

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ *CAMPUS* CASCAVEL
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA - PGEAGRI
SISTEMAS BIOLÓGICOS E AGROINDUSTRIAIS – SBA
GEOPROCESSAMENTO, ESTATÍSTICA ESPACIAL E AGRICULTURA DE PRECISÃO

**MAPEAMENTO E MODELAGEM ESPACIAL PARA ESTIMATIVA DE SAFRAS DE
CULTURAS AGRÍCOLAS COM SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITES**

DENISE MARIA GRZEGOZEWSKI

Cascavel – Paraná – Brasil

Fevereiro – 2016

DENISE MARIA GRZEGOZEWSKI

**MAPEAMENTO E MODELAGEM ESPACIAL PARA ESTIMATIVA DE SAFRAS DE
CULTURAS AGRÍCOLAS COM SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITES**

Tese apresentada ao Programa de Pós-Graduação "*stricto-sensu*" em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais (SBA) e linha de pesquisa em geoprocessamento, Estatística Espacial e Agricultura de Precisão da Universidade Estadual do Oeste do Paraná (UNIOESTE), Campus Cascavel.

Orientador: Prof. Dr. Miguel Angel Uribe Opazo

Coorientador: Prof. Dr. Jerry Adriani Johann

Coorientador: Prof. Dr. Erivelto Mercante

Cascavel – Paraná – Brasil

Fevereiro – 2016

Dados Internacionais de Catalogação-na-Publicação (CIP)

G926m

Grzegozewski, Denise Maria

Mapeamento e modelagem espacial para estimativa de safras de culturas agrícolas com séries temporais de imagens de satélites./Denise Maria Grzegozewski. Cascavel, 2016.

156 p.

Orientador: Prof. Dr. Miguel Angel Uribe Opazo

Coorientador: Prof. Dr. Jerry Adriani Johann

Coorientador: Prof. Dr. Erivelto Mercante

Revisão português e inglês: Ana Maria Martins A. Vasconcelos

Tese (Doutorado) – Universidade Estadual do Oeste do Paraná, Campus de Cascavel, 2016

Programa de Pós-Graduação Stricto Sensu em Engenharia Agrícola

1. Autocorrelação espacial. 2. Dados agrometeorológicos decêndiais. 3. EVI/MODIS. 4. Multiplicação de bandas. I. Uribe Opazo, Miguel Angel. II. Johann, Jerry Adriani. III. Mercante, Erivelto. IV. Vasconcelos, Ana Maria Martins A., rev. V. Universidade Estadual do Oeste do Paraná. VI. Título.

CDD 21.ed. 630.2515

CIP-NBR 12899

DENISE MARIA GRZEGOZEWSKI

"MAPEAMENTO E MODELAGEM ESPACIAL PARA ESTIMATIVA DE SAFRAS DE CULTURAS AGRÍCOLAS COM SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITE"

Tese apresentada ao Programa de Pós-Graduação "*Stricto Sensu*" em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de doutora em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, **aprovada** pela seguinte banca examinadora:


Co-orientador: Prof. Dr. Jerry Adriani Johann

Universidade Estadual do Oeste do Paraná – *Campus* de Cascavel


Prof. Dr. Joelmir André Borsoi

Universidade Tecnológica Federal do Paraná


Prof.ª Dra. Rosângela Aparecida Botinha Assumpção

Universidade Tecnológica Federal do Paraná


Prof.ª Dra. Luciana Pagliosa Carvalho Guedes

Universidade Estadual do Oeste do Paraná – *Campus* de Cascavel


Prof. Dr. Eduardo Godoy de Souza

Universidade Estadual do Oeste do Paraná – *Campus* de Cascavel

Cascavel, 03 de fevereiro de 2016.

BIOGRAFIA

Denise Maria Grzegozewski

Nascimento – dezembro de 1982

Localidade – Cascavel – Paraná

Ensino Fundamental – Colégio Estadual Washington Luiz – Cascavel - PR

Ensino Médio – Colégio Estadual Wilson Joffre – Cascavel - PR

Ensino Superior – Engenheira Agrícola formada pela Universidade Estadual do Oeste do Paraná (UNIOESTE) – 2007 – Cascavel – PR

Mestrado – Universidade Estadual do Oeste do Paraná (UNIOESTE) – Cascavel – PR
Engenharia Agrícola – 2012

Atualmente Doutoranda do Programa de Pós-Graduação em Engenharia Agrícola (PGEAGRI) –
Cascavel – PR.

“Embora ninguém possa voltar atrás e fazer um novo começo, qualquer um pode (re)começar agora e fazer um novo fim”.

Chico Xavier.

Ao meu querido paizinho, Sigismundo, e
À minha querida mãezinha, Zelma,
com todo amor e carinho dedico.

Agradecimentos

Primeiramente a Deus;

À Universidade Estadual do Oeste do Paraná (UNIOESTE) – Campus Cascavel, pela oportunidade oferecida em fazer o doutorado;

Ao Programa de Pós-Graduação em Engenharia Agrícola (PGEAGRI) da UNIOESTE pela oportunidade oferecida na realização deste trabalho;

À CAPES, ao CNPq e à Fundação Araucária pelo apoio financeiro;

Ao Professor Dr. Miguel Angel Uribe-Opazo, pela orientação ao longo do desenvolvimento deste trabalho e pela utilização da infraestrutura do Laboratório de Estatística Espacial (LEE);

Ao meu Coorientador Professor Dr. Jerry Adriani Johann, pelas contribuições ao trabalho e por sua disponibilidade. Também pela utilização da infraestrutura do Laboratório de Estatística Aplicada (LEA);

Aos docentes do programa de pós-graduação do PGEAGRI, pela contribuição com seus conhecimentos. À secretaria do Programa, pelo auxílio e atendimento prestados;

Aos meus queridos pais, Sigismundo e Zelma, pelo amor, compreensão, apoio e sustentação;

Às minhas queridas irmãs, cunhados e sobrinhos pelos bons momentos proporcionados durante o período de trabalho;

A todos da família, pelo apoio durante esta fase;

Aos amigos do LEE e LEA, Fabiana, Regiane, Gustavo, Daniela, Rosangela, Elizabeth, Fernanda, Willian, Alex, Victor, Jonathan, Laíza, Clóvis, Jaqueline pelo apoio e ajuda nas coletas de dados e

A todos os amigos ou pessoas que de alguma forma contribuíram na realização deste trabalho.

Muito Obrigada!!!

SUMÁRIO

LISTA DE FIGURAS	xi
LISTA DE TABELAS.....	xiv
RESUMO.....	xvi
ABSTRACT	xvii
1. INTRODUÇÃO/JUSTIFICATIVA	1
2. OBJETIVOS.....	3
2.1. Objetivos Gerais.....	3
2.2. Objetivos Específicos.....	3
3. REVISÃO BIBLIOGRÁFICA	4
3.1. Agricultura no Brasil	4
3.2. Agricultura no Paraná.....	4
3.3. Exigências Climatológicas para o Paraná	5
3.3.1. Temperatura	6
3.3.2. Precipitação	7
3.3.3. Radiação solar	7
3.4. Sensoriamento remoto e geoprocessamento	9
3.5. Análise espacial	11
3.5.1. Autocorrelação espacial.....	13
3.5.2. Modelagem espacial	14
4. METODOLOGIA GERAL	16
4.1. Área em estudo.....	16
4.2. Etapas de trabalho	16
5. REFERÊNCIAS BIBLIOGRÁFICAS	21
6. RESULTADOS E DISCUSSÃO.....	27
6.1. ARTIGO 1: Mapeamento das culturas da soja e do milho no Estado do Paraná, Brasil, utilizando imagens de EVI do sensor MODIS.....	27

6.1.1.	Introdução.....	27
6.1.2.	Área de estudo.....	29
6.1.3.	Material e Métodos.....	31
6.1.3.1.	Aquisição de dados de Satélite	31
6.1.3.1.1.	MODIS	31
6.1.3.1.2.	Landsat-8	32
6.1.3.1.3.	LISS-III	32
6.1.3.2.	Seleção de pixels puros	32
6.1.3.3.	Mapeamento das culturas da soja e do milho por meio do método M1	33
6.1.3.4.	Mapeamento da soja e do milho pelo método M2	34
6.1.3.5.	Mapeamento da soja e do milho integrando as metodologias M1 e M2 – M3	36
6.1.3.6.	Análise de comparação de áreas.....	37
6.1.3.7.	Análise de acurácia dos mapas	37
6.1.4.	Resultados e Discussões	38
6.1.4.1.	Resultado obtido do mapeamento pelo método M1	38
6.1.4.2.	Resultado do mapeamento pelo método M2.....	39
6.1.4.3.	Resultado obtido para o método proposto M3.....	39
6.1.4.4.	Comparação das áreas mapeadas com os dados oficiais.....	41
6.1.4.5.	Análise de acurácia dos mapas	44
6.1.5.	Conclusões	45
6.1.6.	Referências	46
6.2.	ARTIGO 2: Variabilidade espacial da produtividade da soja no Estado do Paraná por análise decendial descritiva e índices de autocorrelação global de Moran e Geary	50
6.2.1.	Introdução.....	50
6.2.2.	Material e Métodos.....	52
6.2.2.1.	Área de estudo	52
6.2.2.2.	Aquisição de dados.....	53
6.2.2.2.1.	Dados de produtividade média da soja.....	53

6.2.2.2.2. Dados MODIS do índice de vegetação.....	53
6.2.2.2.3. Dados Agrometeorológicos	55
6.2.2.3. Análise descritiva	55
6.2.2.4. Análise de autocorrelação espacial.....	56
6.2.2.4.1. Matriz de proximidade espacial	56
6.2.2.4.2. Análise de autocorrelação espacial global univariada.....	57
6.2.2.5. Softwares usados	58
6.2.3. Resultados e Discussões	58
6.2.3.1. Análise descritiva da produtividade da soja.....	58
6.2.3.2. Análise descritiva do EVI e variáveis agrometeorológicas médias decendiais	60
6.2.3.2.1. Análise descritiva do ano-safra 2010/2011	60
6.2.3.2.2. Análise descritiva do ano-safra 2011/2012	64
6.2.3.2.3. Análise descritiva do ano-safra 2012/2013	66
6.2.3.2.4. Análise do comportamento entre os decendios e anos-safras.....	68
6.2.3.3. Análise exploratória espacial	70
6.2.3.3.1. Autocorrelação da Produtividade.....	70
6.2.3.3.2. Autocorrelação das variáveis agrometeorológicas.....	70
6.2.3.3.3. Comparação da autocorrelação entre variáveis agrometeorológicas e EVI	75
6.2.4. Conclusões	76
6.2.5. Referências.....	76
6.3. ARTIGO 3: Autocorrelação espacial do índice de vegetação e variáveis agrometeorológicas associadas à produtividade da soja no Estado do Paraná	81
6.3.1. Introdução.....	81
6.3.2. Material e Métodos.....	82
6.3.2.1. Área de estudo	82
6.3.2.2. Aquisição de dados.....	83
6.3.2.3. Análise de autocorrelação espacial global univariada	83

6.3.2.4. Análise de autocorrelação espacial local univariada	84
6.3.2.5. Análise de autocorrelação espacial global bivariada	84
6.3.3. Resultados e Discussões	85
6.3.3.1. Mapa de espalhamento de Moran Global	85
6.3.3.1.1. Produtividade	85
6.3.3.1.2. EVI e variáveis agrometeorológicas para o ano-safra 2010/2011	85
6.3.3.1.3. EVI e variáveis agrometeorológicas para o ano-safra 2011/2012	87
6.3.3.1.4. EVI e variáveis agrometeorológicas para o ano-safra 2012/2013	89
6.3.3.2. Autocorrelação Local	92
6.3.3.2.1. Produtividade	92
6.3.3.2.2. EVI e variáveis agrometeorológicas	92
6.3.3.3. Autocorrelação Global Bivariada	96
6.3.4. Conclusões	98
6.3.5. Referências	99
6.4. ARTIGO 4: Modelos de estimativa de produtividade da soja para o Estado do Paraná utilizando dados de índice de vegetação e variáveis agrometeorológicas decendiais	101
6.4.1. Introdução	101
6.4.2. Material e Métodos	103
6.4.2.1. Aquisição de dados	103
6.4.2.2. Seleção de variáveis	104
6.4.2.3. Modelos de regressão espacial	104
6.4.2.3.1. Modelo de Regressão Espacial Autorregressivo Misto (SAR)	105
6.4.2.3.2. Modelo do Erro Espacial (CAR)	105
6.4.2.3.3. Modelo de Regressão Ponderada Geograficamente (GWR)	106
6.4.2.3.4. Critérios de comparação de modelos	108
6.4.3. Resultados e Discussões	108
6.4.3.1. Seleção de variáveis	108
6.4.3.2. Modelos ano-safra 2010/2011	112

6.4.3.3. Modelos ano-safra 2011/2012.....	115
6.4.3.4. Modelos ano-safra 2012/2013.....	118
6.4.3.5. Discussão dos modelos para os três anos-safras	121
6.4.4. Conclusões	123
6.4.5. Referências.....	123
7. CONSIDERAÇÕES FINAIS	125
APÊNDICE A.....	126
APÊNDICE B.....	129

LISTA DE FIGURAS

Figura 1 Temperatura no Paraná no trimestre mais quente.	6
Figura 2 Precipitação no Paraná no trimestre mais chuvoso.	7
Figura 3 Refletância dos alvos.	8
Figura 4 Área em estudo.	16
Figura 5 Fluxograma de trabalho.	17
Figura 6 Estado do Paraná dividido de acordo com as Mesorregiões da SEAB.	30
Figura 7 Fluxograma das etapas do mapeamento pelo método M1.	33
Figura 8 Fluxograma das etapas do mapeamento pelo método M2.	35
Figura 9 Fluxograma das etapas realizadas para a separação da soja e do milho pelo método M3.	36
Figura 10 Composição RGB para o Estado do Paraná: Método M1 (a e b), método M2 (c e d) e mapeamento de soja e milho (e e f).	38
Figura 11 Relação entre área (ha) colhida do mapeamento MODIS (milho (a e b) e soja (c e d) para os anos-safras 2012/2013 e 2013/2014), e dados oficiais da SEAB para 399 municípios (a e c) e 6 mesorregiões (b e d).	42
Figura 12 Fluxograma das etapas de trabalho realizadas.	52
Figura 13 Delimitação da área em estudo.	53
Figura 14 Representação da malha regular das estações virtuais do ECMWF (A) e estações virtuais usadas para obtenção da média municipal de cada variável agrometeorológica (B). ...	55
Figura 15 Mapas descritivos espaço-temporais da produtividade da soja ($t\ ha^{-1}$) para os anos-safras 2010/2011 (A), 2011/2015 (B) e 20112/2013(C).	58
Figura 16 Visualização descritiva espaço-temporal das variáveis agrometeorológicas Cw: Balanço hídrico; Ra: Precipitação; Et: Evapotranspiração; Gr: Radiação global; Te: Temperatura média; Ta: Temperatura máxima; Ti: Temperatura mínima e EVI: índice de vegetação melhorado em quartis para cada decêndio de estudo do ano safra 2010/2011.	61
Figura 17 Visualização descritiva espaço-temporal das variáveis agrometeorológicas Cw: Balanço hídrico; Ra: Precipitação; Et: Evapotranspiração; Gr: Radiação global; Te: Temperatura média; Ta: Temperatura máxima; Ti: Temperatura mínima e EVI: índice de vegetação melhorado em quartis para cada decêndio de estudo do ano safra 2011/2012.	64
Figura 18 Visualização descritiva espaço-temporal das variáveis agrometeorológicas Cw: Balanço hídrico; Ra: Precipitação; Et: Evapotranspiração; Gr: Radiação global; Te: Temperatura	

média; Ta: Temperatura máxima; Ti: Temperatura mínima e EVI: índice de vegetação melhorado em quartis para cada decêndio de estudo do ano safra 2012/2013.....	66
Figura 19 Média decendial estadual por ano-safra do EVI e das variáveis agrometeorológicas.	69
Figura 20 Autocorrelação espacial da variável EVI para cada decêndio no Estado do Paraná. 71	
Figura 21 Autocorrelação espacial da variável Cw para cada decêndio no Estado do Paraná. 72	
Figura 22 Autocorrelação espacial da variável Ra para cada decêndio no Estado do Paraná. 73	
Figura 23 Autocorrelação espacial da variável Et para cada decêndio no Estado do Paraná... 73	
Figura 24 Autocorrelação espacial da variável Gr para cada decêndio no Estado do Paraná. . 74	
Figura 25 Autocorrelação espacial das variáveis Te, Ta e Ti para cada decêndio no Estado... 75	
Figura 26 Mapa espaço-temporal de espalhamento de Moran Global da produtividade da soja no Estado do Paraná para o ano-safra 2010/2011 (a), 2011/2012 (b) e 2012/2013 (c).....	85
Figura 27 Mapa espaço-temporal de espalhamento de Moran Global para as variáveis agrometeorológicas e EVI em quartis para cada decêndio de estudo do ano-safra 2010/2011. 86	
Figura 28 Mapa espaço-temporal de espalhamento de Moran Global para as variáveis agrometeorológicas e EVI em quartis para cada decêndio de estudo do ano-safra (2011/2012).	88
Figura 29 Mapa espaço-temporal de espalhamento de Moran Global para as variáveis agrometeorológicas e EVI em quartis para cada decêndio de estudo do ano-safra (2012/2013).	90
Figura 30 Nível de significância do índice de Moran Local (Lisa Map) para a produtividade da soja ano-safra 2010/2011 (a), 2011/2012 (b) e 2012/2013 (c), autocorrelação significativa (p -valor $< \alpha$).	92
Figura 31 <i>Lisa Map</i> por decêndio e variáveis (EVI e agrometeorológicos) ano-safra 2010/2011.	93
Figura 32 <i>Lisa Map</i> por decêndio e variáveis (EVI e agrometeorológicos) ano-safra 2011/2012.	94
Figura 33 <i>Lisa Map</i> por decêndio e variáveis (EVI e agrometeorológicos) ano-safra 2012/2013.	95
Figura 34 Análise de autocorrelação espacial bivariada entre a Produtividade da soja e as variáveis EVI (A), Balanço hídrico (B), Precipitação (C), Evapotranspiração (D), Radiação global (E) e Temperatura média (F).	97
Figura 35 Representação da malha regular das estações virtuais do ECMWF (A) e estações virtuais usadas para obtenção da média municipal de cada variável agrometeorológica (B) para os 399 municípios do Estado do Paraná.....	103

Figura 36 Exemplo de uma função sobre pontos no espaço.	107
Figura 37 Mapa dos resíduos padronizados para os modelos SAR (a), CAR (b) e GWR (c)..	115
Figura 38 Mapa dos resíduos padronizados para os modelos SAR (a), CAR (b) e GWR (c)..	118
Figura 39 Mapa dos resíduos padronizados para os modelos SAR (a), CAR (b) e GWR (c)..	121

LISTA DE TABELAS

Tabela 1 Qualidade de Classificação associada com os valores do índice Kappa	19
Tabela 2 Calendário agrícola para o milho e soja de acordo com a porcentagem de plantio e colheita das culturas	29
Tabela 3 Composição RGB a fim de gerar o mapeamento da cultura pelo método M2 e os ângulos de ajuste para a separação de milho e de soja pelo método M3	40
Tabela 4 Mapeamento e extração de áreas das culturas do milho e da soja e comparação com os dados oficiais da SEAB e estatísticas obtidas a partir da análise de dados para o Estado do Paraná para os anos-safras 2012/2013 e 2013/2014.....	43
Tabela 5 Matriz de erros entre os mapeamentos de milho e soja (MODIS) e a referência terrestre (imagens composição RGB da LISS-III e Landsat-8) para as safras 2012/2013 e 2013/2014.....	45
Tabela 6 Cálculo das médias de IV de EVI para reescalonamento dos decêndios.....	54
Tabela 7 Estatísticas descritivas para a produtividade da soja ($t\ ha^{-1}$) nos três anos-safras estudados	59
Tabela 8 Índice de Moran e Geary para a Produtividade da soja nos três anos-safras.....	70
Tabela 9 Variáveis altamente correlacionadas com a produtividade da soja	109
Tabela 10 Variáveis selecionadas por <i>stepwise</i> para o ano-safra 2010/2011	109
Tabela 11 Variáveis selecionadas por <i>stepwise</i> para o ano-safra 2011/2012.....	110
Tabela 12 Variáveis selecionadas por <i>stepwise</i> para o ano-safra 2012/2013.....	111
Tabela 13 Resumo do ajuste dos modelos SAR e CAR para o ano-safra 2010/2011.....	112
Tabela 14 Ajuste do modelo GWR para o ano-safra 2010/2011	113
Tabela 15 Critérios de seleção do melhor modelo.....	114
Tabela 16 Resumo do ajuste dos modelos SAR e CAR para o ano-safra 2011/2012.....	115
Tabela 17 Ajuste do modelo GWR para o ano-safra 2010/2011	116
Tabela 18 Critérios de seleção do melhor modelo.....	118
Tabela 19 Resumo do ajuste dos modelos SAR e CAR para o ano-safra 2012/2013.....	119
Tabela 20 Estimativas do ajuste do modelo GWR para o ano-safra 2012/2013	120
Tabela 21 Critérios de seleção do melhor modelo.....	121
Tabela 22 Decêndios significativos para os modelos e anos-safras	122
Tabela 23 Valores dos Índice de Moran e Geary univariado médios decendiais do Estado do Paraná para as variáveis agrometeorológicas e EVI.....	129
Tabela 24 Valores dos Índice de Moran e Geary univariado médios decendiais do estado do Paraná para as variáveis agrometeorológicas e EVI.....	130

Tabela 25 Valores dos Índice de Moran e Geary univariado médios decendiais do estado do Paraná para as variáveis agrometeorológicas e EVI.....	131
Tabela 26 Autocorrelação Bivariada (Lee) da Produtividade da soja com as variáveis EVI e agrometeorológicas.	133
Tabela 27 Autocorrelação Bivariada (Lee) da Produtividade da soja com as variáveis EVI e agrometeorológicas	134
Tabela 28 Autocorrelação Bivariada (Lee) da Produtividade da soja com as variáveis EVI e agrometeorológicas	135

RESUMO

As estimativas das produções agrícolas têm grande importância, principalmente, no âmbito econômico. No entanto, elas são dependentes do conhecimento da área de cultivo e da produtividade da cultura. Desta forma, este trabalho teve por objetivo propor uma metodologia para estimar as áreas cultivadas com soja e milho em escala municipal no Estado do Paraná a partir de imagens multi-temporais do índice de vegetação EVI/MODIS, para os anos-safras 2010/2011, 2011/2012 e 2012/2013. Além disto, trabalhar com a autocorrelação espacial da produtividade da soja nesse Estado, com o índice de vegetação EVI e variáveis agrometeorológicas em escala decendial bem como estimar a produtividade a partir dos modelos CAR, SAR e GWR. No Paraná, há o inconveniente para mapear a soja devido à proximidade de datas de semeadura do milho. Assim, para o mapeamento da soja e do milho, utilizaram-se imagens englobando o período de máximo e mínimo vigor vegetativo de cada cultura, para se obter a área cultivada das duas. Para a separação, utilizou-se o algoritmo *Spectro Angle Mapper* (SAM) para uma das culturas e obteve-se o mapeamento da outra pela multiplicação de bandas. Para aplicação da estatística espacial dos dados mapeados, extraiu-se o perfil médio do EVI de cada município e para cada imagem multi-temporal para transformá-los em escala decendial. De acordo com a estatística espacial de áreas, utilizou-se a análise descritiva, de autocorrelação espacial univariada (global e local) de cada variável decendial com foco no ciclo da soja. Também realizou-se a análise de autocorrelação bivariada entre a produtividade da soja com as variáveis em estudo. Finalizando a metodologia, selecionaram-se as variáveis com maior índice de significância pelo método de *stepwise* e, em seguida, foram gerados os modelos estimados (SAR, CAR e GWR) da produtividade da soja. Como resultados, foram encontradas as seguintes respostas para os mapeamentos da soja $r = 0,95$ e $0,99$, e para o milho de $r = 0,72$ e $r = 0,95$ para os anos-safras 2012/2013 e 2013/2014 em relação aos dados oficiais da SEAB. Logo, comprovou-se a grande eficiência da metodologia para separação e identificação das culturas. Quando realizada a estatística descritiva dos municípios para cada variável, verificaram-se regiões que iniciam as semeaduras antecipadas em relação a outras regiões do Estado pelos decêndios do índice de vegetação. Foi também possível identificar os decêndios em que os fatores climáticos causaram danos à produtividade da soja. Na análise da autocorrelação espacial, as maiores similaridades ocorreram no ano-safra 2011/2012, ano afetado pela variação climática, cujas produtividades foram semelhantes nos municípios do Paraná. Para a modelagem espacial, verificou-se que a seleção das variáveis decêndiais foi diferente para cada ano-safra estudado, e o GWR foi escolhido como melhor modelo pelos critérios de validação, AIC, BIC e R^2 ajustado. Foram encontrados resíduos distribuídos aleatoriamente por todo o Estado, para que assim se eliminasse a autocorrelação espacial.

Palavras-chave: Autocorrelação espacial; Dados agrometeorológicos decêndiais; EVI/MODIS; Multiplicação de bandas.

ABSTRACT

Estimates of agricultural production are greatly important especially in economy field. However, they depend on area knowledge and cropping yield. Thus, this study aimed to propose a methodology to estimate the areas cropped with soybeans and corn in Paraná State according to multi-temporal EVI/MODIS vegetation index images for 2010/2011, 2011/2012 and 2012/2013 crop years. In addition, there was a research with spatial autocorrelation soybean yield in Paraná, with EVI vegetation index and meteorological variables in a decennial scale and estimate yield using CAR, SAR and GWR models. In Paraná State, there is a drawback to map soybeans crop since corn sowing period is very close to the first one. Therefore, images from the maximum and minimum vegetative vigour were drawn of each studied crop for mapping soybean and corn crops in order to obtain both cropping areas. Although, for the separation, Spectro Angle Mapper algorithm (SAM) was applied by one of the studied crops, while mapping was obtained by multiplying the other bands. Thus, for spatial statistics application of mapped data, the average EV profile of each municipality was extracted as well as for each multi-temporal image, in order to change them into a decennial scale. According to the spatial statistics of such areas, the descriptive analysis of univariate spatial autocorrelation (global and local) of each ten-day variable was used based on the soybean cycle. A bivariate autocorrelation analysis between soybean yield and the studied varieties were also performed. Finalizing the methodology, variables with the highest significant level by stepwise method were selected and SAR, CAR and GWR models were generated to estimate soybean yield. As results, regarding mappings, the following answers for soybean were found out: $r = 0.95$ and $r = 0.99$, and while for corn, the answers were: $r = 0.72$ and $r = 0.95$ for 2012/2013 and 2013/2014 crop years in relation to the official data from SEAB. So, it has been proved some great efficiency of this methodology to separate and identify crops. When the descriptive statistics of municipalities for each variable was carried out, it was found out that some regions began an early sowing in relation to other ones in Paraná by the decennial vegetation index. The ten-day scale was also possible to be identified according to the climatic factors that caused soybean yield damage. Based on the analysis of spatial autocorrelation, the greatest similarities occurred in 2011/2012 crop year, the one affected by the weather change, whose yields were similar in the municipalities of Paraná State. For spatial modelling, it was observed that selection of decennial variables was different for each studied crop year, and the best model selected by the validation. And GWR was chosen as the best model by the AIC, BIC and adjusted R^2 validation criteria. The residuals were randomly distributed throughout all the State, so that spatial autocorrelation could be eliminated.

Keywords: Decennial agro-meteorological data; EVI/MODIS; Multiplication bands; Spatial autocorrelation.

1. INTRODUÇÃO/JUSTIFICATIVA

A soja tem se destacado na agricultura nacional como o principal produto do agronegócio brasileiro devido às transformações técnico-produtivas iniciadas na década de 1960 (GUIMARÃES e ALVAREZ, 2011). Em relação aos Estados produtores, o Paraná foi o principal destaque entre os anos 1960 e 1990, e o maior produtor do País tanto em área cultivada quanto em volume produzido. Entretanto, em decorrência da expansão agrícola em direção ao Cerrado, o Paraná perdeu a liderança produtiva para o Estado do Mato Grosso com aproximadamente 18% de produção, o qual responde atualmente em torno de 29% (CONAB, 2015).

De acordo com Figueiredo (2005) e Assad et al. (2007), a geração de informações relacionadas ao cultivo agrícola como a área cultivada, a produção e o rendimento dos grãos tem por objetivo a previsão de safras. Aliado a essas estimativas, torna-se importante o conhecimento de tal distribuição no espaço geográfico para melhorar o planejamento, a logística, a segurança alimentar além da grande relevância para a formação dos preços.

Assim, o uso de técnicas de sensoriamento remoto pode contribuir para o monitoramento de áreas agrícolas, bem como permitir a obtenção de metodologias eficazes e de baixo custo, especialmente no Brasil, que possui grande extensão territorial e volume de produção. O Sistema de Informação Geográfica (SIG) facilita e contribui para com o processo de análise dos dados, pois fornece recursos para visualização, manipulação, armazenamento e processamentos de variáveis georreferenciadas.

O uso de imagens multi-temporais de satélites permite que se possa acompanhar o comportamento de diferentes alvos na superfície. Ao longo das respectivas estações de cultivo, as culturas agrícolas apresentam padrões dinâmicos-temporais peculiares de imagens orbitais e exibem comportamento espectral variável de acordo com o ciclo vegetativo de cada cultura. Segundo Bernardes et al. (2011), durante algumas fases do desenvolvimento das culturas, é possível que essas se assemelhem espectralmente a outras classes de cobertura vegetal da superfície terrestre. Assim, o comportamento espectral, decorrente da dinâmica fenológica, pode ser usado para realçar diferenças em relação às classes fonologicamente mais estáveis ao longo do tempo, como a vegetação nativa. De acordo com Zibordi et al. (2006), quando utilizadas em conjunto com SIGs, as técnicas estatísticas para análise de dados espaciais de áreas podem ser desenvolvidas a fim de permitir e subsidiar a Análise Espacial de Área.

Logo, a análise espacial de área busca um modelo inferencial que incorpore explicitamente as relações espaciais constituintes deste fenômeno com o objetivo de identificar padrões de dependência espacial das variáveis. Variáveis como a precipitação pluvial, a radiação solar global e a temperatura média são elementos agrometeorológicos

limitantes e o conhecimento das ocorrências dessas variáveis dentro do ciclo das culturas permite entendê-las nas estimativas de safra (CARGNELUTTI FILHO et al., 2009).

Assim, tais técnicas são utilizadas para estimar o quanto do valor observado de um atributo em uma região é dependente dos valores dessa mesma variável ou outras nas localizações vizinhas. Esta análise chamada de autocorrelação espacial é uma técnica que permite verificar a força da correlação espacial que melhor descreve o padrão de distribuição dos dados. De acordo com Anselin (2002), seria estimar a magnitude da autocorrelação espacial entre as áreas e evidenciar como os valores estão correlacionados no espaço.

Os dados espaciais agregados são caracterizados pela dependência (autocorrelação espacial) e pela heterogeneidade ou estrutura espacial (ANSELIN, 1988). Enquanto a análise de regressão em dados espaciais incorpora, na modelagem, a dependência espacial entre os dados, e melhora o poder preditivo do modelo.

Desta maneira, a justificativa deste trabalho foi mapear e separar as culturas da soja e do milho semeadas em um mesmo período bem como aplicar técnicas de estatística espacial de áreas utilizando a autocorrelação e regressão espacial a fim de melhor explicar a produtividade da soja.

2. OBJETIVOS

2.1. Objetivos Gerais

Os objetivos deste trabalho foram estudar as áreas cultivadas com as culturas de soja e milho no Estado do Paraná a fim de gerar uma metodologia de previsão de safras da cultura da soja, a partir de uma série temporal de imagens do sensor MODIS/TERRA, e aplicar técnicas de estatística espacial de área com estudo da autocorrelação e regressão espacial, usando variáveis agrometeorológicas e índices de vegetação EVI.

2.2. Objetivos Específicos

Separação e mapeamento das culturas da soja e do milho por município, com base nos perfis temporais de índices de vegetação EVI, para os anos-safras 2010/2011, 2011/012 e 2012/2013;

Estimar as áreas cultivadas com soja no Estado do Paraná a partir das safras mapeadas e confrontar com dados oficiais e com imagem de alta resolução espacial;

Analisar espacialmente a produtividade da soja, associada às variáveis agrometeorológicas e aos índices de vegetação pelos índices de correlação e autocorrelação espacial univariada pelos Índices de Moran e Geary Global e Moran Local e bivariada pelo Índice de Lee;

Gerar modelos de regressão espacial múltipla autorregressivos (SAR), o modelo condicional autorregressivo (CAR) e modelo de regressão geograficamente ponderada (GWR).

3. REVISÃO BIBLIOGRÁFICA

3.1. Agricultura no Brasil

No Brasil, a Companhia Nacional de Abastecimento (CONAB, 2015) e o Instituto Brasileiro de Geografia e Estatística (IBGE, 2015) são órgãos oficiais responsáveis por gerar e divulgar os dados sobre a produtividade e a área colhida das culturas. Estas informações são estimadas baseando-se, quase que exclusivamente, em opiniões de agentes ligados ao setor agropecuário, sendo, portanto, um método subjetivo de aquisição de tais informações.

A cada safra a agricultura brasileira tem evoluído e a Conab, desde 2004, criou o projeto Geosafra, visando melhorar as previsões de safras utilizando técnicas de geoprocessamento aplicadas ao monitoramento das lavouras e contando com a participação de entidades do governo, empresas e universidades (SILVA et al., 2009).

De acordo com o levantamento da Conab de novembro 2015, a estimativa de área cultivada com as principais culturas no País é estimada em 58 milhões de hectares. Para a safra atual da cultura da soja (2015/2016), a produção é estimada em 212 milhões de toneladas, superior em 4 milhões de toneladas do que foi produzido na safra 2014/2015. Este crescimento se deve principalmente ao acréscimo da área plantada com a soja e a diminuição do plantio do milho 1ª safra, sabendo que a produção de milho no Brasil é caracterizada pelo plantio em duas épocas: 1ª safra ou safra de verão e 2ª safra ou safrinha.

3.2. Agricultura no Paraná

A partir dos anos setenta do século passado, o processo de desconcentração econômica regional no Brasil foi importante para explicar as mudanças ocorridas na economia paranaense (TRINTIN, 2001). Em razão do crescimento da produção industrial, esse processo foi marcado pela perda de importância relativa da região Sudeste no PIB nacional. Com isso, o Paraná ganhou importância no cenário nacional e ampliou seu papel junto à economia nacional, com culturas que estavam sendo estimuladas na época como a soja, o trigo e a cana-de-açúcar.

O que se constata a partir das transformações ocorridas é que algumas regiões do Paraná se inseriram de modo diferenciado na produção agrícola nacional, seja em razão de possuírem uma agricultura voltada para o mercado, ou do tipo de solo existente que favorecia o desenvolvimento da cultura da soja, milho e do trigo. No entanto, segundo Trintin (2001), o aproveitamento de incentivos alçou a uma agricultura dinâmica e moderna, tornando-se, em muito curto espaço de tempo, uma das mais importantes áreas agrícolas do País.

Segundo Delgado (2011), o desempenho paranaense frente à safra agrícola tem sido justificado, principalmente, pelos aumentos de produtividade, uma vez que se considera praticamente esgotada a possibilidade de expansão da fronteira agrícola. O aumento na produtividade resultou de fatores tecnológicos que, quando conjugados, possibilitaram o aumento da produção, dentre os quais cabe destacar: melhoramento genético, zoneamento agrícola, plantio direto na palha, desenvolvimento de maquinário mais eficiente para colheita e capacitação do produtor no gerenciamento de custos na cadeia produtiva.

Também vale destacar que a expansão de áreas de lavouras no Estado relaciona-se com as mudanças verificadas na reorganização das safras, com a produção de milho em sucessão à soja. Está prevista uma expressiva redução da área plantada com milho e o recente levantamento apresentou indicativo cuja variação é de 19 a 20% menor sobre a área plantada em relação ao ano passado (CONAB, 2015).

Para Franchini (2011), o Estado do Paraná adota dois sistemas de produção caracterizados como sistemas de culturas. O primeiro com predomínio de soja no verão e trigo no inverno, para as regiões Sul e Sudoeste, e o segundo com predomínio de soja no verão e milho 2ª safra no inverno nas regiões Norte e Oeste. Essa divisão é determinada pelo zoneamento agrícola das culturas.

Além disso, torna-se relevante considerar que a rotação entre as culturas de soja e de milho contribui para elevação da produtividade, por se tratar de uma leguminosa e uma gramínea, respectivamente. Também deve-se levar em consideração as características de temperatura do ar e a incidência de geadas frequentes, principalmente acima de 24 graus de Latitude (WREGGE et al., 2005) com restrições para algumas culturas.

3.3. Exigências Climatológicas para o Paraná

O Estado situa-se em uma região de transição climática com diversos microclimas além de diferentes situações de temperatura e precipitação ao longo do território, todos associados às variações de latitude e altitude. O Instituto Agrônomo do Paraná (IAPAR), vinculado à SEAB, disponibiliza informações atualizadas sobre fenômenos climáticos nas lavouras e também do zoneamento para as principais culturas. Este monitoramento tem informações das condições do tempo e de índices agrometeorológicos a fim de auxiliar a tomada de decisões sobre o manejo do Estado.

A variabilidade da produção agrícola é afetada principalmente pelas condições climáticas, a qual se figura como o de mais difícil controle e de maior impacto sobre a obtenção de máximas produtividades. A imprevisibilidade do clima pode reduzir significativamente os rendimentos em lavouras e restringir as áreas nas quais as espécies comercialmente importantes podem ser cultivadas (EMBRAPA SOJA, 2008). Dentre os

fatores climáticos, a temperatura, o balanço hídrico e a radiação solar são fatores determinantes para o desenvolvimento da cultura da soja (FARIAS et al., 2000).

3.3.1. Temperatura

Em regiões com temperaturas iguais ou menores a 10 °C, o cultivo da soja é impróprio, pois tanto o crescimento como o desenvolvimento da cultura é pequeno ou nulo. Quando a temperatura está acima dos 40 °C, a mesma ocasiona efeito adverso na taxa de crescimento e provoca danos à floração, conseqüentemente diminui a capacidade de retenção de vagens. Esses problemas são acentuados com a ocorrência concomitante de déficits hídricos (FARIAS et al., 2007).

A cultura da soja se adapta melhor às regiões em que as temperaturas oscilam entre 20 e 30 °C, mas a temperatura ideal para seu desenvolvimento está em torno de 30 °C (FARIAS et al., 2000). Para a semeadura, a faixa ideal para uma emergência rápida e uniforme é de 25 °C, e a mesma não deve ocorrer se estiver abaixo dos 20 °C, pois a germinação e a emergência da planta ficam comprometidas.

A floração da soja é induzida de acordo com as temperaturas e varia de cultivar para cultivar. A soja floresce antes do tempo quando ocorrem temperaturas elevadas e pode acontecer o mesmo com a maturação, que acelera devido à incidência de calor. Com isso, a qualidade das sementes é afetada causando o enrugamento e danos mecânicos no momento da colheita, cuja conseqüência é a diminuição da produtividade. A ocorrência de baixas temperaturas na maturação e períodos chuvosos pode provocar atraso na colheita e a dificuldade de seca da haste (EMBRAPA SOJA, 2008). Verifica-se tal fato no trimestre mais quente relativo à média dos últimos dez anos (Figura 1), em regiões cuja temperatura é mais propícia para o cultivo da soja.

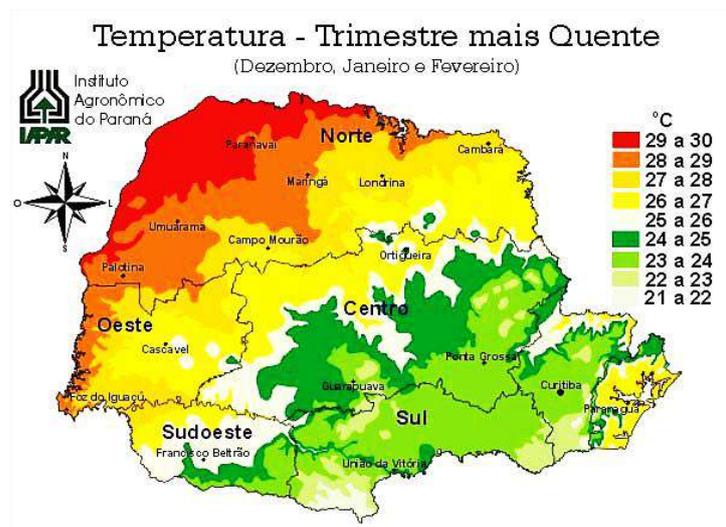


Figura 1 Temperatura no Paraná no trimestre mais quente.

Fonte: IAPAR, 2015.

3.3.2. Precipitação

Aproximadamente 90% do peso da planta são constituídos por água. De acordo com a Embrapa Soja (2008), a quantidade de água exigida para a cultura da soja varia entre 450 e 800 mm/ciclo, e os períodos mais críticos estão ligados à germinação/emergência e à floração/enchimento de grãos. Se houver falta ou excesso de água no primeiro período, a uniformidade na população de plantas é afetada, pois a semente necessita absorver no mínimo 50% de seu peso em água para uma boa germinação (EMBRAPA SOJA, 2008). Conforme a cultura vai crescendo e desenvolvendo, a necessidade de água é de 7 a 8 mm/dia até atingir a fase de floração/enchimento de grãos. Durante a estação do trimestre mais chuvoso no Estado, em média para os dez últimos anos (Figura 2), conseguem-se delimitar as regiões em que há mais precipitações.

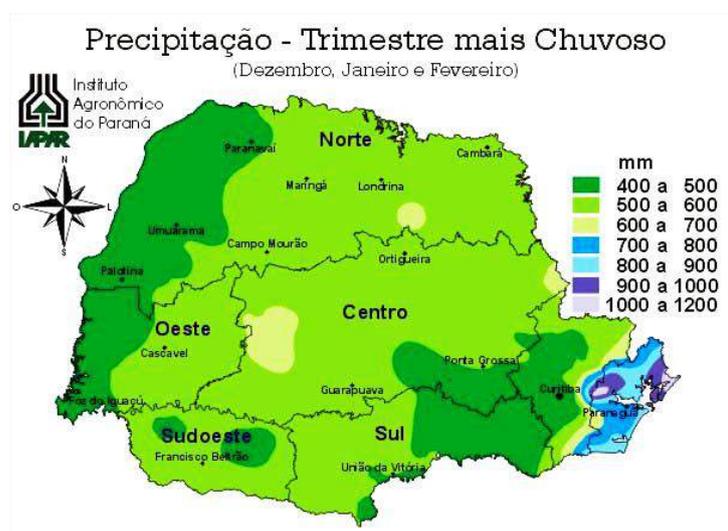


Figura 2 Precipitação no Paraná no trimestre mais chuvoso.

Fonte: IAPAR, 2015.

A maior produção de grãos é obtida pelo volume de água disponibilizado necessário ao longo do ciclo total, o qual deve atender às exigências da cultura, todavia, isto é suprido pela chuva, irrigação ou do armazenamento pelo próprio solo. Ressalta-se ainda que a ausência de chuvas, isoladamente, não significa, obrigatoriamente, ocorrência de déficit hídrico e diminuição do rendimento. A planta busca um ajuste entre a absorção de água e a transpiração e ainda as práticas agrícolas que favoreçam à melhor estruturação do solo, enquanto o aprofundamento do sistema radicular contribui para incrementar o armazenamento de água no solo (EMBRAPA SOJA, 2008).

3.3.3. Radiação solar

A radiação solar é o componente ambiental que fornece energia luminosa para a fotossíntese. Além da intensidade, Thomas (1994) ressalta que a duração e qualidade do

espectro luminoso são determinantes para respostas morfológicas e fenotípicas na soja, por exemplo, a estatura da planta, indução ao florescimento e outros. Ayoade (1986) considera que se não houver radiação suficiente, o sistema radicular da planta não se desenvolve completamente.

Segundo Câmara (2000), para a cultura da soja, a radiação solar está relacionada com a fotossíntese, crescimento da haste principal e ramificações, fixação biológica, expansão foliar, crescimento de vagens e grãos.

Casaroli (2007) demonstra a importância de se conhecerem o clima da região de cultivo e a época de semeadura, pois a cultura da soja quando submetida a altas intensidades de radiação solar, pode levá-la à saturação luminosa, diminuindo a eficiência em seu uso. Já se a mesma é submetida a baixas intensidades luminosas, ela pode apresentar menores taxas de fitomassa, crescimento, assimilação líquida e elevado enfraquecimento da planta, condicionando ao acamamento da cultura.

Cada tipo de alvo interage de modo diferente com a radiação solar incidente na superfície da Terra. Isso é determinado pelas diferentes composições físico-químicas dos objetos ou feições terrestres (FIGUEIREDO, 2005). Tais diferentes composições fazem com que cada alvo na Terra tenha sua própria assinatura espectral, ou seja, cada alvo absorve ou reflete de modo diferente em cada uma das faixas de espectro da luz incidente (Figura 3). Assim, com o uso do sensoriamento remoto, consegue-se a identificação ou detecção de um objeto.

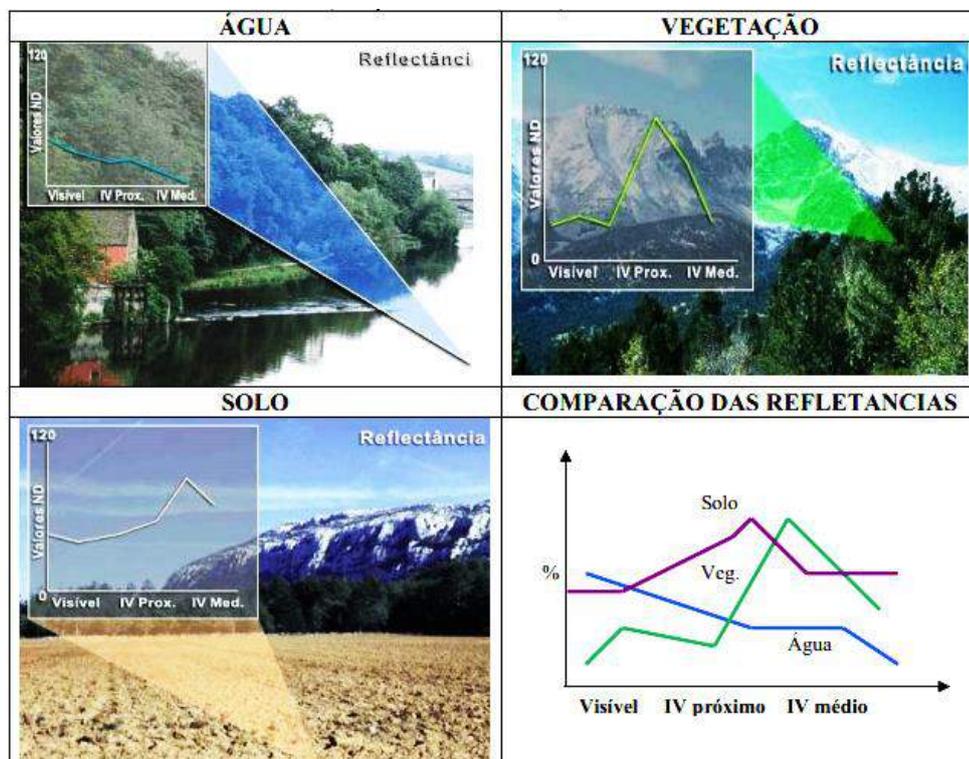


Figura 3 Refletância dos alvos.

