI7 se mantiveram como os mais bem correlacionados às safras de soja e milho, o que atesta sua superioridade frente aos demais, dada sua versatilidade em situações normais e de seca. No caso do milho, esse aumento de desempenho dos IVs não pôde ser associado à cultura, mas sim, um acaso devido ao aumento da variabilidade decorrendo da redução da amostragem. Sendo assim, no presente trabalho, não foi possível tecer conclusões direcionadas unicamente ao milho, mas sim, generalizá-las para ambas culturas, pois, é como está disponibilizado o mapa-base, o qual não é discretizado entre as culturas. Discretizá-las incorreria em maiores imprecisões devido à diferença de resolução entre os sensores a bordo dos satélites Landsat (de onde se originou o mapa) e dos dados obtidos a partir do sensor MODIS (onde o mapa é utilizado). Além disso, não se pode esperar correlações altas entre produtividade e IV-dif somado, pois, diversos outros fatores têm impacto na produtividade final, tais como, a distribuição de chuvas dentro de um mesmo

mês, práticas de manejo e fitossanidade. Ou seja, biomassa não pode ser traduzida diretamente em produtividade, mas, ser um bom indicativo para a mesma.

Os IVs buscaram relacionar o vigor da vegetação à resposta do alvo frente à seca, o que é usado para identificar áreas afetadas por esse fenômeno. No entanto, esses IVs falharam em detectar estresse na planta prematuramente durante os estágios iniciais da seca, pois o sinal do IV só é robusto, para este caso, quando a planta já está severamente comprometida (MORAN, 2004). É o que torna possível identificar a seca em agricultura ainda que sem muita clareza. Por essas razões, não é trivial correlacionar efetivamente os IVs ao nível de estresse da agricultura quando atingida pela seca. Portanto, relacionar os dados de produtividade agrícola aos níveis de seca mostrou-se pouco eficaz, embora baixas correlações ainda tenham sido observadas. Como apresentado nas Seções 4.2.5.1 e 4.2.5.2, embora seja de conhecimento comum que a anomalia negativa nos níveis de precipitação seja a principal causa da seca, esses indicadores são, segundo a literatura, lentos em rastrear os efeitos desse fenômeno na vegetação. Indicadores mais rápidos devem ser considerados, a Seção 4.2.5.4 aborda esta relação.

4.2.5.4 IVs vs. LST

Respostas rápidas aos sinais da seca definitivamente não puderam ser observadas de forma clara a partir do comportamento dos IVs-dif e tampouco pelos indicadores de precipitação. No entanto, um sinal de rápida resposta é tradicionalmente dado pela temperatura, que na abordagem por sensoriamento remoto considerada neste trabalho, é representada pela LST. Foram então calculadas as regressões lineares entre os IVs-VIR de melhor desempenho e a LST, estando apresentadas na Figura 4.18, a qual se refere à microrregião OP-Toledo. Foram avaliados os IVs NDVI, EVI, NDI7 e LSWI, tendo apenas o EVI apresentado desempenho inferior frente aos demais.

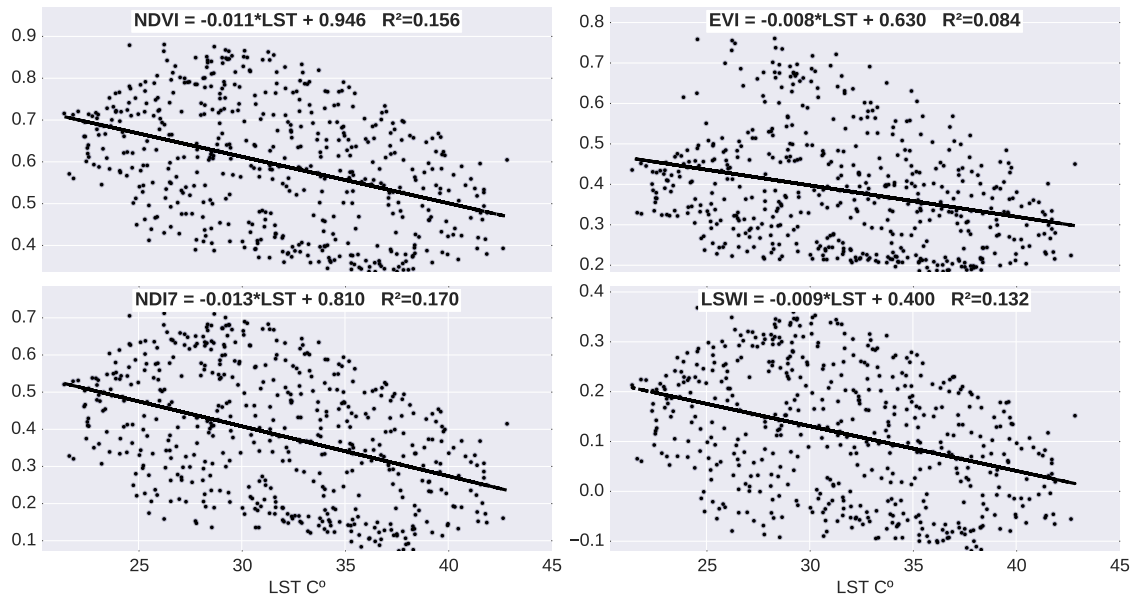


Figura 4.18 - Regressões lineares entre os IVs e LST para a microrregião OP-Toledo.

Foi verificada uma relação inversa entre IV e temperatura, como esperado. Ao passo que a umidade do solo na zona radicular decresce, menos energia é gasta em evapotranspiração, o que incorre em aumento de temperatura, se comparada à vegetação em situação de umidade ideal, quando consideradas as mesmas condições atmosféricas (ANDERSON et al., 2013). Por essa razão, a resposta dos IVs em relação à temperatura pode ser utilizada como uma *proxy* para a umidade do solo e consequentemente, detecção de seca no ambiente agrícola (SON et al., 2012). Foram calculadas as regressões lineares para todas as microrregiões e os resultados agregados em termos de média para cada IV encontram-se apresentados na Tabela 4.3. Os resultados apontaram que, em média, o EVI apresenta um R^2 de 0,15, o que está bem abaixo dos outros índices abordados nesta análise. A Tabela 4.4 resume os resultados das regressões por microrregião, tendo já sido descartado o EVI.

Tabela 4.3 - Média dos resultados da regressão entre IVs e LST por IV.

IV	intercepto	coef. angular	R^2
EVI	0,696	-0,009	0,150
LSWI	0,489	-0,011	0,246
NDI7	0,922	-0,016	0,284
NDVI	1,037	-0,013	0,260

Tabela 4.4 - Média dos resultados das regressões entre IVs (LSWI, NDI7 e NDVI) e LST por microrregião.