Fonte: Adaptado de INPE, 2003.

3.4. Sensoriamento remoto e geoprocessamento

Tudo que está presente na superfície terrestre ou que está se modificando nela passou a ser olhado e vistoriado por sensores imageadores nas últimas quatro décadas (MENESES et al., 2012). O principal objetivo para que se obtenham imagens periódicas é a possibilidade de monitorar o meio ambiente em uma escala global e assim melhorar a obtenção dos recursos naturais renováveis e não renováveis.

Devido ao acelerado avanço do sensoriamento remoto, atualmente, a resolução espectral das imagens obtidas pelos sensores ultrapassa centenas de bandas (sensores hiperespectrais) e a resolução espacial de muitas imagens já é menor que 1 metro. Assim, têm possibilitado a aplicação desses sensores nas áreas de levantamentos de recursos naturais, mapeamentos temáticos, monitoração ambiental, detecção de desastres naturais, desmatamentos florestais, previsão de safras, cartografia de precisão dentre outros (MENESES et al., 2012).

Quanto ao monitoramento agrícola, Labus et al. (2002) destacam a importância do sensoriamento remoto, que possibilita enxergar em diversos comprimentos de ondas. Porém, para o monitoramento das culturas agrícolas, segundo Esquerdo (2007), necessita-se do conhecimento espectral dessas superfícies, pois as culturas são caracterizadas por apresentarem ciclos fenológicos bem definidos. Nesse caso, para medir as variáveis agrícolas específicas, é necessária a aquisição de dados em datas específicas no ciclo fenológico (JOHANNSEN et al., 2003).

Johann (2012) ressalta que uma das formas utilizadas para a distinção dos alvos, quando se utilizam cenas do *Landsat*, *CBERS*, *AWiFs*, é através das combinações de bandas do sensor no espaço de cores RGB (Red, Green, Blue). Como resultado, tem-se a obtenção de informações e maior facilidade nos procedimentos de classificação digital para o mapeamento do uso do solo e vegetação. O autor ainda propõe o uso de imagens multi-temporais de índices de vegetação a fim de se estudar o padrão espectral dos alvos de interesse, quando há indisponibilidade de imagens ou obstruções atmosféricas.

Para Epiphanyo et al. (2008), as transformações de bandas espectrais são lineares, geralmente nas faixas do vermelho (V) e infravermelho próximo (IVP). As equações pelas quais as transformações são efetuadas para o cálculo dos índices de vegetação (IV) se baseiam nas respostas apresentadas pela vegetação.

O *Moderate Resolution Imaging Spectroradiometer* (MODIS) é um sensor a bordo dos satélites Terra e Aqua. E foi projetado para fornecer uma série de observações globais da superfície terrestre, oceano e atmosfera nas regiões do visível e do infravermelho, numa resolução temporal 1 ou 2 dias, dependendo da posição geográfica. Tem elevada sensibilidade radiométrica (12 Bits) em 36 bandas espectrais contidas no intervalo de 0,4 a

14,4 µm do espectro eletromagnético. Duas bandas são adquiridas na resolução de 250 m, outras cinco bandas na resolução de 500 m e as demais 29 bandas em um quilômetro (SOARES et al., 2007).

As imagens do MODIS oferecem uma base sistemática de dados para a elaboração de produtos sobre as interações entre atmosfera, terra e oceano. A utilização se encontra associada à medição de propriedades das nuvens, fluxo de energia radiante, propriedades dos aerossóis, mudanças no uso e cobertura das terras, queimadas e atividades vulcânicas, dentre outras (EMBRAPA MONITORAMENTO POR SATÉLITE, 2009).

O produto MOD13 tem aplicações para a agricultura, contém os índices de vegetação NDVI e EVI, e vem sendo utilizado para monitoramento das condições de cobertura vegetal em escalas global e regional, por ser produzido com resoluções de 1 km, 500 m e 250 m e em composições de imagens ou mosaicos de 16 dias (LATORRE et al., 2007).

Proposto por Huete et al., (1999), o *Enhanced Vegetation Index* ou índice de vegetação melhorado (EVI), do sensor MODIS, foi desenvolvido para otimizar o sinal de resposta da vegetação, aprimorar a sensibilidade em regiões com maiores densidades de biomassa, além de proporcionar o monitoramento da vegetação através de uma ligação do sinal de fundo do dossel e a redução das influências atmosféricas. Já Huete et al. (2002), após analisarem dados de NDVI e EVI, verificaram que a sensibilidade do EVI permite melhor desempenho na monitoração da vegetação, devido à influência do sinal proveniente do substrato do dossel e da redução de influências atmosféricas. Souza et al. (2015) também trabalharam com os IV's e constataram que os resultados mais expressivos foram obtidos com WDRVI e EVI, em relação ao monitoramento da vegetação com o NDVI.

No Brasil, o foco principal de uso de imagens multi-temporais são as culturas de soja e milho nas regiões Sul e Centro-Oeste (YI et al., 2007; RUDORFF et al., 2007; RIZZI et al., 2009; ARAUJO et al., 2011; BERNARDES et al., 2011; DUFT et al., 2011; ESQUERDO et al., 2011; JOHANN et al., 2012) e cana-de-açúcar no Centro Sul (XAVIER et al., 2006; AGUIAR et al., 2008; RUDORFF, 2009; RAMME et al., 2010).

Entretanto, para isso se faz necessário o uso de uma ferramenta que trata a coleta de informações sobre a distribuição geográfica, seja para mapeamento ou para estimativa de produtividade. Neste contexto, com o Geoprocessamento, a disciplina do conhecimento referente às técnicas matemáticas e computacionais trata a informação geográfica e exerce papel fundamental nas áreas de Cartografia, Análise de Recursos Naturais, Transportes, Comunicações, Energia e Planejamento Urbano e Regional. As ferramentas computacionais para Geoprocessamento, chamadas de *Geographical Information System* (GIS) ou Sistemas de Informação Geográfica (SIG), permitem realizar análises complexas, ao integrarem dados de diversas fontes e criarem bancos de dados georreferenciados.

Pinheiro e Silva (2009) dividem a evolução do SIG em três fases. A primeira foi a manipulação e a visualização do banco de dados iniciada na década de 50. Ela é marcada pela necessidade de armazenar, organizar, processar e visualizar os dados que originam os SIG's. A segunda fase são as operações analíticas dos dados não gráficos (modelos matemáticos) e a estrutura organizacional que, conforme Teixeira et al. (1995), ocorreu devido ao aumento da capacidade de processamento e de memória dos computadores para possibilitar novas concepções e a popularização dos SIG's. Na terceira fase, ocorre a análise espacial, que combina atributos não geográficos com as relações topológicas dos objetos geográficos para efetuar análises espaciais sobre dados georreferenciados.

Segundo Miranda (2005), a abordagem mais adequada para a definição de SIG é a que enfatiza a importância da análise espacial e modelagem que pode ser realizada, na qual o SIG é visto mais como uma ciência de informação espacial do que uma tecnologia. As definições de SIG's refletem, cada uma a sua maneira, a multiplicidade de usos e visões possíveis dessa tecnologia e apontam para uma perspectiva interdisciplinar de sua utilização.

3.5. Análise espacial

A distribuição espacial dos dados visa à compreensão de fenômenos ocorridos no espaço para elucidação de questões centrais em diversas áreas do conhecimento, seja em agronomia, ambiente, em geologia, em saúde entre muitos outros. A ideia central é incorporar o espaço à análise que se deseja fazer (SANTOS et al., 2004). Devido à disponibilidade dos SIG's de baixo custo, e com interfaces amigáveis, estes estudos têm se tornando mais comuns (CÂMARA, et al., 2002).

De acordo com Menezes (2003), a análise espacial apresenta duas vertentes principais: estatística espacial e geocomputação. A estatística espacial gera modelos matemáticos de distribuição e correlação, os quais incorporam propriedades de significância e incerteza, resultantes da dimensão espacial. Já a geocomputação usa técnicas de redes neurais, busca heurística e autômatos celulares para explorar grandes bases de dados e gerar resultados empíricos (não exatos) melhores que as técnicas convencionais, mas com ampla aplicabilidade prática. Para Câmara (2000), esses instrumentos proporcionam maior confiabilidade aos resultados de investigações sobre a realidade modelada.

O processo da análise espacial segundo CÂMARA et al. (2002) compreende um conjunto de procedimentos encadeados cuja finalidade é a escolha de um modelo inferencial que considere explicitamente o relacionamento espacial presente no fenômeno. Os procedimentos iniciais incluem o conjunto de métodos genéricos de análise exploratória e a visualização dos dados, em geral a partir de mapas. Essas técnicas permitem descrever

a distribuição das variáveis de estudo, identificar observações atípicas não apenas em relação ao tipo de distribuição, mas também em relação aos vizinhos, além de buscar a existência de padrões espaciais. Através desses procedimentos, é possível que se estabeleçam hipóteses sobre as observações, de forma a selecionar o modelo inferencial melhor suportado pelos dados.

A localização espacial dos dados pode ser representada de forma regular ou irregular, e seus índices podem ser definidos a partir uma área no espaço (LI, 2007). Com o objetivo de aprofundar a compreensão do processo espacial, estudam-se evidências a ele relacionadas ou ainda tentar prever valores em áreas onde as observações não estão disponíveis (BALEY & GATTREL, 1995). Ainda de acordo com os autores, os métodos podem se diferir de acordo com a visualização dos dados espaciais. Eles são exploratórios, investigam, resumem relações e padrões mapeados e também contam com as especificações de um modelo estatístico e da estimação dos parâmetros.

A visualização gráfica dos dados espaciais é fundamental, pois é possível a identificação de padrões espaciais nos dados, que gerem hipóteses testáveis e avaliem o ajuste dos modelos propostos, ou ainda a validade das previsões resultantes. Cardoso et al. (2011) analisam uma série de critérios para justificar a visualização dos dados, como se há variáveis com valores extremos, se as variáveis se dividem em grupos distintos e se há associações entre elas.

Com o auxílio dos métodos gráficos e das estatísticas descritivas, a análise exploratória pode ser classificada em univariada e multivariada, dependendo do número de variáveis envolvidas. Nas técnicas univariadas, destacam-se os histogramas, os mapas, as estimativas de densidade e boxplots; enquanto entre as técnicas multivariadas, poderão ser empregadas matrizes de dispersão, gráficos ligados aos mapas (*linked plots*) e gráficos de coordenadas paralelas, por exemplo (LIMA, 2010).

De forma geral, a análise exploratória é uma ferramenta utilizada na caracterização do arranjo espacial dos eventos que buscam a avaliação e distribuição relativa de maneira a buscar padrões de associações espaciais (*clusters* espaciais) e regimes espaciais ou outras formas de instabilidade espacial (não estacionariedade). Esta análise consiste em verificar se existe algum tipo padrão sistemático nos dados ou se estão distribuídos aleatoriamente no espaço (MONTENEGRO, 2008). Já para Messner et al. (1999), a análise exploratória dos dados espaciais é um conjunto de técnicas de análise estatística de informação geográfica. Com isso, a análise exploratória contribui para indicar uma apropriada modelagem econométrica espacial, ao permitir a identificação de localidades atípicas (*outliers*). Assim, Montenegro (2008) salienta que é possível a extração de medidas de autocorrelação espacial global e local que investiga a influência dos efeitos espaciais por intermédio de instrumentos quantitativos e não somente pela visualização dos mapas.

3.5.1. Autocorrelação espacial

Autocorrelação mede a correlação da própria variável no tempo ou no espaço. A correlação de uma variável com ela mesma, medida no mesmo local, será sempre um (1). No entanto, a correlação de uma variável com ela mesma, porém medida nas áreas vizinhas e terá valor que varia entre -1 e 1. Quanto mais próximo de 1, maior a semelhança entre vizinhos. O valor zero (0) indica inexistência de correlação e os valores negativos indicam diferenças (CÂMARA et al., 2002).

No estudo de fenômenos de áreas, uma das técnicas mais utilizadas é a Análise de Autocorrelação Espacial (CARVALHO, 1997). Essa técnica permite identificar a estrutura de correlação espacial que melhor descreve o padrão de distribuição dos dados, a fim de estimar a magnitude da autocorrelação espacial entre as áreas (ANSELIN, 2002), evidenciando como os valores estão correlacionados no espaço. Assim, as técnicas são utilizadas para estimar o quanto do valor observado de um atributo em uma região é dependente dos valores dessa mesma variável nas localizações vizinhas. Enquadram-se nessa categoria o Índice Global de Moran (TEXEIRA & BERTELLA, 2010), o Índice Global de Geary (GEARY, 1954) e Getis e Ord's G (GETIS & ORD, 1992).

Ao se usar um indicador global de autocorrelação, obtém-se um único valor de associação espacial para todo o conjunto de dados, que é útil na caracterização da região de estudo. No entanto, quando se trabalha com grande número de áreas, Santos et al. (2011) relatam que é muito provável que ocorram diferentes regimes de associação espacial e que apareçam locais em que a dependência espacial é ainda mais pronunciada.

Entre as técnicas univariadas aplicadas à análise local existem as abordagens gráficas e aquelas voltadas para o desenvolvimento formal de estatísticas univariadas locais. Dentre as abordagens gráficas, busca-se, prioritariamente, identificar exceções locais às tendências gerais na distribuição dos dados e nas relações entre variáveis. Trabalham-se, neste sentido, com o auxílio de histogramas, gráficos de dispersão e gráficos em três dimensões (MELO & HEPP, 2008). As mais complexas técnicas gráficas para demonstrar relações locais em bancos de dados univariados incluem o *Spatial Lagged Scatterplot*, o *Variogram Cloud Plot* e o *Moran Scatterplot*, com destaque para o último que, além de permitir a identificação de grupos de valores, também permite a identificação de valores extremos na distribuição. Salame (2008), apresenta uma visualização do nível de autocorrelação espacial existente. Dalposso et al. (2013) apresentam um estudo de estatística espacial de áreas baseado no NDVI, em que foi possível conhecer o perfil da soja nos municípios da região Oeste do Paraná, para identificar épocas diferentes do semeadura.

Ao se analisar a existência de um padrão de associação entre duas variáveis, esta é chamada de autocorrelação espacial bivariada. Ou seja, tem o objetivo de revelar se os

valores da variável observada em dada região revelam uma relação com os valores de outra variável observada em regiões vizinhas.

Quando os dados apresentam a dependência espacial, é pouco provável que a hipótese padrão de observações não correlacionadas seja verdadeira. No caso mais comum, os resíduos continuam apresentando a autocorrelação espacial presente nos dados, que pode se manifestar por diferenças regionais sistemáticas ou ainda por tendência espacial contínua (LOPES et al., 2006). Assim, a investigação dos resíduos da regressão, em busca de sinais da estrutura espacial, pode fornecer um indicativo da necessidade da utilização de um modelo de regressão espacial.

3.5.2. Modelagem espacial

A análise de regressão é o termo que descreve uma família de métodos que permite explorar e inferir a relação entre uma ou mais variáveis dependentes ou respostas e um conjunto de variáveis independentes (FRANCISCO, 2010). É muito utilizada também para a previsão, já que envolve séries temporais de dados e incorpora, na modelagem, a dependência espacial, além de melhorar o poder preditivo do modelo.

Os modelos de regressão linear espacial podem ser vistos como uma generalização do modelo de regressão linear padrão, de tal forma que a autocorrelação é possível e contabilizada explicitamente por modelos espaciais. Os parâmetros do modelo incluem coeficientes usuais de regressão das variáveis explicativas (β) e da variância do termo de erro (σ^2). Com isso, os mais utilizados modelos de regressão espacial têm um coeficiente espacial autorregressivo (ρ), que mede a força de autocorrelação espacial. De acordo com Chi e Zhu (2007), uma matriz e os pesos espaciais (W) correspondentes a uma estrutura de vizinhança e uma matriz de peso (D) são pré-especificadas. Isso culmina na incorporação, para a explicação de y , de um termo em y – por isso denominado, por alguns autores, de variável dependente espacialmente defasada (FRANCISCO, 2010). Encaixa-se nesta forma o modelo *Spatial Auto Regressive Model*, (SAR ou *Spatial Lag Model*), cuja ideia básica é incorporar a autocorrelação espacial como componente do modelo.

Outro modelo, de similar conceituação, denominado *Spatial Error model* (CAR), assume que o termo de erro é espacialmente dependente, e não a variável y . Esse modelo é aplicado quando parece haver significativa autocorrelação espacial e os testes para o *Spatial Lagged model* não sugerem a inclusão de um termo espacial autorregressivo em y no modelo (SMITH; GOODCHILD; LONGLEY, 2007).

De forma geral, os dois modelos capturam a estrutura espacial por meio de um único parâmetro que é adicionado ao modelo de regressão tradicional, ou seja, são modelos de regressão com efeitos espaciais globais. Entretanto, se há grandes variações locais, a confiabilidade das medidas globais como representações das condições locais diminui

(FOTHERINGHAM; BRUNSDON; CHARLTON, 2002; WHIGHAM, 2007). Desta forma, a adoção da técnica *Geographically Weighted Regression* (GWR ou Regressão Ponderada Geograficamente), que foi desenvolvida por Fotheringham, Charlton e Brunson (1997, 2002), contribui de forma local para a explicação de muitos fenômenos.

O GWR é a técnica para descrever uma família de modelos de regressão em que os coeficientes, parâmetros β , podem variar espacialmente. Ela ajusta um modelo de regressão a cada ponto observado e pondera todas as demais observações como função da distância (ou de qualquer medida de vizinhança) deste ponto. Em outras palavras, temos regressões diferentes para cada observação, assim, a contribuição (valor do parâmetro) de cada variável explicativa ao modelo é diferente para cada ponto (FRANCISCO, 2010).

Os ajustes dos modelos locais *versus* modelos globais têm as mesmas técnicas, porém a comparação é problemática. O GWR apresentará sempre os melhores ajustes, pois envolve o ajuste de mais parâmetros e pode ser medido pelo AIC (Critério de Informação de Akaike), que leva em consideração a complexidade do modelo.

4. METODOLOGIA GERAL

4.1. Área em estudo

A área em estudo é para o Estado do Paraná (Figura 4), que possui 399 municípios, para avaliar a cultura agrícola da soja, primavera-verão, durante os anos-safras 2010/2011, 2011/2012 e 2012/2013.

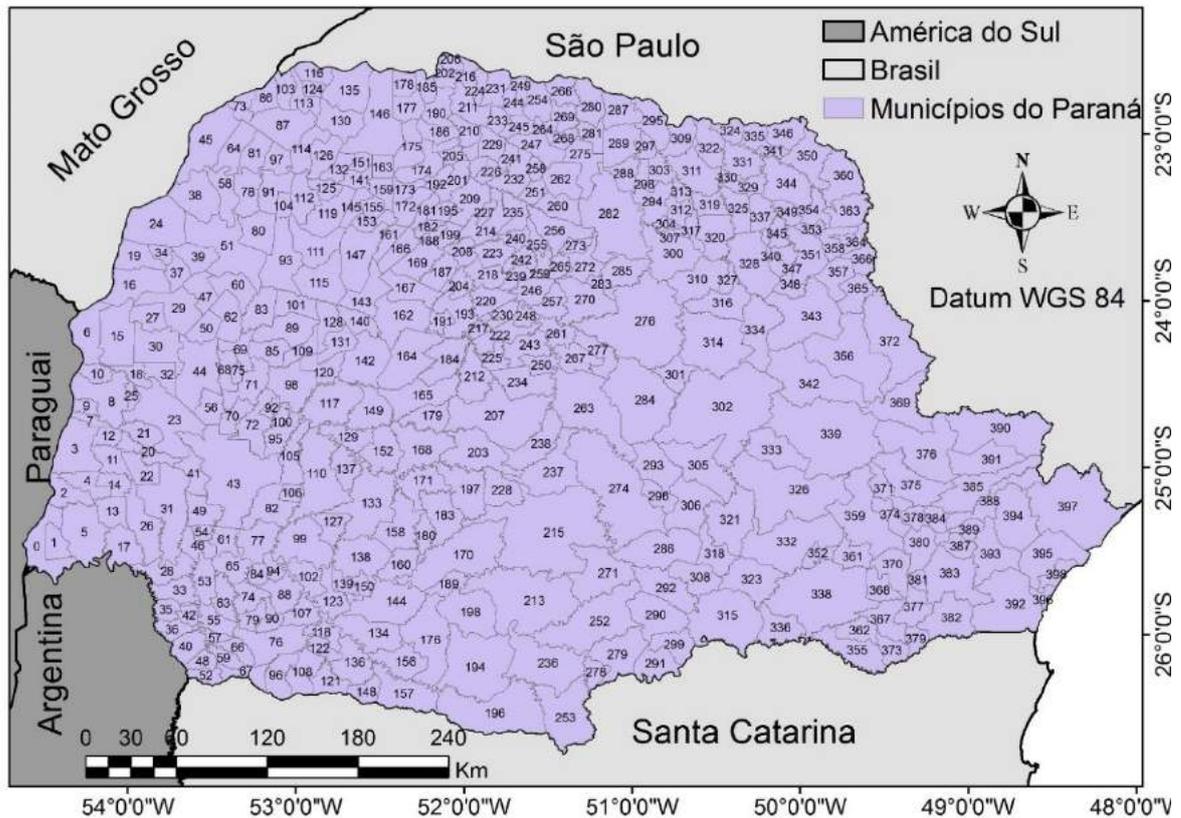


Figura 4 Área em estudo.

*Nome dos municípios no apêndice A.

4.2. Etapas de trabalho

O fluxograma geral das etapas de trabalho (Figura 5) define as atividades realizadas nos Laboratórios de Estatística Espacial (LEE) e Estatística Aplicada (LEA) da Universidade Estadual do Oeste do Paraná - UNIOESTE / Cascavel, no período de fevereiro de 2012 até dezembro de 2015.

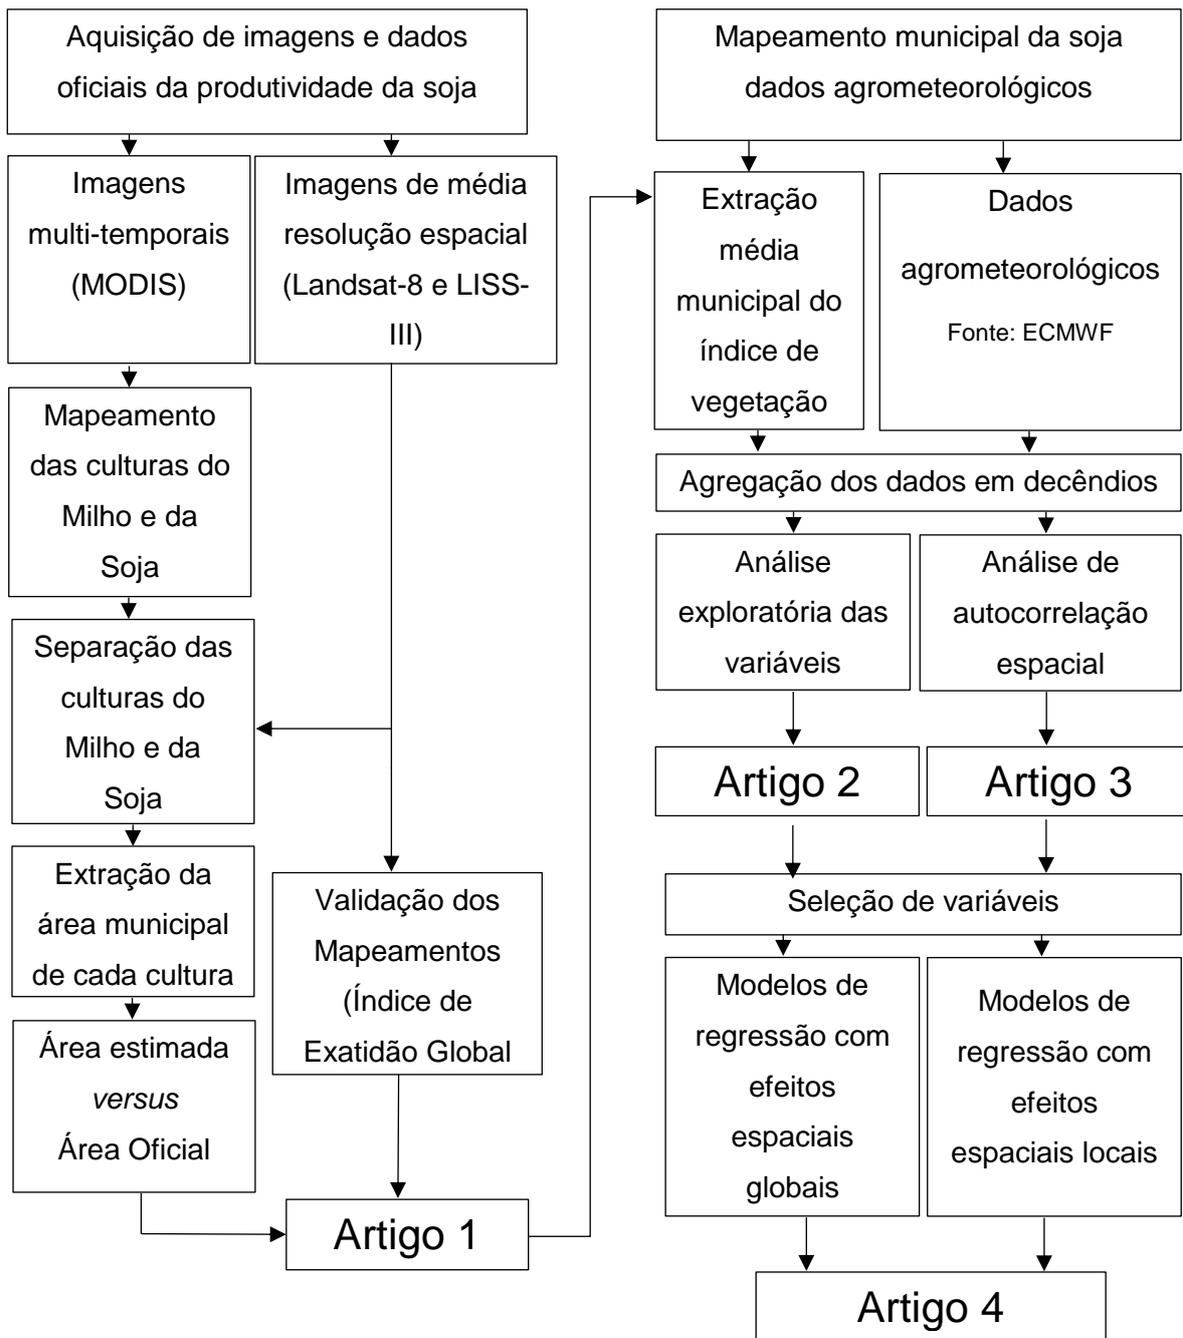


Figura 5 Fluxograma de trabalho.

A aquisição de imagens de satélite de alta resolução foi obtida a partir da base de dados do Instituto Nacional de Pesquisas Espaciais (INPE). As imagens multi-temporais foram obtidas pela Embrapa Informática com composições de 16 dias do índice EVI do sensor MODIS, (TERRA/AQUA, produto MOD13Q1 do “*Tile*” h13v11), com resolução espacial de 250m. As imagens utilizadas foram para determinar a área colhida (ha) por município da cultura da soja e milho bem como a estimativa de produtividade ($t\ ha^{-1}$) no Estado do Paraná. Para a realização dos processos, foram utilizados os softwares *Environment for Visualizing Images* (ENVI 4.5) e *ARCGIS* 9.3. A linguagem de programação *Interactive Data Language* (IDL), versão 7.0 (ESQUERDO, 2007) foi utilizada no

desenvolvimento do sistema de processamento automático das imagens MODIS, assim como na extração dos dados dos perfis temporais.

Os dados informaram as múltiplas datas com a realização da extração dos valores do índice de vegetação (EVI) agregados por fase e como as variáveis estão mudando através do tempo. Isso permite a avaliação do padrão espectro-temporal ao longo de todo o ciclo vegetativo da cultura (JENSEN et al., 2002). Para contemplar o ciclo das culturas estudadas, foram registradas as cenas de 225 (13/08/ano1) a 113 (23/04/ano2), portanto, foram obtidas trinta e três (33) imagens para cada ano-safra (2010/2011 até 2012/2013).

Proposto por Johann et al. (2012), foi realizado o mapeamento das culturas, em que foram utilizadas múltiplas datas de imagens para obtenção das áreas de plantio. Durante o ciclo de desenvolvimento, várias imagens geraram as Imagens de Mínimo e de Máximo índice de vegetação, ao longo do Estado, para a obtenção de uma imagem composição. Desta forma, garantiu-se a abrangência dos valores mínimos e máximos das culturas, uma vez que há grande variabilidade nas datas de semeadura nas diferentes regiões do Estado (IAPAR, 2012).

Assim, foram analisadas as possíveis relações existentes dos dados de EVI, e incorporado o conhecimento sobre a fisiologia da cultura (soja e milho). Desta forma, as fases de desenvolvimento das culturas foram selecionadas nos anos-safras em estudo.

Nesse sentido, para compor a Imagem de Máximo na cultura da soja, compreenderam-se as imagens relacionadas ao pico vegetativo. Para compor a Imagem de Mínimo, foram selecionadas imagens com ausência de culturas.

Assim, para realizar a avaliação da exatidão dos mapeamentos, utilizaram-se as matrizes de erros, que, de acordo com Foody (2002), adotam a metodologia chamada de painel amostral. Resumidamente, caracteriza-se pela distribuição aleatória de pontos amostrais dentro do limite do município, com o objetivo de se realizar um levantamento das classes de uso do solo de cada ponto (LUIZ et al., 2002).

A avaliação dos pontos para se determinar a qual classe eles eram pertencentes foi realizada por inspeção visual nas imagens de média resolução espacial (Landsat-8 e Resource-Sat 1), em composição colorida falsa cor RGB-453. Também foram determinadas as matrizes de erros de cada mapeamento confeccionado, com 400 pontos amostrais espalhados de forma aleatória no mapeamento em todo o Estado.

A partir da matriz de erros, calculada a Exatidão Global (EG) (Equação 1), que significa o total de acertos em relação ao total de amostras da imagem classificada, para o qual, segundo Foody (2002), o valor mínimo aceito que indica o sucesso da classificação foi padronizado em 85%.

$$EG = \frac{A}{n} \times 100 \quad (1)$$

em que:

EG : Exatidão Global,

A : Acerto geral (Pontos amostrais com acerto) e

n : Número de pontos amostrais.

O coeficiente Kappa (κ) (COHEN, 1960), obtido pela matriz de erros, utilizado para expressar a precisão da classificação, vem sendo recomendado, pois apresenta vantagens sobre a EG ao incorporar todas as amostras classificadas de forma correta ou incorreta da matriz dos erros ao invés de apenas utilizar aquelas que se situam na diagonal principal da mesma (Equação 2).

$$\kappa = \frac{n \times \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i \times x_j)}{n^2 - \sum_{i=1}^r (x_i \times x_j)} \quad (2)$$

em que:

κ : Coeficiente Kappa de concordância,

n : Número de pontos amostrais,

r : Número de linhas da matriz de erros,

x_{ij} : Observações da linha i e coluna j ,

x_i : Total marginal da linha i ,

x_j : Total marginal da coluna j .

A avaliação da qualidade da classificação para o coeficiente Kappa proposta por Landis e Koch (1977) é apresentada na Tabela 1.

Tabela 1 Qualidade de Classificação associada com os valores do índice Kappa

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

Fonte: Landis e Koch (1977).

As informações de área, obtidas a partir dos mapeamentos para cada ano-safra e índice de vegetação EVI, foram comparadas com os dados oficiais de área colhida para cada município e disponibilizadas pela SEAB/Deral e IBGE.

As variáveis agrometeorológicas foram obtidas na escala decendial para o balanço hídrico climatológico (mm) [Cw], precipitação pluvial (mm) [Ra], evapotranspiração potencial

(mm) [Et], radiação global ($kJ\ m^{-2}\ dia^{-1}$ transformado para $MJ\ m^{-2}\ dia^{-1}$) [Gr], temperatura média do ar ($^{\circ}C$) [Te], temperatura máxima do ar ($^{\circ}C$) [Ta] e temperatura mínima do ar ($^{\circ}C$) [Ti] no período de agosto a abril, referentes aos anos-safras. Como os dados da produtividade média da soja são disponibilizados por município, foi necessária a adequação dos dados agrometeorológicos das 303 estações virtuais para a escala espacial de 399 municípios e decendial. Mais informações no item 6.2.2, na seção de material e métodos do artigo 2.

Desta forma, os resultados foram obtidos pela análise descritiva da produtividade da soja, variáveis agrometeorológicas, EVI, de autocorrelação espacial univariada pelos índices de Moran e Geary Global, Moran Local, e bivariada pelo índice de Lee (item 6.2.3.).

Depois da verificação da autocorrelação espacial, foi necessário determinar um subconjunto de variáveis independentes que melhor explique a produtividade da soja para cada ano-safra. Assim, utilizou-se o método *stepwise* em que se adicionam e eliminam-se gradativamente novas variáveis ao modelo, a partir daquela com maior correlação com a variável resposta.

Depois da seleção de variáveis, os modelos de regressão espacial foram incorporados ao trabalho. Foram utilizados os modelos baseados em medidas de influência da vizinhança e na conceituação espacial do termo, ou seja, modelos globais e locais (SAR, CAR e GWR).

5. REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, D.A.; RUDORFF, B.F.T., RIZZI, R., SHIMABUKURO, Y.E. Monitoramento da colheita da cana-de-açúcar por meio de imagens MODIS. **Revista Brasileira de Cartografia**, n 60/04, 375-383. 2008.

ARAUJO, G. K. D.; ROCHA, J. V.; LAMPARELLI, R. A. C.; ROCHA, A. M. Mapping of summer crops in the State of Paraná, Brazil, through the 10-day spot vegetation NDVI composites. **Engenharia Agrícola**, v. 31, n. 4, p. 760-770, 2011.

AYOADE, J.O. Introdução a climatologia para os trópicos. São Paulo: Difel, 1986, 332p.
BAILEY, T. C.; GATRELL, A. C. **Interactive spatial data analysis**. Essex: Longman Scientific, 1995.

BERNARDES, T.; ADAMI, M.; FORMAGGIO, A. R.; MOREIRA, M. A.; FRANÇA, D. A.; NOVAES, M. R. Imagens mono e multitemporais MODIS para estimativa da área com soja no Estado de Mato Grosso. **Pesq. agropec. bras.**, Brasília, v. 46, n. 11, p. 1530-1537, nov. 2011.

BRUNSDON, Chris. **An R Library for Geographically Weighted Regression**. Newcastle upon Tyne, England: Department of Geography, University of Newcastle upon Tyne, 2002.

CÂMARA, G.; DAVIS, C.; FARIA, C.C.B. **Conceitos Básicos em Geoprocessamento**. Curso online, INPE, 2000.

CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V. Análise Espacial de Área. In: FUCKS, S. D.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. **Análise Espacial de Dados Geográficos**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais – Divisão de Processamento de Imagens, 2002.

CARDOSO, W. S.; DE SÁ, M., E., R.; CRUZ, S. H. R. **Indicadores socioespaciais urbanos nos assentamentos precários em Belém/PA**. XIV encontro nacional da ANPUR. Rio de Janeiro. 2011.

CARVALHO, M. S. **Aplicação de métodos de análise espacial na caracterização de áreas de risco a saúde**. Tese. Universidade Federal do Rio de Janeiro. Programa de Pós-Graduação em Ciências em Engenharia Biomédica. 1997.

CASAROLI, D.; FAGAN E. B.; SIMON, J.; MEDEIROS, S. P.; MANFRON, P. A.; NETO, D. D.; LIER, Q. J. V.; MÜLLER, L.; MARTIN, T. N. Radiação solar e aspectos fisiológicos na cultura de soja - uma revisão. **Revista da FZVA**. Uruguaiana, v. 14, n. 2, p. 102-120. 2007.

CHARLTON, M.; BRUNSDON, C.; FOTHERINGHAM, A.S. Geographically weighted summary statistics - a framework for localized exploratory data analysis **Computers, Environment and Urban Systems** 26 (6), 501-524. 2002.

CHI, G.; ZHU, J. Spatial regression models for demographic analysis. **Population Research and Policy Review**, Berlin/ Alemanha, p. 17 -42, 2007.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement** 20 (1): 37-46. 1960. doi:10.1177/001316446002000104

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da Safra Brasileira de Grãos 2015/16 – Estimativa – Outubro/2015**.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; MERCANTE, E.; LAMPARELLI, R. A. C. Spatial autocorrelation of ndvi and gvi indices derived from landsat/tm images for soybean crops in the western of the state of Paraná in 2004/2005 crop season. **Eng. Agríc.** [online]., vol.33, n.3 pp. 525-537. 2013. Doi:10.1590/S0100-69162013000300009

DELGADO, P. R.; ZANCHET, M. S. A importância da expansão da área de lavoura para o aumento da produção agrícola no paran . **Cad. IPARDES.** Curitiba, PR, ISSN 2236-8248, v.1, n. 1, p. 1-12, jan./jun. 2011.

DUFT, D. G.; JOHANN, J. A.; ROCHA, J. V.; LAMPARELLI, R. A. C. Metodologia para gera o de m scaras de culturas de ver o para o ano-safra 2007/2008 no Estado do Paran  por meio de  ndices de vegeta o do sensor MODIS. In: SIMP SIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR), 2011, Curitiba-PR. **Anais...** S o Jos  dos Campos: INPE, 2011. p. 0140-0147. DVD, On-line. ISBN 978-85-17-00057-7. Dispon vel em: < <http://www.dsr.inpe.br/sbsr2011/files/p0549.pdf> >. Acesso em: 30.maio. 2012.

EMBRAPA MONITORAMENTO POR SAT LITE. **Sistemas orbitais de monitoramento e gest o territorial.** Campinas: Embrapa Monitoramento por Sat lite, 2009. Dispon vel em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: jul. 2013.

EMBRAPA SOJA. **Tecnologia de produ o de soja – Regi o Central do Brasil 2009 e 2010.** 263p. Sistemas de Produ o n.13. Londrina-PR: Embrapa Soja, Out, 2008. <http://bioinfo.cnpsa.embrapa.br/seca/index.php/ecofisiologia/exigencias-climaticas> acesso em 18/07/13.

EPIPHANIO, R.D.V. **Avalia o da potencialidade das imagens MODIS na Estima o da  rea de soja no Estado do Mato Grosso.** 106p. Disserta o (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, S o Jos  dos Campos/SP, 2008.

ESQUERDO, J. C. D. M. **Utiliza o de perfis multi-temporais do NDVI/AVHRR no acompanhamento da safra de soja no oeste do Paran .** 186p. Tese (Doutorado em Engenharia Agr cola) - Universidade Estadual de Campinas, Campinas/SP, 2007.

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

FARIAS, J.R.B.; NEPOMUCENO, A.L.; NEUMAIER, N.; OYA, T. Ecofisiologia. In: Empresa Brasileira de Pesquisa Agropecu ria (EMBRAPA). **A cultura da soja no Brasil.** Londrina: Embrapa Soja, CD-Rom, 2000.

FARIAS, J.R.B.; NEPOMUCENO, A.L., NEUMAIER, N. **Ecofisiologia da soja.** Londrina: EMBRAPA-CNPSO, 2007. 9 p. (EMBRAPA-CNPSO. Circular t cnica, 48).

FIGUEIREDO, D.C. Projeto GeoSafras - aperfei amento do sistema de previs o de safras da CONAB. **Revista de Pol tica Agr cola**, v. 14, n. 2, p. 110-120, 2005.

FOODY, G. M. Status of Land Cover Classification Accuracy Assessment. **Remote Sensing of Environment** 80 (1): 185–201. 2002. doi:10.1016/S0034-4257(01)00295-4.

FOODY, G. M. Remote sensing of tropical forest environments: Towards the monitoring of environmental resources for sustainable development. **International Journal of Remote Sensing**, v. 24, p. 4035–4046, 2003.

FOTHERINGHAM, A. S.; CHARLTON, M. E.; BRUNSDON, C. Two techniques for exploring non-stationarity in geographical data. **Geographical Systems**, v. 4, p. 59-82, 1997.

FOTHERINGHAM, A.S., BRUNSDON, C., AND CHARLTON, M.E. **Geographically weighted regression: the analysis of spatially varying relationship**. New York, NY: Wiley. 2002.

FRANCHINI, J. C.; COSTA, J. M.; DEBIASI, H. Rotação de culturas: pratica que confere maior sustentabilidade à produção agrícola o Paraná. **Informações Agronômicas** nº 134, junho IPNI. 2011.

Francisco, E. R. **Indicadores de Renda baseados em Consumo de Energia Elétrica: Abordagens Domiciliar e Regional na Perspectiva da Estatística Espacial**. Tese de Doutorado. Escola de Administração de Empresas de São Paulo. 381 f. 2010.

GEARY, R. **The contiguity ratio and statistical mapping**. *The Incorporated Statistician* 5: p. 115-45, 1954.

GETIS, A.; ORD, J.K. The analysis of spatial association by use of distance statistics. **Geographical Analysis**, v. 24, n. 3, p. 189-206, 1992.

GOODCHILD, Michael F. **Spatial autocorrelation**. *CATMOG*, v. 47, 1986.

HUETE, A.; JUSTICE, C.; LEEUWEN, W.V. **MODIS vegetation index (MOD 13) algorithm theoretical basis document**. 1999. Disponível em: http://MODIS.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf. Consultado em 25 de julho de 2013.

HUETE, A.; DIDAN L.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of the Enviroment**. v. 83, n. 1-2, p. 195-213, nov., 2002.

IAPAR - INSTITUTO AGRONÔMICO DO PARANÁ. **Cartas Climáticas do Paraná**. 2000. Disponível em: <http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=677>. Consultado em maio de 2015.

IAPAR – Instituto Agrônômico do Paraná. **Zoneamento agrícola**. Londrina-PR. 2011. Disponível em: <http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=1043>. Consultado em maio de 2015.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Banco de Dados Agregados - Sistema IBGE de Recuperação Automática – SIDRA. 2015. Disponível em: <http://www.sidra.ibge.gov.br>. Consultado em 30 de setembro de 2015.

INPE. INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Manuais: tutorial de geoprocessamento**. 2003. Disponível em <http://www.inpe.br/>. Acesso em maio 2013.

JENSEN, M.E. Water consumption by agricultural plants. In: KOZLOWSKI, T.T. (Ed.) **Water deficits and plant growth**. New York: Academic Press, v. 2, p. 1-22, 1968.

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

JOHANN, J. A. **Calibração de dados agrometeorológicos e estimativa de área e produtividade de culturas agrícolas de verão no Estado do Paraná**. 225p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas/SP, 2012.

JOHANNSEN, C.J.; PETERSEN, G.W.; CARTER, P.G.; MORGAN, M.T. Remote sensing: changing natural resource management. **Journal of Soil & Water Conservation**. v. 58, n. 2, p. 42-45, 2003.

LABUS, M.P.; NIELSEN, G.A.; LAWRENCE, R.L.; ENGEL, R.; LONG, D.S. Wheat yield estimates using multi-temporal NDVI satellite imagery. **International Journal of Remote Sensing**, v. 23 n. 20, p. 4169-4180, 2002.

LANDIS, J. R., AND G. G. KOCH. 1977. **The measurement of observer agreement for categorical data**. *Biometrics*. n. 33, v. 1, p. 159-174. <http://www.jstor.org/stable/2529310>.

LATORRE, M. L.; SHIMABUKURO, Y. E.; ANDERSON, L. O. Produtos para ecossistemas terrestres – MODLAND. p. 23-35. *In: RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; CEBALLOS, J. C. (Orgs). O sensor MODIS e suas aplicações ambientais no Brasil*. São José dos Campos/SP: Parêntese, p. 23-36, 2007.

LI, H. **Approximate Profile Likelihood Estimation for Spatial-Dependence Parameters**. 2007. Tese (Doutorado em Filosofia) - The Ohio State University Graduate School, Columbus OH, 2007.

LIMA, M. T. **Uma proposta de modelagem para o risco de sofrer acidente de trabalho em Piracicaba/SP**. Dissertação. Escola Superior de Agricultura Luiz de Queiroz. 2010.

LONGLEY, P.A.; GOODCHILD, M. F.; MAGUIRE, D. J.; RHIND, D. W. Geographical information systems and science. 2nd ed. New York: **John Wiley**. 2005.

LOPES, S. B.; BRONDINO, N.C. M.; SILVA, A. N. R. Análise do desempenho de Modelos de Regressão Espacial na previsão de demanda por transportes. *In: XIV CONGRESSO PANAMERICANO DE INGENIERÍA DE TRÁNSITO Y TRANSPORTE*, 2006. Las Palmas de Gran Canaria. **Anais...** Las Palmas de Gran Canaria: XIV PANAM, 2006.

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

MELO, A. S.; HEPP, L. U. **Ferramentas estatísticas para análises de dados provenientes de biomonitoramento**. *Oecologia Brasiliensis* 12(3):p.463-486, 2008.

MENESES, H. B. **Interface Lógica em Ambiente SIG para Bases de Dados de Sistemas Centralizados de Controle do Tráfego Urbano em Tempo Real**. Dissertação de Mestrado, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2003.

MENESES, P. R.; ALMEIDA T. Introdução ao processamento de imagens de sensoriamento remoto. Brasília, **Editores UnB- Embrapa Cerrados**. 276 p. 2012.

MESSNER, S. F.; ANSELIN, L.; BALLER, R.D.; HAWKINS, D. F.; DEANE, G.; TOLNAY, S. E. The spatial patterning of country homicide rates: an application of exploratory spatial data analysis. **Journal of Quantitative Criminology**, v. 15, n. 4, p. 423-450, 1999. Disponível em: <<http://dx.doi.org/10.1023/A:1007544208712>>. Acesso em: 12 jun. 2013. DOI 10.1023/A:1007544208712

MIRANDA, J. I. **Fundamentos de Sistemas de Informações Geográficas**. Brasília, DF, Embrapa Informação Tecnológica. Editora Perfil. 425p. 2005.

MONTENEGRO, R. L. G. **Diversificações e Especializações Tecnológicas**: uma análise da atividade inovativa paulista. 2008. Dissertação (Mestrado em Economia Aplicada) - Universidade Federal de Juiz de Fora, Juiz de Fora, 2008.

PINHEIRO, D. M.; SILVA, N. C. Desenvolvimento do programa wingis para análise de informações geográficas. **Espaço e Geografia** (UnB), v. 12, n.2, p. 205-221, 2009.

PINHEIRO, D. M.; SILVA, N. C. **Desenvolvimento do programa wingis para análise de informações geográficas**. Espaço e Geografia (UnB), v. 12, p. 205-221, 2009.

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

RIZZI, R.; RISSO, J.; EPIPHANIO, R. D. V.; RUDORFF, B. F. T.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; FERNANDES, S. L. Estimativa da área de soja no Mato Grosso por meio de imagens MODIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal, RN. **Anais...** São José dos Campos: INPE, 2009. p. 0387-0394. DVD, On-line. ISBN 978-85-17-00044-7. Disponível em: <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.16.18.50.57/doc/387-394.pdf> >. Acesso em: 25.jul.2013.

RUDORFF, B.F.T.; SHIMABUKURO, Y.E.; CEBALLOS, J.C. **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos Campos/SP: Parêntese, 423p, 2007.

RUDORFF, B. F. T.; ADAMI, M.; AGUIAR, D. A.; GUSSO, A.; SILVA, W. F.; FREITAS, R. M. Temporal Series of EVI/MODIS to Identify Land Converted to Sugarcane. IEEE International Geoscience and Remote Sensing Symposium (IGARSS). 2009.

SALAME, C. W. **Análise espaço-temporal da ocorrência de queimadas e desmatamento no Estado do Pará no período de 1999 a 2004**. Dissertação. Programa de Pós-graduação em Matemática e Estatística (PPGME) da universidade Federal do Pará. 2008.

SANTOS, C.B.; HINO P.; CUNHA, T.N. L VILLA, T.C.; MUNIZ, J.N. **Utilização de um Sistema de Informação Geográfica para descrição dos casos de tuberculose**. Bol Pneumol Sanitária 12(1):7-12, 2004.

SANTOS, A.R.; PELUZIO, T.M.O; SAITO, N.S. SPRING 5.1.2 passo a passo – aplicações práticas. Alegre, ES: Gráfica F&M, 2011. 153p. Disponível em: <http://www.mundogeomatica.com.br/spring5x.htm> , acesso em maio/2013.

SEAB/DERAL - SECRETARIA DA AGRICULTURA E DO ABASTECIMENTO DO PARANÁ / DEPARTAMENTO DE ECONOMIA RURAL – Banco de Dados da Produção Agropecuária no Paraná. **Situação mensal de plantio, colheita e comercialização de produtos agrícolas no Paraná**. 2012. Disponível em: <http://www.agricultura.pr.gov.br/> Consultado em 03 de novembro de 2015.

SILVA, W. F.; AGUIAR, D. A.; RUDORFF, B. F. T.; SUGAWARA, L. M.; AULICINO, T. L. I. N. Análise da expansão da área cultivada com cana-de-açúcar na região Centro-Sul do Brasil: safras 2005/2006 a 2008/2009. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. Anais... São José dos Campos: INPE, p. 467-47. 2009.

SMITH, Michael J.; GOODCHILD, Michael F.; LONGLEY, Paul. **Geospatial analysis: a comprehensive guide to principles, techniques and software tools**. Leicester, UK: Matador, 2007.

SOARES, J. V.; BATISTA, G. T.; SHIMABUKURO Y. E. Histórico e descrição. *In*: RUDORFF, B. F. T.; SHIMABUKURO Y. E.; CEBALLOS J. C. **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos campos, SP: Parêntese, p. 3-21. 2007.

SOUZA, C. H. W., E. MERCANTE, J. A. JOHANN, R. A. C. LAMPARELLI, and M. A. URIBE-OPAZO. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**. v.36 (7): p.1809-1824. 2015. doi:10.1080/01431161.2015.1026956.

TEIXEIRA, A.; MATIAS, L.; NOAL, R.; MORETTI, E. Qual a melhor definição de SIG. **Fator GIS – A revista do geoprocessamento**. v. 3, n. 11, p. 20-22. 1995.

TEXEIRA, R. A. P.; BERTELLA, M. A. **Curva de Kuznets Ambiental para o Estado de Mato Grosso**: Modelagem Espacial. XIII Encontro Regional de Economia – ANPEC Sul. Porto Alegre – RS, 2010.

THOMAS, J.F. Ontogenetic and morphological plasticity in crop plants. *In*: BOOTE, K.J. et al. (Comp.). **Physiology and determinations of crop yield**. Madison: ASA/CSSA/SSSA, Cap. 7B, p. 181-185, 1994.

TRINTIN, J. G. **A economia do Paraná: 1985 a 1998**. Campinas, SP. Tese Doutorado, UNICAMP/IE, 2001.

WHIGHAM, Peter. **Geographically Weighted Regression**. Dunedin, New Zealand: University of Otago, (Lecture SPIN 301). 2007.

WREGGE, M.S.; CARAMORI, P.H.; GONÇALVES, A. C. A.; BERTONHA, A.; FERREIRA, R. C.; CAVIGLIONE, J. H.; FARIA, R. T.; FREITAS, P. S. L.; GONÇALVES, S. L. Regiões potenciais para o cultivo de cana-de-açúcar no Paraná, com base na análise de risco de geadas. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.13, n. 1, p. 113-122, 2005.

XAVIER, A.C.; RUDORFF, B.F.T.; SHIMABUKURO, Y.E.; BERKA, L.M.S. & MOREIRA, M.A. Multi-temporal analysis of MODIS data to classify sugarcane crop. **International Journal of Remote Sensing**, v. 27, p. 755-768, 2006.

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

6. RESULTADOS E DISCUSSÃO

6.1. ARTIGO 1: Mapeamento das culturas da soja e do milho no Estado do Paraná, Brasil, utilizando imagens de EVI do sensor MODIS

Resumo: Este artigo objetivou mapear, separar e estimar áreas com culturas de soja e milho no Estado do Paraná, Brasil, nos anos-safras 2012/2013 e 2013/2014, utilizando imagens do Índice de Vegetação (EVI) do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS). Deste modo, duas metodologias foram integradas: a primeira metodologia considerou a heterogeneidade em diferentes datas do ciclo das culturas; contemplou as cenas para gerar imagens de EVI máximos e mínimos, e criou uma composição *Red, Green e Blue* (RGB) para identificar as duas culturas simultaneamente. Na segunda metodologia, soja e milho foram identificados e mapeados usando a seleção de pixels puros com a ajuda do algoritmo de classificação supervisionada *Spectral Angle Mapper* (SAM). A fim de que se evitem áreas de sobreposição, os resultados da primeira e da segunda metodologia foram multiplicados e obteve-se a separação final. A validação final do mapeamento foi comparada aos dados oficiais, resultando em alta correlação para as culturas. Baseado nas imagens *Medium-Resolution Linear Imaging Self-Scanner* (LISS-III) e *Land Remote Sensing Satellite* (Landsat-8), a similaridade dos índices de acurácia, Índice de Exatidão Global (EG) e Kappa (κ) foram calculados para a obtenção das classificações boa e excelente, respectivamente. Por fim, mostrou-se que o uso das duas metodologias em consórcio, para a separação e exclusão de sobreposições para as culturas estudadas no Estado do Paraná, foi eficiente.

Palavras-chave: Agricultura anual, índice de vegetação, séries temporais.

6.1.1. Introdução

No Brasil, a previsão de safras é realizada pela estimativa da produção agrícola anual. O método consiste na aplicação de questionários aos produtores rurais e entidades agrícolas em todas as regiões abrangidas, os quais, em seguida, são então compilados e ajustados em escala nacional. Esta metodologia, que obtém dados indiretos, é demorada, gera custo elevado e não leva em conta qualquer conhecimento da distribuição espacial das culturas (CONAB, 2014).

Haja vista o mapeamento e monitoramento de áreas cultivadas serem essenciais para informar as políticas públicas em relação ao desenvolvimento agrícola (LOBELL & ASNER, 2004; LUNETTA et al., 2006), as ferramentas e tecnologias baseadas em geoprocessamento e sensoriamento remoto podem contribuir de forma mais efetiva, detalhada e rápida em prol da estimação de áreas das culturas pesquisadas (ADAMI et al., 2010; MERCANTE et al., 2010).

Imagens orbitais do *Moderate Resolution Imaging Spectroradiometer* (MODIS), gratuitamente distribuídas, têm mostrado grande potencial para monitorar a atividade

agrícola, devido a sua combinação de alta resolução espectral e temporal com uma resolução espacial moderada (250-1000m) (GALFORD et al., 2008; SAKAMOTO et al., 2010). Existem alguns estudos que visam ao monitoramento agrícola de grandes áreas usando índices de vegetação baseados em dados MODIS (WARDLOW & EGBERT, 2008; ARVOR et al., 2012; JOHANN et al., 2012; BROWN et al., 2013). A maioria dos estudos que envolve a análise do índice de vegetação tem utilizado o Índice de Vegetação Melhorado (EVI) (HUETE et al., 1997; JOHANN et al., 2012; SOUZA et al., 2015).

As culturas apresentam diferentes padrões e comportamento dinâmico-temporal, e o uso de séries temporais dessas imagens mostra esse padrão espectro temporal, que faz com que seja possível identificar os períodos de solo exposto, início da fase vegetativa, crescimento vegetativo máximo e senescência da cultura (BERNARDES et al., 2011). Desta forma, consegue-se associar diferentes padrões a cada fenologia e, por sua vez, ser capaz de distinguir as diferentes culturas.

No Paraná, Araújo et al. (2011) usaram os dados de vegetação do Índice de Vegetação por Diferença Normalizada (NDVI) e precipitação do *Système Probatoire de l'Observation de la Terre* (SPOT) e identificaram diferentes épocas de semeadura, que variaram entre o primeiro decêndio de outubro e o terceiro decêndio de dezembro, a fim de evidenciar a grande variabilidade.

Devido a esta variabilidade, Johann et al. (2012) propuseram um método de mapeamento que cobriu conjuntamente todas as áreas plantadas com soja e milho no Estado do Paraná, baseados no perfil espectro-temporal do índice de vegetação EVI. Esta análise de perfil considera diferentes datas de semeadura e colheita quando se utilizam múltiplas datas de imagens para compor cada um desses períodos em diferentes regiões do Estado. Tal variabilidade pode ser verificada pelo calendário agrícola (Tabela 2), que contém os dados de plantio e colheita em diferentes momentos do tempo.

Souza et al. (2015) observaram que os diferentes índices de vegetação (VIs), já estudados, mostram diferenças na variabilidade da sensibilidade. Portanto, influenciam a classificação em que os índices *Wide Dynamic Range Vegetation Index* (WDRVI) e EVI foram semelhantes e geraram informação espectral, a qual forneceu melhor distinção para o mapeamento das culturas sob estudo.

Logo, é necessária a identificação das áreas de cultivo de soja ou milho separadamente. Neste sentido, a metodologia adotada por Souza et al. (2015) aplica uma classificação supervisionada, através do algoritmo *Spectral Angle Mapper* (SAM) (KRUSE et al., 1993), o qual utiliza o ângulo entre as amostras de treinamento em um espaço n -dimensional, a fim de diferenciar a nuvem de pixels que identificam determinada cultura. Assim, foram realizadas várias simulações para diferentes ângulos a fim de melhorar a separação das culturas para as quais a maioria dos pixels devem ser corretamente classificados. Para obter-se tal medida de eficiência, uma das maneiras é considerar o

mapeamento gerado com imagens de alta resolução espacial *Global Visualization Viewer* [(USGS) (*Land Remote Sensing Satellite* (Landsat-8))] e Instituto Nacional de Pesquisa Espacial [(INPE) (*Medium-Resolution Linear Imaging Self-Scanner* (LISS-III))].

Tabela 2 Calendário agrícola para o milho e soja de acordo com a porcentagem de plantio e colheita das culturas

	Culturas	Estágio	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun
2012/2013	Milho	Plantio (%)	-	26	60	13	1	-	-	-	-	-	-
		Colheita (%)	-	-	-	-	-	-	19	-	73	6	2
	Soja	Plantio (%)	-	3	43	51	3	-	-	-	-	-	-
		Colheita (%)	-	-	-	-	-	1	38	-	59	2	-
2013/2014	Milho	Plantio (%)	-	27	58	14	1	-	-	-	-	-	-
		Colheita (%)	-	-	-	-	-	1	27	35	30	5	2
	Soja	Plantio (%)	-	2	45	48	5	-	-	-	-	-	-
		Colheita (%)	-	-	-	-	-	4	38	37	19	2	-

Source: SEAB (2015).

O objetivo deste trabalho foi mapear, separar e estimar áreas de cultivo de soja e milho no Estado do Paraná, Brasil, nos anos-safras 2012/2013 e 2013/2014, usando imagens de índice de vegetação EVI do Sensor MODIS. Mais especificamente, este trabalho propôs uma forma de separação entre ambas as culturas considerando duas metodologias de mapeamento já desenvolvidas por Johann et al. (2012) e Souza et al. (2015).

6.1.2. Área de estudo

A área de estudo compreende o Estado do Paraná, Sul do Brasil, na América do Sul, entre 22° 29' S e 26° 43' S e 48° 2' W e 54° 38' W, dividida em seis setores pela Secretaria de Agricultura e Abastecimento do Paraná (SEAB), mesorregiões nomeadamente: Oeste, Centro-Oeste, Noroeste, Norte, Sul e Sudoeste (Figura 6). O clima do Estado tem diferenças marcadas de acordo com a região, com clima subtropical predominante no Norte e temperado no Sul, correspondente aos grupos de classificação climática de Köppen de Subtropical úmido (Cfa) e Marinho – Inverno ameno (Cfb), respectivamente.

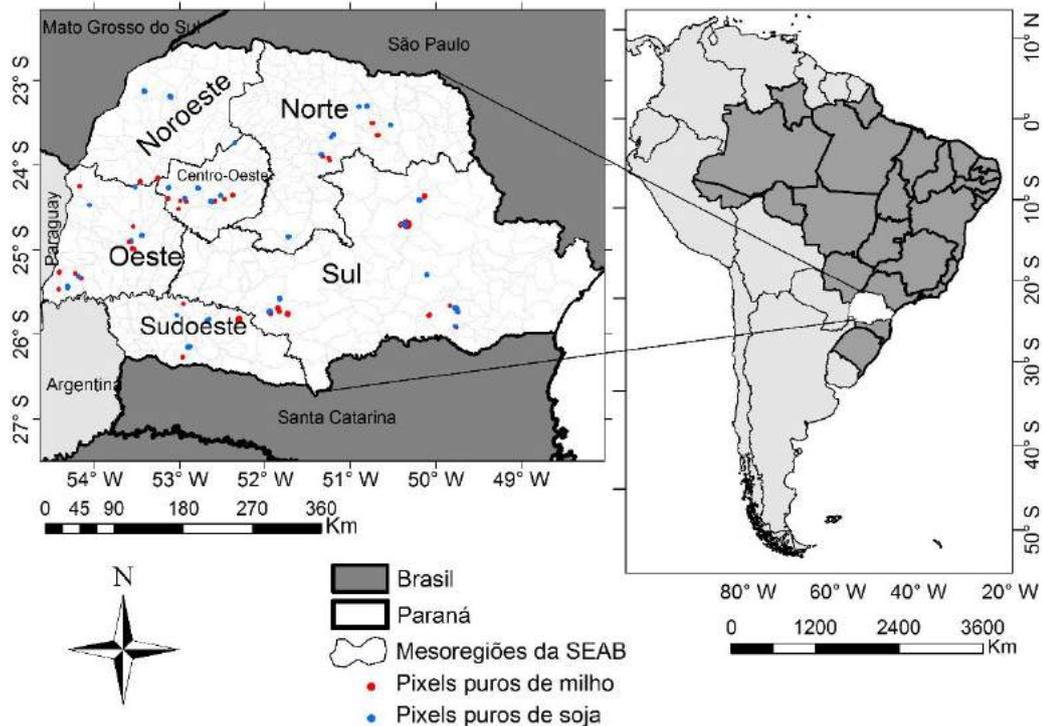


Figura 6 Estado do Paraná dividido de acordo com as Mesoregiões da SEAB.

A cultura da soja vem obtendo uma crescente importância na agricultura mundial, devido à diversidade de seu uso como oleaginosa e aumento da demanda global por alimentos (DERAL, 2012). De acordo com a *Food and Agriculture Organization of the United Nations* (FAOSTAT), a área plantada no mundo aumentou de 78,96 milhões de hectares em 2012 para 111,15 milhões em 2013, ou seja, um crescimento de 41,1% na década. O Brasil teve cerca de 30,23 milhões de hectares de área cultivada na safra de 2014 e, no Paraná, o segundo maior produtor do País, a área cultivada foi de 5,02 milhões de hectares (IBGE, 2015).

Em termos de milho, as superfícies plantadas no mundo entre 2002 e 2013 foram de 137,61 a 185,12 milhões de hectares, isto é, aumento de 34,45%. No Brasil, o terceiro maior produtor mundial do grão detinha em 2013 aproximadamente 15,3 milhões de hectares (FAOSTAT, 2015). No Estado do Paraná, a cultura do milho é semeada em duas épocas distintas, e a primeira concorre diretamente com as áreas utilizadas para a produção de soja. Assim, no ano-safra 2014/2015, a área estimada para a primeira safra foi de 542386 hectares (SEAB, 2015).

6.1.3. Material e Métodos

O método de pesquisa adotado aqui consistiu dos seguintes passos: (i) aquisição dos dados do satélite; (ii) seleção dos pixels puros; (iii) mapeamento de soja e milho usando o método proposto por Johann et al. (2012); (iv) mapeamento de soja e milho usando o método proposto por Souza et al. (2015); (v) mapeamento da soja e milho integrando os passos iii e iv; (vi) análise de comparação de áreas com dados oficiais de cada área colhida, disponíveis pela SEAB (2014) e (vii) análise da precisão de mapas.

6.1.3.1. Aquisição de dados de Satélite

6.1.3.1.1. MODIS

As imagens utilizadas foram obtidas gratuitamente da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Os dados do sensor MODIS são produtos originados do MOD13Q1.5 (Terra) e MYD13Q1.5 (Aqua), do "Tile" h13v11 que engloba todo o Estado do Paraná. As imagens do índice de vegetação EVI estão contidas dentro destes produtos e foram projetadas para World Geodetic System (WGS84) com formato GeoTIFF. As imagens de *quality images* (qualidade de índices de vegetação) e *pixel reliability* (confiabilidade de pixel) foram usadas para eliminação de pixels com ruído. Para contemplar todo o ciclo vegetativo da safra de verão de soja e milho, de acordo com o calendário agrícola do Estado, imagens de 13 de agosto do ano 1 a 23 de abril do ano 2 foram usadas, totalizando 33 imagens para cada ano-safra (2012/2013 e 2013/2014).

Para cada ano-safra, as 31 imagens foram empilhadas temporalmente (composição de imagens) o que permitiu a geração do perfil espectro temporal do EVI. Imagens de satélite de séries temporais podem ser afetadas pela interferência de vários ruídos. Os ruídos são valores anormais que podem ocorrer devido às falhas de processamento, à presença de nuvens, à falha no detector, à geometria de visualização, entre outros (KOBAYASHI & DYE 2005; HIRD & MCDERMID 2009).

A aplicação de um filtro é um procedimento cujo objetivo é de eliminar ou minimizar a interferência de ruídos, assim, a influência é minimizada em estudos fenológicos subsequentes de culturas agrícolas (JÖNSSON & EKLUNDH 2002; SAKAMOTO et al., 2005). Então, após o empilhamento da série temporal das imagens de EVI para cada ano-safra, foi aplicado o filtro proposto por Wardlow et al. (2006) para a eliminação do ruído, sem destruir o perfil espectro-temporal do índice de vegetação.

6.1.3.1.2. Landsat-8

O Landsat-8 é um satélite largamente utilizado para observar a terra com 15 m de *Panchromatic Band* (PAN) (escala de cinza) de resolução e 30 m em multiespectral (cor). As imagens foram obtidas pelo sensor *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS), compostas por nove bandas espectrais, com projeção *Universal Transverse Mercator* (UTM), datum WGS84 e período de revisita de dezesseis dias (USGS, 2012). O download gratuito das imagens de alta resolução espacial foi obtido por catálogo de imagens da USGS, para as órbitas 076-078 e pontos 220-224, Zona 22 Sul. O processamento do Landsat-8 para gerar uma composição de imagens, foi colocar as bandas nos canais *Red* (vermelho), *Green* (verde) e *Blue* (azul) (RGB), em que no vermelho corresponde à banda 5, no verde à banda 6 e no azul à banda 4 (RGB564).

6.1.3.1.3. LISS-III

O LISS-III foi lançado a bordo do Satélite *Indian Remote Sensing Satellite* (IRS-P6) ou satélite RESOURCESAT-1 e operou na resolução espacial de 23,5 m em faixas imageadas de 141 km, datum WGS 1984 (INPE, 2014) e projeção em formato GeoTIFF. O download gratuito das imagens de alta resolução espacial foi obtido por catálogo de imagens do INPE para as órbitas 325-330 e pontos 94 a 97, Zona 22 Sul.

O processamento da LISS-III para gerar composições de imagens RGB correspondeu à banda 4 no canal do vermelho; no verde, correspondeu à banda 5 e no azul à banda 3 (RGB453). Para os anos-safras, este trabalho utilizou mapas de referência e interpretação visual do satélite IRS-P6 (RESOURCESAT-1), sensor LISS-III e imagens de satélite Landsat-8 (USGS) (EPIPHANIO et al., 2010).

6.1.3.2. Seleção de pixels puros

Foram selecionadas cinco áreas amostrais com pixels puros MODIS, para cada uma das culturas analisadas (soja e milho) e para cada mesorregião, totalizando 60 áreas de cada cultura no Estado do Paraná (Figura 6) (RISSO et al., 2012). Os pixels puros MODIS foram transformados em regiões de interesse (ROI) e, por meio da ferramenta de visualização *n*-dimensional, foram selecionados valores de radiância e reflectância espectral para soja e milho. Em outras palavras, os pixels das referidas culturas que ficaram isolados a partir da visualização conjunta foram selecionados e classificados como ROI puros de cada cultura.

6.1.3.3. Mapeamento das culturas da soja e do milho por meio do método M1

A fim de englobar o ciclo da cultura de milho e soja, foram consideradas as trinta e uma (31) cenas EVI, o Dia do ano (DOY) 241 (29 de Agosto) do ano 1 DOY 113 (23 de Abril) do ano 2. Nessas séries temporais, para reduzir os efeitos do ruído habitual do índice de vegetação, aplicou-se o *flat smoother filter*, que permitiu a geração do perfil espectral EVI pela composição de imagens usando rotinas desenvolvidas em linguagem *Iterative Data Language* (IDL) para a geração de as imagens de máximos e mínimos EVI (ESQUERDO, ZULLO JUNIOR, e ANTUNES, 2011).

Para o ano-safra 2012/2013, as cenas de DOY 273 (30 de Setembro 2012) até a DOY 313 (09 de Novembro 2012) foram utilizadas para gerar imagens de mínimo EVI (solo exposto, fase pré-plantio e desenvolvimento inicial). Para imagens de máximo EVI, foram usadas cenas de DOY 313 (09 de Novembro 2012) até DOY 57 (26 de Fevereiro 2013), que compreendem o crescimento máximo vegetativo e o desenvolvimento final das culturas. Para o ano-safra 2013/2014, o período de imagens usadas para gerar as imagens de mínimo e máximo EVI foram as cenas DOY 249 (06 de Setembro 2013) até DOY 313 (09 de Novembro 2013), e cenas DOY 313 (09 de Novembro 2013) até DOY 113 (23 de Abril 2014), respectivamente. E, um fluxograma dos passos da metodologia M1 é apresentado na Figura 7.

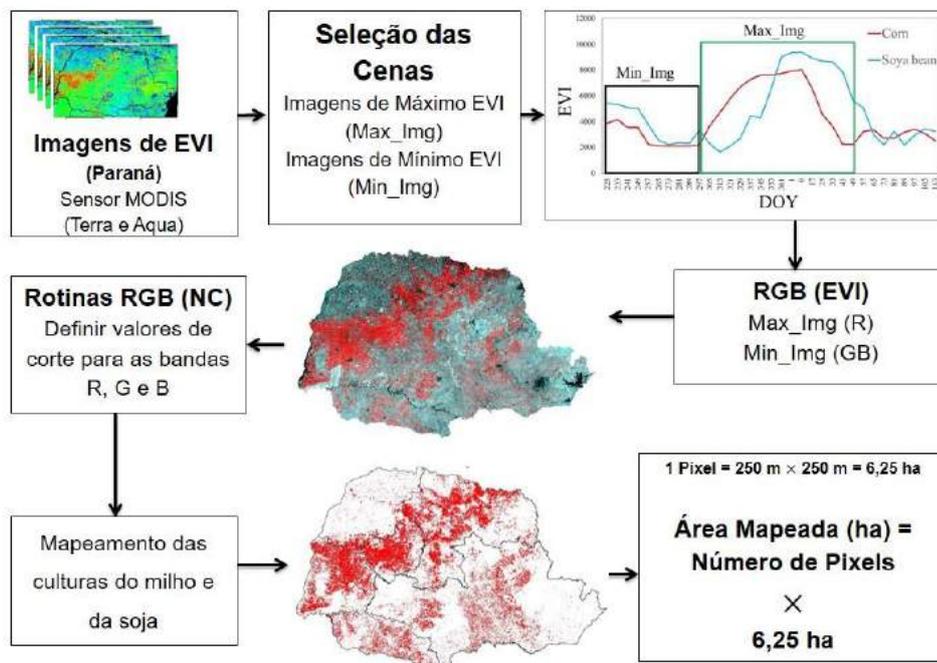


Figura 7 Fluxograma das etapas do mapeamento pelo método M1.

O software *Environment for Visualizing Images* (ENVI) foi utilizado para gerar uma composição RGB, em que no canal do vermelho correspondeu à imagem de máximo EVI. Enquanto, os canais verde e azul corresponderam à imagem de mínimo EVI, pois cria uma

composição de cor em que as áreas em vermelho representam as culturas de verão e as outras cores representam os outros alvos.

A composição de cores RGB, com valores de EVI originais, foi transformada em Níveis de Cinza (NC), os quais variaram de 0 a 255. Tal transformação teve como objetivo normalizar os valores de acordo com a variação intra-anual dos índices de vegetação, devido às condições agrometeorológicas em cada ano-safra (LHERMITTE et al., 2011). Subsequentemente, os valores de corte foram definidos para cada ano da cultura, uma vez que esse procedimento foi realizado para obter o mapeamento das culturas de verão (JOHANN et al., 2012).

Para cada ano-safra, muitas simulações foram feitas e a escolha foi baseada na comparação entre os mapeamentos gerados e as imagens de alta resolução espacial (mosaicos LISS-III para o ano-safra 2012/2013 e Landsat-8 para o ano-safra 2013/2014), usadas como referências terrestres. Para compará-los com os dados oficiais da SEAB, em IDL, os dados RGB foram transformados em NC, considerando-se os pontos de corte para as bandas R, G e B por simulação, originando o mapeamento de pixels de verão (ESQUERDO, ZULLO JUNIOR, e ANTUNES, 2011). Esta operação resultou no mapeamento da área municipal (soja com milho), cujas culturas foram agrupadas de acordo com cada mesorregião da SEAB. Assim, o objetivo da aplicação do método M1 foi mapear as culturas de soja e milho conjuntamente, conforme metodologia proposta por Johann et al. (2012).

6.1.3.4. Mapeamento da soja e do milho pelo método M2

A análise dos perfis temporais para ambas as culturas aponta que M2 (Figura 8) consiste em gerar as composições de mínimo e máximo EVI para soja e milho, para cada mesorregião da SEAB e na geração de uma composição RGB, obtida por avaliação de épocas de semeadura das culturas de soja e milho.

Para este propósito, analisou-se o calendário agrícola oficial do Paraná, a fim de identificar a variabilidade das épocas de plantio de cada cultura (Tabela 2). Em relação ao milho, o plantio tem início em setembro, com a maior área semeada em outubro (~59%). Por outro lado, a soja possui a maior parte (~94%) semeada entre outubro e novembro (SEAB, 2014). Adicionalmente ao calendário agrícola, os perfis espectro-temporal de índice de vegetação foram analisados e gerados por pixels puros (Figura 6) para determinar a cena a ser usada na construção da composição RGB (LUNETTA et al., 2006).

Assim, no canal do vermelho, foi colocada a imagem de máximo EVI para a cultura de milho. Para isso, selecionaram-se as cenas com maior diferença entre os perfis temporais de milho e soja. Portanto, foram consideradas apenas as cenas que

apresentaram valores EVI da cultura de milho durante a fase vegetativa para o efeito de contraste com os valores de soja durante a fase de semeadura.

No canal do verde, foi colocada a cena considerada como o período de mínimo EVI para ambas as culturas, ou seja, período em que ambas culturas estavam ausentes. Finalmente, no canal do azul, foram colocadas as composições de máximo EVI da soja, obtida pelo método M1 em cada ano-safra e mesorregiões. A partir da ferramenta *n-D Visualizer*, que é um diagrama de dispersão de pontos em n -dimensões, em que n depende do número de frequências utilizadas (três bandas RGB – M2), tem-se a descrição da radiância e a reflectância espectral em cada banda (R com milho, G ausência de culturas e B cultura de soja). Assim, a distribuição desses pontos no espaço n -dimensional foi utilizada para estimar o número de valores extremos; e, quando o diagrama de dispersão mostrou um ângulo de projeção conveniente o suficiente para diferenciar a nuvem de pixel, essa foi definida e classificada como novo ROI para as culturas, diferenciando-se assim o milho da soja.

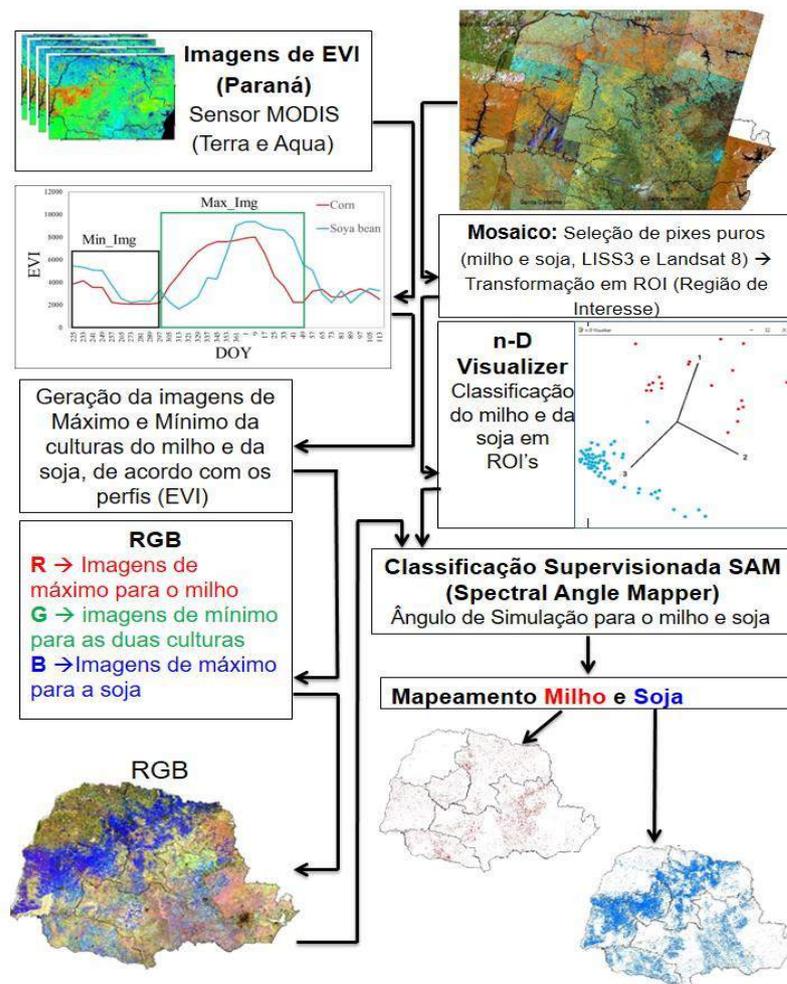


Figura 8 Fluxograma das etapas do mapeamento pelo método M2.

Usando a classificação supervisionada SAM, com os ROI's que foram selecionados e classificados pela ferramenta *n-D Visualizer* para cada cultura, simulações foram feitas com a finalidade de gerar mapeamentos para soja e milho, as quais foram validadas a partir das informações obtidas através de imagens com alta resolução espacial (SOUZA et al., 2015).

A fim de prosseguir com o mapeamento, foram selecionadas imagens de alta resolução (mosaicos LISS-III para o ano-safra 2012/2013 e Landsat-8 para o ano-safra 2013/2014), obtidas pelas composições RGB453 e RGB564, respectivamente, bem como parcelas de referências colhidas no campo.

6.1.3.5. Mapeamento da soja e do milho integrando as metodologias M1 e M2 – M3

Como resultado final M1, foram obtidos um ótimo ajuste e uma excelente acurácia espacial entre os dados gerados pelas máscaras, embora este procedimento não tenha promovido a separação das culturas. Esta separação foi encontrada pelo método M2 para soja ou para o milho em cada uma das mesorregiões, devido à alta variabilidade de datas de semeadura. Assim, o método M3 (Figura 9) é uma maneira de melhorar esta separação, portanto é possível que o mapeamento integrado através de M1 e, por meio de M2 se obtenha o mapeamento para soja e milho sem sobreposições, de acordo com o melhor ângulo, pela comparação das imagens de alta resolução espacial e dados oficiais (SEAB, 2014).

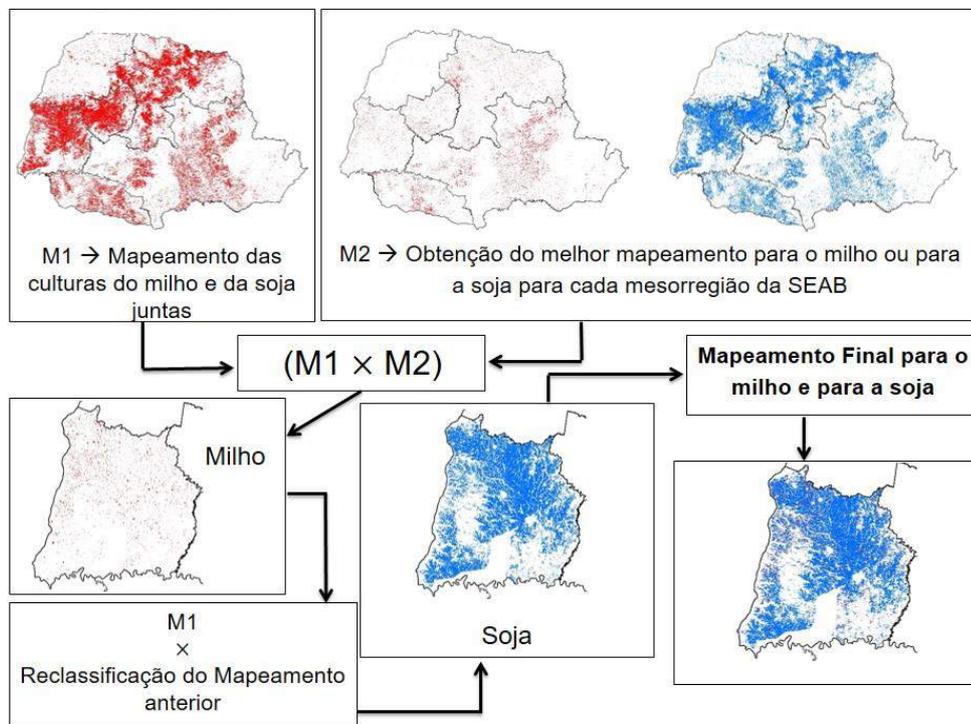


Figura 9 Fluxograma das etapas realizadas para a separação da soja e do milho pelo método M3.

Para concluir o mapeamento de separação, uma vez que o melhor resultado para determinada cultura (soja ou milho) para cada mesorregião é encontrado, o mapeamento M1 é multiplicado pelo mapeamento M2 (melhor simulação encontrada em soja ou milho). Portanto, o resultado M3 é uma cultura, isto é, os pixels que estão contidos em M1 e M2, para então obter soja ou milho. Assim, para gerar o outro mapeamento, os pixels da cultura encontrada foram reclassificados e multiplicados novamente por M1, levando-se a um mapeamento das culturas separadas, sem sobreposição. O procedimento é verificado para cada mesorregião pela extração de cada valor de área e comparação dos dados oficiais.

6.1.3.6. Análise de comparação de áreas

As informações de área por municípios e mesorregiões, obtidas para os anos-safras 2012/2013 e 2013/2014, respectivamente, foram comparadas com os dados oficiais de cada área colhida, disponível pela SEAB (2014), pelo coeficiente linear de Pearson. Foram utilizados os coeficientes estatísticos Erro Médio (ME), Raiz quadrada do erro médio (RMSE) e Índice de concordância melhorado de Willmott (IW) (WILMOTT, ROBESON, e MATSUURA, 2012), como indicadores estatísticos que estão definidos, respectivamente, nas Equações (3)–(5):

$$ME = \frac{1}{n} \sum_{i=1}^n (O_i - E_i) \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - E_i)^2} \quad (4)$$

$$IW = 1 - \frac{\sum_{i=1}^n |E_i - O_i|}{2 \sum_{i=1}^n |E_i - \bar{O}|} \quad (5)$$

em que n_i : número de municípios; O_i : área cultivada (soja e milho) como informado pela SEAB; E_i : área obtida pela mapeamento; $1 \leq i \leq n$; \bar{O} : área média cultivada (soja e milho) dos municípios conforme informado pela SEAB.

6.1.3.7. Análise de acurácia dos mapas

A avaliação da acurácia espacial foi obtida ao serem considerados os índices de Exatidão Global (EG) e índice de Acurácia Kappa (κ) (COLGATON, 1991; COLGATON & GREEN, 1999; DE BASTIANI, URIBE-OPAZO, e DALPOSSO, 2012; DALPOSSO et al., 2012). Além disso, foram obtidos os Erros de Inclusão (IE) e de Omissão (OE), que usaram como referência terrestre as imagens de alta resolução espacial (LISS-III e Landsat-8). Para o erro amostral de aproximadamente 5%, determinou-se um total de 400 amostras

necessárias, cuja metade foi selecionada aleatoriamente sobre o alvo pretendido (mapeamento das culturas de soja e milho), e os demais sobre outros alvos, ou seja, amostragem aleatória estratificada.

6.1.4. Resultados e Discussões

6.1.4.1. Resultado obtido do mapeamento pelo método M1

Dentre as várias simulações de corte de NC, para os canais de composição RGB (Figura 10a), o melhor resultado observado para o ano-safra 2012/2013 quando definindo 150 como o valor de corte para o canal do R (valores NC acima de 150), 140 e 130 como valores de corte para os canais de G e B, respectivamente (valores NC de corte abaixo dos valores para G e B). No ano-safra 2013/2014 (Figura 10b), a composição de valores dos cortes para o RGB foram 150, 140 e 140, respectivamente.

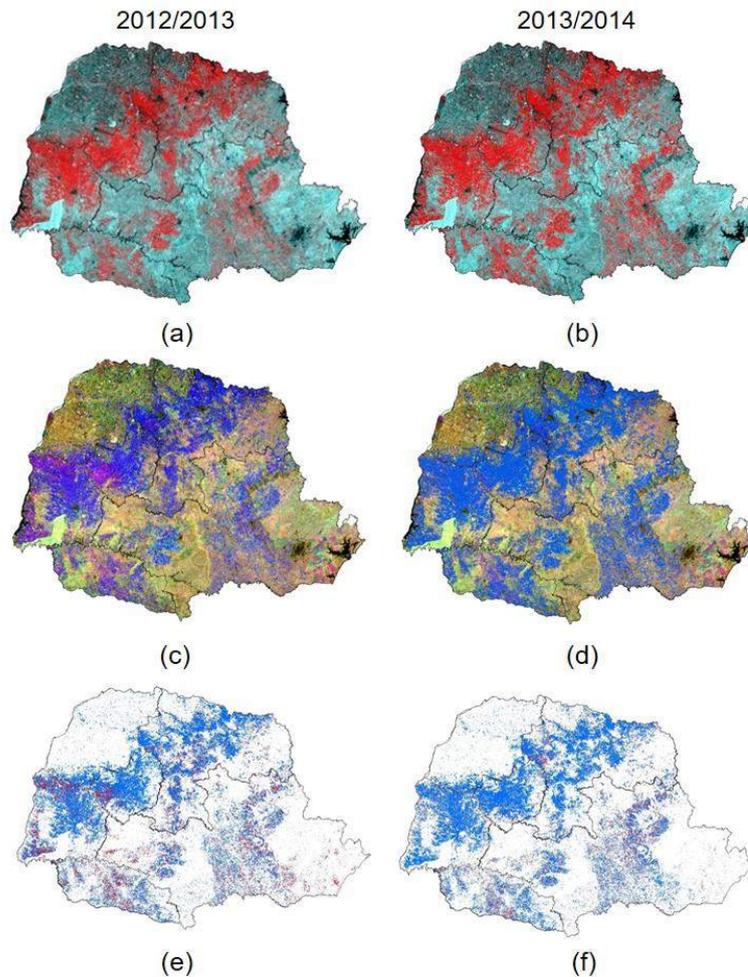


Figura 10 Composição RGB para o Estado do Paraná: Método M1 (a e b), método M2 (c e d) e mapeamento de soja e milho (e e f).

Os resultados observados pelo método M1 concordam com aqueles obtidos por Johann et al., (2012), e a distribuição espacial das áreas cultivadas com soja e milho,

distribuídas no chamado “cinturão da soja”, está localizada a partir da região Oeste para região Norte do Estado bem como as concentrações na mesorregião Sul.

6.1.4.2. Resultado do mapeamento pelo método M2

As imagens utilizadas para a elaboração deste mapeamento foram obtidas durante os períodos de solo exposto, desenvolvimento vegetativo e senescência da soja no Estado do Paraná. As composições RGB foram geradas de acordo com cada mesorregião (Tabela 3) a fim de contemplar todo o pico vegetativo da cultura da soja considerando a imagem de máximo no canal do R para a cultura do milho, no canal do G, a imagem em que havia solo exposto e finalmente, no canal do B, a imagem mapeada de máximo EVI obtida pelo método M1. É notório que, para ambos os anos-safras no canal do R, houve variação entre as imagens de máximo EVI para as mesorregiões, que vão do DOY 289 (16 de Outubro 2013) ao DOY 329 (25 de Novembro 2013). E, devido a tal variabilidade nas épocas de semeadura, não foi possível adotar-se uma única data de máximo EVI para a cultura do milho para todo o Estado.

É importante ressaltar que o plantio precoce, principalmente nas mesorregiões Oeste e Centro-Oeste, é justificado pela colheita antecipada, devido às semeaduras da segunda safra de milho. Nota-se que no canal do G, o DOY variou somente para o ano-safra 2013/2014, de DOY 249 (06 de Setembro 2013) ao DOY 257 (14 de Setembro 2013), enquanto para o ano-safra 2012/2013 foi usado o DOY 265 (22 de Outubro 2012). Isto é justificado pela variabilidade inicial das chuvas; por isso, a necessidade de realizar o estudo de datas em que o solo esteve exposto bem como o plantio e o vigor vegetativo máximo, para o mapeamento da soja e milho.

Verificando as composições RGB para ambos os anos-safras por mesorregião no método M2 (Figura 10c e Figura 10d), há maior incidência da coloração vermelha no ano-safra 2012/2013 (mesorregiões Oeste, Sul e Centro-Oeste) quando comparada a 2013/2014, e isso indica áreas com redução do plantio de milho de um ano para o outro.

6.1.4.3. Resultado obtido para o método proposto M3

A partir da classificação SAM, foram simulados vários ângulos com o ROI classificado para soja e milho de cada mesorregião (Tabela 3). Para o ano-safra 2012/2013, somente na mesorregião Noroeste, o ângulo gerado pela ROI foi usado para a separação, para o milho 0.06, e a para a soja 0.27. Para as demais mesorregiões, a área de soja cultivada foi encontrada através de matemática de bandas, ou seja, verificou-se o mapeamento de milho pelos ângulos simulados, reclassificado (masculino pra concordar com mapeamento) e então multiplicado por M1 para encontrar o mapeamento de soja.

Tabela 3 Composição RGB a fim de gerar o mapeamento da cultura pelo método M2 e os ângulos de ajuste para a separação de milho e de soja pelo método M3

Mesorregião	Método M2						Método M3			
	2012/2013			2013/2014			2012/2013		2013/2014	
	R	G	B	R	G	B	Milho	Soja	Milho	Soja
Noroeste	297	265	M1	297	249	M1	0,06	0,27	0,50 × M1	0,50
Norte	321	265	M1	329	257	M1	0,30	0,30 × M1	0,20	0,20 × M1
Centro-Oeste	297	265	M1	297	249	M1	0,13	0,13 × M1	0,80 × M1	0,80
Oeste	297	265	M1	289	249	M1	0,17	0,17 × M1	0,20	0,20 × M1
Sul	329	265	M1	321	257	M1	0,30	0,30 × M1	0,45	0,45 × M1
Sudoeste	305	265	M1	321	257	M1	0,24	0,24 × M1	0,30	0,30 × M1

Nota= R: canal do vermelho; G: canal do verde; B: canal do azul.

No ano-safra 2013/2014, somente as mesorregiões Centro-Oeste e Noroeste foram classificadas por ângulos que geraram o mapeamento da soja. Esse fato é explicado pela reduzida plantação de milho nestas regiões, o que fez a classificação por SAM difícil. As outras mesorregiões foram mapeadas com milho classificado com ROI e, em seguida, foi feita a multiplicação de banda para poder encontrar o mapeamento das áreas de soja.

Os resultados obtidos foram os mapas separados para as culturas de soja e milho em todas as mesorregiões do Estado (Figura 10e e Figura 10f).

6.1.4.4. Comparação das áreas mapeadas com os dados oficiais

Uma extração de área foi feita para a comparar com os dados oficiais da SEAB, obtidos pelo pacote de rotina desenvolvida em linguagem IDL (ESQUERDO, ZULLO JUNIOR, e ANTUNES, 2011). Essa operação resulta na área (ha) de soja e milho para os município e mesorregião. Verificou-se uma superestimação para o milho de 16% quando comparados com os dados oficiais em ambos anos-safras em estudo (Tabela 4).

Este resultado pode ser devido às tentativas de encobrir a variabilidade das datas de plantio em cada mesorregião pelos pixels puros. Outra explicação é baseada no tamanho das áreas cultivadas com milho, que são menores em relação à soja, portanto, o tamanho do pixel é maior do que área cultivada. Este fato corrobora com Arvor et al. (2011) que mapearam áreas de milho com MODIS e observaram uma subestimação em relação à área real. Quando se credita esse fato ao pequeno tamanho das parcelas onde o milho foi cultivado, observa-se que não é possível o mascaramento devido à resolução espacial do MODIS.

Em relação à cultura de soja, a diferença média para o ano-safra 2012/2013 foi de 3,48%, a qual variou entre -2,50% (mesorregião Noroeste) e 12,73% (Mesorregião Norte) (Tabela 4). Durante o ano-safra 2013/2014, a diferença média obtida foi de 0,93% e variou entre -9,44% (mesorregião Sudoeste) e 41,42% (mesorregião Noroeste).

Para o ano-safra 2012/2013, primeiramente realizou-se o mapeamento do milho em todas as mesorregiões, para então proceder-se o mapeamento da soja, ao contrário de 2013/2014, no qual, em duas mesorregiões (Noroeste e Centro-Oeste), mapeou-se primeiro a soja. Isso ocorre porque essas duas mesorregiões têm poucas áreas cultivadas com milho bem como a diminuição da área plantada em relação ao ano-safra anterior. No entanto, para melhor funcionamento do método, é preferível primeiro o mapeamento do milho para então mapear a soja. E quando se analisam as culturas de verão (milho, soja e sorgo), Wardlow e Egbert (2008) encontraram um coeficiente de correlação linear igual a $r = 0,76$. Quando analisaram as culturas separadamente, obtiveram $r = 0,92$ (milho), $r = 0,86$ (sorgo) e $r = 0,42$ (soja).