Região	intercepto	coef. angular	R^2
COCP - Campo Mourão	0,757	-0,012	0,238
COCP - Goioerê	0,741	-0,012	0,178
NCP - Apucarana	0,894	-0,016	0,361
NCP - Faxinal	0,820	-0,013	0,257
NCP - Florai	0,934	-0,018	0,210
NCP - Ivaiporã	0,670	-0,008	0,141
NCP - Londrina	0,943	-0,017	0,243
NCP - Maringá	0,873	-0,015	0,199
NCP - Porecatu	0,932	-0,017	0,226
NP - Assaí	0,954	-0,018	0,238
NP - Cornélio Procópio	0,888	-0,016	0,225
OP - Cascavel	0,683	-0,009	0,153
OP - Foz do Iguaçu	0,619	-0,007	0,127
OP - Toledo	0,718	-0,011	0,152

Após as análises apresentadas nesta e nas Seções anteriores, foram comparados os desempenhos dos IVs-VIR e, resumindo os resultados, concluiu-se que o LSWI reuniu os melhores atributos para caracterização da seca, se comparado aos demais índices. Este se mostrou versátil quando a anos normais e secos, desempenho mediano em relação às variáveis de precipitação e correlação satisfatória com a produtividade de soja. Embora o desempenho de índices como o NDWI e NDI7 tenha sido bastante similar ao do LSWI, julgou-se este último como sendo o mais propício para a análise de seca agrônômica. Isto se deveu principalmente à base com a qual o LSWI é calculado, pois potencialmente capta a umidade do dossel da vegetação e também do solo. Optou-se, então, por levar o LSWI adiante em algumas análises específicas. Foram calculadas as correlações cruzadas entre os LSWI-LST e NDVI-LST, este último par servindo apenas como critério comparativo. A Figura 4.19 apresenta os correlogramas cruzados dos pares apresentados para a microrregião OP-Toledo. A análise da figura indica que a LST é sempre muito correlacionada com o NDVI, mas não com o LSWI, o qual tem um pico após 10 períodos (80 dias). Isto equivale a dizer que a relação NDVI e LST é ligeiramente redundante, embora também apresente um pico no 10º período. Já para o caso do LSWI, essa relação é nitidamente crescente, ou seja, no $lag = 0$, a correlação é menor que no $lag = 10$, ou seja, o LSWI tem menor redundância que o NDVI em relação à LST. Esta interpretação não é conclusiva, uma vez que a LST é resultante, primeiramente, de fatores ambientais,

sendo apenas uma porção menor advinda da cobertura do solo. Segundo [Goward et al. \(2002\)](#), os fatores mais críticos que causam variação na relação entre LST e IV são a umidade do solo nas camadas mais superficiais, radiação incidente e, em menor grau, a velocidade do vento. Segundo [Chandrasekar et al. \(2010\)](#), enquanto o NDVI se baseia nas relações de refletância do R e NIR, fornecendo informações sobre a condição da vegetação, o LSWI se baseia no NIR e SWIR, sendo que a água apresenta alta absorvância da radiação no SWIR. Assim, tanto a água da vegetação quando a do solo exercem influência sobre o comportamento do LSWI. Os resultados apresentados em relação ao desempenho do LSWI se destacando frente aos outros IVs é corroborado pelas as observações de [Goward et al. \(2002\)](#) e [Chandrasekar et al. \(2010\)](#), o que permitiu concluir que o LSWI foi, dentre os IVs avaliados, o de melhor desempenho na caracterização da seca em agricultura.

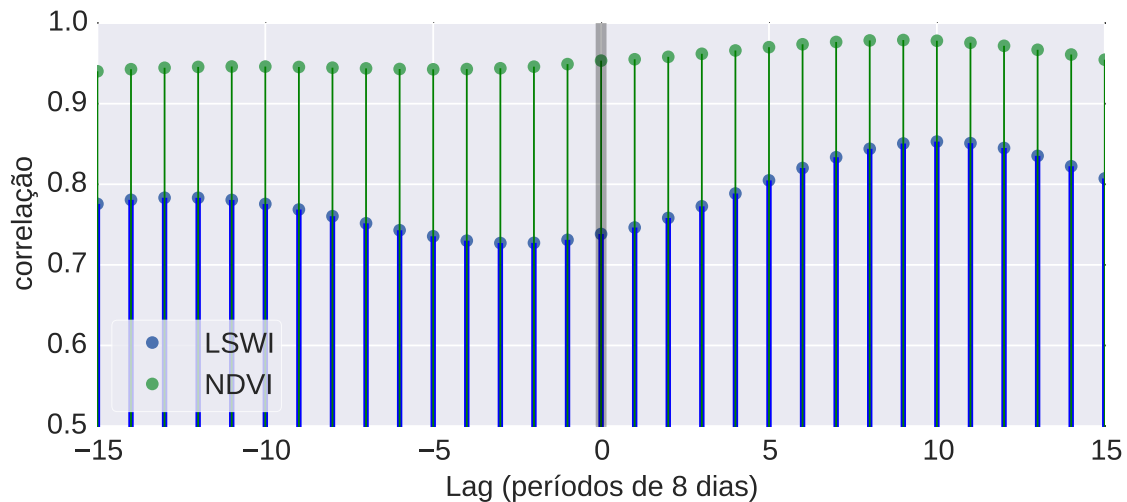


Figura 4.19 - Correlação cruzada entre NDVI-LST e LSWI-LST para a microrregião de OP-Toledo.

4.3 Relações de causa e efeito entre LSWI e LST

A partir deste ponto, tendo sido considerado o LSWI como sendo o índice que melhor caracteriza a seca em agricultura, optou-se por levá-lo adiante em análises mais aprofundadas. Foram avaliadas as relações entre as WT de LSWI e LST através das técnicas XWT e WCT. Por questões de sequência, as análises foram mantidas com foco na microrregião de OP-Toledo. A Figura 4.20 apresenta as WTs para LSWI e LST, utilizando *wavelet* mãe de Morlet. Como observado na Figura, há alta potência em ambas as séries para os períodos 23 e 46, ou seja, metade e um ano, o que equivale às épocas da safrinha e safra, respectivamente. É notado também que o

LSWI tem sua potência mais uniforme que o LST nos períodos significativos, dada a própria natureza do perfil da temperatura ao longo dos anos.




Figura 4.20 - WT do LSWI e LST para a região de OP-Toledo. A escala representa a variância normalizada (potência) entre as séries.