No presente estudo, os seguintes coeficientes foram obtidos: $r = 0,72$ e $r = 0,95$ (anos-safras 2012/2013 e 2013/2014) para o milho, e $r = 0,95$ e $r = 0,99$ para soja (Figura 11), indicando alta correlação linear entre os dados em comparação com os oficiais. A área oficial cultivada com a cultura do milho diminuiu cerca de 200000 ha de 2012/2013 para 2013/2014, ao passo que a cultura da soja apresentou aumento de mesma grandeza na área cultivada (Tabela 4). No Brasil, o milho é plantado em duas épocas, sendo a segunda época plantada após a colheita das variedades de soja precoce (USDA, 2015). Assim explica-se a diminuição das primeiras áreas plantadas com milho e, conseqüentemente, o aumento nos campos de soja (238736 ha).

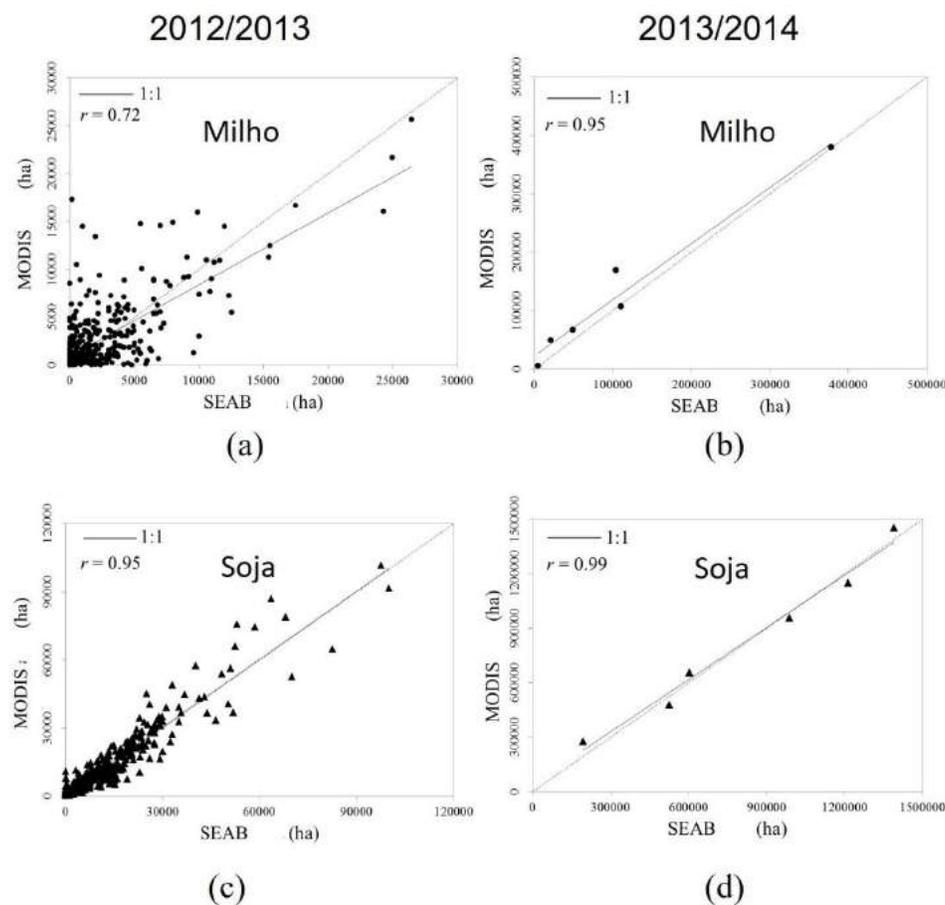


Figura 11 Relação entre área (ha) colhida do mapeamento MODIS (milho (a e b) e soja (c e d) para os anos-safras 2012/2013 e 2013/2014), e dados oficiais da SEAB para 399 municípios (a e c) e 6 mesorregiões (b e d).

Tabela 4 Mapeamento e extração de áreas das culturas do milho e da soja e comparação com os dados oficiais da SEAB e estatísticas obtidas a partir da análise de dados para o Estado do Paraná para os anos-safras 2012/2013 e 2013/2014

Mesorregião	Milho						Soja					
	2012/2013			2013/2014			2012/2013			2013/2014		
	SEAB (ha)	MODIS (ha)	Diferença (%)									
Noroeste	6844	5050	-26,21	4609	5350	16,08	193846	188994	-2,5	194252	275500	41,83
Norte	142914	213100	49,11	104330	169838	62,79	1313745	1480927	12,73	1388882	1450307	4,42
Centro-Oeste	35172	58300	65,76	21365	49193	130,25	587763	648976	10,41	603365	655494	8,64
West	81930	164538	100,83	49110	67325	37,09	949510	933607	-1,67	986536	953663	-3,33
Sul	454860	430288	-5,40	378285	379525	0,33	1145785	1104932	-3,57	1213920	1147276	-5,49
Sudoeste	153150	144700	-5,52	110560	107513	-2,76	485520	478419	-1,46	524970	475419	-9,44
Total	874870	1015975	16,13	668259	778744	16,53	4673189	4835854	3,41	4911925	4957660	0,93
<i>n</i>		399			6			399			6	
Diferença (ha)		141106			110485			159685			45735	
<i>r</i>		0,72			0,95			0,95			0,99	
<i>IW</i>		0,64			0,89			0,85			0,92	
<i>ME</i>		353,65			276,91			400,21			114,62	
<i>RMSE</i>		2642			3682			4242			7267	

Nota: Diferença (ha) entre os mapeamentos gerados e dados oficiais da SEAB; *n*: Números de municípios ou mesorregiões; *r*: Coeficiente de correlação linear de Pearson; *IW*: Coeficiente modificado de Willmott; *ME*: erro médio; *RMSE*: raiz quadrada do erro médio.

Outra explicação para o aumento das áreas cultivadas de milho, segunda safra, em relação à primeira, é a necessidade de rotação de culturas. Em geral, o Estado do Paraná adota dois sistemas de rotação de culturas, com a predominância de soja no verão e trigo no inverno e soja no verão e milho na segunda safra, no inverno (Embrapa Soja, 2011).

Klering et al. (2013) apresentam a comparação entre a estimativa oficial de plantação de arroz e o mapeamento originado a partir de composições RGB, com imagens NDVI para seis regiões de arroz, em que o índice *IW* mostrou concordância de 95% nos valores encontrados. Nos mapeamentos realizados, o coeficiente modificado de Willmott obtido para o milho e soja apresentou valores de concordância acima de 0,64. Souza et al. (2015) obtiveram taxas de concordância de 0,86 e 0,84 para a soja, e 0,66 e 0,69 para milho, para os anos-safras 2010/2011 e 2011/2012, respectivamente.

Pelo *ME*, verificou-se que as áreas de ambas as culturas foram superestimadas para ambas as safras. Por outro lado, o *RMSE* aumentou para ambas as culturas do ano-safra 2012/2013 cuja variação média foi de 2642 para 3682 ha para milho e de 4242 para 7267 ha para a cultura da soja. Johann et al. (2012) encontraram valores de *RMSE* com variação entre 3816 e 6573 hectares, quando mapearam a soja e o milho conjuntamente para os anos-safras de 2004/2005 a 2007/2008.

6.1.4.5. Análise de acurácia dos mapas

A comparação entre os resultados obtidos com o mapa gerado pela interpretação visual (mapa de referência composição RGB LISS-III e Landsat-8) mostrou que o EG para o milho variou entre 89,50% (2012/2013) e 92,25% (2013/2014), e para soja, os resultados foram de 86,75% (2012/2013) e 87,75% (2013/2014) (Tabela 5). O índice κ analisado para a safra de milho variou entre 0,79 (2013/2014) e 0,84 (2012/2013), e para soja entre 0,74 (2012/2013) e 0,75 (2013/2014). Portanto, de acordo com a classificação de Landis e Koch (1977), considera-se como muito bom ($0,60 < \kappa \leq 0,80$) e excelente ($\kappa > 0,81$).

Quando foram comparados os valores obtidos a partir do trabalho de Lamparelli, Carvalho, e Mercante (2008), que obtiveram κ entre 0,60 e 0,80 com os dados dos satélites MODIS/Terra e Landsat-5/TM, pode-se afirmar que os resultados deste trabalho foram semelhantes quando se trata do mapeamento de soja.

A análise de IE e OE (COLGATON & GREEN, 1999) aponta que o IE de milho variou entre 4,81% (2012/2013) e 10,50% (2013/2014) e, para a soja, o resultado variou entre 10,47% (2013/2014) e 11,50% (2012/2013), isto é, classificando outros alvos como as referidas culturas. Então, o mapeamento erroneamente classificou estes lugares como soja e milho, mas na realidade eles eram outros alvos (floresta) e /ou estavam escondidos por nuvens na imagem de alta resolução espacial, logo, não foi possível determinar o alvo.

Tabela 5 Matriz de erros entre os mapeamentos de milho e soja (MODIS) e a referência terrestre (imagens composição RGB da LISS-III e Landsat-8) para as safras 2012/2013 e 2013/2014

Mapa MODIS		Milho				Soja			
		TR		Total	IE (%)	TR		Total	IE (%)
Cultura	Não Cultura	Cultura	Não Cultura			Cultura	Não Cultura		
2012/2013	Cultura	178	9	187	4,81	169	22	191	11,50
	Não Cultura	22	191	213	10,33	31	178	229	22,27
	Total	200	200	400		200	200	400	
	OE (%)	11,00	4,50			15,50	11,00		
		EG = 92,25%		$\kappa = 0,84$		EG = 86,75%		$\kappa = 0,74$	
2013/2014	Cultura	179	21	200	10,50	171	20	191	10,47
	Não Cultura	21	179	200	10,50	29	180	209	13,88
	Total	200	200	400		200	200	400	
	OE (%)	10,50	10,50			14,50	10,00		
		EG = 89,50%		$\kappa = 0,79$		EG = 87,75%		$\kappa = 0,75$	

Nota: TR: Referência Terrestre; IE: Erros de Inclusão; OE: Erros de Omissão; EG: Índice de Exatidão Global; κ : Índice Kappa de acurácia.

De acordo com as amostras classificadas ao longo de áreas não cultivadas, o milho teve OE com variação entre 10,33% (2012/2013) e 10,50% (2013/2014); enquanto esses mesmos dados para a soja apresentaram variação entre 13,88% (2013/2014) e 14,80 % (2012/2013), ou seja, não houve a seleção das culturas durante o mapeamento.

Em relação ao OE, a variação do milho foi muito menor em comparação com a soja. A variação do OE para o milho esteve entre 10,50% (2013/2014) e 11,00% (2012/2013), e para soja foi entre 14,50% (2013/2014) e 25,50% (2012/2013), mostrando a proporção de amostras excluídas das classes às quais elas pertenciam (cultivadas ou não-cultivadas).

6.1.5. Conclusões

A validação dos mapeamentos foi classificada como boa e excelente, mostrando que o método utilizado para a separação de culturas de milho e soja no Estado do Paraná foi eficiente. Esta eficiência resolveu as limitações que Johann et al. (2012) encontraram por não separarem as culturas e também a sobreposição de culturas encontradas por Souza et al. (2015). De acordo com o calendário agrícola e a análise do perfil de espectro-temporal do índice de vegetação EVI, verificou-se grande variabilidade nas datas de diferentes regiões do Estado para semeadura. A análise mostra a importância de efetuar o mapeamento por mesorregiões. Outro fator importante foi a seleção de pixels puros incorporados ao método, porque através deles, mesmo quando não havia confusão na análise de perfil, o algoritmo

SAM foi capaz de fazer a distinção para realizar o mapeamento. Além disso, de acordo com os resultados, é mostrada a importância da utilização de sensoriamento remoto para mapear culturas agrícolas, devido ao atraso na disponibilidade dos dados oficiais.

Agradecimentos

À CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), à Fundação Araucária e à Embrapa Informática Agropecuária pelo apoio financeiro para os autores.

6.1.6. Referências

ADAMI, M., RIZZI, R., MOREIRA, M.A., RUDORFF B. F. T. FERREIRA, C. C. “Amostragem probabilística estratificada por pontos para estimar a área cultivada com soja”. **Pesq. Agropec. Bras.** 45, (6): 585-592. 2010. doi: 10.1590/S0100-204X2010000600008.

ARAÚJO, G. K. D., ROCHA, J. V. R., LAMPARELLI, ROCHA., A. C. A. M. “Mapping of summer crops in the State of Paraná, Brazil, through the 10-day spot vegetation NDVI composites”. **Engenharia Agrícola (Impresso)**, 31: 760-770. 2011. doi:10.1590/S0100-69162011000400014.

ARVOR, D., JONATHAN, M. MEIRELLES, M. S. DUBREUIL, P. V. DURIEUX, L. “Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil”, **International Journal of Remote Sensing**, 29, 1-25, 2011. doi:10.1080/01431161.2010.531783

ARVOR, D., MEIRELLES, M., DUBREUIL, V., BÉGUÉ, A., SHIMABUKURO, Y. E. “Analyzing the Agricultural Transition in Mato Grosso, Brazil, using Satellite-Derived Indices”. **Applied Geography**. 32 (2): 702-713. 2012. doi:10.1016/j.apgeog.2011.08.007.

BERNARDES, T., ADAMI, M., FORMAGGIO, A. R., MOREIRA, M. A., FRANÇA, D., NOVAES, M. “Imagens mono e multitemporais MODIS para estimativa da área com soja no Estado de Mato Grosso”. **Pesq. Agropec. Bras.** 46: 1530-1537. 2011. doi:10.1590/S0100-204X2011001100015.

BROWN, J. C., KASTENS, H., COUTINHO, A. C., VICTORIA, D. D. C., BISHOP, C. R. “Classifying Multiyear Agricultural Land Use Data from Mato Grosso Using Time-Series MODIS Vegetation Index Data”. **Remote Sensing of Environment**, 130: 39-50. 2013. doi:10.1016/j.rse.2012.11.009.

CONAB (Companhia Nacional de Abastecimento). “**Indicadores da Agropecuária** (Agricultural Indicators)”. <http://www.conab.gov.br/conab/Main.php?MagID=3&MagNo=262>. Acessado em Dezembro 2014.

CONGALTON, R. G. “A review of assessing the accuracy of classifications of remotely sensed data”. **Remote Sensing of Environment**, 37: 35-46. 1991. doi:10.1016/0034-4257(91)90048-B.

CONGALTON, R. G., GREEN, K. "Assessing the accuracy of remotely sensed data: principles and practices". **Boca Raton: CRC Press**, 160. 1999. doi:10.1016/j.jag.2009.07.002.

DALPOSSO, G. H., URIBE-OPAZO, M. A., MERCANTE, E., BORSSOI, J. A., JOHANN, J. A. "Comparison measures of maps generated by geostatistical methods". **Engenharia Agrícola (Impress)**, 32: 174-183. 2012. doi:10.1590/S0100-69162012000100018.

DERAL (Departamento de Agricultura e do Abastecimento do Paraná. Departamento de Economia Rural). "**Soja - Análise da Conjuntura Agropecuária**". 2012. http://www.agricultura.pr.gov.br/arquivos/File/deral/Prognosticos/soja_2012_13.pdf

DE BASTIANI, F., URIBE-OPAZO, M. A., DALPOSSO, G. H. "Comparison of maps of spatial variability of soil resistance to penetration constructed with and without covariables using a spatial linear model". **Engenharia Agrícola (Impress)**, 32: 394-404. 2012. doi:10.1590/S0100-69162012000200019.

EMBRAPA INFORMÁTICA AGROPECUÁRIA (Empresa Brasileira de Pesquisa Agropecuária). "**Banco de Produtos MODIS**". Acessado em 12 Agosto 2014. <http://www.MODIS.cnptia.embrapa.br/geonetwork/srv/pt/main.home>. 2014.

EMBRAPA SOJA (Empresa Brasileira de Pesquisa Agropecuária). "**Importância da rotação de culturas para a produção agrícola sustentável no Paraná**". Acessado em 16 Julho 2015. http://www.cnpso.embrapa.br/download/Doc_327-VE.pdf. 2011.

EPIPHANIO, R. D. V., FORMAGGIO, A. R., RUDORFF, B. F. T., MAEDA, E. E., LUIZ, A. J. B., "Estimating soya bean crop areas using spectral-temporal surfaces derived from MODIS images in Mato Grosso, Brazil". **Pesq. Agropec. Bras.** 45: 72-80. 2010. doi:10.1590/S0100-204X2010000100010.

ESQUERDO, J. C. D. M., ZULLO JUNIOR, J., ANTUNES, J. F. G., "Use of NDVI/AVHRR time series profiles for soya bean crop monitoring in Brazil". **International Journal of Remote Sensing**. 32 (13): 3711-3727. 2011. doi:10.1080/01431161003764112.

ENVI (Exelis Visual Information Solutions). "**Spectral Angle Mapper**". Acessado em 15 Outubro de 2014. <http://www.exelisvis.com/docs/SpectralAngleMapper.html>. 2014.

FAOSTAT (Food and Agriculture Organization of the United Nations Statistics Division). "**Download Data**". Accessed on 17 July 2015. <http://faostat3.fao.org/download/Q/QC/E>. 2015.

GALFORD, G. L., MUSTARD, J. F., MELILLO, J., GENDRIN, A., CERRI, C. C., CERRI, C. E. P., "Wavelet Analysis of MODIS Time Series to Detect Expansion and Intensification of Row-Crop Agriculture in Brazil". **Remote Sensing of Environment**. 112 (2): 576-587. 2008. doi:10.1016/j.rse.2007.05.017.

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. doi:10.1016/j.rse.2008.09.003.

HUETE, A., LIU, H. G., BATCHILY, K., LEEUWEN, W. J. D. V. "A comparison of Vegetation Indices over a Global Set of TM Images for the EOS-MODIS". **Remote Sensing of Environment**. 59: 440-451. 1997. doi:10.1016/S0034-4257(96)00112-5.

IBGE (Instituto Brasileiro de Geografia e Estatística). “**Produção Agrícola Municipal**” ftp://ftp.ibge.gov.br/Producao_Agricola/Producao_Agricola_Municipal_%5Banual%5D/2013/tabelas_pdf/tabela02.pdf. 2013.

INPE (Instituto Nacional de Pesquisas Espaciais). “**Catálogo de imagens**”. Acessado em 13 Agosto de 2014. <http://www.dgi.inpe.br/CDSR/>

JOHANN, J. A., ROCHA, J. V., DUFT, D. G., LAMPARELLI, R. A. C. “Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/MODIS”. **Pesq. Agropec. Bras.** 47 (9): 1295-1306. 2012. doi:10.1590/S0100-204X2012000900015.

JÖNSSON, P., EKLUND, L. Seasonality extraction by function fitting to time-series of satellite sensor data. **IEEE Transactions on Geoscience and Remote Sensing**. v. 40, n. 8, p. 1824-1832. 2002.

KOBAYASHI, H. DYE, D. Atmospheric conditions for monitoring the long-term vegetation dynamics in the Amazon using normalized difference vegetation index. **Remote Sensing of Environment**. v. 97, p. 519–525. 2005.

KLERING, E. V., FONTANA, D. C., ALVES, R., ROCHA, J., BERLATO, M. A. “Estimativa de área cultivada com arroz”. **Ciência e Natura**. 35 (2): 126-135. 2013. doi:10.5902/2179460x12567.

KRUSE, F. A., LEFKOFF, A. B., BOARDMAN, J. W., HEIDEBRECHT, K. B., SHAPIRO, A. T., BARLOON, P. J., GOETZ, A. F. H. “The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging Spectrometer Data”. **Remote sensing of environment**, 44 (2-3): 145-163. 1993. doi:10.1016/0034-4257(93)90013-N.

LAMPARELLI, R. A. C., CARVALHO, W. M. O., MERCANTE, E. “Mapeamento de semeaduras de soja (*Glycine max* (L.) Merr.) mediante dados MODIS/Terra E TM/Landsat 5: um comparativo”. **Engenharia Agrícola**, 28 (2): 334-344. 2008. doi:10.1590/S0100-69162008000200014.

LANDIS, J. R., KOCH, G. G. “The measurement of observer agreement for categorical data”. **Biometrics**. 33 (1): 159-174. 1977. <http://www.jstor.org/stable/2529310>

LHERMITTE, S., VERBESSELT, J., VERSTRAETEN, W.W., VERAVERBEKE, S., COPPIN, P. “Assessing intra-annual vegetation regrowth after fire using the pixel based regeneration index”. **Journal of Photogrammetry and Remote Sensing**, 66, 17-27, 2011. doi:10.1016/j.isprsjprs.2010.08.004.

LOBELL, D. B., ASNER, G. P. “Cropland distributions from temporal unmixing of MODIS data”. **Remote Sensing of Environment**, 93 412-422, 2004. doi:10.1016/j.rse.2004.08.002

LUNETTA, R. L., KNIGHT, F. K., EDIRIWICKREMA, J., LYON, J. G., WORTHY, L. D. 2006. Landcover change detection using multi-temporal MODIS NDVI data. **Remote Sensing of Environment**, 105, 142-154. doi: 10.1016/j.rse.2006.06.018

MERCANTE, E., LAMPARELLI, R. A. C., URIBE-OPAZO, M. A., ROCHA, J. V. “Modelos de regressão lineares para estimativa de produtividade da soja no Oeste do Paraná, utilizando dados espectrais”. **Engenharia Agrícola**, 30 (3): 504-517. 2010. doi: 10.1590/S0100-69162010000300014.

RISSO, J., RIZZI, R., RUDORFF, B. F. T., ADAMI, M., SHIMABUKURO, Y. E., FORMAGGIO, A. R., EPIPHANIO, R. D. V. “Índices de vegetação MODIS aplicados na

discriminação de áreas de soja”. **Pesq. Agropec. Bras.** 47 (9): 1317-1326. 2012. doi: 10.1590/S0100-204X2012000900017.

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.9 6, p. 366-374. 2005. doi:10.1016/j.rse.2005.03.008.

SAKAMOTO, T., B. D. WARDLOW, A. A. GITELSON, S. B. VERMA, A. E. SUYKER, AND T. J. ARKEBAUER. “ATwo-Step Filtering Approach for Detecting Maize and Soya bean Phenology with Time-Series MODIS Data.” **Remote Sensing of Environment**, 114 (10): 2146–2159. 2010. doi:10.1016/j.rse.2010.04.019.

SEAB (Secretaria da Agricultura e Abastecimento do Paraná)2014. “**Produção agropecuária. Produção Agrícola Paranaense por Município**”. Accessed on 05 June 2014. <http://www.agricultura.pr.gov.br/modules/conteudo/conteudo.php?conteudo=137>

SEAB (Secretaria da Agricultura e Abastecimento do Paraná). 2015. “**Estimativa de safra**”. Acessado em 10 Julho 2015. <http://www.agricultura.pr.gov.br/modules/conteudo/conteudo.php?conteudo=32>

SOUZA, C. H. W., MERCANTE, E., JOHANN, J. A., LAMPARELLI, R. A. C., URIBE-OPAZO, M. A., “Mapping and discrimination of soya bean and corn crops using spectrum-temporal profiles of vegetation indices”. **International Journal of Remote Sensing**. 36 (7): 1809-1824. 2015. doi:10.1080/01431161.2015.1026956.

USGS (Department of the Interior U.S. Geological Survey). “**Landsat data continuity mission (ldcm) - Mission data - Data format control Book (dfcb)**”. Acessado em 13 de Agosto 2014. <http://landsat.usgs.gov/documents/LDCM-DFCB-001.pdf>

USDA (United States Department of Agriculture). 2015. **World Agricultural Production**. Circular Series. WAP 7-15. July. Acessado em 07 de outubro de 2015. <http://usda.mannlib.cornell.edu/usda/current/worldag-production/worldag-production-07-10-2015.pdf>

WARDLOW, B. D., KASTENS, J. H., EGBERT, S. L., Using USDA crop progress data for the evaluation of green up onset date calculated from MODIS 250-meter data. **Photogrammetric Engineering and Remote Sensing**, 72, 1225-1234, 2006. doi:10.14358/PERS.72.11.1225.

WARDLOW, B. D., EGBERT, S. L., “Large-area crop mapping using time-series MODIS 250m NDVI data: an assessment for the U.S. Central Great Plains”. **Remote Sensing of Environment**. 112 (3): 1096-1116, 2008. doi:10.1016/j.rse.2007.07.019.

WILLMOTT, C. J., ROBESON, S. M., MATSUURA, K., “A Refined Index of Model Performance”. **International Journal of Climatology**. 32 (13): 2088-2094, 2012. doi:10.1002/joc.2419.

6.2. ARTIGO 2: Variabilidade espacial da produtividade da soja no Estado do Paraná por análise decendial descritiva e índices de autocorrelação global de Moran e Geary

Resumo: O levantamento de informações das regiões de cultivo, a interação com os índices de vegetação e as variáveis climáticas têm grande importância em busca do aumento da produtividade da soja. O Paraná é o segundo maior produtor de soja do Brasil e apresenta grande variabilidade espacial, tanto em períodos do ciclo da cultura como no solo e clima. Assim, objetivou-se analisar a variabilidade espacial da produtividade da soja, o índice de vegetação EVI e as variáveis agrometeorológicas no Estado do Paraná em escala decendial e os índices de autocorrelação global de Moran e Geary para os anos-safras 2010/2011, 2011/2012 e 2012/2013. Como resultados, ao serem comparados os anos-safras, constatou-se semelhança nos anos 2010/2011 e 2012/2013, com médias de 3,35 e 3,23 t ha⁻¹, superiores em 7,37% e 9,86% em relação à média nacional, respectivamente. Entretanto, o ano-safra 2011/2012 teve uma média de 2,38 t ha⁻¹, 10,19% inferior à média nacional. Em relação aos índices de vegetação, verificou-se que em todos os anos-safras estudados nas regiões Oeste, Centro-Oeste e parte do Sudoeste, as semeaduras foram antecipadas em comparação com o restante do Estado, mostrando a grande variabilidade temporal. Pela autocorrelação espacial global da produtividade da soja, observou-se maior semelhança no ano-safra 2011/2012 com os índices de Moran e Geary 0,735 e 0,317, respectivamente. Com este estudo, foi possível identificar as regiões que antecipam as semeaduras, e ainda que, no ano-safra 2011/2012, houve maior similaridade da produtividade no Estado com a queda de produção em todos os municípios, causada pelos efeitos climatológicos de falta de precipitação em fases de florescimento e enchimento de grãos.

Palavras-chave: Ciclo da cultura, EVI, variáveis climáticas.

6.2.1. Introdução

A cultura da soja tem grande importância na agricultura mundial e, segundo a FAOSTAT (2015), as produções nos anos de 2010, 2011, 2012 e 2013 foram, respectivamente, de 265,120; 261,886; 240,971 e 276,032 milhões de toneladas. A produção dessa leguminosa no Brasil tem papel fundamental na economia do País, já que em 2010 representou 28,76% da produção mundial de soja. Porém, segundo a Conab (2015), no ano-safra 2011/2012, a seca nas regiões produtoras reduziu a produção para 66,38 milhões de toneladas (27,54%). Com condições climáticas favoráveis, foram produzidos 29,52% de soja no ano-safra 2012/2013, sendo o Paraná segundo maior produtor nacional responsável por 19,5%.

Assim, para a estimação da produção, é necessário conhecer as áreas cultivadas com a espécie de interesse e a sua produtividade em diferentes regiões (ASSAD et al., 2007). A produtividade das culturas também pode ser estimada a partir de modelos agrometeorológicos. Dentre os fatores agrometeorológicos, a disponibilidade hídrica, o foto-

período e a temperatura são os fatores que mais afetam a produtividade da soja (FARIAS et al., 2007). Assim, os efeitos do déficit hídrico dependem de sua intensidade, duração, época de ocorrência além da interação com outros componentes determinantes na produtividade final (FONTANA et al., 2001; CUNHA & BERGAMASCHI, 1992).

Em geral, a necessidade de água durante todo o ciclo fenológico da soja varia entre 450 e 800 mm, e é muito importante, principalmente em dois períodos do desenvolvimento: a germinação-emergência e floração-enchimento de grãos (FARIAS et al., 2007). Durante o primeiro período, tanto o excesso como a falta de precipitações é prejudicial, é necessário que a semente absorva 50% de peso da mesma para assegurar boa germinação e emergência. No segundo período, são necessários de 7 a 8 mm dia⁻¹ de água para obtenção da máxima produtividade. Além do estágio de desenvolvimento, o consumo de água pela cultura da soja depende da demanda evaporativa da atmosfera que pode variar de acordo com a região, ano e época de semeadura. A evapotranspiração é um dos fatores da relação solo, planta, água e atmosfera, pois o padrão de água utilizado pela cultura é diretamente relacionado ao desenvolvimento de estresse nas plantas.

Ressalta-se ainda a importância de se conhecerem o clima da região de cultivo e a época de semeadura, pois a cultura da soja, quando submetida a elevadas intensidades de radiação solar absorvida, pode sofrer (VER) saturação luminosa, por isso há redução na eficiência no uso da radiação (CASAROLI et al., 2007).

A cultura da soja se adapta melhor às regiões onde as temperaturas oscilam entre 20°C e 30°C (FARIAS et al., 2007) e a faixa ideal para semeadura é de 25°C. Porém, para que ocorra emergência rápida e uniforme, a soja não deve ser submetida a temperaturas abaixo de 20°C, pois tanto a germinação quanto a emergência da planta ficam comprometidas. Por outro lado, temperaturas acima de 40 °C têm efeito adverso na taxa de crescimento, provocam estragos na floração e diminuem a capacidade de retenção de vagens. Assim, o crescimento, o desenvolvimento e a produtividade de uma cultura agrícola são afetados pela variabilidade climática (VIRGENS FILHO et al., 2013) além dos diferentes tipos de cultivares que variam de região para região.

Sendo assim, baseado na classificação Koeppen, estudos realizados pelo IAPAR (2015) definem dois principais tipos de clima no Estado. O clima subtropical (Cfa) com tendência à concentração de chuvas nos meses de verão, contudo, sem estação seca definida, e ocupa as regiões Norte, Oeste, grande parte do Sudoeste e parte do Sul. E o clima temperado (Cfb), sem estação seca definida, predominante no Sul do Estado. Além disso, outro fato relevante é que o Paraná possui o litoral mais úmido do Sul do Brasil.

Uma forma de se analisar esta variabilidade é a partir de um método estatístico que faz uso da referência geográfica, a Estatística Espacial de Áreas (EEA). Portanto, para entender e compreender a distribuição espacial de dados ocorridos, estudos são cada vez

mais comuns devido à disponibilidade de sistemas de informações geográficas (SIG), de baixo custo e que permitem apresentar um mapa de visualizações dos padrões espaciais das variáveis (CÂMARA, et al., 2002).

Neste contexto, para o desenvolvimento da estatística espacial de áreas, podem ser empregados indicadores globais e locais de autocorrelação espacial que medem a correlação da própria variável no tempo ou espaço. Enquadram-se na categoria Global univariada o Índice Global de Moran [I_{Moran}](BAILEY & GATRELL, 1995) e o Índice Global de Geary [C_{Geary}] (GEARY, 1954).

Desta forma, neste trabalho, o objetivo foi analisar a variabilidade espacial da produtividade da soja ($t\ ha^{-1}$), índice de vegetação EVI e variáveis agrometeorológicas no Estado do Paraná em escala decencial e índices de autocorrelação global de Moran e Geary para os anos-safras 2010/2011, 2011/2012 e 2012/2013.

6.2.2. Material e Métodos

O método de trabalho foi composto das seguintes etapas: (i) determinação da área de estudo; (ii) aquisição de dados; (iii) análise descritiva da produtividade, variáveis agrometeorológicas e índice de vegetação; (iv) análise de autocorrelação espacial (Figura 12).



Figura 12 Fluxograma das etapas de trabalho realizadas.

6.2.2.1. Área de estudo

A área de estudo compreende os 399 municípios, divididos de acordo com as mesorregiões da IBGE para o Estado do Paraná, região Sul do Brasil, limitada pelas coordenadas 22° 29' S e 26° 43' S e 48° 2' W e 54° 38' W (Figura 13).

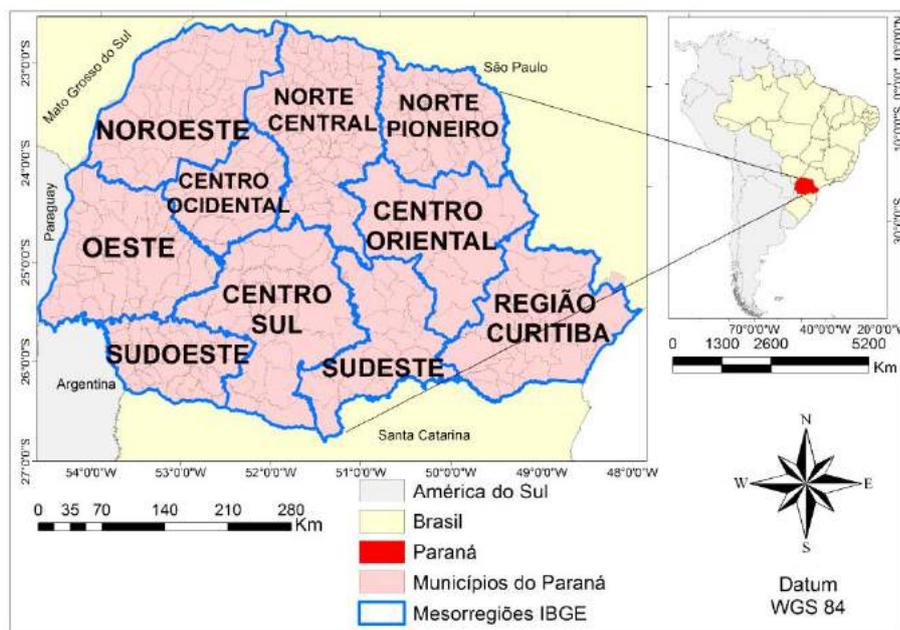


Figura 13 Delimitação da área em estudo.

6.2.2.2. Aquisição de dados

Foram utilizados dados da produtividade da soja [Prod] ($t\ ha^{-1}$), para os anos-safras 2010/2011, 2011/2012 e 2012/2013. Os índices de vegetação utilizados foram extraídos de imagens orbitais do sensor MODIS (*Moderate resolution imaging spectroradiometer*) e dados agrometeorológicos provenientes do modelo do ECMWF (*European Center for Medium-Range Weather Forecast*).

6.2.2.2.1. Dados de produtividade média da soja

Os dados da produtividade média dos municípios ($t\ ha^{-1}$) para os anos-safras estudados foram obtidos na Secretaria da Agricultura e do Abastecimento do Paraná (SEAB), no Departamento de Economia Rural (Deral) e Instituto Brasileiro de Geografia e Estatística (IBGE). Na análise da produtividade da soja, de acordo com dados oficiais, para o ano-safra 2010/2011, 37 municípios, não continha informações de produtividade média. Já para 2011/2012 e 2012/2013, 38 e 31 deles não possuíam valores, respectivamente.

6.2.2.2.2. Dados MODIS do índice de vegetação

As imagens utilizadas na obtenção do índice de vegetação (IV) foram obtidas no banco de produtos MODIS da Empresa Brasileira de Pesquisa Agropecuária (ESQUERDO

et al., 2010) e fazem parte do produto MOD13Q1.5 a bordo do satélite Terra, “Tile” h13v11 de EVI (*Enhanced Vegetation Index*), resolução de 250 m e resolução temporal de 16 dias. As medidas radiométricas que funcionam como indicadores da abundância relativa e da atividade da vegetação verde são definidas como adimensionais, de forma geral as IV (JI et al., 2011). O período de imagens para cada ano-safra foi do dia 13/08/ano1 até 23/04/ano2.

O mapeamento das áreas cultivadas com soja para os anos-safras 2010/2011 e 2011/2012 foi fornecido por Souza et al. (2015). Para o ano-safra 2012/2013, foi realizado o mapeamento das áreas cultivadas com soja no Paraná. Destes mapeamentos, extraíram-se para cada município os valores dos pixels do índice de vegetação EVI médio dos anos-safras estudados (JOHANN et al., 2013), e o procedimento foi operacionalizado em linguagem de programação “*interactive data language*” (IDL) (ESQUERDO et al., 2011).

Entretanto, este produto do MODIS contém composições de imagens de 16 dias do IV, portanto, houve a necessidade de se adequarem os dados do EVI para a escala decendial utilizada com dados agrometeorológicos (Tabela 6).

Tabela 6 Cálculo das médias de IV de EVI para reescalonamento dos decêndios

Decêndios	EVI utilizado ou calculado	DOY	Decêndios	EVI utilizado ou calculado	DOY
3º decêndio julho	29 julho	180	2º decêndio dezembro	19 dezembro	353
1º decêndio agosto	Média	-	3º decêndio dezembro	Média	-
2º decêndio agosto	13 agosto	225	1º decêndio janeiro	01 janeiro	1
3º decêndio agosto	29 agosto	241	2º decêndio janeiro	17 janeiro	17
1º decêndio setembro	Média	-	3º decêndio janeiro	Média	-
2º decêndio setembro	14 setembro	257	1º decêndio fevereiro	02 fevereiro	33
3º decêndio setembro	30 setembro	273	2º decêndio fevereiro	18 fevereiro	49
1º decêndio outubro	Média	-	3º decêndio fevereiro	Média	-
2º decêndio outubro	16 outubro	289	1º decêndio março	06 março	65
3º decêndio outubro	Média	-	2º decêndio março	Média	-
1º decêndio novembro	01 novembro	305	3º decêndio março	22 março	81
2º decêndio novembro	17 novembro	321	1º decêndio abril	07 abril	97
3º decêndio novembro	Média	-	2º decêndio abril	Média	-
1º decêndio dezembro	03 dezembro	337	3º decêndio abril	23 abril	113

DOY: Dia do ano. Adaptado de Johann et al. (2013).

Esta adequação reescalou os dados para cada ano-safra em escala decendial. Para tanto, obteve-se a média entre as cenas que não continham informações para os decêndios do EVI.

6.2.2.2.3. Dados Agrometeorológicos

Os dados globais estão em uma resolução espacial de grau de longitude e latitude, são pré-processados e transformados em grades de 0,25 graus ($\pm 25 \times 25$ km) e disponibilizados, gratuitamente no *website* do JRC (ECMWF, 2012) em formato Shape (Figura 14A). As variáveis obtidas, na escala decendial foram: balanço hídrico climatológico (mm) [Cw], precipitação pluvial (mm) [Ra], evapotranspiração potencial (mm) [Et], radiação global ($kJ m^{-2} dia^{-1}$ transformado para $MJ m^{-2} dia^{-1}$) [Gr], temperatura média do ar ($^{\circ}C$) [Te], temperatura máxima do ar ($^{\circ}C$) [Ta] e temperatura mínima do ar ($^{\circ}C$) [Ti] no período de agosto a abril, referentes aos anos-safras. Como os dados da produtividade média da soja são disponibilizados por município, foi necessária adequação dos dados agrometeorológicos das 303 estações virtuais para a escala espacial de 399 municípios. O procedimento foi a determinação para cada decêndio e para cada município um dado e foram calculadas as médias dos valores das estações virtuais de cada variável agrometeorológica contidos no centro, próximas ou ao redor do polígono (Figura 14B).

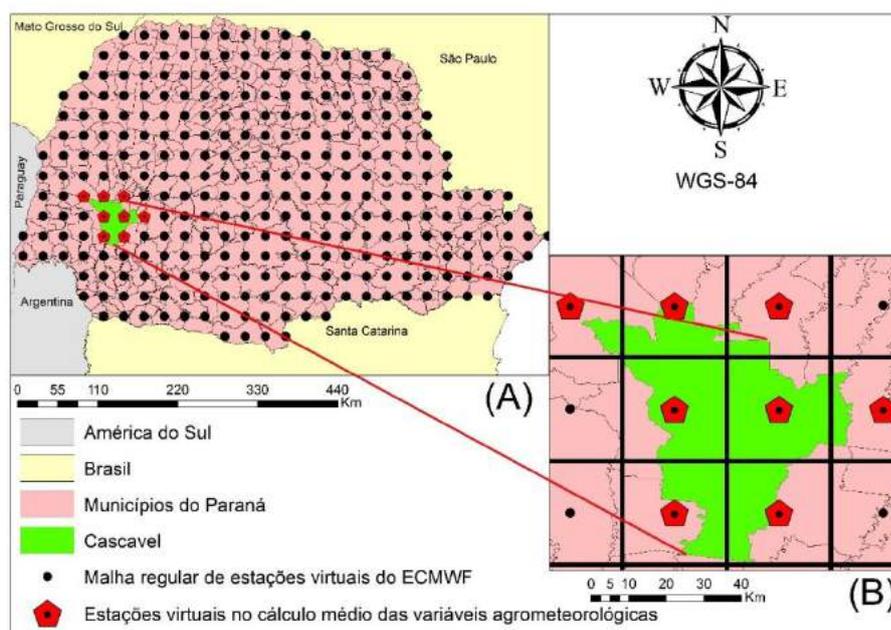


Figura 14 Representação da malha regular das estações virtuais do ECMWF (A) e estações virtuais usadas para obtenção da média municipal de cada variável agrometeorológica (B).

6.2.2.3. Análise descritiva

Na análise descritiva, os dados médios da produtividade da soja de cada município e dados decendiais médios de EVI, Cw, Ra, Et, Gr, Te, Ta e Ti foram divididos em quartis para os três anos-safras. Em seguida, foram construídos os mapas descritivos de cada variável

no período decenal e suas comparações médias. Assim, as legendas destes mapas tiveram, na primeira classe, os dados com variação entre o valor mínimo e o primeiro quartil; na segunda classe, os dados variaram entre o primeiro quartil e a mediana; na terceira classe, os dados variaram entre a mediana e o terceiro quartil e na quarta classe, os dados variaram entre o terceiro quartil e o máximo.

A classificação em quartis para o IV de EVI tratou de representar aproximadamente as classes de uso e cobertura do solo. O primeiro intervalo determinado (mínimo até o quartil 1) atribui aos municípios os períodos com solo exposto. O segundo intervalo (quartil 1 até a mediana) atribui o período de semeadura da cultura da soja. A terceira classe utilizada (mediana até o quartil 3) apresenta valores de IV de acordo com os estádios vegetativo e reprodutivo da cultura, além de englobar a emergência (VE) e o início do florescimento (R1). O último intervalo do quartil 3 ao valor máximo considera valores de IV em que a planta obtém os máximos valores do índice, determinada como pico vegetativo.

6.2.2.4. Análise de autocorrelação espacial

6.2.2.4.1. Matriz de proximidade espacial

Qualquer variável pode ser espacialmente defasada para qualquer unidade regional (ANSELIN, 1992). Assim, a maneira mais comum para quantificar a estrutura de dependência espacial é utilizando a matriz de peso espacial (LESAGE, 2004). Também conhecida como matriz de proximidade espacial W . É usada para representar como a vizinhança influencia cada observação e expressa a estrutura espacial dos dados. De acordo com Câmara e Monteiro (2004) e Anselin et al. (2007), $W = [w_{ij}]$, é uma matriz quadrada, com $n \times n$ elementos, onde cada elemento w_{ij} representa uma medida de proximidade espacial entre as populações (municípios) A_i e A_j , a qual pode ser calculada a partir de um critério. O critério de contiguidade (torre, rainha e bispo) $w_{ij} = 1$, se A_i compartilha um lado comum com A_j , caso contrário $w_{ij} = 0$; para $i \neq j = 1, \dots, n$.

É importante convencionar as formas de vizinhança quando se utilizam matrizes de proximidade espacial. Assim, necessita-se impor um arranjo que permita estimar coeficientes que deem a ideia do grau de interação entre as unidades espaciais (municípios). Desta forma, no presente estudo, foi adotado o critério de contiguidade tipo *Queen* (Rainha), onde se consideram vizinhas duas regiões que possuam fronteiras comuns, analisando os nós (vértices) (Figura 14B).

Todas as matrizes foram normalizadas de modo que a soma dos elementos de cada uma de suas linhas seja igual a 1. A significância das estatísticas foi obtida por meio de técnicas de aleatorização, utilizando 999 permutações.

6.2.2.4.2. Análise de autocorrelação espacial global univariada

A análise exploratória espacial é caracterizada pela dependência espacial, ou seja, a partir da avaliação de como os valores estão correlacionados no espaço. Portanto, para verificar a presença de dependência espacial, recorre-se a um teste estatístico global, no qual a hipótese nula é a existência de uma distribuição aleatória da variável sob estudo e a hipótese alternativa é a existência de uma associação de valores similares ou diferentes a um nível de significância α definido (MEDEIROS & PINHO NETO, 2011).

Neste estudo, as funções utilizadas para estimar quanto o valor observado de um atributo em uma região é dependente dos valores desta mesma variável, nas localizações vizinhas, é o Índice de Moran [I_{MG}] (MORAN, 1950) (Equação 6), que varia entre -1 (perfeita autocorrelação negativa), 0 (ausência de autocorrelação) e +1 (perfeita autocorrelação positiva). Outra medida de autocorrelação espacial global é o Índice de Geary [C_{GG}] (GEARY, 1954) (Equação 7), que varia entre 0 (perfeita autocorrelação positiva), 1 (ausência de autocorrelação) e 2 (perfeita autocorrelação negativa).

$$I_{MG} = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} . \quad (6)$$

$$C_{GG} = \frac{(n-1)}{2 \sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - x_j)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} . \quad (7)$$

em que:

n : tamanho da amostra;

$i = j = 1, \dots, n$;

x_i e x_j : valor do atributo considerado nas áreas i e j ;

\bar{x} : é o valor médio do atributo na região de estudo;

w_{ij} : os elementos da matriz normalizada de proximidade espacial.

6.2.2.5. Softwares usados

Para análise do EVI, foram obtidos softwares utilizando um sistema de extração de dados de imagens, operacionalizado em linguagem IDL 7.0.1 (2008). O software R versão 3.2.2 (2015) foi utilizado para a análise espacial de áreas e representação da autocorrelação global e local dos dados médios de produtividade da soja e variáveis agrometeorológicas.

6.2.3. Resultados e Discussões

6.2.3.1. Análise descritiva da produtividade da soja

Apesar de toda tecnologia hoje existente e disponível, a obtenção de máximas produtividades continua extremamente dependente do clima durante o ciclo de cada cultura. Características genéticas que variam de região para região também podem ser afetadas pelo manejo de cultivo.

Como segundo maior produtor de soja do País, o Estado do Paraná teve uma área cultivada de 5,02 milhões de hectares (IBGE, 2015), com produção aproximadamente de 17 milhões de toneladas (SEAB, 2015). Para o ano-safra 2010/2011 (Figura 15a), sete municípios localizados nas regiões Noroeste e Sudeste (Bituruna, Cruzeiro do Sul, Douradina, Icaraíma, Ivaté, Maria Helena e Mirasselvã) do Estado obtiveram produtividades menores de $2,60 \text{ t ha}^{-1}$.