A partir da XWT, foram identificadas as frequências onde ambas as séries têm potência significativa em comum, sendo esta traduzida em covariância³. Visualmente, esse procedimento é equivalente a sobrepor os dois espectros de potência apresentados na Figura 4.20 identificando as regiões coincidentes em potência significativa. A XWT entre LSWI e LST encontra-se apresentada na Figura 4.21 (A), onde a área demarcada significativa apresenta, na frequência de 46, ângulos de fase em torno de 270° , indicando que as séries não estão nem em fase nem em anti-fase, e que a LST afeta o LSWI. Já no período 23, que é o de safrinha, a relação é de anti-fase com ângulos de aproximadamente 210° , ou seja, o comportamento da LST é o simples

³ Dá-se o nome de covariação à variação simultânea entre duas ou mais variáveis, e de covariância à grandeza estatística que serve para medi-la.

reflexo do LSWI, porém, tendo essas duas variáveis uma relação inversa, o que era esperado. Apesar das constatações, a análise da XWT foi pouco conclusiva, pois, a ocorrência de frequências de alta potência em comum entre as séries pode ser decorrente de simples coincidência, ou então, como verificado, uma relação indicando que o comportamento de uma variável é espelho da outra, sem necessariamente haver uma relação de causalidade.

A Figura 4.21 (B) apresenta a WCT, a qual permitiu entender essas relações mais a fundo. Foi observada presença de coerência significativa apenas entre os períodos de 16 a 32, os quais perfazem a safrinha. As ocorrências de anomalias significativas se deram nas safrinhas de 2005 e 2010 e em menor grau em 2008. Não estava no escopo deste trabalho avaliar a performance das safrinhas, no entanto, a análise da WCT indica que, assim como na XWT, as regiões de coerência significativa apresentam-se em anti-fase (aproximadamente 210°), também indicando uma ligeira relação inversa entre LST e LSWI.




Figura 4.21 - XWT e WCT entre LSWI e LST para a microrregião OP-Toledo. A Figura (A) refere-se à XWT, sua escala é a da esquerda e representa a covariância. A Figura (B) refere-se à WCT e sua escala é a da direita, representando a covariação. Para ambas figuras, as setas apontadas para cima (norte) indicam que a relação está em fase (causa-efeito), sendo o contrário apontado para baixo (sul), ou seja, anti-fase (espelho). Setas apontando para a direita (leste) indicam que a relação LSWI/LST é positiva, enquanto que setas apontando para a esquerda indicam o contrário, ou seja, LSWI e LST tem relação inversa.

Como já discutido na Seção 4.2.5.4 e agora reforçado pela análise da XWT e WCT,

há uma relação inversa entre LST e LSWI. No entanto, esta foi significativamente coerente apenas para alguns anos de safra, indicando que a temperatura possa ter tido alguma influência no comportamento de LSWI. Quanto às safras de verão, nestas não foram detectadas situações de causa-efeito entre as variáveis, o que é corroborado com as afirmações de [Goward et al. \(2002\)](#), ou seja, a temperatura é principalmente reflexo de variáveis ligadas à umidade do solo e fatores atmosféricos, não exercendo influência direta sobre o LSWI.

4.4 Espacialização da seca

Esta Seção teve como intuito apresentar, em forma de mapas, os resultados dos cálculos da diferença de LSWI entre safra e linha de base (*LSWI-dif*) para a área de estudo. Os mapas foram elaborados utilizando a métrica estabelecida na Seção 4.2.4, ou seja, foram somados os 15 primeiros períodos de cada safra e subtraídos os equivalentes da linha de base. As Figuras 4.22 e 4.23 apresentam os mapas de *LSWI-dif*. Nas Figuras, a cor vermelha indica regiões onde o LSWI esteve abaixo do linha de base, azul indica regiões de comportamento próximo à linha de base enquanto a cor verde indica acúmulo de *LSWI-dif* acima da base.

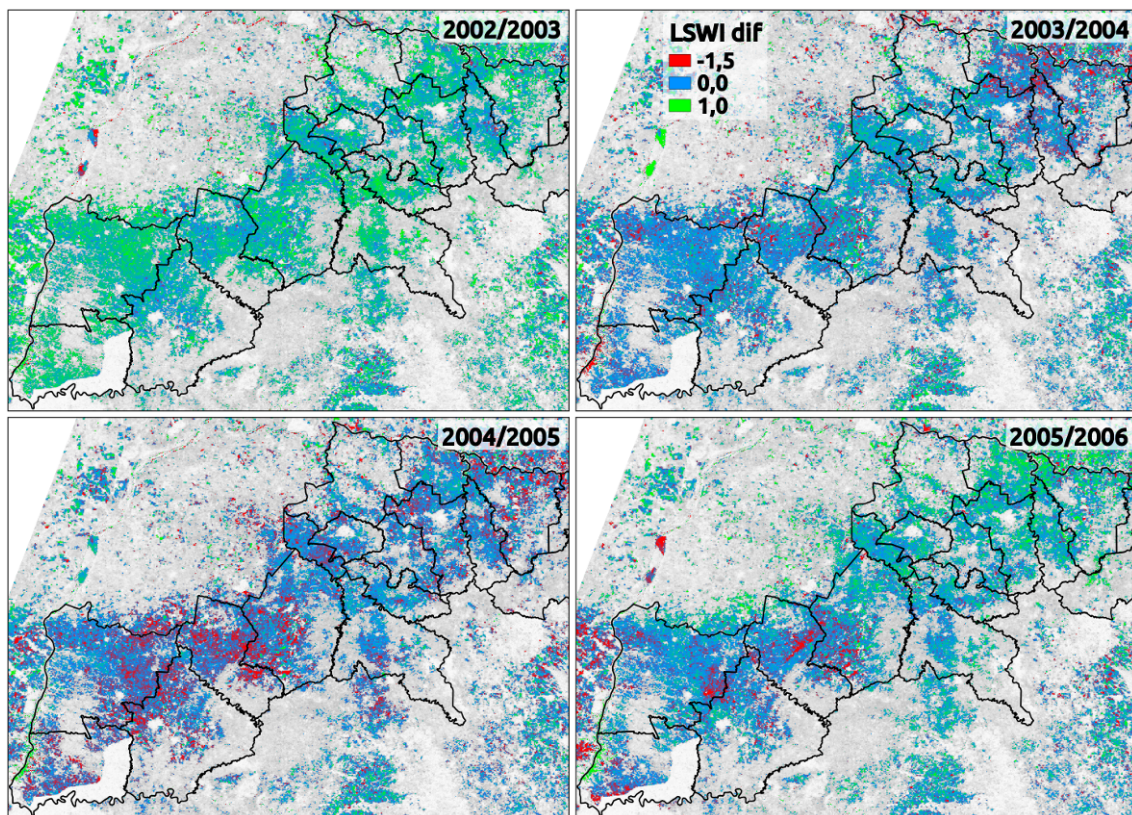


Figura 4.22 - Mapas de *LSWI-dif* para a região de estudo de 2002/2003 a 2005/2006.




Figura 4.23 - Mapas de *LSWI-dif* para a região de estudo de 2006/2007 a 2013/2014.