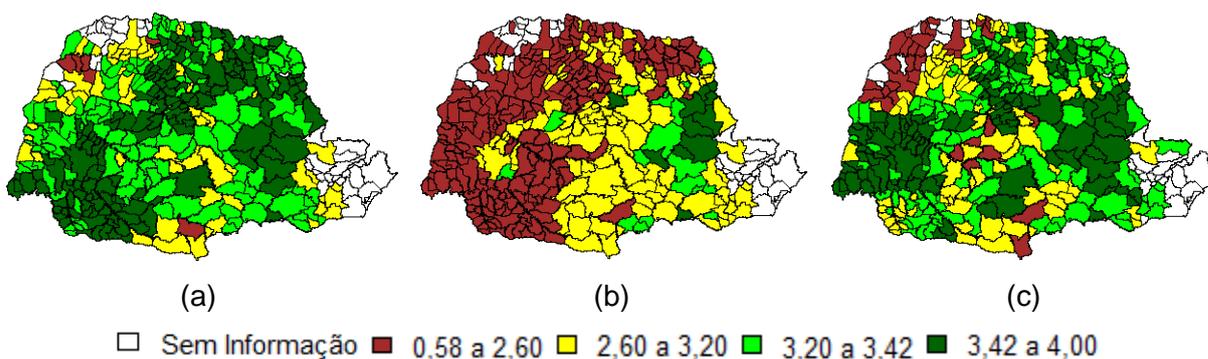


Figura 15 Mapas descritivos espaço-temporais da produtividade da soja (t ha^{-1}) para os anos-safras 2010/2011 (A), 2011/2015 (B) e 20112/2013(C).

Fonte: SEAB (2015)

Para o ano-safra 2011/2012 (Figura 15b), verificou-se que, em praticamente todo o Estado, a produtividade média municipal da soja foi menor que $3,20 \text{ t ha}^{-1}$. Ressalta-se que, nas regiões produtoras como o Oeste, Sudoeste e Centro Ocidental do Paraná a maior produtividade foi de $2,60 \text{ t ha}^{-1}$, e somente onze municípios obtiveram produtividade considerada na classe mais alta (Antônio Olinto, Arapoti, Carambeí, Castro, Faxinal,

Ipiranga, Jaguariaíva, Piraí do Sul, Santana do Itararé, São José da Boa Vista e Wenceslau Braz).

De acordo com Ferreira et al. (2007), as variações a longo prazo na produtividade das culturas são causadas por fatores como a introdução de novas técnicas de manejo, as variedades e os insumos. Por outro lado, variações de curto prazo na produtividade, ou seja, de um ano para o outro, são, principalmente, devido às alterações climáticas. Justificativa esta que pode ser vinculada aos anos-safras 2010/2011 e 2011/2012 no Estado.

No ano-safra 2012/2013 (Figura 15c), as produtividades nas regiões com maiores produções foram normalizadas de acordo com suas médias históricas. Entretanto, na região Noroeste do Estado, a produtividade média municipal continuou na classe mais baixa de 0,58 a 2,60 t ha⁻¹ como no ano-safra anterior. Em uma comparação espacial, essa região do Estado registrou o menor potencial produtivo quando comparada às outras. Em uma pesquisa, ao se analisar a classificação de épocas de semeadura em relação ao risco hídrico à cultura da soja no Estado do Paraná, Farias et al. (2001) relataram que a região é caracterizada com áreas desfavoráveis ao cultivo da soja, sendo de alto risco de ocorrência de veranicos, durante as fases mais críticas de floração e frutificação no desenvolvimento da cultura da soja.

Quando se comparam as estatísticas descritivas da produtividade média de soja do Estado, entre anos-safras 2010/2011 e 2012/2013 (Tabela 7), verificam-se produtividades mais próximas 3,36 e 3,22 t ha⁻¹, respectivamente. Entretanto, o ano-safra 2010/2011 teve melhor desempenho e menor variação, ou seja, a amplitude foi 1,55 t ha⁻¹, em 2011/2012 de 3,14 t ha⁻¹ e em 2012/2013 que foi de 2,5 t ha⁻¹.

Tabela 7 Estatísticas descritivas para a produtividade da soja (t ha⁻¹) nos três anos-safras

Estatísticas	2010/2011	2011/2012	2012/2013	Três anos-safras
Valor Mínimo*	2,45	0,58	1,50	0,58
1º Quartil*	3,20	1,98	3,10	2,60
Mediana*	3,35	2,45	3,30	3,20
3º Quartil*	3,50	2,90	3,48	3,42
Valor Máximo*	4,00	3,72	4,00	4,00
Média Estadual**	3,36 a A	2,45 b A	3,22 c A	
Média Nacional**	3,12 B	2,65 B	2,94 B	
Diferença Média	7,14%	-7,54%	9,52%	

*Dados Oficiais (SEAB, 2015) ** (IBGE, 2015). Teste t (5%) de comparação de médias entre os anos-safras com letras minúsculas e comparação entre média Estadual e Nacional com letras maiúsculas.

No ano-safra 2011/2012, a produtividade média no Estado diminuiu em aproximadamente uma tonelada por hectare em relação aos outros anos-safras. A variação

entre anos é considerada de curto prazo e relacionada principalmente a eventos climáticos ocorridos durante o ciclo da cultura. Tais eventos ocorreram em todo o Estado com faltas das precipitações.

Quando as produtividades médias são comparadas entre os anos-safras estudados, realizados pelo teste t-student a 5% de significância, rejeita-se a hipótese nula de que as médias são iguais. Assim, concluímos com 95% de confiança que há diferença entre as produtividades médias entre os três anos-safras.

Logo, ao se confrontar a produtividade média estadual com a nacional, observa-se que foi maior em 7,14% e 9,52% nos anos-safras 2010/2011 e 2012/2013, respectivamente. Verificou-se também que, ao nível de 5% de significância, a rejeição da hipótese nula apresentou médias estatisticamente iguais; portanto, as produtividades Estaduais foram superiores às Nacionais. Já para o ano-safra 2011/2012, a diferença média obtida foi negativa em 7,54%, e também se rejeitou a hipótese nula de produtividades médias iguais.

6.2.3.2. Análise descritiva do EVI e variáveis agrometeorológicas médias decendiais

6.2.3.2.1. Análise descritiva do ano-safra 2010/2011

Analisando espacialmente a variável EVI (Figura 16), verifica-se que nos 1º e 2º decêndios de agosto a maior parte do IV do Estado está na contido nas classes do 1º quartil até o 3º quartil (2875 a 4952 respectivamente), ou seja, naquele período, havia culturas agrícolas de inverno ou apenas a cobertura do solo. No 3º decêndio de agosto aparece uma terceira classe do valor mínimo 0 até o 1º quartil, principalmente na região Noroeste do Estado, o solo exposto. Já a partir do 1º decêndio do mês de setembro até o 1º decêndio do mês de novembro, o Estado fica dividido entre o valor mínimo e 1º quartil, considerando então o solo exposto ou pouca cobertura do solo à espera da semeadura da safra de verão, e do 1º quartil até a mediana que identifica restos culturais e/ou início da fase vegetativa. No 2º decêndio do mês de novembro, pode-se visualizar na maioria do Estado apenas uma coloração, indicando o começo da semeadura. De acordo com Albrecht et al. (2008), novembro é o mês preferencial para a semeadura da soja no Estado do Paraná, porém, a época indicada para a maioria das cultivares estende-se de 15 de outubro até 15 de dezembro (EMBRAPA SOJA, 2006).

Na região Oeste do Paraná, a cultura da soja é semeada antecipadamente em relação a outras regiões, e isto pode ser observado no 3º decêndio do mês de novembro em que o IV nestes municípios estão contidos na divisão interquartilica do 3º quartil ao valor máximo do índice. Isso engloba o início do florescimento e máximo vegetativo da cultura. A partir do 1º decêndio do mês de dezembro até o 1º decêndio do mês de fevereiro, observa-

se que, em todo o Estado, a média de EVI dos municípios considera os maiores valores de IV. Isso determina o pico vegetativo da cultura da soja, período em que as variações agroclimáticas têm efeitos diretos no desenvolvimento da planta.

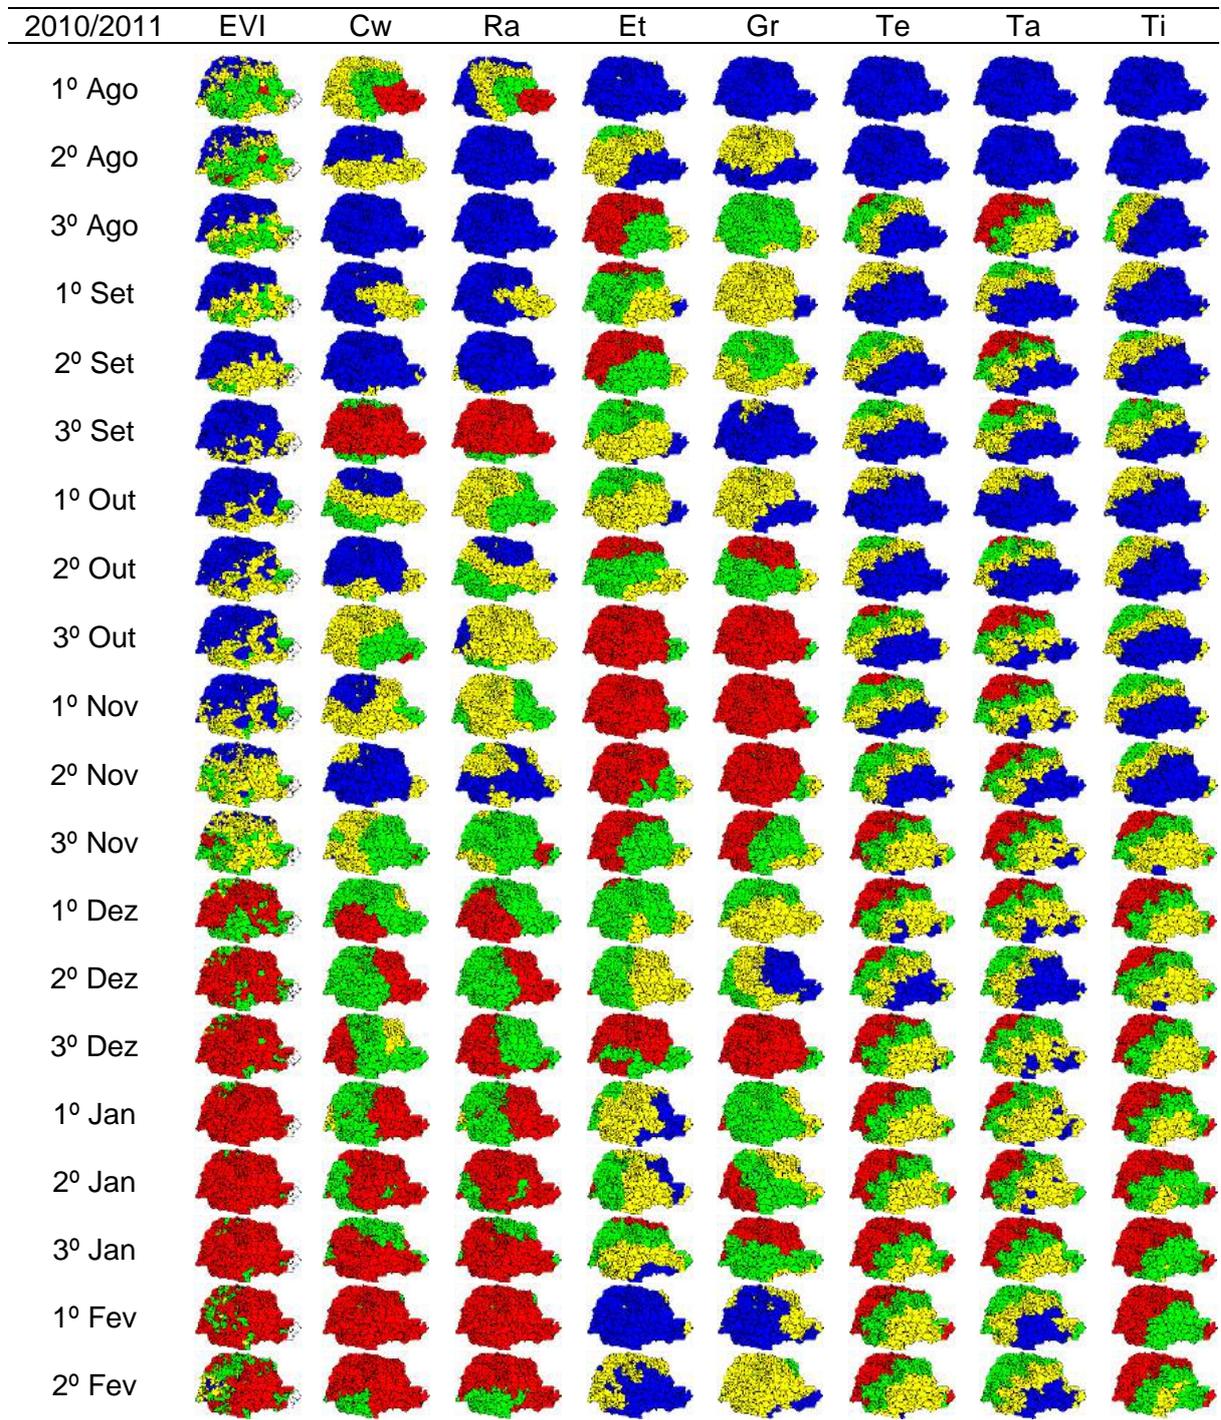
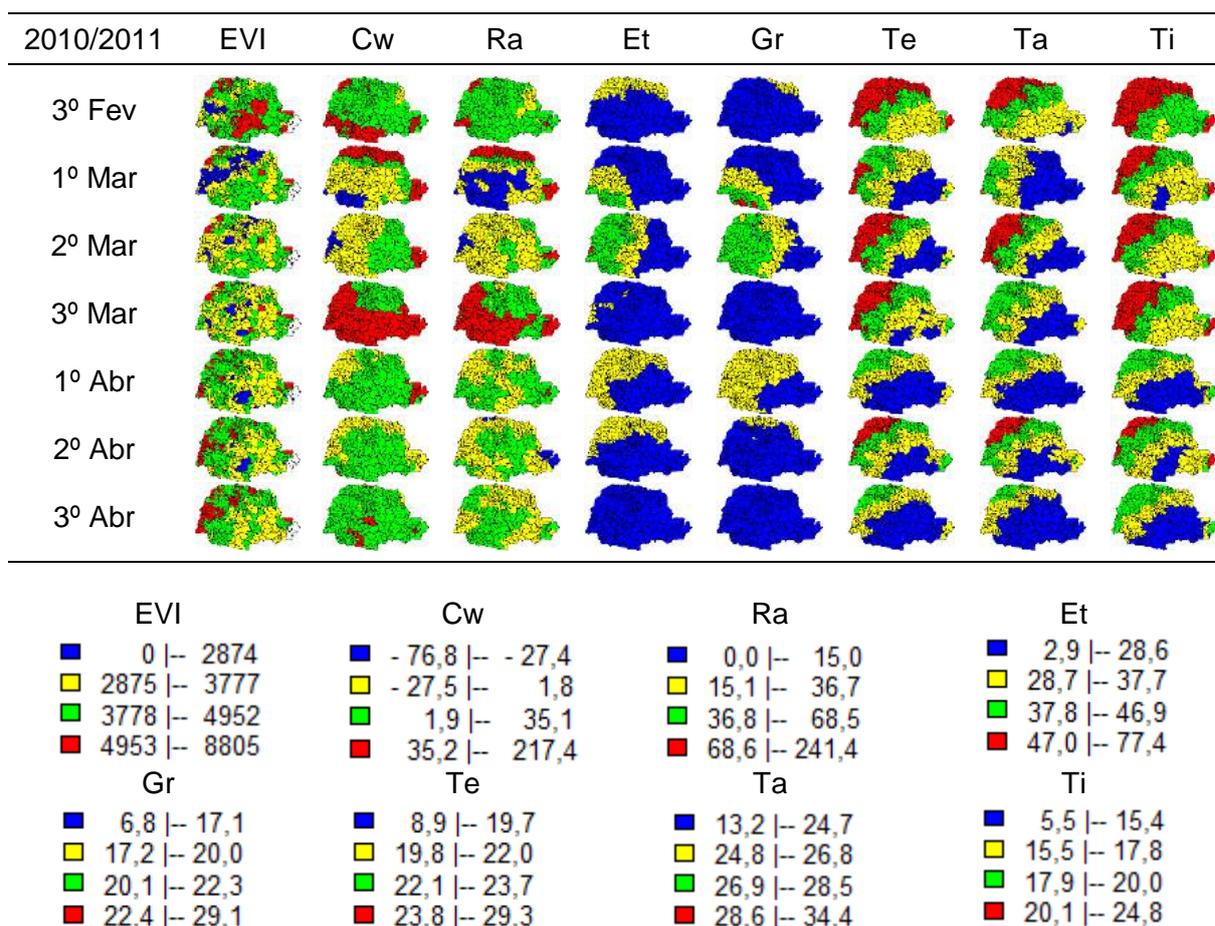


Figura 16 Visualização descritiva espaço-temporal das variáveis agrometeorológicas Cw: Balanço hídrico; Ra: Precipitação; Et: Evapotranspiração; Gr: Radiação global; Te: Temperatura média; Ta: Temperatura máxima; Ti: Temperatura mínima e EVI: índice de vegetação melhorado em quartis para cada decêndio de estudo do ano safra 2010/2011.

Continua....

Continuação da **Figura 16...**



Legenda: divisão interquartilica para cada variável considerando dados dos três anos-safras.

Considerando que a cultura da soja é influenciada por diversos fatores ao longo de seu ciclo, é relevante destacar a época da colheita, iniciada no 1º decêndio de fevereiro na região Oeste, municípios que fizeram a semeadura antecipada (Cafelândia, Maripá, Nova Santa Rosa e Ubiratã, (Figura 1, Apêndice A)).

Então, pode-se visualizar que, no 1º decêndio de agosto, houve precipitação (Ra) e balanço hídrico (Cw) positivo nas proximidades do litoral paranaense. Após esse período, em média, a Ra não ultrapassou os 36,72 mm do 2º decêndio de agosto até o 2º decêndio de setembro em todo o Estado. Em função das poucas chuvas, o Cw foi negativo, e devido à falta de água no solo, podem-se explicar os atrasos na semeadura da soja, mesmo com elevados índices de Ra e Cw no 3º decêndio de setembro.

As condições pluviométricas estabilizaram-se no Estado a partir do 3º decêndio de novembro, e durante todas as fases de florescimento e frutificação, a cultura da soja não sofreu com déficit hídrico. Todavia, na região Oeste que fez a semeadura antecipada em relação às outras regiões, no início da colheita (1º decêndio de fevereiro), a média de Ra e Cw foram elevadas, evidenciando certo atraso, e ocorreu no decêndio seguinte. Já a

colheita nas outras regiões ocorreu a partir do 1º decêndio de março e não foram afetadas com as chuvas.

De acordo com Camargo & Camargo (2000), a chuva e a evapotranspiração potencial (Et) são elementos meteorológicos de sentidos opostos, ou seja, a Et corresponde à transferência de água do solo para a atmosfera. Esse processo requer suprimento de energia, e para isto a única fonte disponível é a radiação solar (Gr). A Et, portanto, é mais elevada no verão, quando os dias são mais longos e a radiação solar maior, no entanto, isto pode ser visualizado do 2º decêndio de outubro até o 3º decêndio de novembro. Em razão das chuvas constantes do início de dezembro até metade de fevereiro, pode ser verificada a diminuição da Gr e conseqüentemente Et.

Em relação às temperaturas no período, a ideal para a semeadura da soja segundo Farias et al. (2007) é 25°C, e não deve ocorrer se estiver abaixo dos 20°C. A partir da análise da temperatura média do ar (Te), temperatura máxima (Ta) e temperatura mínima (Ti), poderia ser realizada a semeadura no 3º decêndio de agosto, entretanto, nesse período o Estado do Paraná tem uma medida que proíbe o plantio ou manutenção de plantas vivas de soja entre os dias 15 de junho até 15 de setembro. Esta medida é chamada de vazio sanitário, cujo objetivo é evitar ou retardar ao máximo o aparecimento do fungo causador da ferrugem asiática, doença que ataca a cultura da soja e causa prejuízos econômicos e perdas na produtividade.

Em todo o Estado do Paraná, a cultura da soja pode ser implantada a partir do 2º decêndio de setembro, dependendo das condições climáticas. No entanto, para este ano-safra, apesar das chuvas registradas no final de setembro, houve quedas nas temperaturas no mesmo período. Para Braccini et al. (2006), temperaturas abaixo da faixa ideal tendem a prejudicar a germinação e a emergência das plântulas sendo então outro fator que evidencia atrasos na semeadura. A semeadura então que começou no 2º decêndio de novembro em condições agrometeorológicas favoráveis e em praticamente todas as regiões do Estado.

Durante a fase de florescimento e frutificação também conhecida como pico vegetativo da soja, considerada a partir de dezembro entre as regiões do Paraná, houve oscilações da Te. No entanto essa variou entre os 20º e 30°C, considerada ideal para o crescimento (EMBRAPA SOJA, 2006).

De forma geral, para a cultura da soja no Estado do Paraná, no ano-safra 2010/2011, houve deficiência hídrica, conseqüentemente atraso nas semeaduras, no entanto, depois, a disponibilidade hídrica não afetou o desenvolvimento da cultura. Quanto ao regime térmico, infere-se como adequado durante o ciclo, uma vez que, em termos médios decendiais, as temperaturas não foram inferiores aos 10°C afetando o crescimento, nem superiores aos 40°C provocando problemas com a floração e retenção de vagens. Ainda ressalta-se que, como não houve eventos meteorológicos inesperados, tais fatores não interferiram na perda

da produtividade no Estado, em média de $3,35 \text{ t ha}^{-1}$, considerada estatisticamente elevada em relação à produtividade média nacional neste ano-safra de $3,12 \text{ t ha}^{-1}$.

6.2.3.2.2. Análise descritiva do ano-safra 2011/2012

Na análise descritiva do EVI para o ano-safra 2011/2012 (Figura 17), visualiza-se de agosto até o 3º decêndio de outubro a incidência de solo exposto ou pouca vegetação. A partir do 1º decêndio de novembro, principalmente na região Oeste, inicia-se a semeadura da soja. Entretanto, no 3º decêndio de novembro em alguns municípios, o IV já está na fase de florescimento e frutificação, devido ao uso de cultivares de soja precoce. Com tais variedades de desenvolvimento rápido, a antecipação de semeadura é devido ao estabelecimento da cultura de sucessão, o milho safrinha. As semeaduras antecipadas podem ser praticadas nas regiões mais quentes do Estado, onde ocorre inverno úmido, solos de alta fertilidade e temperaturas favoráveis à emergência das plantas desde o início de outubro. Estas condições são mais comuns na Região Oeste do Paraná, em áreas de menor altitude. Em praticamente todo o Estado, no 3º decêndio de dezembro, foi concluída a semeadura da cultura da soja.

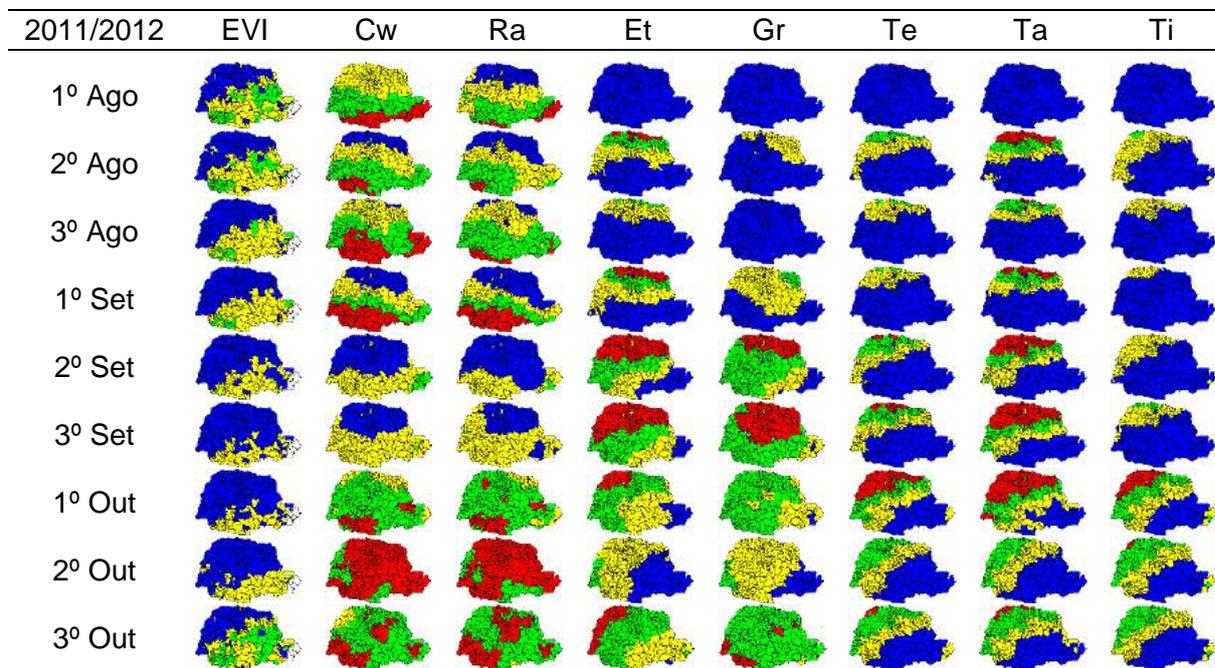
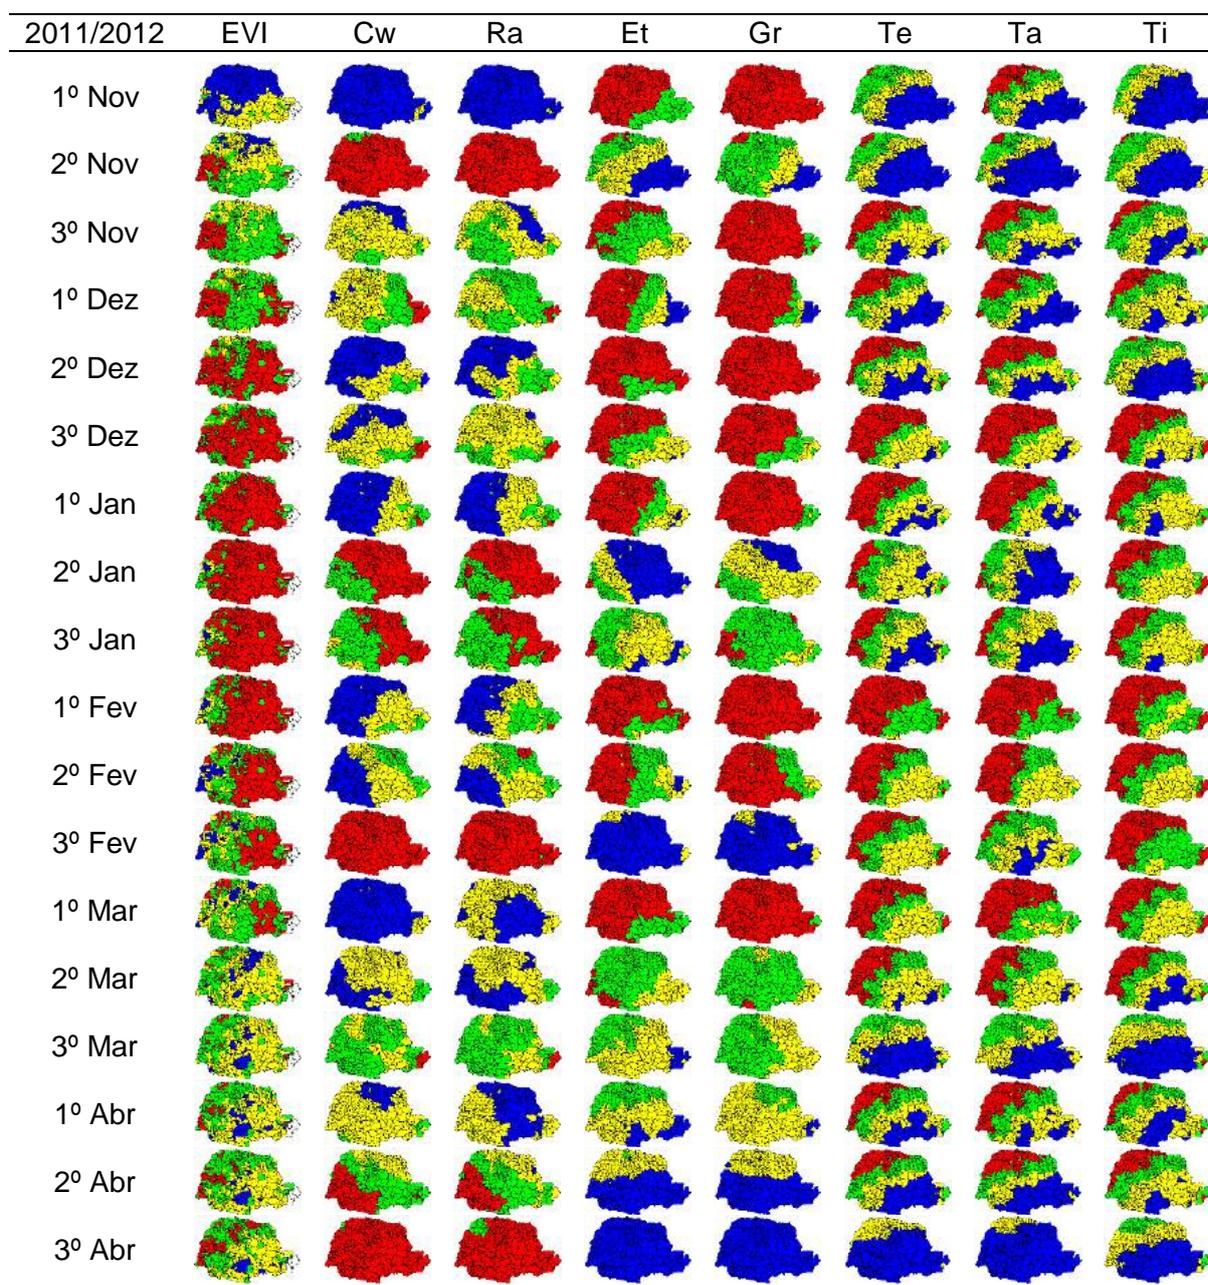


Figura 17 Visualização descritiva espaço-temporal das variáveis agrometeorológicas Cw:

Balanço hídrico; Ra: Precipitação; Et: Evapotranspiração; Gr: Radiação global; Te: Temperatura média; Ta: Temperatura máxima; Ti: Temperatura mínima e EVI: índice de vegetação melhorado em quartis para cada decêndio de estudo do ano safra 2011/2012.

Continua...

Continuação da **Figura 17...**

No 2º decêndio de janeiro começa a colheita da soja (Oeste) devido à antecipação (Nova Santa Rosa, Palotina, Maripá, Quatro Pontes e Terra Roxa (Figura 1, Apêndice A)) e termina no mês de março em todo o Estado. Ao se avaliar a Ra, do 2º decêndio de setembro até 1º decêndio de outubro, observa-se que a incidência de chuvas foi pequena, sendo identificado um Cw negativo neste período e atrasando as semeaduras. Já nos 2º e 3º decêndios de outubro, a Ra e Cw foram o suficiente para o início da semeadura, entretanto, só houve a ocorrência de chuvas com Cw positivo até o 2º decêndio de novembro. No restante do ano de 2011, o balanço hídrico ficou negativo principalmente nas fases de florescimento e frutificação.

A soja tem uma demanda no consumo de água crescente conforme o desenvolvimento; e o ponto máximo de consumo encontra-se durante as fases da floração até enchimento de grãos, justamente fases afetadas pela disponibilidade hídrica causando danos em sua formação.

Em alguns municípios, da região Norte até o litoral, em que as semeaduras foram tardias, esses apresentaram melhor eficiência climática indicando menores perdas pela falta de Ra e Cw negativo.

Além disso, neste mesmo período, a elevada Gr provocou aumento de Et, ou seja, a água evaporada do solo e transpirada pelas plantas na fase do crescimento não foi de maneira uniforme devido à estiagem ocorrida. De acordo com Farias et al. (2011), a Gr é o fator desencadeador da fotossíntese, na qual o CO₂ atmosférico, com a participação da água, é transformado em carboidratos. Esses carboidratos são usados para o crescimento e para a manutenção da cultura, porém, nesta fase da planta ocorreram as estiagens que prejudicaram a produtividade final em praticamente todo o Estado. Em relação às temperaturas, essas se mantiveram menores até o final de outubro. Nos períodos de estiagem e desenvolvimento da cultura, as temperaturas mínimas decendiais se mantiveram acima dos 15,46 °C e chegando à máxima de 34,31 °C.

6.2.3.2.3. Análise descritiva do ano-safra 2012/2013

Durante a análise da variável EVI, no ano-safra 2012/2013 (Figura 18), observa-se no mês de agosto que a maior parte está contida entre 3778 e 4952 (coloração verde claro). Isso indica que ocorreram plantações de inverno ou as áreas estão cultivadas com plantas de cobertura do solo que antecedem a semeadura das culturas de verão. Já para os meses de setembro e outubro, visualizam-se pequenos valores de IV englobando todo o Estado, à espera da semeadura da soja. Esta semeadura demorou a ocorrer devido à falta das precipitações além de Cw negativo do período de agosto até 2º decêndio de outubro.

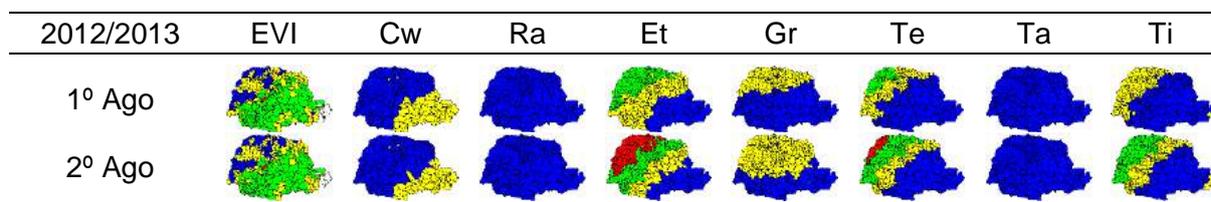
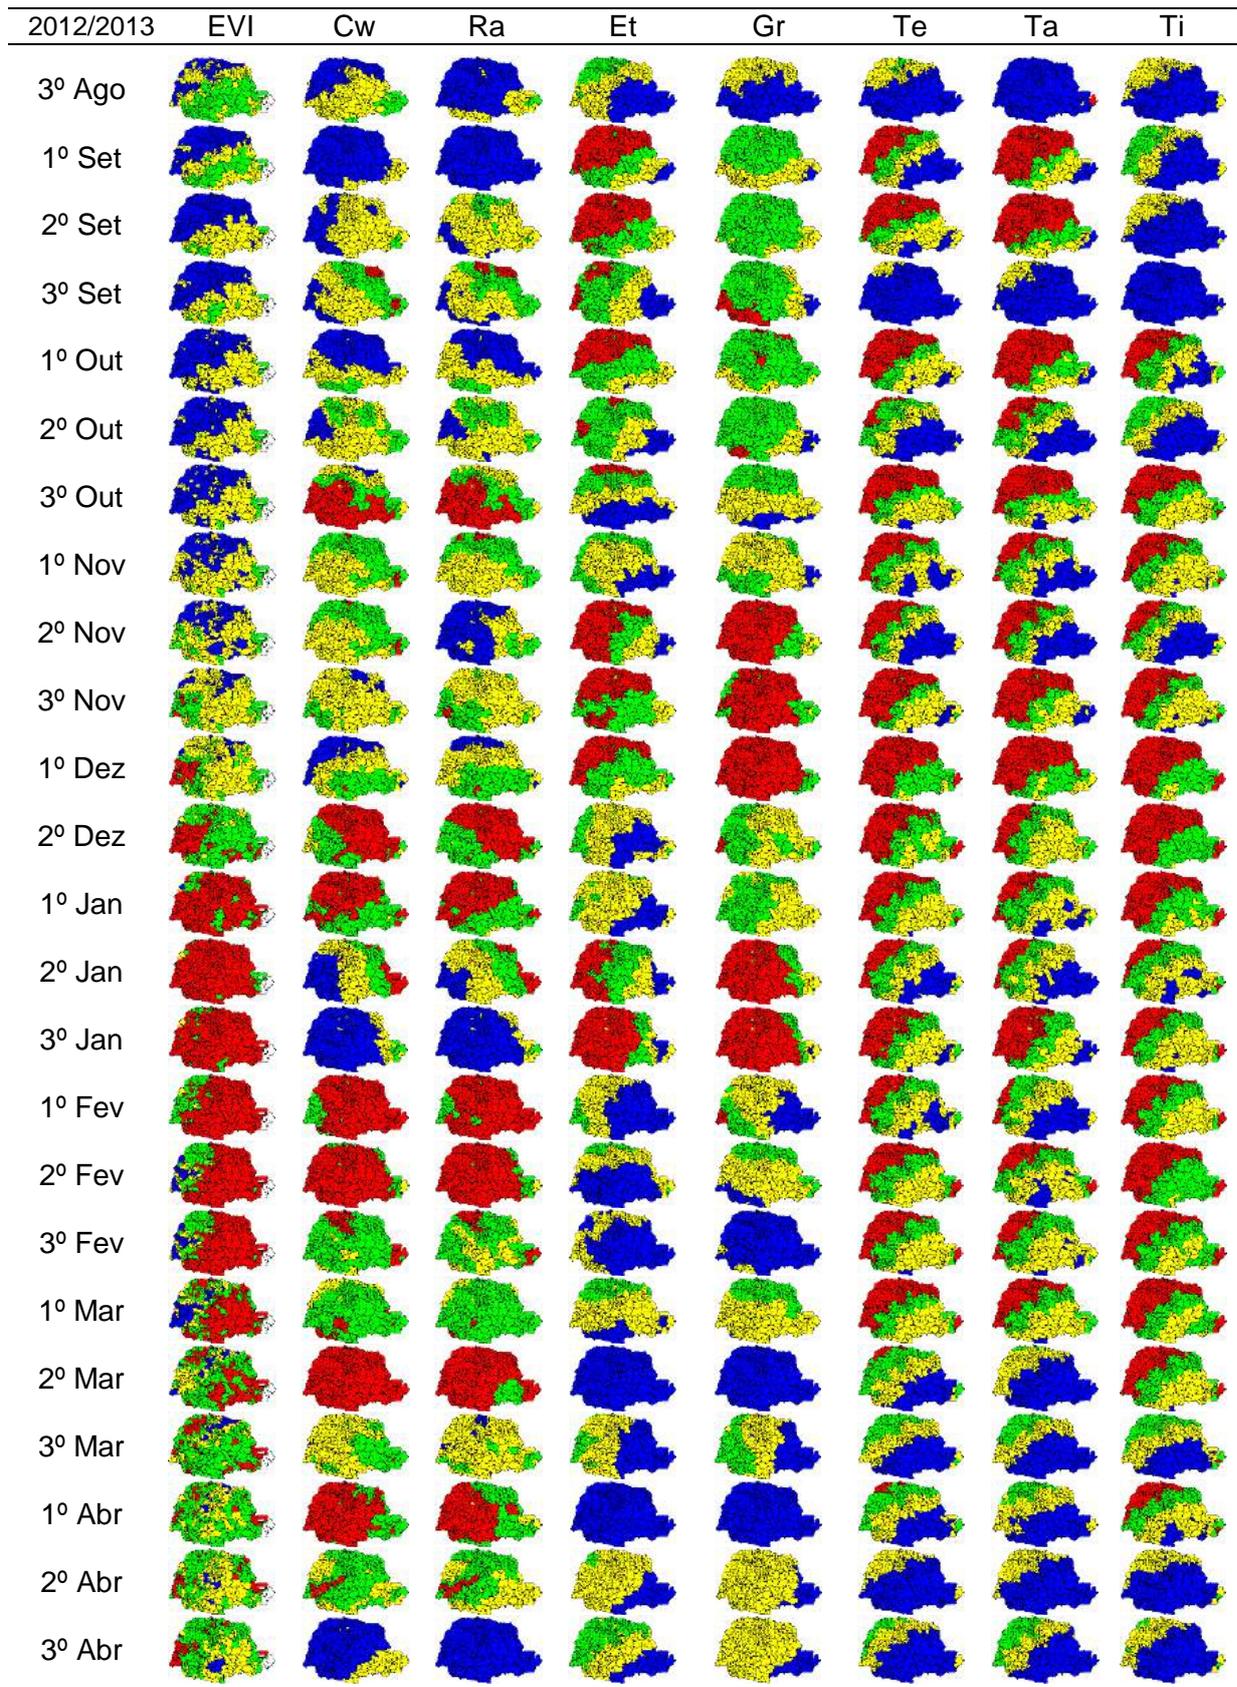


Figura 18 Visualização descritiva espaço-temporal das variáveis agrometeorológicas Cw:

Balanço hídrico; Ra: Precipitação; Et: Evapotranspiração; Gr: Radiação global; Te: Temperatura média; Ta: Temperatura máxima; Ti: Temperatura mínima e EVI: índice de vegetação melhorado em quartis para cada decêndio de estudo do ano safra 2012/2013.

Continua...

Continuação da Figura 18...



As precipitações ocorreram no final do mês de outubro, mas ficaram novamente escassas no mês de novembro. Mesmo assim, a semeadura da soja começou no 2º

decêndio de novembro, com Cw negativo. Ressalta-se ainda que no 1º decêndio de dezembro apenas a região Oeste do Estado realizou a semeadura da soja. Isto ocorreu devido às precipitações localizadas terem apresentado variações entre 36,76 e 68,56 mm na média decendial no final de novembro.

A partir do 3º decêndio de dezembro, praticamente todo o Estado do Paraná está com IV máximos, portanto, no estágio de pico vegetativo, com as Ra normais para o período e Cw positivo, além das temperaturas contidas nas faixas ideais para o desenvolvimento da cultura da soja. E a normalidade das variáveis climáticas segue até o começo do mês de janeiro. Nos dois primeiros decêndios subsequentes, houve um período em que Ra e Cw foram negativos, assim como as respostas para Gr e Et obtidas estiveram com seus máximos valores. Os balanços negativos das variáveis em relação ao desenvolvimento da cultura voltaram ao normal no mês de fevereiro, mês em que começam as colheitas nos municípios da região Oeste.

No trabalho de Bettolli et al. (2003), os resultados apontam que a produtividade é função da precipitação nos meses de novembro e dezembro, e da temperatura máxima no mês de janeiro em trabalho realizado na Argentina. Isto indica forte tendência da produtividade ser maior ou menor em relação à disponibilidade hídrica que é determinada principalmente pela associação entre a Ra e as temperaturas. Todavia, no Paraná, de acordo com o que foi observado nas figuras, não é possível estabelecer determinado mês de semeadura para todo Estado, ou determinadas datas para as regiões, pois se semearem antes ou depois precisam das características climáticas adequadas. Também ocorrem em épocas diferentes devido ao uso de cultivares com ciclo de desenvolvimento desde precoce a tardio.

6.2.3.2.4. Análise do comportamento entre os decendios e anos-safras

Ao serem comparados os três anos-safras das variáveis agrometeorológicas no ciclo de desenvolvimento da soja (Figura 19), pode-se avaliar o quanto o clima interferiu (especialmente a precipitação), positiva (2010/2011 e 2012/2013) e negativamente (2011/2012) na produtividade da cultura.

A interação entre a planta, o ambiente e o manejo define a produtividade, por conseguinte, a obtenção da elevada produtividade somente é possível quando as condições ambientais são favoráveis durante todo o ciclo da cultura (Gilioli et al., 1995). No entanto, nesta avaliação gráfica não é possível verificar as diferenças regionais visto que a análise média foi efetuada para todo o Estado.

Outro fator determinante para conseguir elevadas produtividades é a época de semeadura. As épocas de semeadura variam de região para região no Estado do Paraná.

Para os anos-safras estudados, na região Oeste, as sementeiras foram antecipadas em relação às outras regiões. Isto acontece principalmente pela justaposição do desenvolvimento das fases fenológicas da cultura da soja com a presença de ambiente climático favorável. Ressalta-se que, para o ano-safra 2011/2012, apesar do clima favorável para sementeira da soja, com Ra e Cw positivos entre o 3º decêndio de outubro e 2º de novembro, o restante do ciclo foi afetado pela indisponibilidade hídrica no solo levando à redução da produtividade.



Figura 19 Média decenal estadual por ano-safra do EVI e das variáveis agrometeorológicas.

A cultura da soja tem dois períodos mais críticos em seu desenvolvimento, o estágio fenológico da germinação-emergência e da floração e o enchimento de grãos nas vagens. Na região Oeste, onde a sementeira foi antecipada em relação a outras regiões do Estado, não houve problemas na fase de germinação-emergência nos três anos-safras estudados. Entretanto, o resultado referente à comparação entre os 2010/2011, 2012/2013, no ano-safra 2011/2012 mostrou que o estresse hídrico afetou a fase destinada ao enchimento de grãos e conseqüentemente à produtividade final nas mesorregiões Oeste, Sudoeste e Centro Ocidental. Porém, para o restante do Estado, a fase afetada foi a germinação-emergência, em que, na maioria dos municípios, a cultura não conseguiu se recuperar devido ao longo período em déficit hídrico.

Portanto, como o consumo da água pela cultura da soja é dependente do estágio de desenvolvimento, da demanda evaporativa da atmosfera, essas podem variar tanto em

função das condições climáticas de cada região como em função do ano e da época de semeadura na mesma região climática (STEWART & NIELSEN, 1990; BERGAMASCHI et al., 1992). Isto comprova as diferenças na produtividade final dos municípios no Estado do Paraná em cada ano-safra estudado e também mostra a relação da produtividade com as variáveis.

6.2.3.3. Análise exploratória espacial

6.2.3.3.1. Autocorrelação da Produtividade

De acordo com a análise exploratória dos dados espaciais, confirmou-se a hipótese de que a distribuição espacial da produtividade não é aleatória, ou seja, existe correlação positiva entre os dados (Tabela 8). Isso significa dizer que, em termos de escala global, tanto o I_{MG} quanto o C_{GG} indicam que, no Paraná, existem municípios com altas ou baixas produtividades cercados por municípios com a mesma situação. Podem-se verificar maiores índices da autocorrelação espacial para o ano-safra 2011/2012 (0,735 e 0,317), indicando que houve mais similaridade da produtividade entre os municípios, mas ressalta-se que foi o que teve pior desempenho na média produtiva entre as safras estudadas, justificado pela estiagem ocorrida na maior parte do Estado (Figura 15).

Tabela 8 Índice de Moran e Geary para a Produtividade da soja nos três anos-safras

Índice	2010/2011	2011/2012	2012/2013
I_{MG}	0,552*	0,735*	0,627*
C_{GG}	0,510*	0,317*	0,403*

*Índices significativos ao nível de 0,05 de probabilidade.