A análise das Figuras 4.22 e 4.23 evidenciou as regiões onde a agricultura apresentou desempenho abaixo da média histórica, demarcadas em vermelho, próximas à média em azul e acima da média, em verde. Nos mapas de precipitação acumulada (Figura 4.1 na Seção 4.1), foi possível identificar os anos com baixa pluviosidade na época da safra para a maior parte da região estudada, a saber: anos-safra 2003/2004, 2004/2005, 2007/2008, 2008/2009 e em menor grau de severidade, 2012/2013. Já os anos de 2002/2003, 2009/2010 e 2011/2012 foram de chuva abundante. Ao comparar visualmente os mapas de precipitação aos de *LSWI-dif*, foi verificada razoável coerência. No entanto, as correlações com a precipitação acumulada, apresentaram-se muito baixas, 0,063 para o mês de outubro nos anos secos e 0,13 para janeiro se considerados todos os anos, como já apresentado na Seção 4.2.5.2.

Embora associar indicadores espectrais ou pluviométricos às estimativas de produtividade não estivesse incluso no escopo deste trabalho, algumas comparações foram pertinentes a fim de ilustrar os resultados. Para exemplificar uma situação clara, basta observar a microrregião NCP-Floraí para os anos-safra 2008/2009 (*LSWI-dif* muito baixo) e 2009/2010 (*LSWI-dif* muito alto), tendo apresentado produtividade de soja estimada em 1563kg/ha e 3232kg/ha, respectivamente. Outro exemplo, para a microrregião de COCP-Goioerê para os anos-safra de 2004/2005 (baixo *LSWI-dif*), 2003/2004 (*LSWI-dif* mediano) e 2010/2011 (alto *LSWI-dif*), a produtividade estimada de soja foi de 2437kg/ha, 2674kg/ha e 3314kg/ha, respectivamente. Como apresentado na Seção 4.2.5.3, o *LSWI-dif* apresentou correlações com a produtividade estimada de soja de 0,38 para anos secos e 0,29 se considerados todos os anos.

5 CONCLUSÕES

O presente trabalho objetivou caracterizar a seca agrônômica em soja e milho para a região do Paraná utilizando dados MODIS e PERSIANN. Para tal, dentre uma ampla gama de IVs e métodos disponíveis, vários testes e análises foram realizados a fim de eleger o melhor conjunto de técnicas e métodos.

Foi analisado o regime de precipitação durante o período estudado, demonstrando um gradiente crescente nos níveis acumulados de leste para oeste e identificados os anos-safra mais secos como sendo 2003/2004, 2004/2005, 2007/2008, 2008/2009 e, em menor grau de severidade, 2012/2013. A análise do SPI3, dada sua resolução (54km) bastante grosseira, não possibilitou fazer a distinção entre os graus de severidade de seca com boa precisão. Desta forma, concluiu-se que os dados de precipitação foram mais eficientes que os de SPI em caracterizar a seca em termos meteorológicos, ainda que de forma pouco precisa.

Criou-se uma linha de base para cada pixel, baseado na fenologia da agricultura e uma mediana histórica para 11 anos, tendo os índices VCI, VHI e SDI apresentado alto desvio padrão, o que de antemão já pôs em descrédito sua utilização, não sendo levados adiante nas avaliações. Já os índices IV-VIR (NDVI, NDWI, EVI, NDI7 e LSWI) apresentaram comportamento mais coerente e também bastante correlacionados entre si. Este índices foram então colocados à prova, no sentido de verificar seu comportamento em caracterizar as safras agrícolas em anos secos e anos normais. Após vários testes, concluiu-se que, em anos secos, a precipitação de outubro é de maior importância, enquanto que, em anos normais, as chuvas de janeiro são as mais relevantes. Quanto aos índices, o LSWI apresentou-se como sendo o mais versátil, pois teve bom desempenho em todos os anos, sendo considerado ligeiramente superior aos outros IVs-VIR.

Baseado na literatura e após análises, aliou-se o LSWI à uma variável ambiental que pudesse alternativamente auxiliar na caracterização da seca agrônômica. Foi então estudado o comportamento do LSWI conjuntamente com o LST, tendo sido verificadas, através de regressões lineares, relações inversas entre as variáveis. Utilizando-se técnicas de WT cruzada e coerência de WT, não foi encontrada relação de causa-efeito entre LSWI e LST durante a safra, mas sim, de espelho. Ou seja, as variáveis respondem de forma inversa a um terceiro ou a n fatores externos. Segundo a literatura, estes fatores são a umidade do solo próxima à superfície, radiação solar incidente e velocidade do vento. Em safrinha, foi verificada uma relação mais estreita entre as variáveis, mas também não sendo de causa-efeito.

Por fim, a métrica para mensuração do desempenho da agricultura na safra em termos de LSWI-dif foi espacializada na forma de mapas. Foi verificada visualmente razoável concordância entre os mapas de vegetação e os de precipitação acumulada. Para fins ilustrativos e não de validação do método, verificou-se que a coerência se manteve quando os resultados de LSWI-dif foram confrontados com dados de produtividade do IBGE, o que demonstrou que o método utilizado é capaz de auxiliar na análise das safras agrícolas. Sugere-se a aplicação do metodologia em áreas menores, com melhor controle das variáveis e maior precisão dos dados para validação.

Em síntese, o método proposto para se mensurar as condições da agricultura em anos de seca e não seca, se mostrou eficiente, provando também que o LSWI tem melhor desempenho para este propósito, porém, ainda é pouco utilizado, segundo a literatura. Ademais, experimentos localizados para validação são ainda necessários. O LSWI se baseia em variáveis que têm maior relação com a umidade do solo, que é o principal fator de causalidade na seca, por isso, apresentou desempenho superior para esta finalidade. Portanto, os resultados aqui apresentados demonstraram que um esforço deve ser feito no sentido de incluir nas futuras metodologias, dados de umidade do solo estimadas por sensoriamento remoto.

Com a aplicação do método proposto, uma série de limitações veio à tona. A utilização de um máscara estática para todo o período é uma possível fonte de erro, causadora de variância nas estatísticas regionais. A resolução espacial dos dados MODIS é, em muitos casos, muito grosseira para a escala de ocorrência de agricultura no Paraná, sendo isso uma das principais fontes de erros. Quanto aos dados meteorológicos, a resolução é sabidamente ainda mais degradada, porém, no caso do SPI, esse foi um fator que praticamente o inutilizou neste trabalho, tendo sido consideradas inconclusivas as análises nele baseadas. A generalização regional do SOS também apresenta-se como uma fonte de imprecisão, fazendo com que as linhas de base sejam menos precisas. Quanto às filtragens de séries temporais, estas representaram um *trade off*, pois, ter séries suavizadas que permitiram realizar todos os procedimentos posteriores teve o custo de uma certa perda de informação, porém, não se sabe o quanto foi perdido.