6.2.3.3.2. Autocorrelação das variáveis agrometeorológicas

A análise espacial visa identificar a estrutura de correlação espacial entre as variáveis agrometeorológicas. Em um primeiro momento analisou-se o índice de autocorrelação global de Moran para a variável EVI em cada decêndio estudado (Figura 20a), em que apresentaram-se valores positivos em todos os decêndios. De acordo com os dados para os decêndios estudados, os meses de agosto e setembro apresentaram as maiores autocorrelações em relação aos outros períodos. Isto é, a maioria dos municípios do Paraná, naquele período, apresentava índices de vegetação semelhantes.



Figura 20 Autocorrelação espacial da variável EVI para cada decêndio no Estado do Paraná.

Dados em Apêndice B (Tabela 23 a Tabela 25).

Conforme a cultura da soja é semeada (Figura 16 a Figura 18), meses de outubro e novembro, a autocorrelação espacial entre os municípios vai diminuindo, ou seja, os índices de vegetação naquele período ficam heterogêneos no Estado. E, apesar da redução, esses índices indicam correlação direta e positiva. Quando se analisa o ano-safra 2011/2012 nos três decêndios de dezembro, observa-se certa anomalia em relação aos outros anos-safra estudados. Os índices de Moran encontrados durante aquele período de tempo diminuíram, e mostram que os índices de vegetação foram afetados. Por conseguinte, foram considerados heterogêneos entre os municípios na fase de desenvolvimento da cultura da soja.

Os índices encontrados em janeiro também diferem entre os anos-safra. Para o ano-safra 2010/2011, foram encontrados índices menores em relação ao ano-safra 2011/2012 e 2012/2013. Isto ocorreu devido às variações nas semeaduras no Estado, consequentemente onde foram efetuadas semeaduras antecipadas em que se seguiu o mesmo padrão para a colheita, logo, foi considerada como autocorrelação dissimilar no período de estudo para os municípios.

Já para o ano-safra 2011/2012, não foram encontrados resultados semelhantes ao ano-safra anterior. Naqueles períodos, os índices de autocorrelação espacial foram maiores, portanto, semelhantes em todo o Estado. Isso ocorre de acordo com Carvalho et al. (2008), porque os índices de vegetação são proporcionais à atividade fotossintética, com valores maiores quando a atividade é maior e há mais biomassa verde. Mesmo ocorrendo colheitas antecipadas em alguns municípios, a rápida implantação de outras culturas (milho 2ª safra) em sequência da soja manteve os I_{MG} elevados, portanto, semelhantes no Estado.

Pela análise de autocorrelação espacial pelo índice de C_{GG} (Figura 20b), os resultados são semelhantes ao índice I_{MG} , mas não iguais. Os resultados C_{GG} corroboram

com I_{MG} entre o 1º decêndio de agosto até 3º decêndio de dezembro. De janeiro em diante os índices para os três anos safras são semelhantes, indicando homogeneidade espacial entre os municípios paranaenses para o período.

Porém, para definição das causas de perdas na produtividade da soja, é imprescindível o conhecimento dos comportamentos das variáveis agrometeorológicas durante o ciclo da soja. Entre tais variáveis, o Cw é essencial durante todo o ciclo das culturas. E durante a análise dos índices de autocorrelação espacial do Cw para o período em estudo (Figura 21a e Figura 21b), verifica-se que para os três anos-safras os índices I_{MG} e C_{GG} foram semelhantes de acordo com os decêndios. Isto demonstra que se o balanço hídrico estava positivo em um município, seus vizinhos também continham Cw positivo, assim como no Estado. Em contrapartida, em outro período dentro do ciclo os municípios com Cw negativo tinham como vizinhos municípios também com balanço hídrico negativo.

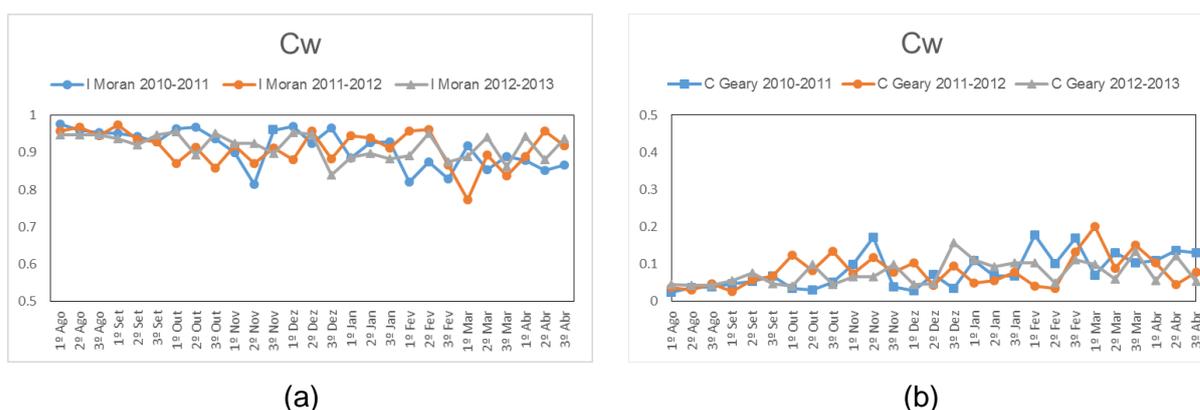


Figura 21 Autocorrelação espacial da variável Cw para cada decêndio no Estado do Paraná.

Dados em Apêndice B (Tabela 23 a Tabela 25).

A precipitação não controla diretamente qualquer processo nas plantas, mas, atua como modulador, assim afeta o desenvolvimento da planta (Serio et al., 2006), ou seja, as irregularidades pluviométricas têm influência direta no balanço hídrico do solo. Verificam-se os índices de autocorrelação espacial para a precipitação (Figura 22a e Figura 22b), observa-se semelhança na ocorrência de precipitações nos municípios durante o ciclo vegetativo da soja para os três anos-safras.

A variabilidade espacial da precipitação revela concordância espacial entre as regiões que obtiveram melhores produtividades, isto é, as áreas onde as ofertas de Ra foram mais elevadas (ALMEIDA, 2000). Esta concordância espacial entre as regiões também revelam as causas de insucesso e quedas da produtividade. E, mesmo obtendo alta correlação entre os municípios, isso ocorreu para o ano-safra 2011/2012, pois devido à falta de chuvas, o desenvolvimento da cultura durante o período vegetativo foi afetado. A

falta da Ra naquele período retardou o crescimento principalmente na última parte de floração e desenvolvimento da vagem provocando fortes quedas de flores e no preenchimento de grãos (BERLATO & FONTANA, 1999).

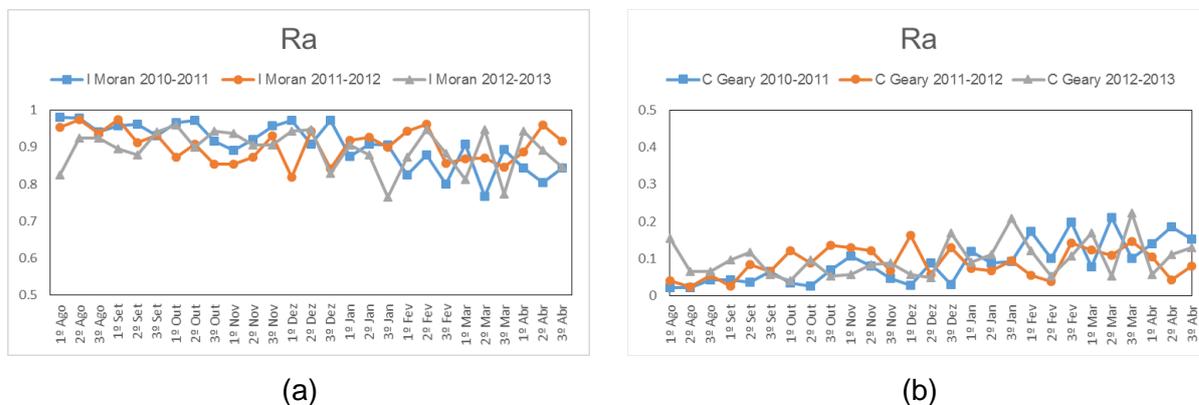


Figura 22 Autocorrelação espacial da variável Ra para cada decêndio no Estado do Paraná. Dados em Apêndice B (Tabela 23 a Tabela 25).

Desta forma, verificou-se que a quantidade e a distribuição das chuvas são fatores limitantes para o bom desenvolvimento da cultura e produtividade. Neste contexto, verificou-se que as produtividades da soja, relativamente elevadas em âmbito nacional, para os anos-safras 2010/2011 e 2012/2013, ocorreram devido aos valores de precipitações adequadas durante o ciclo da cultura. De forma inversa, para o ano-safra 2011/2012, fica evidente que o principal fator responsável pela diminuição da produtividade foi a falta de Ra do 2º decêndio de novembro até 3º decêndio de dezembro.

Em relação à análise espacial global da Et (Figura 23a e Figura 23b), verificou-se elevada correlação entre os municípios, para os três anos-safras e o ciclo da cultura. Tal variável é controlada pela disponibilidade de energia, pela demanda atmosférica além do suprimento de água do solo as plantas (ROSSATO, 2002). Portanto, a Et segue a mesma tendência das variáveis analisadas anteriormente, a Cw e Ra.

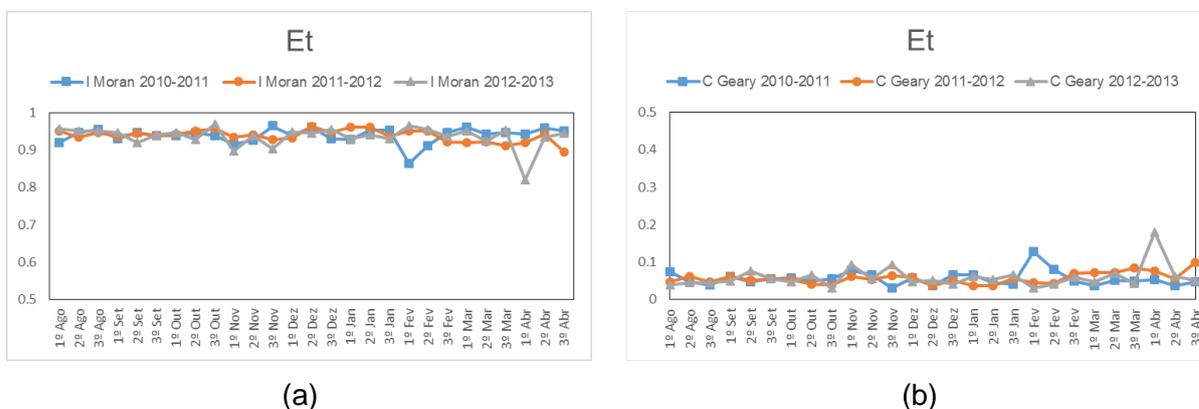


Figura 23 Autocorrelação espacial da variável Et para cada decêndio no Estado do Paraná. Dados em Apêndice B (Tabela 23 a Tabela 25).

De acordo com Confalone & Navarro (1999), a Gr permanece relativamente constante nas diferentes fases fenológicas da cultura da soja, crescendo em condições ótimas. Analisando os índices de autocorrelação global para a Gr (Figura 24a e Figura 24b), verificaram-se elevados valores para I_{MG} quanto C_{GG} . Entretanto, para o ano-safra 2011/2012 em que houve déficit hídrico por um longo período do ciclo da soja, a eficiência da utilização da radiação solar foi reduzida. A eficiência, de acordo com Casaroli (2007), pode levar à saturação luminosa quando a cultura é submetida a elevadas intensidades de Gr absorvidas.



Figura 24 Autocorrelação espacial da variável Gr para cada decênio no Estado do Paraná. Dados em Apêndice B (Tabela 23 a Tabela 25).

Pela análise de autocorrelação espacial para as temperaturas média, máxima e mínima (Figura 25a, Figura 25b, Figura 25c, Figura 25d, Figura 25e e Figura 25f), verificaram-se elevadas correlações no Estado durante o ciclo da soja. Isso indica similaridade entre os municípios, ou seja, é pequena a variabilidade espacial para tais variáveis. De acordo com Mello et al. (2008), os aumentos na temperatura do ar podem causar aumento da evaporação da superfície e provocarem alterações no Cw e assim afetarem a cultura.

Assim como há o efeito no Cw, com a falta de Ra, pode haver temperaturas elevadas por vários dias principalmente nos meses mais quentes no Paraná (dezembro e janeiro) e segundo Silva et al. (2005) podem afetar o crescimento e acelerar o desenvolvimento das plantas, além de reduzir a fotossíntese, a respiração e a produção de matéria seca.

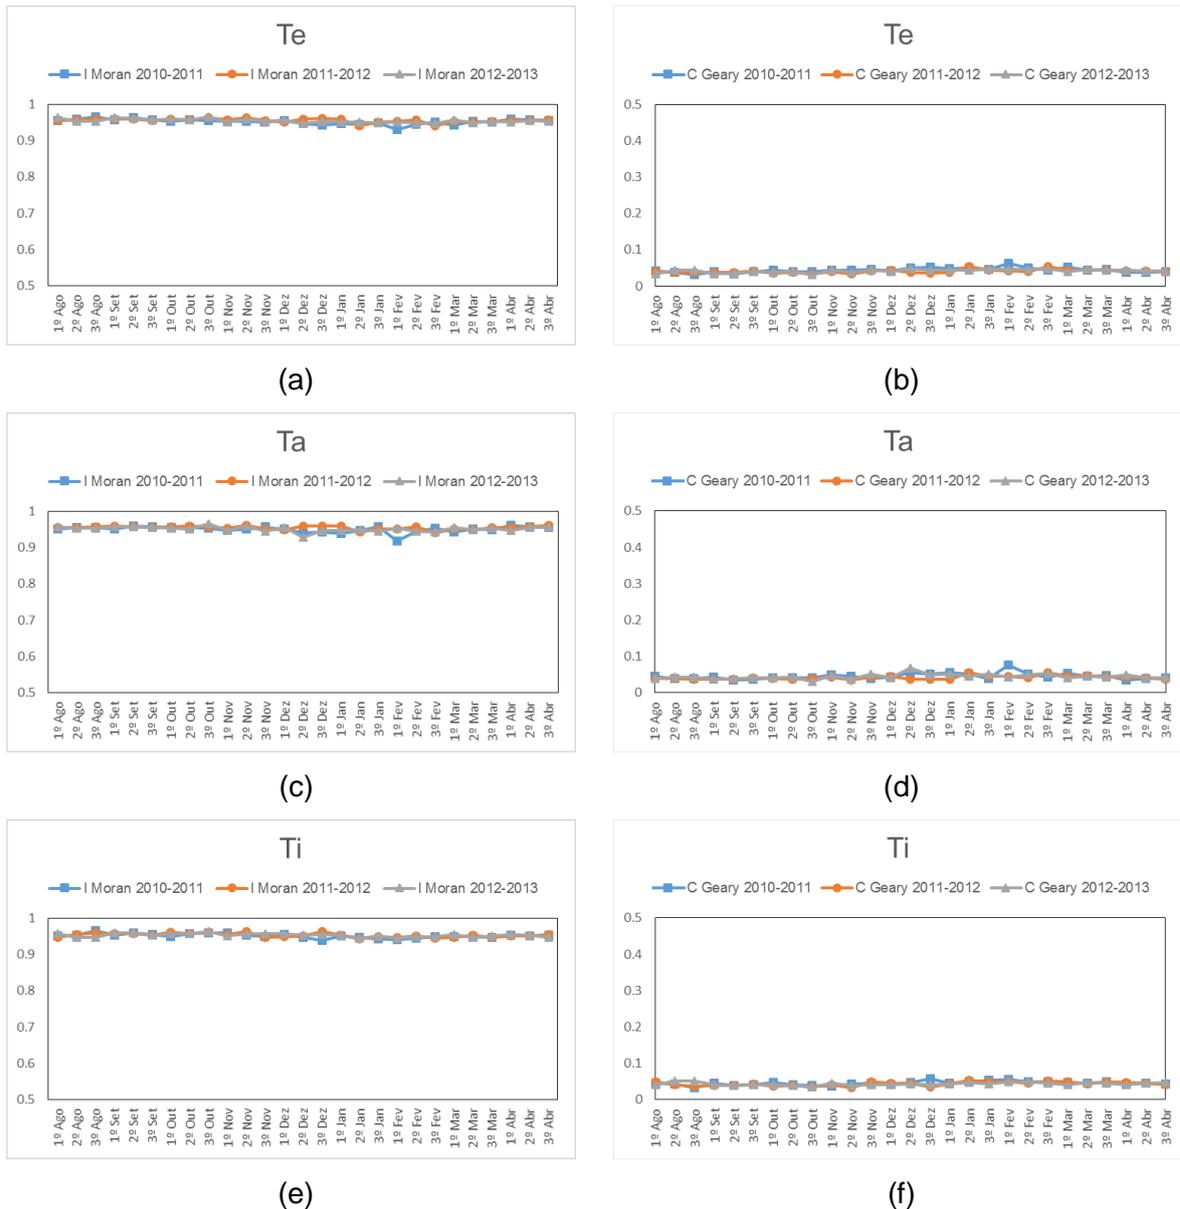


Figura 25 Autocorrelação espacial das variáveis Te, Ta e Ti para cada decêndio no Estado.

Dados em Apêndice B (Tabela 23 a Tabela 25).

6.2.3.3.3. Comparação da autocorrelação entre variáveis agrometeorológicas e EVI

A ideia básica foi estimar a magnitude da autocorrelação espacial entre os municípios durante o ciclo, e realizar uma análise geral sobre os índices de autocorrelação espacial a partir dos I_{MG} e C_{GG} . Para todas as variáveis agrometeorológicas, verificou-se que as correlações foram elevadas em todo o ciclo fenológico da cultura da soja. Isto é, não variou muito em relação aos municípios, entretanto, se analisar com relação ao índice de vegetação EVI, verifica-se que esse foi afetado no ano-safra 2011/2012. Sob este foco, é

adequado dizer que, naquele ano-safra, a produtividade foi afetada pelas variáveis agrometeorológicas. Todavia, a partir dos índices globais, não foi possível identificar qual variável foi limitante a tais perdas de produção nem o período. Para a identificação destas variáveis e decêndios que afetaram a produtividade, é preciso a utilização dos indicadores de associação espacial local.

6.2.4. Conclusões

Verificaram-se grandes diferenças entre o ano-safra 2011/2012 em relação à 2010/2011 e 2012/2013 para a produtividade da soja. As diferenças foram influenciadas por fatores climáticos durante fases críticas do ciclo da cultura. Dentre os fatores climáticos, a falta de precipitações ocasionou o balanço hídrico negativo, aliada à elevada radiação global, evapotranspiração e temperaturas nas fases de semeadura e desenvolvimento afetaram a produtividade final. No estudo do índice de vegetação EVI, foram identificados os municípios que iniciam antecipadamente as semeaduras, a fim de mostrar a variabilidade encontrada no Estado. Pela análise de autocorrelação espacial, identificaram-se maiores similaridades no ano-safra 2011/2012 com menores produtividades, ou seja, devido às variações do clima, os índices de autocorrelação espacial foram semelhantes nos municípios do Paraná devido às produtividades mais próximas.

Agradecimentos

À CAPES, ao CNPq e à Fundação Araucária pelo apoio financeiro.

6.2.5. Referências

ALBRECHT, L. P.; BRACCINI, A. L.; SCAPIM, C. A.; AGUIAR, C. G.; ÁVILA, M. R.; STÜLP, M. Qualidade fisiológica e sanitária das sementes sob semeadura antecipada da soja. **Scientia Agraria**, Curitiba/PR, v. 9, n. 4, p. 445-454, 2008.

ALMEIDA, I. R. de. **Variabilidade pluviométrica interanual e produção de soja no Estado do Paraná**. 2000. 200f. Dissertação (Mestrado em Geografia) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2000.

ANSELIN, L. **SpaceStat Tutorial**. 1992. Disponível em: <<http://www.spacestat.com>>.

ANSELIN, L. Local indicators of spatial association - LISA. **Geographical Analysis**. v. 27, n. 2, p. 93-115. 1995.

ANSELIN, L.; BONGIOVANNI, R.; LOWENBERG-DEBOER, J.; A spatial econometric approach to the economics of site-specific nitrogen management in corn production,

American Journal of Agricultural Economics, 86, 3, p. 675-687, Oxford University Press, 2004.

ANSELIN, L.; SRIDHARAN, S.; GHOLSTON, S. Using exploratory spatial data analysis to leverage social indicator databases: the discovery of interesting patterns, *Social Indicators Research*, 82, 2, p.287-309, **Springer**, 2007

ARAÚJO, E. C.; URIBE-OPAZO, M. A.; JOHANN, J. A. Análise de agrupamento da variabilidade espacial da produtividade da soja e variáveis agrometeorológicas na região Oeste do Paraná. **Engenharia Agrícola** (Impresso), v. 34, p. 782-795, 2013.

ASSAD, E. D.; MARIN, F. R.; EVANGELISTA, S. R.; PILAU, F. G.; FARIAS, J. R. B.; PINTO, H. S. e ZULLO JÚNIOR, J. Sistema de previsão da safra de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v. 42, n. 5, p. 615-625, maio, 2007.

BAILEY, T. C.; GATRELL, A. C. **Interactive spatial data analysis**. Essex: Longman Scientific, 1995.

BERGAMASCHI, H. Desenvolvimento de déficit hídrico em culturas. In: BERGAMASCHI, H. (Coord.). **Agrometeorologia aplicada à irrigação**. Porto Alegre: Ed. UFRGS, p. 25-32. 1992.

BERLATO, M. A.; FONTANA, D. C. Variabilidade interanual da precipitação pluvial e rendimento da soja no Estado do Rio Grande do Sul, **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 7, n. 1, p. 119-125, 1999.

BETTOLLI, M. L.; PENALBA, O. C.; VARGAS, W. M. Relación entre el rendimiento de la soja y las variables climáticas en la Pampa Húmeda Argentina. XIII Congresso Brasileiro de Agrometeorologia, Santa Maria, RS, Brasil, 2003. http://www.conicet.gov.ar/new_scp/detalle.php?keywords=&id=23281&congresos=yes&detalles=yes&congr_id=80112

BUNTLEY, G. J.; McCUTCHEN, T.; MORGAN, H. Jr. Soybean yields as affected by rainfall distribution during flowering and pod filling. **Tennessee Farm and Home Science**, Karamville, p. 8-10, oct. 1973.

CÂMARA, G.; MONTEIRO, A. M. V. **Conceitos básicos em ciência da geoinformação**. São José dos Campos: INPE, 2004, 36p.

CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V. Análise Espacial de Área. In: FUCKS, S. D.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. **Análise Espacial de Dados Geográficos**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais – Divisão de Processamento de Imagens, 2002.

CAMARGO, Â.P.; CAMARGO, M. B. P. Uma revisão analítica da evapotranspiração potencial. **Bragantia**, Campinas, 59(2) 125-137, 2000.

CASAROLI, D.; FAGAN E. B.; SIMON, J.; MEDEIROS, S. P.; MANFRON, P. A.; NETO, D. D.; LIER, Q. J. V.; MÜLLER, L.; MARTIN, T. N. Radiação solar e aspectos fisiológicos na cultura de soja - uma revisão. **Revista da FZVA**. Uruguaiiana, v. 14, n. 2, p. 102-120. 2007.

Cliff, A. D., Ord, J. K. **Spatial processes**. Pion, p. 21, 1981.

Cliff, A. D., Ord, J. K. **Spatial Autocorrelation**. Pion, p. 15-16, 21, 1973.

CONAB, Acompanhamento da Safra Brasileira, 2008. Disponível em: <http://www.conab.gov.br/conabweb/download/safra/12_levantamento_set2014.pdf>. Acesso em: 24 set. 2014.

CONFALONE, A. & NAVARRO-DUJMOVICH, M. Influência do “déficit” hídrico sobre a eficiência da radiação solar em soja. **Rev. Bras. de AGROCIÊNCIA**, v.5 n3, p.195-198, 1999. Doi: 10.18539/cast.v5i3.292

CUNHA, G. R.; BERGAMASCHI, H. Efeitos da disponibilidade hídrica sobre o rendimento das culturas. In: BERGAMASCHI, H. (Coord.). **Agrometeorologia aplicada à irrigação**. Porto Alegre: Editora da UFRGS, p. 85-97. 1992.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; MERCANTE, E.; LAMPARELLI, R. A. C.. Spatial autocorrelation of ndvi and gvi indices derived from landsat/tm images for soybean crops in the western of Paraná in 2004/2005 crop season. **Eng. Agric.** [online], v. 33, n. 3 p. 525-537. 2013. Doi:10.1590/S0100-69162013000300009

ECMWF – European Centre for Medium-Range Weather Forecasts. 2012. Disponível em: http://old.ecmwf.int/about/corporate_brochure/leaflets/Corporate-brochure-2012-en.pdf. Consultado em janeiro de 2015.

EMBRAPA INFORMÁTICA AGROPECUÁRIA. **Desenvolvimento do banco de produtos MODIS na base estadual brasileira**. Comunicado Técnico, n. 100. Campinas, SP, 2010. Disponível em: <http://www.cnptia.embrapa.br/files/ct100_10.pdf>. Acesso em: 25 jul. 2014.

EMBRAPA SOJA. **Tecnologia de produção de soja** – Paraná 2007. 217p. Sistemas de Produção n. 10. Londrina-PR: Embrapa soja, 2006.

ESQUERDO, J. C. D. M.; ANTUNES, J. F. G.; ANDRADE, J. C. de. **Desenvolvimento do banco de produtos MODIS na Base Estadual Brasileira**. (Comunicado Técnico, 100) - Campinas: Embrapa Informática Agropecuária, 7 p., 2010.

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

FAOSTAT - FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. ProdSTAT – Crops. 2015. Disponível em <http://faostat3.fao.org/download/Q/QC/E> 2015.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N.; OYA, T. Ecofisiologia. In: Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). **A cultura da soja no Brasil**. Londrina: Embrapa Soja, CD-Rom, 2000.

FARIAS, J. R.; ASSAD, E. D.; ALMEIDA, I. R.; EVANGELISTA, B. A.; LAZZAROTTO, C.; NEUMAIER, N.; NEPOMUCENO, A. L. Caracterização de risco de déficit hídrico nas regiões produtoras de soja no Brasil. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 415-421, 2001. Número especial.

FARIAS, J. R. B. Limitações climáticas à obtenção de rendimentos máximos de soja. In: CONGRESO DE LA SOJA DEL MERCOSUR, 5.; FORO DE LA SOJA ASIA, 1., 2011, Rosário. **Un grano: un universo**. [Rosário: Asociación de la Cadena de la Soja Argentina], 2011. 4 p. 1 CD-ROM. MERCOSOJA 2011. <http://www.alice.cnptia.embrapa.br/handle/doc/906919>

FERREIRA, W. P. M.; COSTA, L. C.; SOUZA, C. de F. Teste de um modelo agrometeorológico para estudo da influência da variabilidade climática na cultura da soja. **Revista Ceres**, Viçosa, v. 54, n. 312, p. 207-214, 2007.

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

GEARY, R. The contiguity ratio and statistical mapping. **The Incorporated Statistician** 5: p.115-45, 1954.

GILIOLI, J. L.; TERASAWA, F.; WILLEMANN, W.; ARTIAGA, O. P.; MOURA, E. A. V. & PEREIRA, W. V. **Soja**: Série 100. FT Sementes, Cristalina, Goiás. 18 p. (Boletim Técnico 3). 1995.

IAPAR. Instituto Agrônomo do Paraná. **Cartas climáticas do Paraná**. Disponível em <http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=863>. Acesso em 16 de Junho de 2015.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Banco de dados agregados - Sistema IBGE de Recuperação Automática – SIDRA. 2015. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 24 jun. 2015.

JI, L.; ZHANG, L.; WYLIE, B.K.; ROVER, J. On the terminology of the spectral vegetation index (NIR – SWIR)/(NIR+SWIR). **International Journal of Remote Sensing**, v. 32, p. 6901-6909, 2011. doi: 10.1080/01431161.2010.510811.

JOHANN, J. A., ROCHA, J. V., OLIVEIRA, S. R. DE M., R., LUIZ H. A., & LAMPARELLI, R. A. C. Data mining techniques for identification of spectrally homogeneous areas using NDVI temporal profiles of soybean crop. **Engenharia Agrícola**, 33(3), p. 511-524, 2013. doi: 10.1590/S0100-69162013000300008.

LEE, S. Developing a bivariate spatial association measure: An integration of Pearson's r and Moran's I. **J Geograph Syst.** 3, p. 369-385. 2001.

LEE, S. A generalized significance testing method for global measures of spatial association: an extension of the Mantel test. **Environment and Planning A.** v. 36, p. 1687-1703. 2004.

LESAGE, J. P. A. Family of Geographically Weighted Regression Models. In: ANSELIN, Luc; FLORAX, Raymond J. G. M.; REY, Sergio J. *Advances in Spatial Econometrics*. Berlin; Heidelberg: **Springer**, cap. 11, p. 241-266, 2004.

LONG, M. E. F.; HURTADO, R. H.; MURPHY, G. M. Validación de las temperaturas máximas y mínimas diarias de la región pampeana estimadas por el modelo atmosférico del ECMWF. p. 37-44. In: 2° INTERNATIONAL WORKSHOP ON CROP MONITORING AND FORECASTING IN SOUTH AMERICA, 2006. **Proceedings...** Montevideo: South America Scientific Network on Crop Monitoring and Forecasting, 2006.

MARQUES, A. P. S.; HOLZSCHUH, M. L.; TACHIBANA, V. M.; IMAI, N. N. Análise exploratória de dados de área para índices de furto na mesorregião de Presidente Prudente-SP. In: III SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO. Recife, PE, 27 a 30 de julho de 2010, **Anais** do III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Informação, Recife, p. 1- 8. 2010.

MEDEIROS, C. N.; PINHO NETO, V. R. Análise Espacial da Extrema Pobreza no Estado do Ceará. In: VII Encontro de Economia Ceará em Debate. Fortaleza, 2011, **Anais... Encontro de Economia Ceará em Debate**, 2011.

MELLO, E. L.; OLIVEIRA, F.A.; PRUSKI, F. F.; FIGUEIREDO, J. C. Efeito das mudanças climáticas na disponibilidade hídrica da bacia hidrográfica do Rio Paracatu. **Engenharia Agrícola**, Jaboticabal, v. 28, n. 4, p. 635-644, 2008.

MORAN, P. A. P. Notes on continuous stochastic phenomena, **Biometrika** 37, p. 17-23. 1950.

PRUDENTE, V. H. R.; SOUZA, C. H. W. DE; MERCANTE, E.; JOHANN, J. A.; URIBE-OPAZO, M. A. Spatial Statistics Applied to Soybean Production Data from Paraná State for 2003-04 to 2009-10 Crop-Years. **Eng. Agríc.** n. 4, v. 34, p. 755-769, 2014.

R DEVELOPMENT CORE TEAM, **R: A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing, ISBN 3-90005107-0. Disponível em: <http://www.R-project.org>. Acesso em: Agosto, 2015.

ROSSATO, L. **Estimativa da capacidade de armazenamento de água no solo do Brasil**. 147f. Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos/SP, 2002.

SEAB/DERAL - SECRETARIA DA AGRICULTURA E DO ABASTECIMENTO DO PARANÁ / DEPARTAMENTO DE ECONOMIA RURAL – Banco de Dados da Produção Agropecuária no Paraná. Produção Agrícola Paranaense. 2012. Disponível em: <http://www.agricultura.pr.gov.br/modules/conteudo/conteudo.php?conteudo=137>. Consultado em 20 de fevereiro de 2013.

SERIO, L.; SPESCHA, L.; MURPHY, G. M. Validación de lãs precipitaciones decádicas de la región pampeana na estimadas por el modelo atmosférico del ECMWF. p. 45-52. In: 2° INTERNATIONAL WORKSHOP ON CROP MONITORING AND FORECASTING IN SOUTH AMERICA, 2006. **Proceedings...** Montevideo: South America Scientific Network on Crop Monitoring and Forecasting, 2006.

SILVA, R. A. B.; SOUZA, A. L. F.; CAMPOS, P. M.; BILICH, M. R.; ROCHA, J. V. Estimativa de área plantada de soja utilizando imagens MODIS, no Estado de Goiás. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12. 2005, Goiânia. **Anais...** XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 483-489. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.18.10.21>>. Acesso em 31 de setembro de 2012.

SOUZA, C. H. W. de; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soybean and corn crops using spectrum-temporal profiles of vegetation indices. **International Journal of Remote Sensing** (Online), v. 36, p. 1809-1824, 2015.

STEWART, D. A., NIELSEN, D. R. **Irrigation of Agricultural Crops**. Madison: Agronomical Monograph 30, American Society of Agronomy, WI. 1990.

VIRGENS FILHO, J. S. das; OLIVEIRA, R. B.; LEITE, M. L. and TSUKAHARA, R. Y. Desempenho dos modelos CLIGEN, LARS-WG e PGECLIMA_R na simulação de séries diárias de temperatura máxima do ar para localidades do Estado do Paraná. **Engenharia Agrícola**. v. 33, n. 3, p. 538-547. 2013.a

6.3. ARTIGO 3: Autocorrelação espacial do índice de vegetação e variáveis agrometeorológicas associadas à produtividade da soja no Estado do Paraná

Resumo: Neste trabalho, o objetivo foi empregar uma análise de autocorrelação espacial univariada (global e local) e bivariada (global) da produtividade oficial média municipal da soja ($t\ ha^{-1}$), com dados agrometeorológicos e índices de vegetação agrupados por decêndios nos anos-safras 2010/2011, 2011/2012 e 2012/2013 no Estado do Paraná. Com este estudo, foi possível identificar os municípios vizinhos de com elevada produtividade assim como aqueles que se localizam com baixa-baixa produtividade. De acordo com as variáveis em estudo, foram observadas a diferença entre as épocas de semeadura nas diferentes regiões, a irregularidade climática durante períodos de floração e o enchimento de grãos no ano-safra 2011/2012 em todo o Estado, que causaram grande queda de produção em todos os municípios do Paraná. Pela análise local, verificou-se que na região Noroeste, nos três anos-safras, a produtividade foi significativa, e mostrou baixo potencial produtivo desta região. Outra constatação foi identificar o período de 3º decêndio de outubro até o 2º de janeiro, como essenciais do ciclo da soja nas diferentes regiões do Estado visto que engloba fases críticas da cultura.

Palavras-chave: Ano-safra 2011/2012, épocas de semeadura, região Noroeste.

6.3.1. Introdução

Uma forma de se analisar a variabilidade espacial utilizando a referência geográfica é pelo método da estatística espacial de áreas. Neste contexto, para seu desenvolvimento, podem ser empregados indicadores globais e locais de autocorrelação espacial que medem a correlação da própria variável no tempo ou espaço. Portanto, o Índice Global de Moran I_{MG} enquadra-se na categoria global univariada (BAILEY & GATRELL, 1995).

Já a autocorrelação espacial local tem como objetivo captar padrões de associação em uma subárea composta por vizinhos. Esta abordagem, para a análise da estrutura espacial, é a função *Local Indicator of Spatial Association* (LISA) (ANSELIN, 1995).

Dalposso et al. (2013) estudaram a autocorrelação espacial global e local de Moran da soja e, pelos índices encontrados, foi possível conhecer o perfil da cultura da soja nos municípios da região Oeste do Paraná, além de identificar diferentes épocas de semeadura. Prudente et al. (2014) demonstraram a partir desses métodos como os municípios se relacionam espacialmente quanto à produção da soja no Estado do Paraná, a fim de que se conheçam os principais municípios produtores de soja.

Quando se trabalha com a autocorrelação bivariada global, verifica-se a existência de um padrão de associação entre duas variáveis, ou seja, o objetivo é mostrar se os valores da variável observada em dada região revelam uma relação com os valores de outra

variável observada em regiões vizinhas. Nesta etapa, enquadra-se o teste de autocorrelação espacial de Lee's [L_{LEE}] (LEE, 2001; LEE, 2004).

Ainda na região Oeste do Paraná, Araújo et al. (2013) trabalharam a autocorrelação espacial bivariada de Moran entre a produtividade da soja e as variáveis agrometeorológicas precipitação média, temperatura média e radiação solar global média, e encontraram correlação espacial negativa e significativa entre a produtividade da soja e todos os elementos agrometeorológicos analisados no ano-safra 2005/2006.

Desta forma, neste trabalho, o objetivo foi empregar uma análise de autocorrelação espacial univariada (global e local) e bivariada (global) da produtividade oficial média municipal da soja ($t\ ha^{-1}$), com dados agrometeorológicos e índices de vegetação agrupados por decêndios nos anos-safras 2010/2011, 2011/2012 e 2012/2013 no Estado do Paraná.

6.3.2. Material e Métodos

O método de trabalho foi composto das seguintes etapas: (i) determinação da área de estudo; (ii) aquisição de dados; (iii) análise de autocorrelação espacial univariada global; (iv) análise de autocorrelação espacial univariada local e (v) análise de autocorrelação espacial bivariada global (Figura 26).

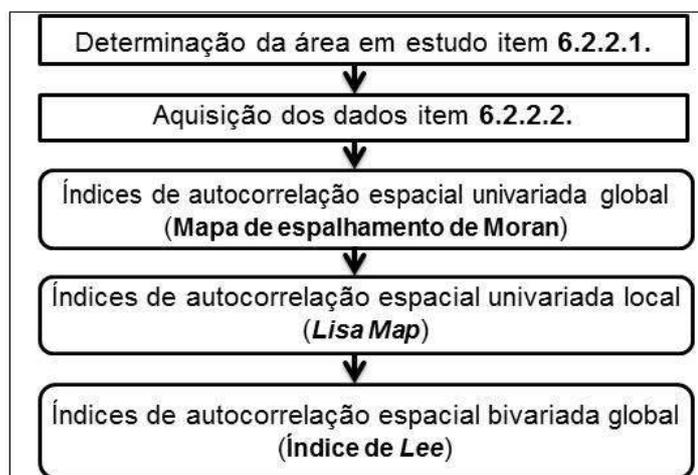


Figura 26 Fluxograma das etapas de trabalho realizadas.

6.3.2.1. Área de estudo

A área de estudo compreende os 399 municípios, divididos de acordo com as mesorregiões da IBGE para o Estado do Paraná, região Sul do Brasil, limitada pelas coordenadas $22^{\circ} 29' S$ e $26^{\circ} 43' S$ e $48^{\circ} 2' W$ e $54^{\circ} 38' W$ (Figura 13). Maiores detalhes seção 6.2.2.1.

6.3.2.2. Aquisição de dados

Foram utilizados dados da produtividade da soja [Prod] ($t\ ha^{-1}$), para os anos-safras 2010/2011, 2011/2012 e 2012/2013. Os índices de vegetação utilizados foram extraídos de imagens orbitais do sensor MODIS (*Moderate resolution imaging spectroradiometer*) e dados agrometeorológicos provenientes do modelo do ECMWF (*European Center for Medium-Range Weather Forecast*). Maiores detalhes seção 6.2.2.2.

6.3.2.3. Análise de autocorrelação espacial global univariada

A análise exploratória espacial é caracterizada pela dependência espacial, ou seja, avaliar como os valores estão correlacionados no espaço. Assim, para verificar a presença de dependência espacial, recorre-se a um teste estatístico global, no qual a hipótese nula é a existência de distribuição aleatória da variável sob estudo e a hipótese alternativa, a existência da associação de valores similares ou diferentes a um nível de significância α definido (MEDEIROS & PINHO NETO, 2011).

Neste estudo, as funções utilizadas para estimar quanto o valor observado de um atributo em uma região é dependente dos valores desta mesma variável, nas localizações vizinhas, é o Índice de Moran I_{MG} (MORAN, 1950) (Equação 8), que varia entre -1 (perfeita autocorrelação negativa), 0 (ausência de autocorrelação) e +1 (perfeita autocorrelação positiva).

$$I_{MG} = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}. \quad (8)$$

em que:

n : tamanho da amostra;

x_i e x_j : valor do atributo considerado na área i e j ;

\bar{x} : é o valor médio do atributo na região de estudo;

w_{ij} : os elementos da matriz normalizada de proximidade espacial.

Os Mapas de Espalhamento de Moran foram construídos com o objetivo de identificar pontos com associação espacial positiva ou não (ANSELIN, 1995). Este mapa foi construído com base no diagrama de espalhamento de Moran, que é dividido de acordo com quatro quadrantes: Alto-Alto [Q(+/+)], Baixo-Baixo [Q(-/-)], Baixo-Alto [Q(-/+)] e Alto-Baixo [Q(+/-)].

6.3.2.4. Análise de autocorrelação espacial local univariada

O objetivo da autocorrelação espacial é captar padrões de associação local (*clusters* ou *outliers* espaciais). Embora seja capaz de apontar a tendência geral de agrupamento dos dados, o *I* de Moran é uma medida global e por isso não revela padrões locais de associação espacial, quer dizer, eles são geralmente ocultos pelas estatísticas de autocorrelação global. Assim, neste trabalho, foi utilizado o valor do indicador na subárea composta por vizinhos, e esta abordagem para a análise da estrutura espacial é a função *Local Indicator of Spatial Association* (LISA) (ANSELIN, 1995) (Equação 9).

$$I_{Local} = \frac{x_i - \bar{x}}{S_i^2} \sum_{j=1, j \neq i}^n w_{ij} (x_j - \bar{x}) \quad (9)$$

$$S_i^2 = \frac{\sum_{j=1, j \neq i}^n w_{ij}}{n-1} - \bar{x}^2$$

Assim, quando determinados os valores do índice de Moran local, esses podem ser visualizados em um mapa denominado *LISA MAP* (Indicador local de autocorrelação espacial). De acordo com Marques et al. (2010), neste mapa, pode-se considerar que não há autocorrelação espacial se o nível descritivo *p-valor* for maior que 0,05, caso contrário, a autocorrelação é significativa. Em seguida, as áreas são classificadas em até cinco diferentes níveis de significância. Neste trabalho, os níveis significância: 0,5, 0,1; e 0,01.

6.3.2.5. Análise de autocorrelação espacial global bivariada

A existência da autocorrelação espacial univariada identifica padrões espaciais considerando cada variável isoladamente, porém, é interessante verificar a relação espacial considerando duas variáveis. Assim, quando é observada a existência de correlação espacial entre duas variáveis, há interesse em descobrir se os valores de uma variável em dada região estão associados aos valores de outra variável observada em regiões vizinhas (ANSELIN et al 2004).

Neste contexto, Lee (2001) propõe uma medida de associação espacial bivariada, a estatística *L* (Equação 10) ao integrar a medida de associação bivariada de Pearson e a medida de associação espacial univariada do Índice de Moran.

$$L(x, y) = \frac{n \sum_{i=1}^n \left(\sum_{j=1}^n w_{ij} (x_i - \bar{x}) \right) \left(\sum_{j=1}^n w_{ij} (y_j - \bar{y}) \right)}{\sum_{i=1}^n \left(\sum_{j=1}^n w_{ij} \right)^2 \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

Em que:

y_i e y_j : valor do atributo da segunda variável considerado na área i e j ;

\bar{y} : é o valor médio do atributo da segunda variável na região de estudo;

6.3.3. Resultados e Discussões

6.3.3.1. Mapa de espalhamento de Moran Global

6.3.3.1.1. Produtividade

A análise da autocorrelação espacial global pelo mapa de espalhamento de Moran (Figura 27) para os três anos-safras permite que se verifique certa semelhança entre os anos-safras 2010/2011 (Figura 27a) e 2012/2013 (Figura 27c), com as maiores produtividades e se concentra em parte das regiões Sudoeste, Oeste, Centro-Occidental, Norte-Central e Centro-Oriental, e menores no Centro-Sul e Noroeste do Estado. Em relação ao ano-safra 2011/2012 (Figura 27b), identificou-se elevada autocorrelação global, pois se visualizam mais semelhanças entre os municípios, ou seja, municípios com alta-alta e com baixa-baixa produtividade próximos a municípios de igual escala. Entretanto, identifica-se que houve queda da produtividade em 2011/2012 nas grandes regiões produtoras - Sudoeste, Oeste e Centro-Occidental.

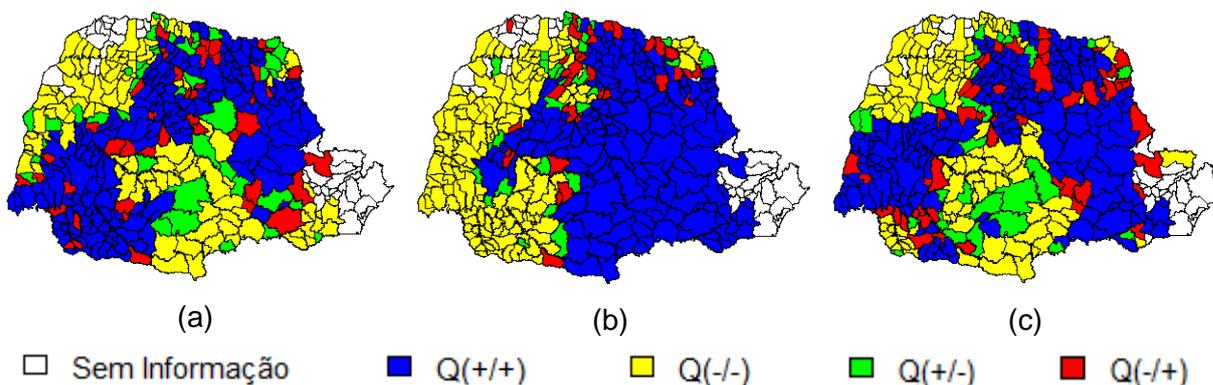


Figura 27 Mapa espaço-temporal de espalhamento de Moran Global da produtividade da soja no Estado do Paraná para o ano-safra 2010/2011 (a), 2011/2012 (b) e 2012/2013 (c).

6.3.3.1.2. EVI e variáveis agrometeorológicas para o ano-safra 2010/2011

Os mapas de espalhamento de Moran (Figura 28) para o ano-safra 2010/2011 mostraram elevadas correlações espaciais locais para todas as variáveis. Isto indica que municípios com autocorrelação positiva são vizinhos de municípios com autocorrelação

espacial positiva, e o inverso, municípios com autocorrelação negativa vizinhos de municípios com autocorrelação negativa.