Muito ainda pode ser melhorado, abrindo novas linhas a serem exploradas, por exemplo: estabelecer linhas de base com fenologia baseada no próprio *pixel* ao invés de região provavelmente melhoraria o desempenho do método; verificar o *LSWI dif* em períodos menores permitiria rastrear os impactos da seca e associá-los às fases fenológicas. Isso permitira, baseado também em dados de previsão meteorológica, abrir

caminho para um sistema robusto de monitoramento e previsão de seca agrônômica, o que representaria não só um grande ganho científico, mas também uma poderosa ferramenta para tomada de decisão.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE ÁGUAS. **Inventários de estações pluviométricas**. Brasília, 2009. 495 p. Disponível em: <<http://arquivos.ana.gov.br/inf hidrologicas/InventariodasEstacoesPluviometricas.pdf>>. 6

ANDERSON, M. C.; HAIN, C.; OTKIN, J.; ZHAN, X.; MO, K.; SVOBODA, M.; WARDLOW, B.; PIMSTEIN, A. An Intercomparison of Drought Indicators Based on Thermal Remote Sensing and NLDAS-2 Simulations with U.S. Drought Monitor Classifications. **Journal of Hydrometeorology**, v. 14, n. 4, p. 1035–1056, ago. 2013. ISSN 1525-755X. Disponível em: <<http://journals.ametsoc.org/doi/abs/10.1175/JHM-D-12-0140.1>>. 63

ANTUNES, J. F. G.; ESQUERDO, J. C. D. M. Monitoramento agrícola usando análise harmônica de séries temporais de dados NDVI/AVHRR-NOAA. In: INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2009. **Anais...** Natal: INPE. p. 49–55. 43

ATZBERGER, C. Advances in remote sensing of agriculture: context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949–981, fev. 2013. ISSN 2072-4292. 9

ATZBERGER, C.; EILERS, P. H. A time series for monitoring vegetation activity and phenology at 10-daily time steps covering large parts of South America. **International Journal of Digital Earth**, v. 4, n. 5, p. 365–386, set. 2011. ISSN 1753-8947. 9, 13

BAYARJARGAL, Y.; KARNIELI, A.; BAYASGALAN, M.; KHUDULMUR, S.; GANDUSH, C.; TUCKER, C. A comparative study of NOAA-AVHRR derived drought indices using change vector analysis. **Remote Sensing of Environment**, v. 105, n. 1, p. 9–22, nov. 2006. ISSN 00344257. 50

BREUNIG, F. M.; GALVAO, L. S.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Variation of MODIS reflectance and vegetation indices with viewing geometry and soybean development. **Anais da Academia Brasileira de Ciências**, v. 84, n. 2, p. 263–74, jun. 2012. ISSN 1678-2690. 9, 28

CACCAMO, G.; CHISHOLM, L.; BRADSTOCK, R.; PUOTINEN, M. Assessing the sensitivity of MODIS to monitor drought in high biomass ecosystems. **Remote Sensing of Environment**, Elsevier Inc., v. 115, n. 10, p. 2626–2639, out. 2011. ISSN 00344257. 8, 56

CAMARGO, A. P.; PINTO, H. S.; BRUNINI, O.; PEDRO, M. J.; ORTOLANI, A. A.; ALFONSI, R. R. Clima do Estado de São Paulo. **Zoneamento Agrícola do Estado de São Paulo**, Secretaria da Agricultura São Paulo, v. 1, p. 51–86, 1974. 4

CARAMORI, P. H.; WREGE, M. S.; CAVIGLIONE, J. H.; MARTORANO, L. Época de semeadura com menor risco climático para milho nos Campos Gerais do Paraná. In: **Congresso Brasileiro de Meteorologia**. Rio de Janeiro: Sociedade Brasileira de Meteorologia, 2000. p. 460–464. 3

CARLSON, T. N.; RIPLEY, D. a. On the relation between NDVI, fractional vegetation cover, and leaf area index. **Remote Sensing of Environment**, v. 62, n. 3, p. 241–252, 1997. ISSN 00344257. 50

CAZELLES, B.; CHAVEZ, M.; BERTEAUX, D.; MENARD, F.; VIK, J. O.; JENOUVRIER, S.; STENSETH, N. C. **Wavelet analysis of ecological time series**. maio 2008. 287–304 p. Disponível em:
<<http://www.ncbi.nlm.nih.gov/pubmed/18322705>>. 19

CHANDLER, R. E.; SCOTT, M. E. **Statistical methods for trend detection and analysis in the environmental sciences**. West Sussex, UK: John Wiley & Sons, 2011. 388 p. ISBN 111999196X. Disponível em:
<<http://books.google.com/books?hl=en&lr=&id=zLh30kKWJ7QC&pgis=1>>. 13, 15, 18

CHANDRASEKAR, K.; SETHA-SAI, M. V. R.; ROY, P. S.; DWEVEDI, R. S.; ROY, P. S.; DWEVEDI, R. S. Land Surface Water Index (LSWI) response to rainfall and NDVI using the MODIS Vegetation Index product. **International Journal of Remote Sensing**, v. 31, n. 15, p. 3987–4005, ago. 2010. ISSN 0143-1161. Disponível em:
<<http://www.tandfonline.com/doi/abs/10.1080/01431160802575653>>. 65

CHEN, D.; HUANG, J.; JACKSON, T. J. Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. **Remote Sensing of Environment**, v. 98, n. 2-3, p. 225–236, out. 2005. ISSN 00344257. 10

COLLISCHONN, B.; ALLASIA, D.; EDUARDO, C.; TUCCI, M. Desempenho do satélite TRMM na estimativa de precipitação sobre a Bacia do Paraguai Superior. **Revista Brasileira de Cartografia**, v. 59, n. 1, p. 93–99, 2007. 7

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira: grãos, nono levantamento, junho 2012**. Brasília, 2012. 33 p. 1

CONFALONE, A.; DUJMOVICH, N. Influência do déficit hídrico sobre a eficiência da radiação solar em soja. **Revista Brasileira de Agrociência**, v. 5, n. 3, p. 195–198, 1999. 16

DOORENBOS, J.; KASSAM, A. H. Irrigation and drainage paper 33. In: **Yield response to water**. Rome: FAO, 1979. cap. Irrigation, p. 201. 15

DU, L.; TIAN, Q.; YU, T.; MENG, Q.; JANCOS, T.; UDVARDY, P.; HUANG, Y. A comprehensive drought monitoring method integrating MODIS and TRMM data. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier B.V., v. 23, p. 245–253, ago. 2013. ISSN 03032434. 8, 10, 11, 12, 16

EMBRAPA. **Sistema Brasileiro de Classificação de Solos**. Rio de Janeiro: Embrapa, 1999. 412 p. 24

EZZINE, H.; BOUZIANE, A.; OUAZAR, D. Seasonal comparisons of meteorological and agricultural drought indices in Morocco using open short time-series data. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier B.V., v. 26, p. 36–48, fev. 2014. ISSN 03032434.

Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S0303243413000548>>. 9

FENSHOLT, R.; PROUD, S. R. Evaluation of earth observation based global long term vegetation trends - Comparing GIMMS and MODIS global NDVI time series. **Remote Sensing of Environment**, Elsevier Inc., v. 119, p. 131–147, 2012. ISSN 00344257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.12.015>>. 15

GAO, B. C. NDWI - A Normalized Difference Water Index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. April, p. 257–266, 1996. 9, 12

GARCIA, A.; ALMEIDA, C.; NEUMAIER, N. Instalação da lavoura: época e densidade de semeadura. In: **A cultura da soja no Brasil**. Londrina: Empresa Brasileira de Pesquisa Agropecuária, 2000. 3

GOWARD, S. N.; XUE, Y.; CZAJKOWSKI, K. P. Evaluating land surface moisture conditions from the remotely sensed temperature/vegetation index measurements: An exploration with the simplified simple biosphere model. **Remote Sensing of Environment**, v. 79, p. 225–242, 2002. ISSN 00344257. 65, 68

GRINSTED, A.; MOORE, J. C.; JEVREJEVA, S. Nonlinear processes in geophysics application of the cross wavelet transform and wavelet coherence to geophysical time series. **Nonlinear Processes in Geophysics**, v. 11, n. 5/6, p. 561–566, 2004. 20, 45

GU, Y.; BROWN, J. F.; VERDIN, J. P.; WARDLOW, B. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, v. 34, n. 6, p. L06407, mar. 2007. ISSN 0094-8276. 9, 13

HAMED, K. H. Trend detection in hydrologic data: The Mann Kendall trend test under the scaling hypothesis. **Journal of Hydrology**, v. 349, n. 3-4, p. 350–363, fev. 2008. ISSN 00221694. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0022169407006865>>. 18

HIRD, J. N.; MCDERMID, G. J. Noise reduction of NDVI time series: An empirical comparison of selected techniques. **Remote Sensing of Environment**, v. 113, n. 1, p. 248–258, 2009. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425708002745>>. 13, 32

HSU, K.-L.; GAO, X.; SOROOSHIAN, S.; GUPTA, H. V. Precipitation estimation from remotely sensed information using artificial neural networks. **Journal of Applied Meteorology**, v. 36, n. September, p. 1176–1190, 1997. 7

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.; GAO, X.; FERREIRA, L. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195–213, nov. 2002. ISSN 00344257. 9, 12

IBGE. **Sistema IBGE de Recuperação Automática de Dados - SIDRA**. 2015. Disponível em: <<http://www.sidra.ibge.gov.br/bda/tabela/listabl.asp?z=t&o=10&i=P&c=1612>>. xix, 3

_____. _____. 2015. Disponível em: <<http://sidra.ibge.gov.br/bda/tabela/listabl.asp?z=t&c=839>>. xix, 4

JACKSON, T. Passive microwave remote sensing of soil moisture and regional drought monitoring. In: BOKEN, V. K.; CRACKNELL, A. P.; HEATHCOTE, R. L. (Ed.). **Predicting Agricultural Drought: A Global Study**. Oxford University Press, 2005. cap. Passive Mi, p. 89. Disponível em: <http://books.google.com.br/books?hl=en&lr=&id=y6r9jUTzJiYC&oi=fnd&pg=PA89&dq=trmm+drought+ndvi+index&ots=skFsG7aDZ8&sig=pRSpzmyldN_rQLibUiluSPGS1Ts>.

16

JOHNSON, D. M. An assessment of pre- and within-season remotely sensed variables for forecasting corn and soybean yields in the United States. **Remote Sensing of Environment**, v. 141, p. 116–128, fev. 2014. ISSN 00344257.

Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425713003957>>.

59

JULIEN, Y.; SOBRINO, J. A. The Yearly Land Cover Dynamics (YLCD) method: An analysis of global vegetation from NDVI and LST parameters. **Remote Sensing of Environment**, v. 113, n. 2, p. 329–334, fev. 2009. ISSN 00344257.

Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425708003131>>.

11

KARNIELI, A.; AGAM, N.; PINKER, R. T.; ANDERSON, M.; IMHOFF, M. L.; GUTMAN, G. G.; PANOV, N.; GOLDBERG, A. Use of NDVI and land surface temperature for drought assessment: merits and limitations. **Journal of Climate**, v. 23, n. 3, p. 618–633, fev. 2010. ISSN 0894-8755. Disponível em:

<<http://journals.ametsoc.org/doi/abs/10.1175/2009JCLI2900.1>>.

50

KOGAN, F. Application of vegetation index and brightness temperature for drought detection. **Advanced Space Research**, v. 15, n. 11, p. 91–100, 1995. 12, 50

_____. Droughts of the late 1980s in the United State as derived from NOAA data. **Bulletin of the American Meteorological Society**, v. 76, n. 5, p. 655–668, 1995. 10, 11, 12, 15

KOVALSKYY, V.; ROY, D. P.; ZHANG, X. Y.; JU, J. The suitability of multi-temporal web-enabled Landsat data NDVI for phenological monitoring - a comparison with flux tower and MODIS NDVI. **Remote Sensing Letters**, v. 3, n. 4, p. 325–334, jul. 2012. ISSN 2150-704X. 13

LIU, W. T.; KOGAN, F. N. Monitoring regional drought using the Vegetation Condition Index. **International Journal of Remote Sensing**, Taylor & Francis,

v. 17, n. 14, p. 2761–2782, set. 1996. ISSN 0143-1161. Disponível em:

<<http://dx.doi.org/10.1080/01431169608949106>>
<<http://www.tandfonline.com/doi/abs/10.1080/01431169608949106>>. 11, 12

LU, X.; LIU, R.; LIU, J.; LIANG, S. Removal of noise by wavelet method to generate high quality temporal data of terrestrial MODIS products.

Photogrammetric Engineering & Remote Sensing, v. 73, n. 10, p.