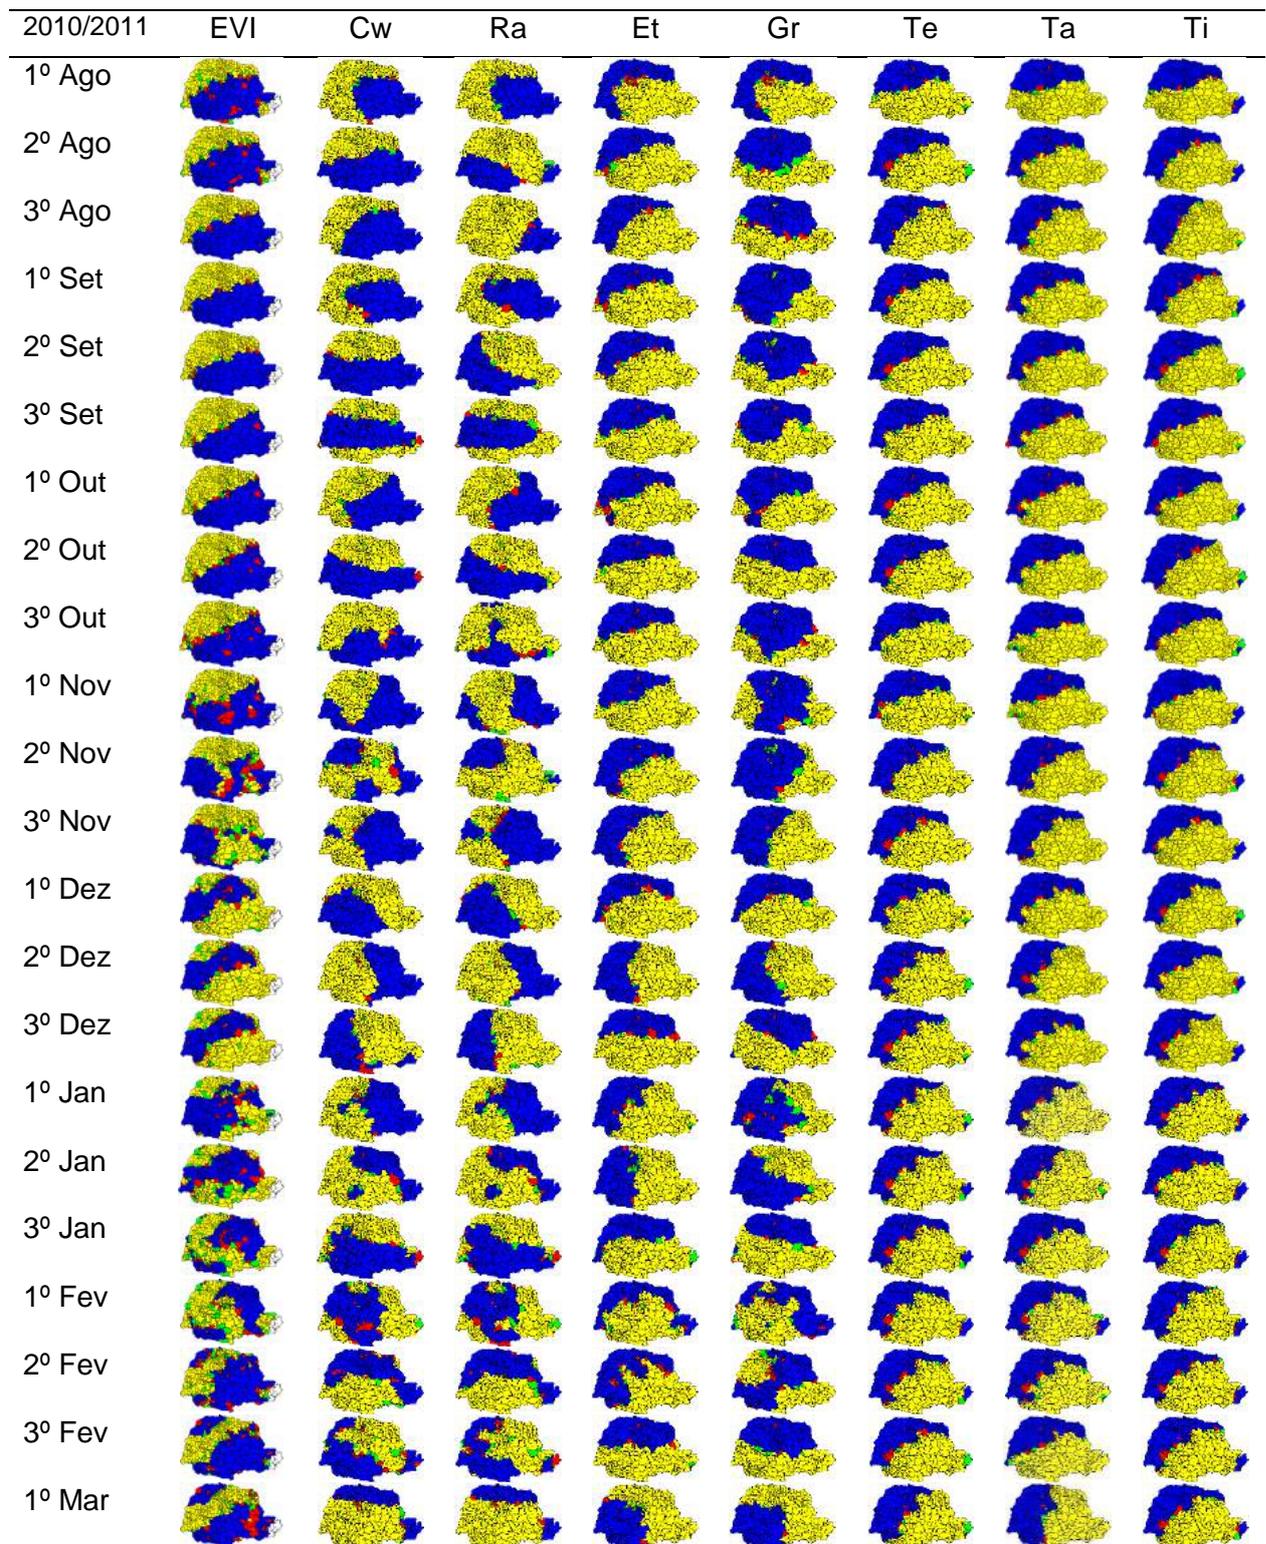
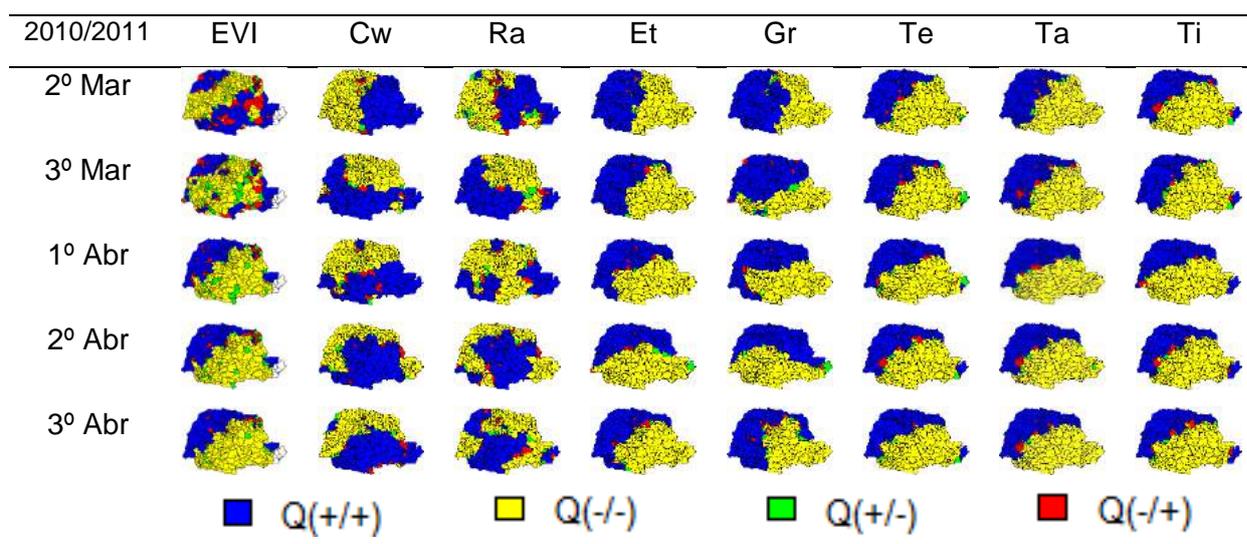


Figura 28 Mapa espaço-temporal de espalhamento de Moran Global para as variáveis agrometeorológicas e EVI em quartis para cada decêndio de estudo do ano-safra

2010/2011.

Continua...

Continuação da **Figura 28...**



Para as variações espaciais encontradas para a variável EVI, esta pode ser explicada em função das diferenças entre as datas de semeaduras e cobertura vegetal no período de análise. Esta variabilidade fica evidente no Estado, sendo metade na autocorrelação positiva em municípios que contêm cultura nesses períodos, e negativa nos municípios em que não apresentam elevado índice de vegetação.

A autocorrelação espacial positiva nos municípios da região Oeste ocorreu a partir do 3º decêndio de novembro; e também relaciona o início antecipado de semeaduras devido aos aumentos dos níveis dos índices de vegetação nestes municípios, e demonstraram as diferenças para outras regiões do Estado. Entretanto, a variação dos índices de vegetação no Estado está associada ao balanço hídrico, precipitações, intensidade luminosa e as temperaturas. Isto pode ser verificado pela autocorrelação para tais variáveis durante o período estudado. Ou seja, as semeaduras da soja ocorreram quando o Cw e Ra estiveram com autocorrelação espacial positiva [Q(+/+)] a partir do 2º decêndio de outubro.

Quando analisadas as variáveis Et e Gr naquele período, os valores da autocorrelação foram negativos em parte do Estado, ou seja, devido às chuvas e balanço hídrico do solo positivo, a evapotranspiração foi menor e isto também devido à baixa radiação global. De maneira geral, a Gr média decendial apresentou autocorrelação positiva nas regiões Noroeste, parte do Oeste, Centro-Occidental no superior do Norte-Central em praticamente todos os decêndios. Tal constatação também é obtida para as temperaturas.

6.3.3.1.3. EVI e variáveis agrometeorológicas para o ano-safra 2011/2012

A autocorrelação do EVI para os meses de agosto e setembro foi semelhante, contudo, houve variação em relação às regiões do Estado. Igualmente ao ano anterior,

identifica-se a região Oeste, a qual inicia o cultivo da soja, visto que houve ocorrências das Ra, Cw positivo além de Et, Gr e as temperaturas serem adequadas à sementeira a partir do 3º decêndio de setembro (Figura 29). No entanto, a distribuição das variáveis agrometeorológicas, propícia ao desenvolvimento da cultura, foi até o 2º e o 3º decêndio de novembro, fase inicial nas regiões Oeste e implantação das sementeiras no restante do Estado. No mês de dezembro, prevalece a falta de Ra em regiões com a cultura mais avançada, pois causa déficit hídrico, que em conjunto com elevada intensidade da luminosidade ocasiona elevada evapotranspiração, a qual afeta a atividade fotossintética.

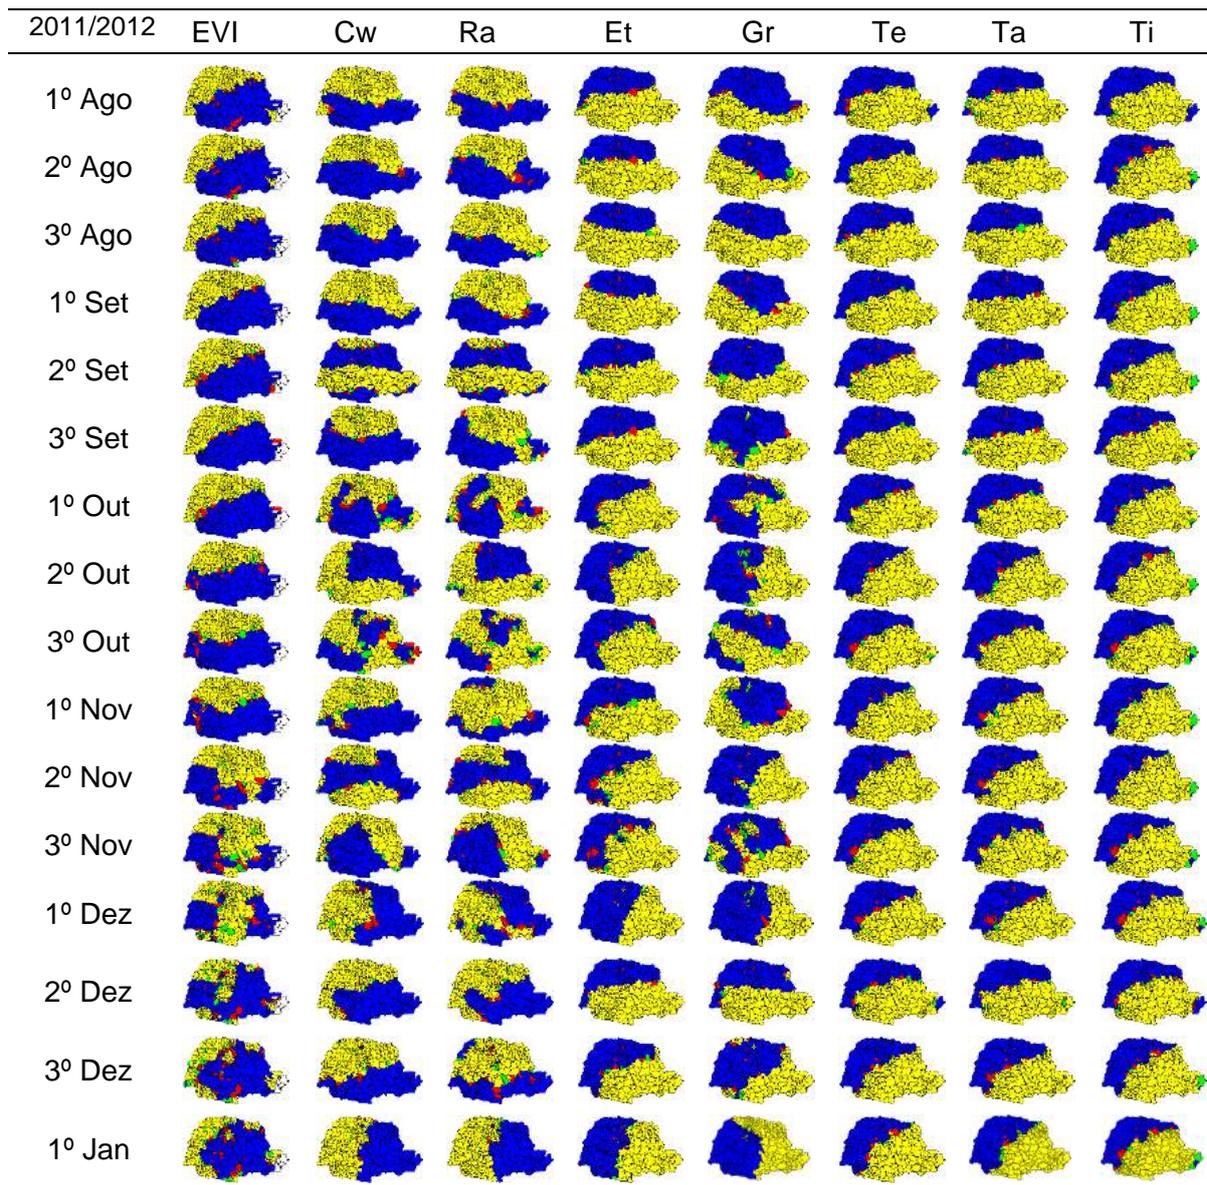
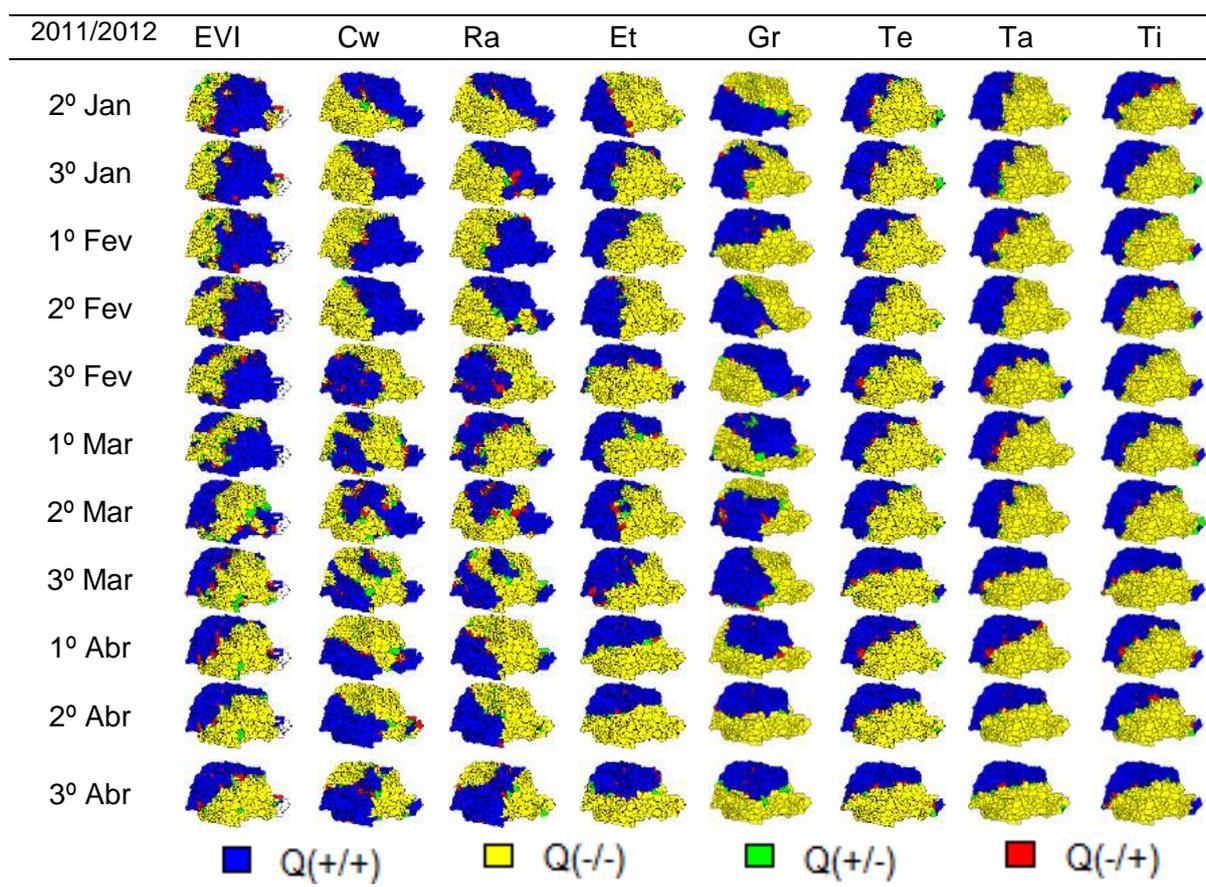


Figura 29 Mapa espaço-temporal de espalhamento de Moran Global para as variáveis agrometeorológicas e EVI em quartis para cada decêndio de estudo do ano-safra (2011/2012).

Continua...

Continuação da **Figura 28...**



Os problemas que ocorreram com o clima ocasionaram perdas na produtividade em praticamente todo o Estado, com exceção da região Centro-Oriental (Ponta Grossa, Castro e Tibagi (Figura 4, Apêndice A)) cuja produção foi maior do que a da média nacional com os seguintes resultados: 3,35, 3,55 e 3,30 t ha⁻¹. Nesses municípios, todas as variáveis agrometeorológicas não tiveram variações durante o ciclo, assim não foi comprometida a produtividade da soja como nas outras regiões do Paraná.

As temperaturas foram semelhantes entre os decêndios para as regiões do Estado. Isso indica pouca variação entre Ta e Ti. Ressalta-se a região Noroeste que, durante todo o período, apresentou alta/alta [Q(++)] autocorrelação espacial e região Sul apresentou baixa/baixa [Q(--)] autocorrelação. Tal constatação corrobora com dados de temperatura obtidos pelo IAPAR (2015) no trimestre mais quente do Paraná.

6.3.3.1.4. EVI e variáveis agrometeorológicas para o ano-safra 2012/2013

Os índices locais mostraram semelhanças para o EVI do ano-safra 2012/2013 ao de 2010/2011, com as variabilidades de acordo com as regiões, além da semeadura antecipada no Oeste Paranaense e parte do Sudoeste (Figura 30).

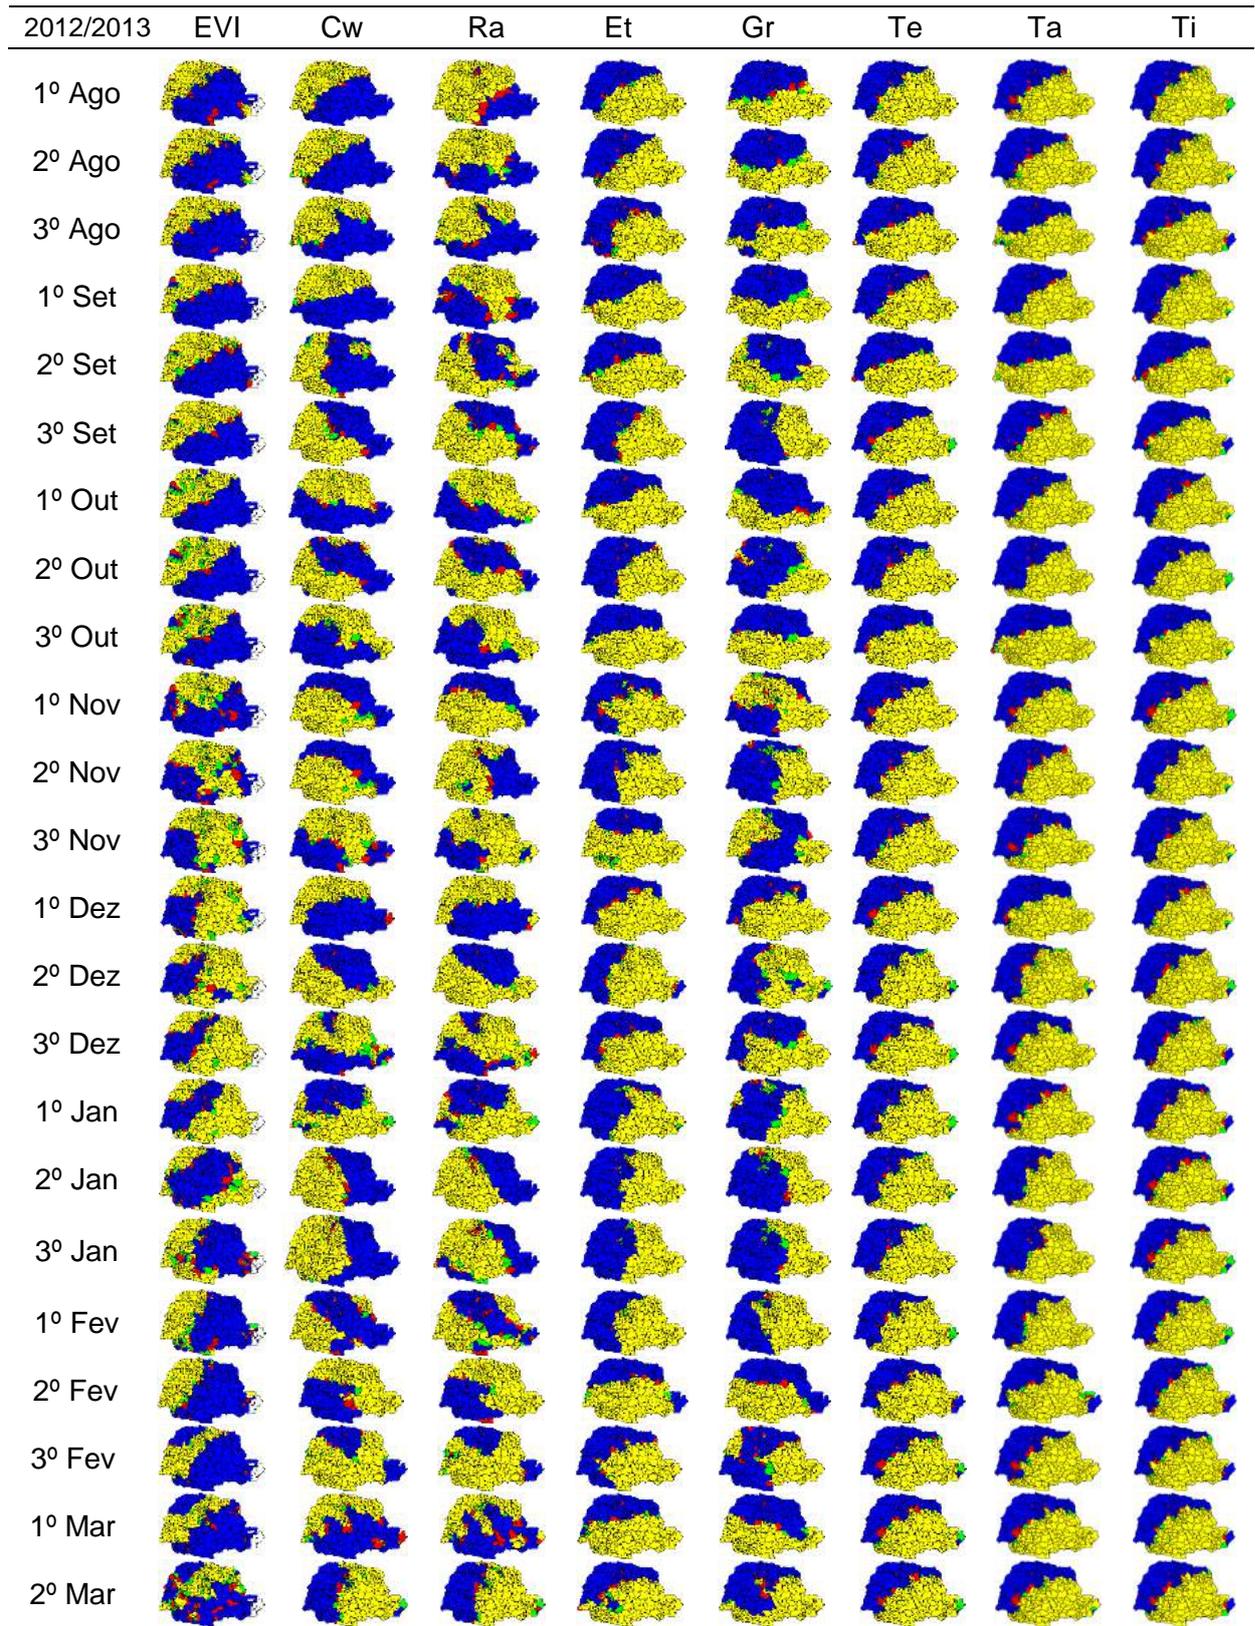
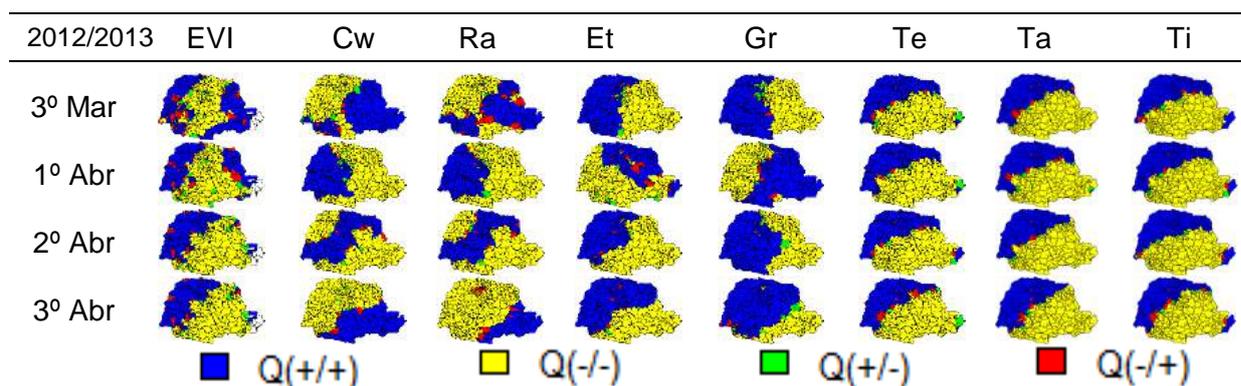


Figura 30 Mapa espaço-temporal de espalhamento de Moran Global para as variáveis agrometeorológicas e EVI em quartis para cada decêndio de estudo do ano-safra (2012/2013).

Continua...

Continuação da **Figura 31...**



A precipitação durante o ciclo da cultura apresentou, nos dois primeiros decêndios de novembro, autocorrelação espacial Q(-/-), principalmente nas regiões em que a soja já estava em estágio vegetativo. No entanto, as irregularidades que ocorreram não prejudicaram a cultura em seus momentos críticos (emergência- germinação ou floração-frutificação). Logo, não foram considerados prejudiciais na produtividade final em praticamente todo o Estado. Isto porque, em parte da região Noroeste, a autocorrelação espacial baixa encontrada indica que ocorreram irregularidades nas precipitações do 2º decêndio de novembro até o 3º de dezembro, aliada ao baixo potencial produtivo da região, afetando diretamente a produtividade.

Identificaram-se doze municípios (Loanda, Pérola, Santa Isabel do Ivaí, Xambê, Douradina, Cruz Machado, Santa Cruz do Monte Castelo, Cafezal do Sul, Colorado, Iporã, Tapira e Itaguajé) com produtividade menor que 2,20 t ha⁻¹. Desses, dez estão localizados no Noroeste do Paraná. Outros fatores que contribuíram para a queda de produtividade na região podem ser visualizados nos períodos decendiais para as variáveis Gr, Et e temperaturas (Figura 30), em que houve autocorrelação espacial positiva Q(+/-) indicando que também afetaram o desenvolvimento em momentos críticos.

As maiores produtividades de soja do Estado (3,8 t ha⁻¹) foram obtidas em dezesseis municípios (Céu Azul, Cruzmaltina, Ivaiporã, Três Barras do Paraná, Boa Vista da Aparecida, Serranópolis do Iguaçu, Jesuítas, Entre Rios do Oeste, Cafelândia, Maripá, Quarto Centenário, Foz do Iguaçu, Catanduvas, Nova Santa Rosa, Arapoti e Arapuã (Figura 4, Apêndice A)) e desses, doze deles pertencem à região Oeste. Eles tiveram elevada autocorrelação espacial durante o ciclo. Portanto, há indícios de que desde a semeadura, o pico vegetativo e a colheita, as variabilidades agrometeorológicas favoreceram o desenvolvimento da cultura.

6.3.3.2. Autocorrelação Local

6.3.3.2.1. Produtividade

O cálculo do índice de Moran Local (*Lisa Map*) permitiu classificar a produtividade da soja dos municípios em função do nível de significância dos valores de seus índices locais (Figura 32). Pode-se verificar que para os três anos-safras na região Noroeste, a produtividade foi significativa (p -valor $< 0,01$), ou seja, como já foi explorado anteriormente, são municípios com baixo potencial produtivo e também a região é susceptível aos veranicos, os quais prejudicam a produtividade da soja. Entretanto, no ano-safra 2011/2012 (Figura 32b), identificou-se que a produtividade foi significativa em duas regiões distintas, além do Noroeste, em parte da região Oeste, a produtividade foi afetada por variáveis climáticas, por isso a semelhança com o Noroeste. Ao contrário das regiões Sudeste e Centro-Oriental, em que os municípios com p -valor $< 0,01\%$, 1% e 5% , naquele ano-safra, houve as maiores produtividades, assim, observa-se a elevada significância. Em relação ao ano-safra 2012/2013 (Figura 32c), identificam-se municípios das regiões Oeste e Centro-Oriental com produtividades significativas.

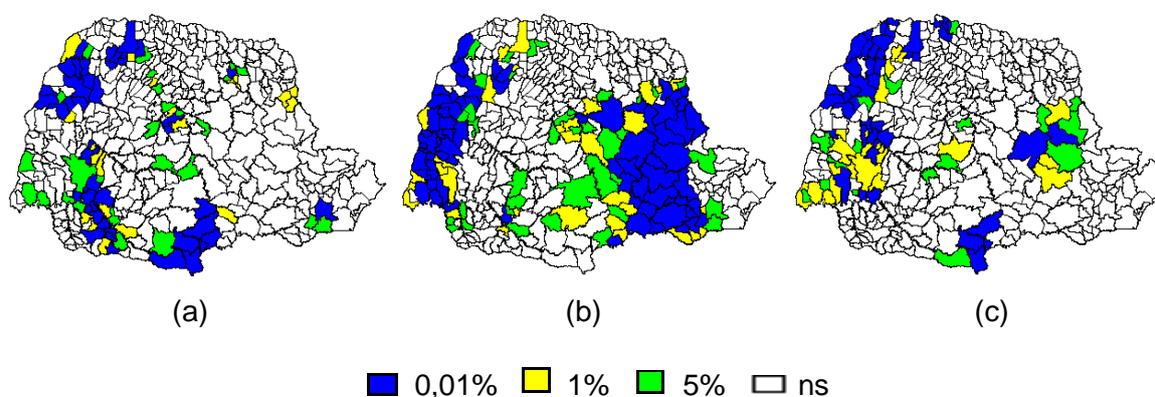


Figura 32 Nível de significância do índice de Moran Local (*Lisa Map*) para a produtividade da soja anos-safras 2010/2011 (a), 2011/2012 (b) e 2012/2013 (c), autocorrelação significativa (p -valor $< \alpha$).

6.3.3.2.2. EVI e variáveis agrometeorológicas

Os LISA mapas de Moran (Figura 31, Figura 34 e Figura 35) para os anos-safras 2010/2011, 2012/2011 e 2012/2013 mostraram elevadas correlações espaciais locais em alguns municípios para todas as variáveis. Para a variável EVI, isto indica que nesses municípios a autocorrelação é significativa (p -valor $< \alpha$). Isso indica que há diferenças em

relação aos decêndios em que acontecem as semeaduras. Porém, há semelhança entre os anos-safras. Para a variável Cw ela está relacionada com a Ra, assim como Et e Gr. Em relação aos LISA mapas, para as temperaturas máxima, média e mínima, verifica-se semelhança entre os decêndios e anos-safras, sendo então coerente a análise com a Te.

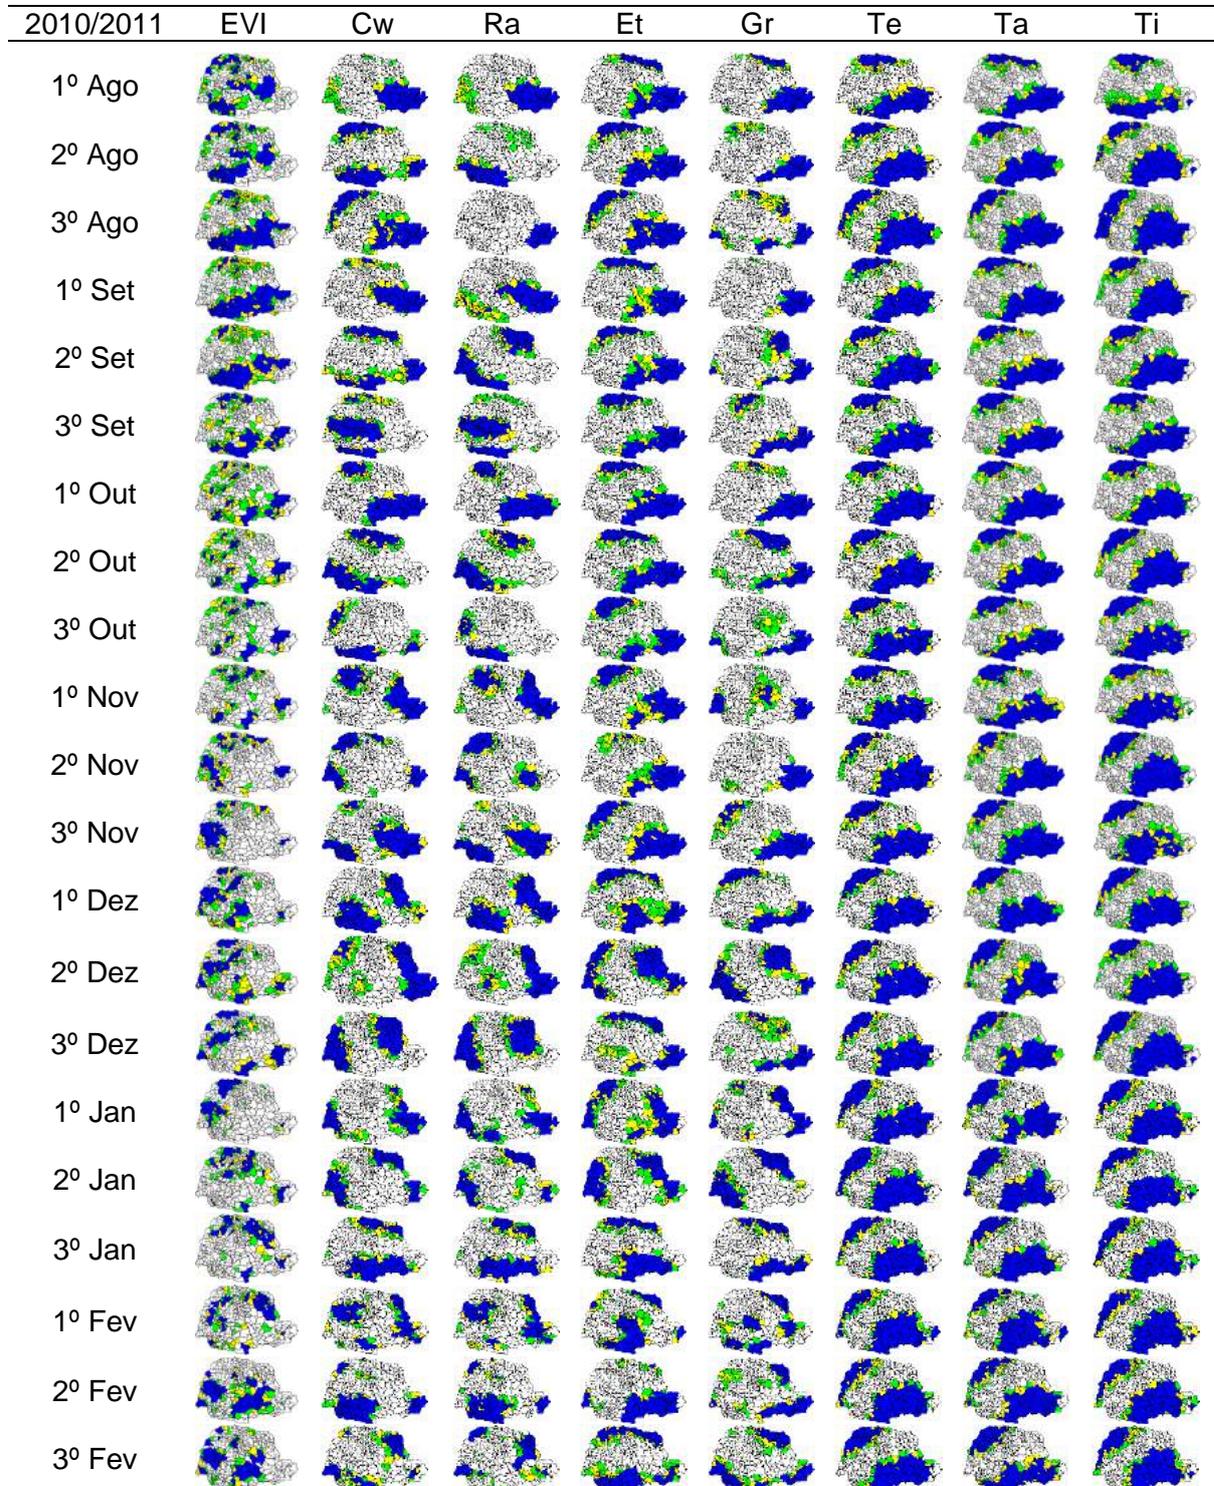


Figura 33 Lisa Map por decêndio e variáveis (EVI e agrometeorológicos) ano-safra

2010/2011.

Continua...

Continuação da **Figura 33...**

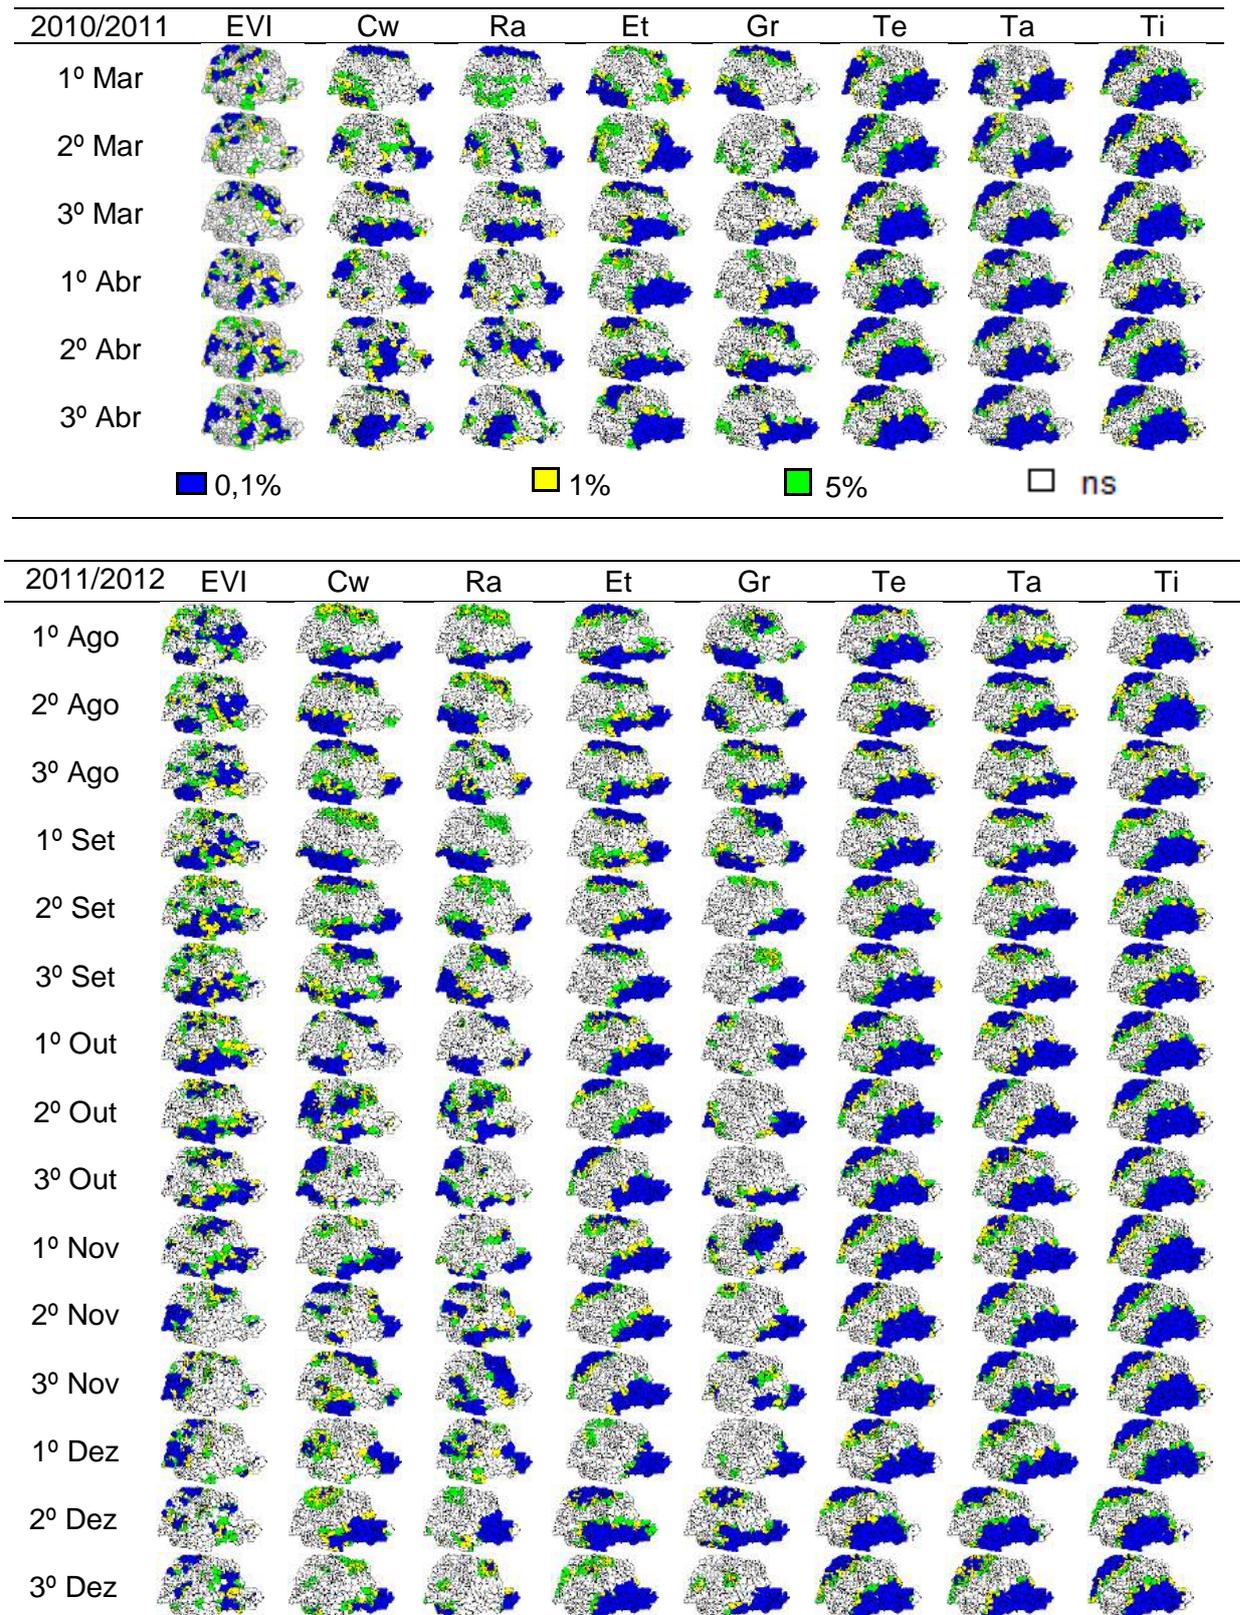


Figura 34 *Lisa Map* por decêndio e variáveis (EVI e agrometeorológicos) ano-safra

2011/2012.

Continua...