1129–1139, out. 2007. ISSN 0099-1112. Disponível em:

<<http://essential.metapress.com/openurl.asp?genre=article&id=doi:10.14358/PERS.73.10.1129>>. 14

MARIANO, D. A.; FOSCHIERA, W. **Repositório**

Geopaitos-PythonRemoteSensing. 2014. Disponível em:

<<https://bitbucket.org/geopaitos/python-remotesensing/src>>. 24, 30

MARIANO, D. A.; FOSCHIERA, W.; MOREIRA, M. A. A simple method for mapping annual agricultural areas by analyzing MODIS Land Surface

Temperature time-series Denis. In: SOCIEDADE DE ESPECIALISTAS

LATINO-AMERICANOS EM SENSORIAMENTO REMOTO. **Anais...** Medellin: SELPER, 2014. 25

MARTÍNEZ, B.; GILABERT, M. A. Vegetation dynamics from NDVI time series analysis using the wavelet transform. **Remote Sensing of Environment**,

Elsevier Inc., v. 113, n. 9, p. 1823–1842, set. 2009. ISSN 00344257. Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S0034425709001254>>. 14, 20

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales. In: AMERICAN METEOROLOGICAL SOCIETY, 8., 1993. **Anais...** Anaheim: AMS. p. 17–22. 7, 38

MORAN, M. S. Thermal infrared measurement as an indicator of planet

ecosystem health. In: QUATTROCHI, D. A.; LUVALL, J. C. (Ed.). **Thermal**

remote sensing in land surface processes. Oxfordshire, UK: CRC-Taylor & Francis, 2004. p. 257–282. 62

NAGARAJAN, R. **Drought Assessment**. New Delhi, India: Capital Publishing Company, 2010. 380 p. ISBN 978-90-481-2500-5. 5

NGUY-ROBERTSON, A. L. **Remote sensing of Green Leaf Area Index in maize and soybean : from close-range to satellite by**. 151 p. Tese

(Dissertation) — University of Nebraska-Lincoln, 2013. Disponível em: <http://digitalcommons.unl.edu/natresdiss/70/?utm_source=digitalcommons.unl.edu%2Fnatresdiss%2F70&utm_medium=PDF&utm_campaign=PDFCoverPages>. 4, 5

ORTIZ, M. J.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Classification of croplands through integration of remote sensing, GIS, and historical database. **International Journal of Remote Sensing**, v. 18, n. 1, p. 95–105, jan. 1997. ISSN 0143-1161. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/014311697219295>>. 25

OTKIN, J. A.; ANDERSON, M. C.; HAIN, C.; MLADENOVA, I. E.; BASARA, J. B.; SVOBODA, M. Examining rapid onset drought development using the thermal infrared-based Evaporative Stress Index. **Journal of Hydrometeorology**, v. 14, n. 4, p. 1057–1074, ago. 2013. ISSN 1525-755X. Disponível em: <<http://journals.ametsoc.org/doi/abs/10.1175/JHM-D-12-0144.1>>. 60

RAKWATIN, P.; TAKEUCHI, W.; YASUOKA, Y. Restoration of Aqua MODIS band 6 using histogram matching and local least squares fitting. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 2, p. 613–627, 2009. ISSN 01962892. 28

REINIGN, P. The use of ERTS-1 data in carrying capacity estimates for sites in Upper Volta and Niger. **Proceedings of the Annual Meeting of the American . . .**, 1974. Disponível em: <http://scholar.google.com.br/scholar?q=+the+use+of+ERTS-1+data+in+carrying+capacity+estimates+for+sites+in+Upper+Volta&btnG=&hl=en&as_sdt=0,5#1>. 10

RHEE, J.; IM, J.; CARBONE, G. J. Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. **Remote Sensing of Environment**, Elsevier Inc., v. 114, n. 12, p. 2875–2887, dez. 2010. ISSN 00344257. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S003442571000221Xhttp://dx.doi.org/10.1016/j.rse.2010.07.005>>. 11, 16

ROJAS, O.; VRIELING, A.; REMBOLD, F. Assessing drought probability for agricultural areas in Africa with coarse resolution remote sensing imagery. **Remote Sensing of Environment**, Elsevier Inc., v. 115, n. 2, p. 343–352, fev. 2011. ISSN 00344257. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425710002798>>. 15

ROUAULT, M.; RICHARD, Y. Intensity and spatial extension of drought in South Africa at different time scales. **Water SA**, v. 29, n. 4, p. 489–500, 2003. 7, 8

ROUSE, J.; HAAS, R.; SCHELL, J. **Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation**. 164 p. Tese (Doutorado) — Texas A & M University, 1974. Disponível em: <<http://library.wur.nl/WebQuery/clc/154154>>. 9, 12

RUBIO, M. A.; RIANO, D. Estimation of canopy water content from MODIS using artificial neural networks trained with radiative transfer models. In: **6th European Meteorological Society Annual Meeting**. Ljubljana, Slovenia: [s.n.], 2006. 9, 12

SAKAMOTO, T.; GITELSON, A. A.; ARKEBAUER, T. J. MODIS-based corn grain yield estimation model incorporating crop phenology information. **Remote Sensing of Environment**, Elsevier Inc., v. 131, p. 215–231, abr. 2013. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S003442571200483X><http://linkinghub.elsevier.com/retrieve/pii/S003442571200483X>>. 29

SAKAMOTO, T.; WARDLOW, B. D.; GITELSON, A. A.; VERMA, S. B.; SUYKER, A. E.; ARKEBAUER, T. J. A Two-Step Filtering approach for detecting maize and soybean phenology with time-series MODIS data. **Remote Sensing of Environment**, v. 114, n. 10, p. 2146–2159, out. 2010. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S003442571000132X>>. 32

SAKAMOTO, T.; YOKOZAWA, M.; TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N.; OHNO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, v. 96, n. 3-4, p. 366–374, jun. 2005. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425705001057><http://linkinghub.elsevier.com/retrieve/pii/S0034425705001057>>. 19

SMITH, S. W. **Digital signal processing: a practical guide for engineers and scientists**. 1st. ed. [S.l.]: Newnes, 2003. 672 p. ISBN 978-0750674447. 14

SON, N.; CHEN, C.; CHEN, C.; CHANG, L.; MINH, V. Monitoring agricultural drought in the Lower Mekong Basin using MODIS NDVI and land surface temperature data. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier B.V., v. 18, n. June 2006, p. 417–427, ago. 2012. ISSN

03032434. Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S030324341200058X>>. 63

SONG, Y.; NJOROGE, J. B.; MORIMOTO, Y. Drought impact assessment from monitoring the seasonality of vegetation condition using long-term time-series satellite images: a case study of Mt. Kenya region. **Environmental monitoring and assessment**, v. 185, n. 5, p. 4117–24, maio 2013. ISSN 1573-2959. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22972316>>. 9, 16

SOROOSHIAN, S.; HSU, K.-L.; GAO, X. Evaluation of PERSIANN system satellite-based estimates of tropical rainfall. **Bulletin of the American Meteorological Society**, v. 81, n. 9, p. 2035–2046, 2000. 7

SOUSA, M. A.; SAUSEN, T. M.; LACRUZ, M. S. P. **Monitoramento de estiagem na região sul do Brasil utilizando EVI/MODIS no período de Dezembro de 2000 a Junho de 2009**. São José dos Campos: [s.n.], 2010. 136 p. 1, 15

TANG, H.; LI, Z.-L. **Quantitative remote sensing in thermal infrared**. Berlin: Springer, 2014. 298 p. (Springer Remote Sensing/Photogrammetry). ISBN 978-3-642-42027-6. Disponível em: <<http://link.springer.com/10.1007/978-3-642-42027-6>>. 11

TORRENCE, C.; COMPO, G. P. A Practical Guide to Wavelet Analysis. **Bulletin of the American Meteorological Society**, v. 79, n. 1, p. 61–78, 1998. 20, 45

TORRENCE, C.; WEBSTER, P. J. Interdecadal changes in the ENSO-monsoon system. **Journal of Climate**, v. 12, p. 2679–2690, 1999. ISSN 08948755. 21

TROMBETTI, M.; RIANO, D.; RUBIO, M.; CHENG, Y.; USTIN, S. Multi-temporal vegetation canopy water content retrieval and interpretation using artificial neural networks for the continental USA. **Remote Sensing of Environment**, v. 112, n. 1, p. 203–215, jan. 2008. ISSN 00344257. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425707001915>>. 10

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127–150, 1979. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/0034425779900130>>.

9

VARGAS, R.; DETTO, M.; BALDOCCHI, D. D.; ALLEN, M. F. Multiscale analysis of temporal variability of soil CO₂ production as influenced by weather and vegetation. **Global Change Biology**, v. 16, n. 5, p. 1589–1605, maio 2010. ISSN 13541013. Disponível em:

<<http://doi.wiley.com/10.1111/j.1365-2486.2009.02111.x>>. 20

VRIELING, A.; BEURS, K. M. de; BROWN, M. E. Recent trends in agricultural production of Africa based on AVHRR NDVI time series. **Remote Sensing for Agriculture, Ecosystems and Hydrology**, v. 7104, n. Proc. of SPIE Vol. 7104 71040R-1, p. 71040R–71040R–10, out. 2008. Disponível em: <<http://proceedings.spiedigitallibrary.org/proceeding.aspx?articleid=796063>>.

15

WAGLE, P.; XIAO, X.; SUYKER, A. E. Estimation and analysis of gross primary production of soybean under various management practices and drought conditions. **ISPRS Journal of Photogrammetry and Remote Sensing**, International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS), v. 99, p. 70–83, jan. 2015. ISSN 09242716. Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S0924271614002597>>. 10, 16

WAGLE, P.; XIAO, X.; TORN, M. S.; COOK, D. R.; MATAMALA, R.; FISCHER, M. L.; JIN, C.; DONG, J.; BIRADAR, C. Sensitivity of vegetation indices and gross primary production of tallgrass prairie to severe drought.

Remote Sensing of Environment, Elsevier Inc., v. 152, p. 1–14, set. 2014.

ISSN 00344257. Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S0034425714001989>>. 21

WAGNER, M. V.; JADOSKI, S. O.; MAGGI, M. F.; SUCHORONCZEK, A. Avaliação do ciclo fenológico da cultura do milho em função da soma Evaluación del ciclo fenológico de los cultivos de maíz debido a lo tempo térmico en Guarapuava , Sur de Brasil Resumen. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 4, n. 1, p. 135–149, 2011. 3

WAN, Z. New refinements and validation of the MODIS Land-Surface Temperature/Emissivity products. **Remote Sensing of Environment**, v. 112, n. 1, p. 59–74, jan. 2008. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425707003665>>. 29

WANG, Q.; ADIKU, S.; TENHUNEN, J.; GRANIER, A. On the relationship of NDVI with leaf area index in a deciduous forest site. **Remote Sensing of Environment**, v. 94, n. 2, p. 244–255, 2005. ISSN 00344257. 50

WARDLOW, B. D.; ANDERSON, M. C.; VERDIN, J. P. **Remote Sensing of Drought: Innovative Monitoring Approaches**. Boca Raton, FL: CRC Press, 2012. 484 p. ISBN 1439835578. Disponível em: <<http://books.google.com/books?hl=en&lr=&id=n1gqnmglvLoC&pgis=1>>. 1, 5

WARDLOW, B. D.; EGBERT, S. L. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. **Remote Sensing of Environment**, v. 112, n. 3, p. 1096–1116, mar. 2008. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425707003458>>. 25

WESSELS, K.; BERGH, F. van den; SCHOLE, R. Limits to detectability of land degradation by trend analysis of vegetation index data. **Remote Sensing of Environment**, v. 125, p. 10–22, out. 2012. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425712002581><http://linkinghub.elsevier.com/retrieve/pii/S0034425712002581>>. 19

WHITE, M. A.; THORNTON, P. E.; RUNNING, S. W. **A continental phenology model for monitoring vegetation responses to interannual climatic variability**. 1997. 217 p. Disponível em: <<http://onlinelibrary.wiley.com/doi/10.1029/97GB00330/pdf>>. 33

WILHITE, D. A. **Drought volume 1: a global assessment**. London: Routledge, 2001. 422 p. ISBN 978-0415168342. 6

WILHITE, D. A.; SVOBODA, M. D.; HAYES, M. J. Understanding the complex impacts of drought: A key to enhancing drought mitigation and preparedness. **Water Resources Management**, v. 21, n. 5, p. 763–774, jan. 2007. ISSN 0920-4741. 2

WMO. **Standardized Precipitation Index User Guide**. Geneva: World Meteorological Organization, 2012. 24 p. Disponível em: <http://library.wmo.int/opac/index.php?lvl=notice_display&id=13682>. 8

XIAO, X.; HOLLINGER, D.; ABER, J.; GOLTZ, M.; DAVIDSON, E. A.; ZHANG, Q.; MOORE, B. Satellite-based modeling of gross primary production in

an evergreen needleleaf forest. **Remote Sensing of Environment**, v. 89, n. 4, p. 519–534, fev. 2004. ISSN 00344257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425703003456>>. 12

XIAO, X.; QINGYUAN, Z.; BOBBY, B.; SHAWN, U.; STEPHEN, B.; STEVEN, W.; BERRIEN, M. I.; DENNIS, O. Modeling gross primary production of temperate deciduous broadleaf forest using satellite images and climate data.

Remote Sensing of Environment, v. 91, n. 2, p. 256–270, maio 2004. ISSN 00344257. Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S0034425704000975>>. 10

ZHANG, X.; FRIEDL, M. A.; SCHAAF, C. B.; STRAHLER, A. H.; HODGES, J. C.; GAO, F.; REED, B. C.; HUETE, A. Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, v. 84, n. 3, p. 471–475, mar. 2003. ISSN 00344257. Disponível em:

<<http://linkinghub.elsevier.com/retrieve/pii/S0034425702001359>>. 15, 33, 34

ZUUR, A.; IENO, E. N.; SMITH, G. M. **Analysing ecological data**. New York: Springer, 2007. 685 p. ISBN 0387459677. 17