Continuação da **Figura 34...**

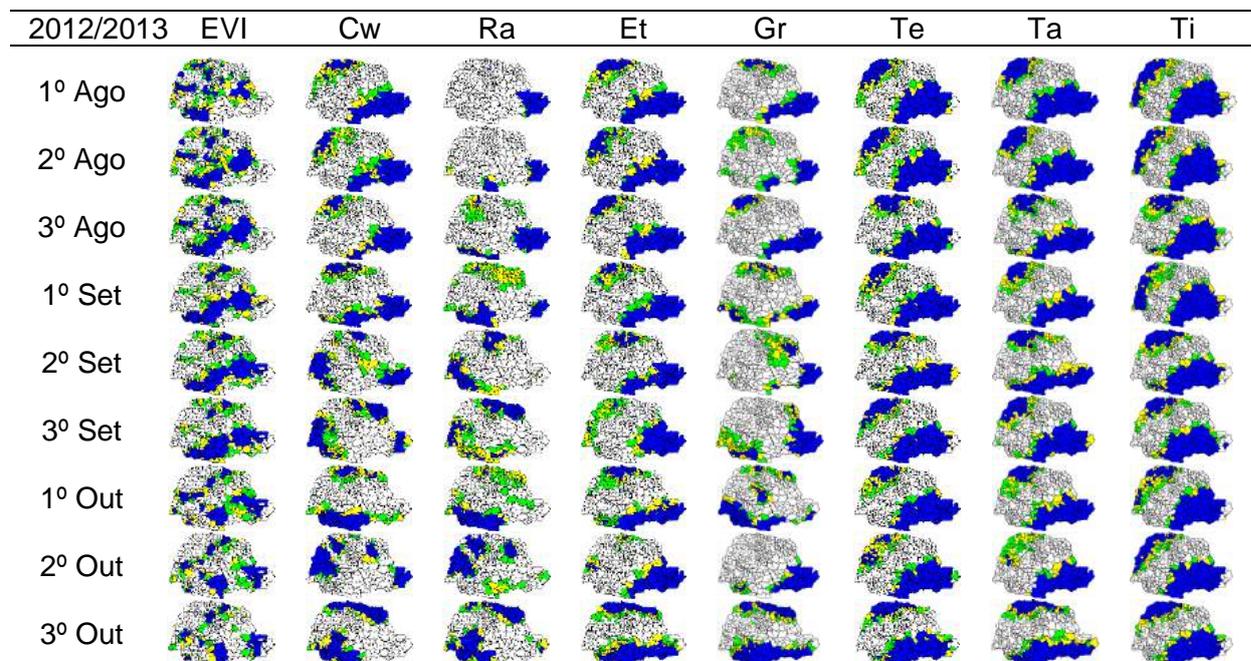
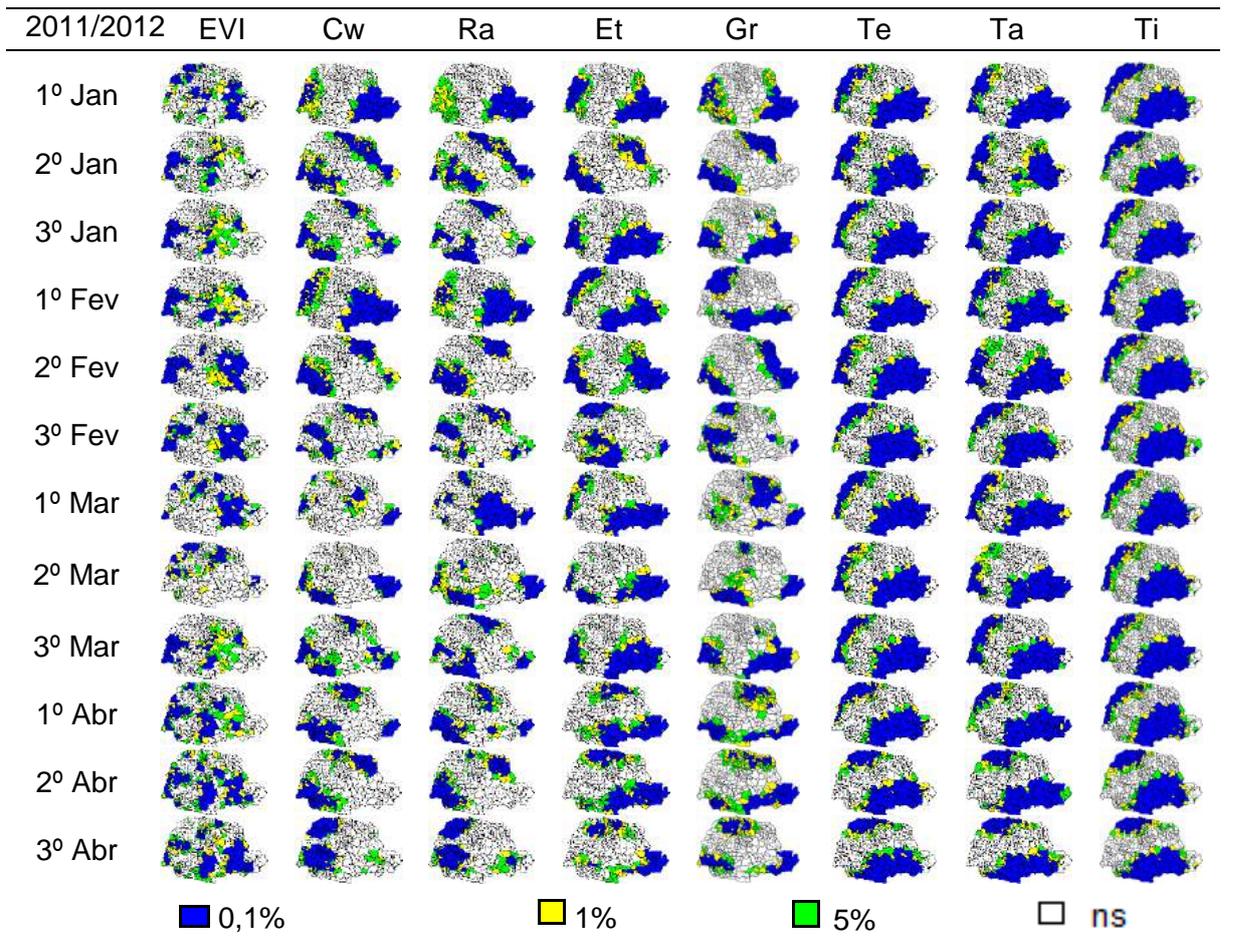
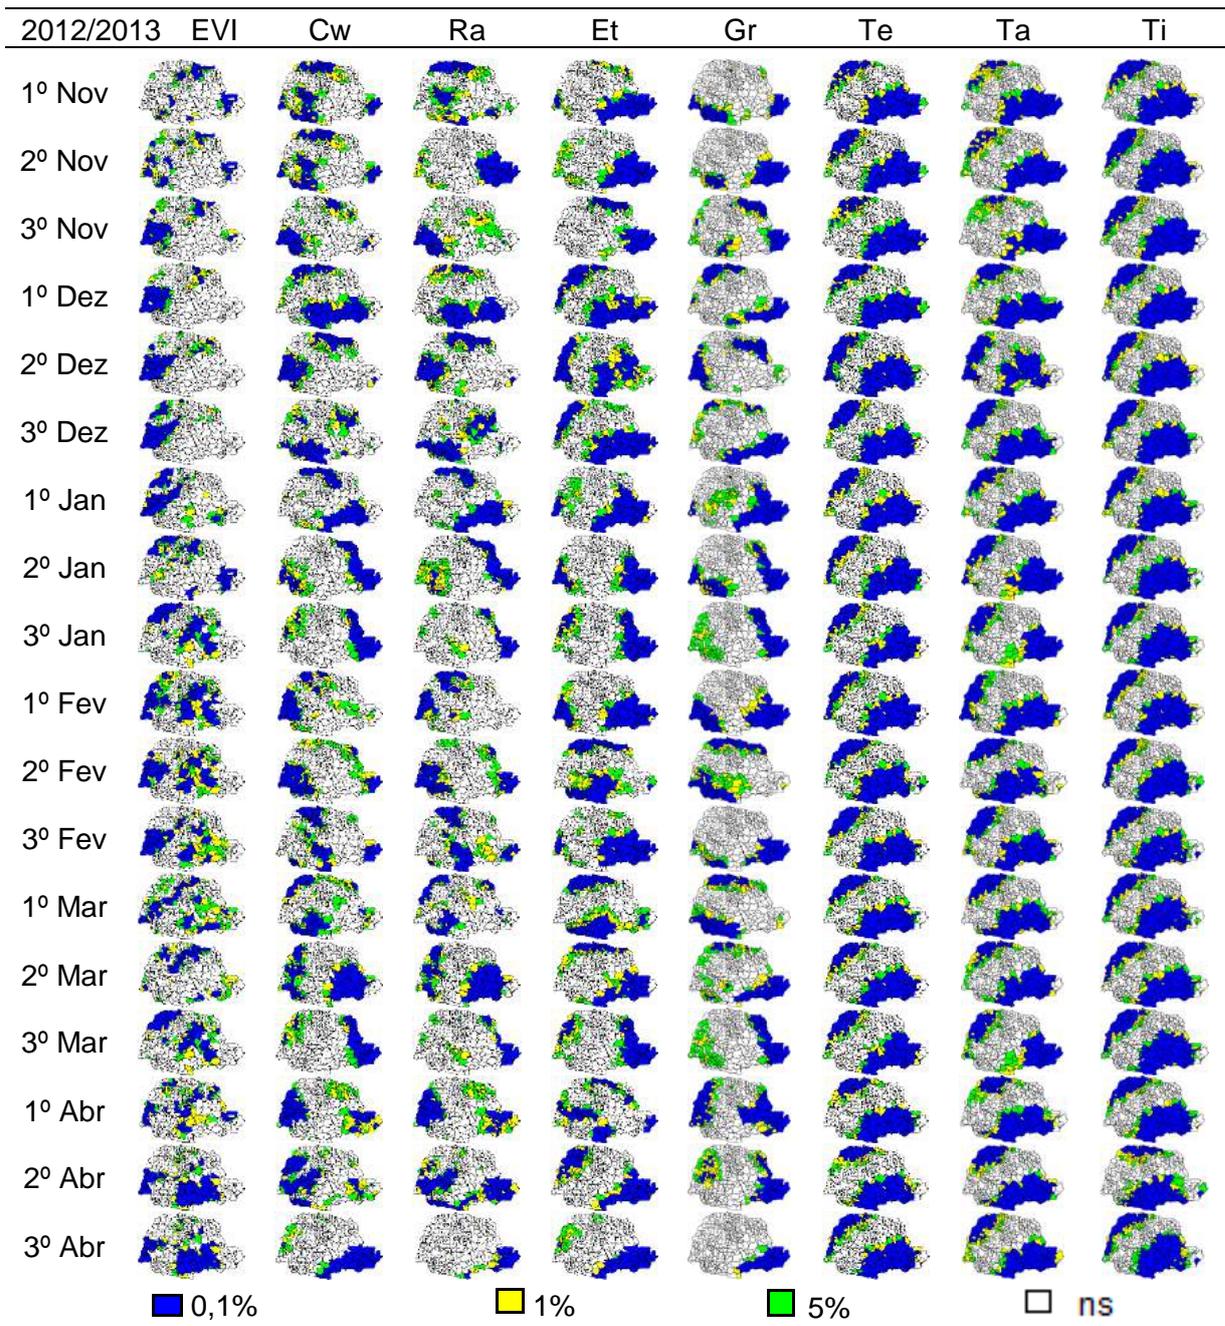


Figura 35 *Lisa Map* por decêndio e variáveis (EVI e agrometeorológicos) ano-safra

2012/2013.

Continuação...

Continuação da **Figura 35...**



6.3.3.3. Autocorrelação Global Bivariada

A avaliação da influência do EVI e das variáveis agrometeorológicas na produtividade da soja apresentou a determinação da autocorrelação bivariada pelo índice de Lee (Figura 36). Nesta análise, verificou-se a autocorrelação espacial global de cada município em função do período decendial de cada variável. A autocorrelação entre a produtividade e o EVI (Figura 36a) para os três anos-safras é negativa do 1º decêndio de agosto até o 1º de novembro. Isso se deve aos níveis do índice de vegetação estarem muito

baixo ou ausentes. A partir do 2º decêndio de novembro, a autocorrelação fica positiva, contudo, para 2011/2012, em período de comparação com os outros anos-safras é menor, indicando problema no desenvolvimento da cultura.

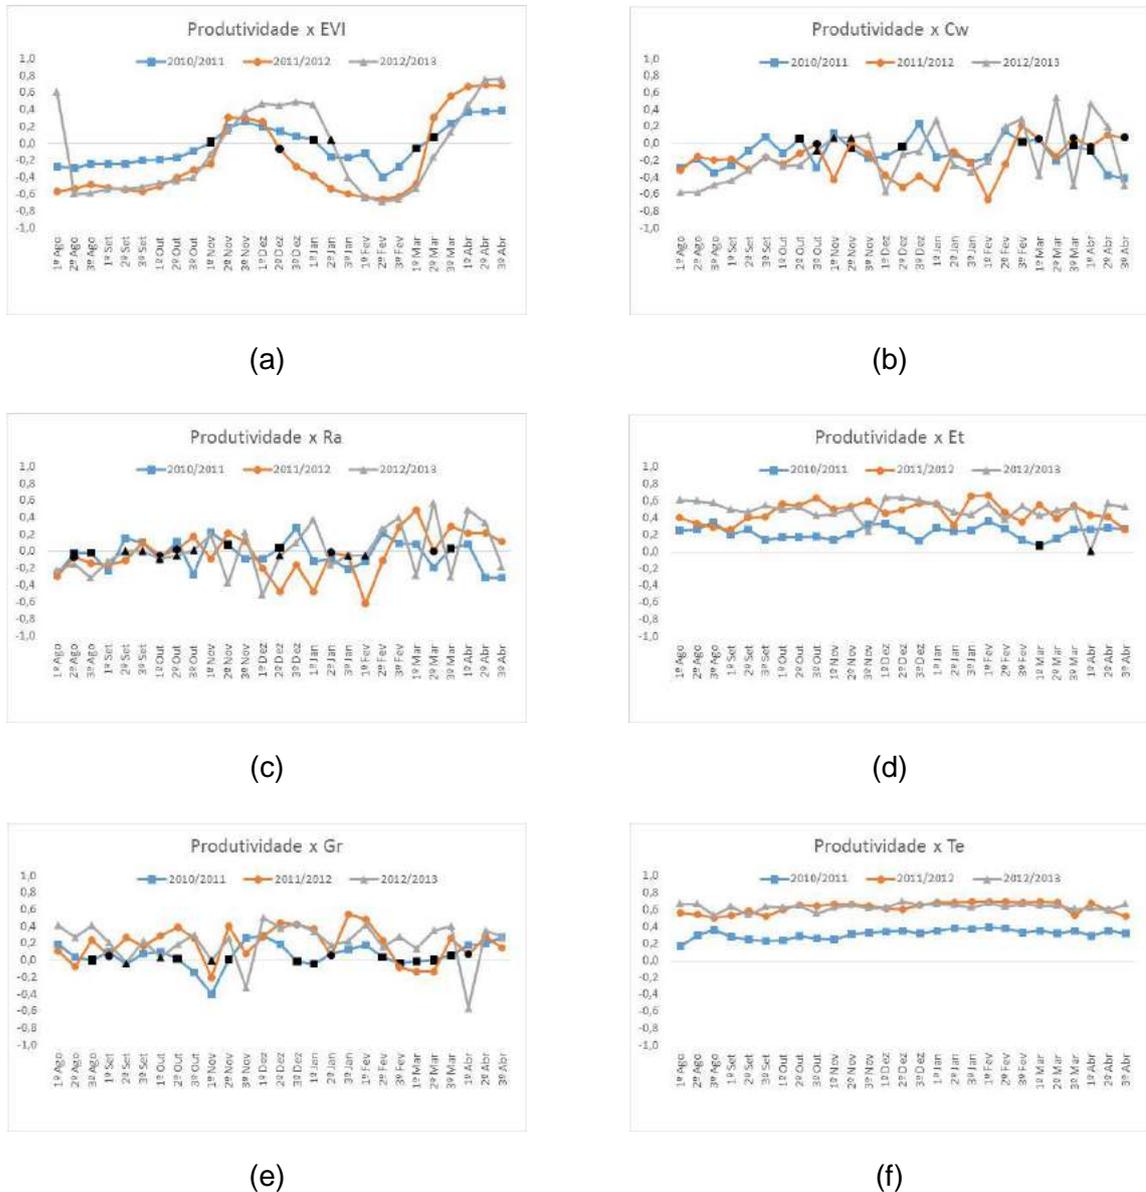


Figura 36 Análise de autocorrelação espacial bivariada entre a Produtividade da soja e as variáveis EVI (A), Balanço hídrico (B), Precipitação (C), Evapotranspiração (D), Radiação global (E) e Temperatura média (F).

Pontos em preto indicam autocorrelação não significativa ao nível de 5%.

Verificaram-se similaridades entre 2010/2011 e 2012/2013 com a autocorrelação espacial global no período do 2º decêndio de novembro até 1º de janeiro. No entanto, quando os índices de 2010/2011 foram analisados, os municípios foram mais heterogêneos em relação ao ano-safra 2012/2013. Identifica-se, portanto, que a partir do 2º decêndio de

janeiro, a cultura entra na fase de senescência e colheita. A análise da autocorrelação da produtividade e Cw (Figura 36b) aponta que a relação foi inversa do 1º decêndio de agosto até o 2º de outubro para os anos-safras 2011/2012 e 2012/2013, ou seja, nesse período, o solo estava com déficit hídrico, o qual afetou as semeaduras.

Em 2010/2011, os índices variaram menos com autocorrelação espacial próxima de 0 do 2º decêndio de setembro até 2º de outubro. Tanto a baixa autocorrelação como a negativa foram identificadas do 1º de novembro até 2º de dezembro e 1º janeiro a 1º fevereiro. Entretanto, para esse ano-safra, não afetou a produtividade da soja mesmo que tenham ocorrido em um período de desenvolvimento da cultura. Ou seja, ao se verificar a autocorrelação da produtividade com a Ra (Figura 36c), é possível observar um resultado semelhante ao encontrado na produtividade e Cw, indicando heterogeneidade espacial entre os municípios. Todavia, não pode ser concluído o mesmo para o ano-safra 2011/2012, que teve autocorrelação espacial negativa entre a produtividade e Cw e também produtividade e Ra, que afetaram o desenvolvimento das plantas em fase crítica. Devido aos elevados valores negativos, até então inversos, pode-se concluir que houve homogeneidade na maior parte do Estado, e o Cw e a Ra afetaram a produtividade final da soja.

Em resultados obtidos para produtividade e Et (Figura 36d), verifica-se que os índices bivariados foram menores no ano-safra 2010/2011 em relação aos outros. Este resultado também pode ser observado na análise de autocorrelação entre a produtividade e Gr (Figura 36e) e produtividade e Te (Figura 36f).

Em relação ao ano-safra 2011/2012, afetado pelas precipitações e balanço hídrico negativo, verificaram-se elevados índices de autocorrelação espacial entre produtividade e Et, Gr e Te no Estado. Isso indica a dependência que as variáveis agrometeorológicas exercem na produtividade final da cultura.

Na análise de 2012/2013, verificaram-se semelhanças com o ano-safra 2010/2011, entretanto, com índices de autocorrelação espacial maiores. Isso indica menores variações entre os municípios e o clima.

6.3.4. Conclusões

Identificaram-se maiores similaridades no ano-safra com menores produtividades a partir da análise de autocorrelação espacial, ou seja, devido às variações do clima, os índices de autocorrelação espacial foram semelhantes nos municípios do Paraná. Outra constatação foi em relação à região Noroeste, onde foram identificados municípios com baixa produtividade nos três anos-safras estudados. Assim, observa-se o baixo potencial

produtivo da região. Em análise bivariada, identificou-se o período essencial de 3º decêndio de outubro até 2º de janeiro no ciclo da cultura.

Agradecimentos

À CAPES, ao CNPq e à Fundação Araucária pelo apoio financeiro.

6.3.5. Referências

ANSELIN, L.. Local indicators of spatial association - LISA. **Geographical Analysis**. v. 27, n. 2, p. 93-115. 1995.

ANSELIN, L.; BONGIOVANNI, R.; LOWENBERG-DEBOER, J. A spatial econometric approach to the economics of site-specific nitrogen management in corn production, **American Journal of Agricultural Economics**, v. 86, n. 3, p. 675-687, Oxford University Press, 2004.

ARAÚJO, E. C.; URIBE-OPAZO, M. A.; JOHANN, J. A. Análise de agrupamento da variabilidade espacial da produtividade da soja e variáveis agrometeorológicas na região Oeste do Paraná. **Engenharia Agrícola** (Impresso), v. 34, p. 782-795, 2013.

BAILEY, T. C.; GATRELL, A. C. **Interactive spatial data analysis**. Essex: Longman Scientific, 1995.

BERGAMASCHI, H.. Desenvolvimento de déficit hídrico em culturas. In: BERGAMASCHI, H. (Coord.). **Agrometeorologia aplicada à irrigação**. Porto Alegre: Ed. UFRGS, p. 25-32, 1992.

BERLATO, M. A.; FONTANA, D. C. Variabilidade interanual da precipitação pluvial e rendimento da soja no Estado do Rio Grande do Sul, **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 7, n. 1, p. 119-125, 1999.

DALPOSSO, G. H.; URIBE-OPAZO, M. A.; MERCANTE, E.; LAMPARELLI, R. A. C. Spatial autocorrelation of ndvi and evi indices derived from landsat/tm images for soybean crops in the western of the state of Paraná in 2004/2005 crop season. **Eng. Agríc.** [online]., v. 33, n. 3, p. 525-537. 2013. Doi:10.1590/S0100-69162013000300009

ECMWF – **EUROPEAN CENTRE FOR MEDIUM-RANGE WEATHER FORECASTS**. 2012. Disponível em: http://old.ecmwf.int/about/corporate_brochure/leaflets/Corporate-brochure-2012-en.pdf. Consultado em janeiro de 2015.

EMBRAPA INFORMÁTICA AGROPECUÁRIA. **Desenvolvimento do banco de produtos MODIS na base estadual brasileira**. Comunicado Técnico, n. 100. Campinas, SP, 2010. Disponível em: <http://www.cnptia.embrapa.br/files/ct100_10.pdf>. Acesso em: 25 jul. 2014.

LEE, S.. Developing a bivariate spatial association measure: An integration of Pearson's r and Moran's I. **J Geograph Syst** 3, p. 369-385. 2001.

LEE, S.. A generalized significance testing method for global measures of spatial association: an extension of the Mantel test. **Environment and Planning A**. v. 36, p. 1687-1703. 2004.

MARQUES, A. P. S.; HOLZSCHUH, M. L.; TACHIBANA, V. M.; IMAI, N. N. Análise exploratória de dados de área para índices de furto na mesorregião de Presidente Prudente-SP. In: III SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO. Recife, PE, 27 a 30 de julho de 2010, **Anais do III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Informação**, Recife, p.1- 8. 2010.

MEDEIROS, C. N.; PINHO NETO, V. R. Análise Espacial da Extrema Pobreza no Estado do Ceará. In: VII Encontro de Economia Ceará em Debate. Fortaleza, 2011, **Anais...** Encontro de Economia Ceará em Debate, 2011.

MORAN, P.A.P.. Notes on continuous stochastic phenomena, **Biometrika** v. 37, p. 17-23. 1950.

PRUDENTE, V. H. R.; SOUZA, C. H. W. DE; MERCANTE, E.; JOHANN, J. A.; URIBE-OPAZO, M. A. Spatial Statistics Applied to Soybean Production Data from Paraná State for 2003-04 to 2009-10 Crop-Years. **Eng. Agríc.** n. 4, v. 34, p. 755-769, 2014.

6.4. ARTIGO 4: Modelos de estimativa de produtividade da soja para o Estado do Paraná utilizando dados de índice de vegetação e variáveis agrometeorológicas decendiais

Resumo: Na busca para obter informação de dados de produtividade da soja, este trabalho teve como objetivo gerar modelos de estimação da produtividade da soja para o Estado do Paraná. Para esta modelagem, foram utilizados como variáveis explicativas os dados decendiais das variáveis agrometeorológicas em conjunto com o índice de vegetação EVI englobando o ciclo da cultura da soja. A técnica de stepwise foi utilizada para seleção de variáveis. A avaliação do desempenho dos modelos de Regressão Espacial Autorregressivo (SAR), Modelo do Erro Espacial (CAR) e Modelo de Regressão Ponderada Geograficamente (GWR) foi realizada com base no máximo valor do logaritmo da função verossimilhança (MLL), critério de informação de Akaike (AIC) e bayesiano de Schwarz (BIC). Dos 108 decêndios utilizados, para o ano-safra 2010/2011, foram selecionados 24, para 2011/2012 foram selecionados 29 e para 2012/2013 um total de 30 foram significativos. Em relação aos modelos pela avaliação de desempenhos, o modelo GWR ofereceu melhores resultados em relação aos modelos SAR e CAR.

Palavras-chave: Ciclo da cultura, EVI, GWR, SAR, CAR.

6.4.1. Introdução

O conhecimento da variabilidade climática é de grande importância, principalmente para o setor agropecuário. O clima aparece como o de mais difícil controle e de maior ação limitante sobre as máximas produtividades. Aliada a isso, a imprevisibilidade o torna o principal fator de insucesso nos cultivos (FARIAS et al., 2007). Também depende dele que o planejamento seja realizado de forma racional, além de auxiliar na diminuição dos custos de produção.

Em relação ao ciclo fenológico das culturas eles também têm influência direta na produtividade. Devido aos diferentes estádios de desenvolvimento da planta, pode-se identificar o melhor manejo e adotar práticas culturais específicas em regiões de cultivo. Sendo assim, relaciona-se o ciclo vegetativo da cultura da soja com a variabilidade espacial e temporal.

No Paraná, atualmente segundo maior produtor mundial da cultura da soja do Brasil, a variabilidade deve ser levada em consideração. Isto pode incorporar novos procedimentos e tecnologias à agricultura. Para que isso ocorra, podem-se utilizar a associação das técnicas de sensoriamento remoto e os métodos estatísticos que geram informações sobre a área plantada das culturas e a variabilidade existente nelas.

Associada à estimação da produtividade da soja há outra dificuldade, é a sua adequada representação espacial. Os modelos agrometeorológicos integram o acúmulo (ou a perda) de biomassa das culturas ao longo do tempo, pois utilizam dados das estações meteorológicas de superfície. No entanto, têm-se resultados pontuais que precisam ser interpolados para a obtenção da estimação em escala estadual e nacional. A geração de mapas é facilitada, quando se dispõem de modernos recursos da tecnologia da informação, que permitem o tratamento e a espacialização de dados pontuais para a composição de mapas (ROMANI et al., 2003).

O uso de modelos espectrais que usam informações de imagens de satélite tem se mostrado uma alternativa viável para o monitoramento regional de culturas agrícolas. São denominados modelos espectrais os métodos que relacionam os índices de vegetação à produtividade das culturas através de equações de regressão (JOHANN, 2012).

Junges e Fontana (2011) citam que, em modelos agrometeorológicos-espectrais, as variáveis agrometeorológicas expressam a influência das condições meteorológicas no crescimento e desenvolvimento das plantas.

Assim, faz-se necessário o uso de metodologias que englobam a informação de dependência espacial, dentre eles há o uso de modelos autorregressivos, que incorporam o fenômeno em escala global, ou seja, partem do pressuposto de que o processo espacial é estacionário. Assim, há um único padrão de associação e adiciona-se ao modelo de regressão (CÂMARA et al., 2002). Desta forma, duas abordagens podem modelar espacialmente: Modelo de Regressão Espacial Autorregressivo Misto (SAR) e o Modelo do Erro Espacial (CAR) (LOPES et al., 2006). Os modelos autorregressivos assumem que a resposta de cada lugar Y_i é uma função não apenas da variável explicativa nesse local, mas também dos valores das respostas dos vizinhos (CRESSIE, 1993).

No entanto, quando o processo é não estacionário, há a necessidade de que os coeficientes de regressão reflitam essa heterogeneidade espacial (CÂMARA et al., 2002). Assim, utilizam-se modelos com efeitos espaciais locais. Muitas técnicas, incluindo a *Geographically Weighted Regression* ou Regressão Ponderada Geograficamente (GWR), são adequadas para processos espaciais não estacionários que buscam modelar explicitamente as diferenças locais (SMITH; GOODCHILD; LONGLEY, 2007).

A GWR foi desenvolvida por Fotheringham, Brunson e Charlton (1997, 2002) para descrever uma família de modelos de regressão em que os coeficientes, parâmetros β podem variar espacialmente. A GWR ajusta um modelo de regressão a cada ponto observado e pondera todas as demais observações como função da distância deste ponto. Assim têm-se regressões diferentes para cada observação, cuja contribuição (valor do parâmetro) de cada variável é explicativa ao modelo diferente em cada ponto.

O objetivo deste trabalho foi apresentar os modelos SAR, CAR e GWR, no intuito de investigar a associação da produtividade da soja e as variáveis agrometeorológicas de balanço hídrico (C_w), evapotranspiração (E_t), radiação global (G_r), temperatura média (T_e) assim como o índice de vegetação do EVI nos anos-safras 2010/2011, 2011/2012 e 2012/2013.

6.4.2. Material e Métodos

6.4.2.1. Aquisição de dados

A área de estudo compreende os 399 municípios, para o Estado do Paraná, região Sul do Brasil, limitada pelas coordenadas $22^{\circ} 29' S$ e $26^{\circ} 43' S$ e $48^{\circ} 2' W$ e $54^{\circ} 38' W$. Foram utilizados dados da produtividade da soja [Prod.] ($t\ ha^{-1}$) para os anos-safras 2010/2011, 2011/2012 e 2012/2013. Os índices de vegetação utilizados foram extraídos de imagens orbitais do sensor MODIS (*Moderate resolution imaging spectroradiometer*) e dados agrometeorológicos provenientes do modelo do ECMWF (*European Center for Medium-Range Weather Forecast*) em escala decenal (**Figura 37**). Mais detalhes ver item 6.2.2.

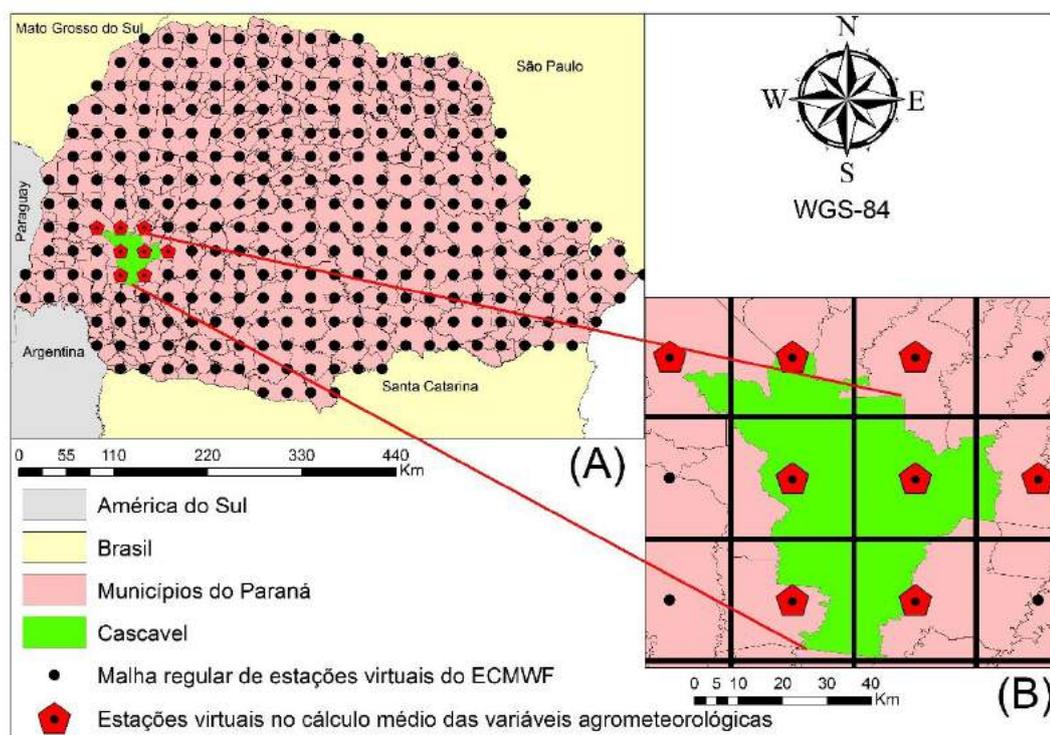


Figura 37 Representação da malha regular das estações virtuais do ECMWF (A) e estações virtuais usadas para obtenção da média municipal de cada variável agrometeorológica (B) para os 399 municípios do Estado do Paraná.

6.4.2.2. Seleção de variáveis

Em modelos de regressão múltipla, é necessário determinar um subconjunto de variáveis explicativas que melhor descrevem a variável resposta, isto é, dentre todas as variáveis explicativas disponíveis, devemos encontrar um subconjunto de variáveis significantes para o modelo. Para isto, utilizamos uma técnica denominada de seleção de variáveis. O critério para a adição ou remoção de variáveis explicativas é geralmente baseado na estatística F, comparando-se modelos com e sem as variáveis em questão. Dentre os vários métodos, pode ser destacado o da regressão passo a passo, conhecida como *stepwise*. Neste método, o algoritmo adiciona e elimina gradativamente novas variáveis ao modelo. E inicia daquela com maior correlação com a variável resposta, desta forma este método consiste na combinação de dois outros métodos o *forward* e *backward* (CHONG; JUN, 2005).

Entre as variáveis estudadas, devido à elevada correlação entre a precipitação (Ra) e o balanço hídrico (Cw), optou-se por selecionar a variável pela regressão linear simples em função da produtividade da soja, com maior coeficiente de determinação (R^2) e menor critério de informação de Akaike (AIC). Também foram escolhidas por regressão linear composta, de acordo com os maiores índices quando foram analisados juntamente com a radiação global (Gr), a temperatura média (Te) e o índice de vegetação (EVI). No entanto, se a variável utilizada for o Cw, não se faz uso dos decêndios referentes à evapotranspiração (Et), pois essa é calculada em função da disponibilidade de água no solo.

As variáveis decendiais (dec) explicativas utilizadas foram para os três anos-safras:

1º dec de Cw de agosto,	2º dec de Cw de agosto,	...	3º dec de Cw de abril,
1º dec de Ra de agosto,	2º dec de Ra de agosto,	...	3º dec de Ra de abril,
1º dec de Et de agosto,	2º dec de Et de agosto,	...	3º dec de Et de abril,
1º dec de Gr de agosto,	2º dec de Gr de agosto,	...	3º dec de Gr de abril,
1º dec de Te de agosto,	2º dec de Te de agosto,	...	3º dec de Te de abril,
1º dec de EVI de agosto,	2º dec de EVI de agosto,	...	3º dec de EVI de abril.

6.4.2.3. Modelos de regressão espacial

Duas características fundamentais a serem consideradas nos modelos que tratam de dados espaciais são a autocorrelação espacial e a heterogeneidade espacial e, para que elas possam ser analisadas, é fundamental o uso de uma matriz de pesos espaciais que indique a posição relativa das observações (VALCARCE; SERRANO, 2000). Ver item **6.2.2.4.**

Formas menos simplistas de se incorporar natureza espacial nas técnicas de regressão incluem termos autorregressivos baseados em proximidade ou adjacência (alguma medida de influência da vizinhança) ou pela adoção de métodos locais (na melhor conceituação espacial do termo) ao invés de globais. Esses métodos serão apresentados nas seções seguintes.

6.4.2.3.1. Modelo de Regressão Espacial Autorregressivo Misto (SAR)

De acordo com Anselin, (2002), considera-se a dependência espacial através da adição ao modelo de regressão de um novo termo na forma de uma relação espacial para a variável dependente (Equação 10).

$$Y = \rho WY + X\beta + \varepsilon, \quad (10)$$

Em que:

Y : vetor da variável dependente $n \times 1$;

ρ : coeficiente espacial autorregressivo;

W : matriz de vizinhança espacial ou matriz de ponderação espacial, $n \times n$;

X : matriz de variáveis explicativas, $n \times p$;

β : coeficientes de regressão, $p \times 1$;

ε : vetor de erros aleatórios com vetor de médias zero e covariância $\sigma^2 I_n$.

A ideia básica é incorporar a autocorrelação espacial como componente do modelo. Para isso, testa a hipótese nula ($H_0: \rho = 0$) para a não existência de autocorrelação versus a hipótese alternativa ($H_1: \rho \neq 0$) existência de autocorrelação a um nível α % de significância. O método de estimação de parâmetros é o de máxima verossimilhança (ML).

6.4.2.3.2. Modelo do Erro Espacial (CAR)

O modelo CAR considera que os efeitos espaciais são ruído ou perturbação, portanto, precisam removidos. Assim, os efeitos da autocorrelação espacial são associados ao termo de erro ε e o modelo é descrito na Equação (11) (LOPES et al., 2006).

$$Y = X\beta + \varepsilon, \quad \varepsilon = \lambda W_\varepsilon + \xi \quad (11)$$

em que:

λ : coeficiente autoregressivo;

W_ε : vetor de erros com efeito espacial, $p \times 1$;

ξ : vetor $n \times 1$ do componente do erro com média zero, variância constante e não correlacionada (ruído).

Neste caso, a hipótese nula ($H_0: \lambda = 0$) para a não existência de autocorrelação é que o termo de erro não é espacialmente correlacionado versus a hipótese alternativa ($H_1: \lambda \neq 0$) com existência de autocorrelação. O método de estimação de parâmetros é o de máxima verossimilhança (ML).

6.4.2.3.3. Modelo de Regressão Ponderada Geograficamente (GWR)

Desenvolvida por Fotheringham, Charlton e Brunsdon (1997, 2002), a técnica *Geographically Weighted Regression* ou Regressão Ponderada Geograficamente (GWR) é usada para descrever uma família de modelos de regressão em que os parâmetros β 's, que podem variar espacialmente. Ela ajusta um modelo de regressão a cada ponto observado; pondera todas as demais observações como função da distância (ou de qualquer medida de vizinhança) deste ponto (FRANCISCO, 2010). Desta forma, têm-se regressões diferentes para cada observação e cada variável explicativa ao modelo é diferente para cada ponto. O modelo é descrito na Equação 12.

$$y(g) = \beta_0(g) + \beta_1(g)x_1 + \beta_2(g)x_2 + \dots + \beta_p(g)x_p + \varepsilon, \quad (12)$$

em que, g é um vetor dos n pontos, no espaço bidimensional, os parâmetros do vetor $\beta(g)$ são específicos para cada observação i de localização $g_i = (u_i, v_i)$ e o termo de erro ε é suposto independente e de comportamento $\varepsilon \sim N(0, \sigma^2 I)$. Assim, tem-se um conjunto de n regressões diferentes, uma para cada ponto g_i do espaço.

Desta forma, temos a estimação dos parâmetros da matriz $\hat{\beta}_g$, para cada linha independente ou para cada vetor $\hat{\beta}_{(g_i)}$ (Equação 13).

$$\hat{\beta}_{(g_i)} = (X^T W(g_i) X)^{-1} X^T W(g_i) y, \quad (14)$$

Em que:

$$W(g_i) = \begin{pmatrix} w_{i1} & 0 & \dots & 0 \\ 0 & w_{i1} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & w_{i1} \end{pmatrix}$$

é uma matriz diagonal de n linhas com as ponderações espaciais de cada observação para o ponto g_i .

w_{ij} representa o peso do ponto g_j na calibração do modelo para o local g_i .

Em relação à escolha da função de proximidade ou ponderações, essa é muito importante, pois determina a influência espacial das observações entre si. Desta forma, pode-se estabelecer uma distância h (largura de bandas) máxima de influência para cada ponto g_i , e estabelecer que $w_{ij} = \begin{cases} 1 & \text{se } d_{ij} < h \\ 0 & \text{se } d_{ij} \geq h \end{cases}$. Portanto, têm-se n regressões clássicas aplicadas a cada ponto g_i e sua amostra de influência (pontos localizados até h unidades de g_i) (FRANCISCO, 2010). Os diferentes esquemas de ponderações são denominados kernels, os quais são uma função sobre cada ponto do espaço, em que se determinam todos os pontos da regressão local que é ponderada pela distância. Os pontos mais próximos do ponto central têm maior peso, podem ser fixos ou adaptáveis à densidade dos dados, conforme ilustra a **Figura 38**.

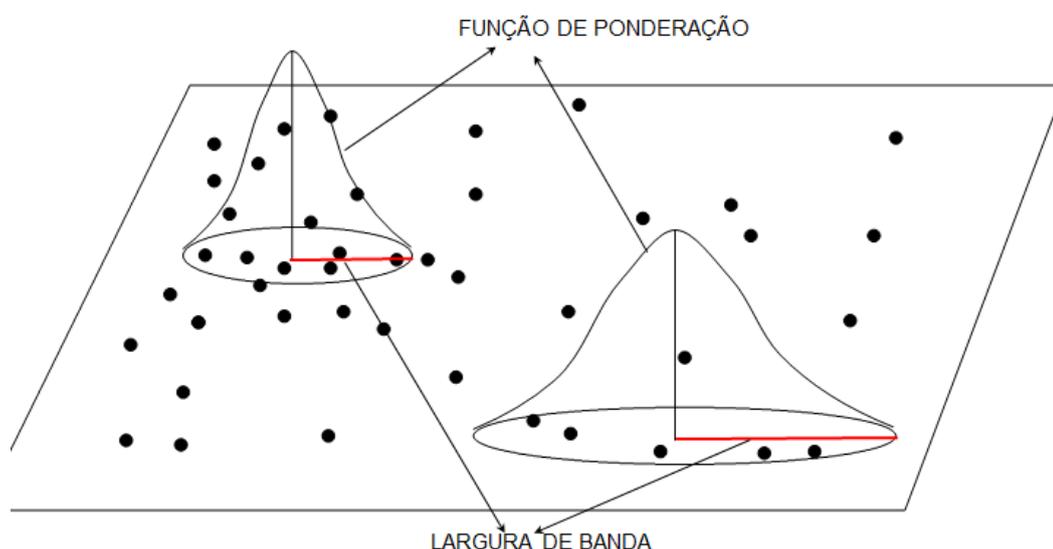


Figura 38 Exemplo de uma função sobre pontos no espaço.

FONTE: Adaptado de: Fotheringham, 2002.

Se os pontos são regularmente espaçados, não há problema na adoção de um *kernel* fixo. Porém, em casos de diferença significativa de densidade de observações, pode-se trabalhar com kernels adaptivos ou esquemas de ponderação adaptáveis, em que o número de vizinhos é fixo (FRANCISCO, 2010). Desta forma, utilizou-se o seguinte *kernel* adaptável bi-quadrado (Equação 14):

$$\begin{aligned} \text{kernel Bi - quadrado: } w_{ij} &= \left(1 - \left(\frac{d_{ij}^2}{h^2}\right)\right)^2 & (a) \\ w_{ij} &= 0 & (b) \end{aligned} \quad (14)$$

Se g_j é um dos k vizinhos mais próximos de g_i e h é a distância do k -ésimo vizinho mais próximo (Equação 14a), ou caso contrário (Equação 14b).

em que:

h : largura de banda; e

d_{ij} : é a distância entre os pontos g_i e g_j .

6.4.2.3.4. Critérios de comparação de modelos

O Critério de Informação de Akaike (AIC) foi utilizado para comparar os resultados a partir dos modelos SAR, CAR e GWR (AKAIKE, 1974). Este critério é utilizado para verificar qual dos modelos apresenta melhor desempenho em termos de ajuste, sendo selecionado aquele que apresenta o menor valor. É definido a seguir (15):

$$AIC = -2\ln(L(\theta)) + 2p, \quad (15)$$

em que:

$\ln(L(\theta))$: Logaritmo neperiano da função de verossimilhança;

p : o número de parâmetros considerados do modelo; e

θ : vetor de parâmetros desconhecidos para cada modelo.

O máximo valor do logaritmo da função verossimilhança (MLL) (MCBRATNEY & WEBSTER, 1986) e o Critério de Informação Bayesiano (BIC) (SCHWARZ, 1978) também são utilizados e definidos pela Equação 16:

$$BIC = -2 \ln(L(\theta)) + (p + 1)\ln(n) \quad (16)$$

em que:

n : Número de amostras.

6.4.3. Resultados e Discussões

6.4.3.1. Seleção de variáveis

Primeiro, relacionam-se as variáveis com maior coeficiente de determinação R^2 ajustado e AIC (Tabela 9) para os três anos-safras estudados. Nos três anos-safras, foi possível verificar que os decêndios de Cw têm R^2 ajustado maior e AIC menor em relação à Ra em função da produtividade da soja. Ao se analisar juntamente com a Gr, o Cw também tem melhores índices em relação à Ra. Já Cw + Te teve melhores índices para 2011/2012 e 2012/2013, enquanto para o ano-safra 2010/2011, melhores índices ocorreram com Ra + Te. Em análise conjunta com o EVI, o ano-safra 2010/2011 registrou os melhores resultados com o Cw e os outros anos estudados com a Ra. Em resumo, para os três anos-safras

estudados, o coeficiente de determinação e AIC foram melhores para o Cw. Logo, para a seleção de variáveis, foram utilizadas as variáveis decendiais do Cw, Gr, Te e EVI.

Tabela 9 Variáveis altamente correlacionadas com a produtividade da soja

	2010/2011		2011/2012		2012/2013	
	R ² Ajustado	AIC	R ² Ajustado	AIC	R ² Ajustado	AIC
Cw	0,445	-102,18	0,681	323,96	0,5168	165,197
Ra	0,430	-92,355	0,673	332,82	0,5168	167,146
Cw + Gr	0,573	-142,94	0,749	291,67	0,6458	106,921
Ra + Gr	0,550	-124,17	0,744	298,97	0,6432	107,611
Cw + Te	0,568	-139,12	0,763	270,79	0,6164	134,243
Ra + Te	0,569	-139,53	0,750	290,11	0,5953	155,942
Cw + EVI	0,594	-161,55	0,808	195,53	0,6249	124,004
Ra + EVI	0,591	-158,66	0,809	194,00	0,6348	116,097

R²: Coeficiente de determinação; AIC: Critério de Akaike. Melhores índices em negrito.

De acordo com a utilização dos decêndios das variáveis selecionadas, pelo método de *stepwise* (Tabela 10), foram obtidos os mais significantes resultados com auxílio da regressão linear simples e múltipla e o método dos mínimos quadrados. Destacam-se entre os decêndios escolhidos, o 2º novembro e 1º janeiro de Cw, 1º, 2º de novembro, 1º de dezembro e 3º janeiro de EVI, 2º dezembro e 1º janeiro de Gr, além de 3º outubro e 1º janeiro de Te que englobam fases da semeadura, florescimento e enchimento de grãos nas diversas regiões do Estado e podem afetar diretamente a produtividade da soja.

Tabela 10 Variáveis selecionadas por *stepwise* para o ano-safra 2010/2011

Variáveis	Estimativa	Variáveis	Estimativa	Variáveis	Estimativa
Intercepto	0,27960 ^{NS} (1,57600)	X ₉ = 1ºNov EVI	-0,00018 ^{***} (0,00004)	X ₁₇ = 3ºOut Te	-0,28430 ^{**} (0,08834)
X ₁ = 3ºJan EVI	0,00009 ^{***} (0,00002)	X ₁₀ = 1ºFev Gr	-0,08740 ^{***} (0,01927)	X ₁₈ = 2ºSet Gr	0,20970 ^{***} (0,05370)
X ₂ = 2ºNov Cw	-0,00618 ^{**} (0,00224)	X ₁₁ = 3ºSet Gr	-0,29900 ^{***} (0,07789)	X ₁₉ = 3ºAgo Cw	0,06949 ^{***} (0,01044)
X ₃ = 1ºJan Cw	0,01036 ^{***} (0,00187)	X ₁₂ = 2ºMar Cw	-0,00820 ^{***} (0,00227)	X ₂₀ = 1ºAgo Te	-0,30490 ^{***} (0,08838)
X ₄ = 1ºAgo Cw	0,00424 [*] (0,00212)	X ₁₃ = 2ºFev EVI	-0,00005 [*] (0,00002)	X ₂₁ = 1ºSet Cw	-0,01182 [*] (0,00552)
X ₅ = 1ºDez EVI	0,00004 [*] (0,00002)	X ₁₄ = 3ºAgo EVI	-0,00016 ^{**} (0,00005)	X ₂₂ = 1ºAbr Gr	0,10660 ^{***} (0,03178)
X ₆ = 2ºAbr Cw	-0,00412 ^{**} (0,00142)	X ₁₅ = 2ºFev Cw	-0,00343 [*] (0,00151)	X ₂₃ = 2ºDez Gr	0,14450 ^{**} (0,04609)
X ₇ = 3ºFev Cw	-0,00613 ^{**} (0,00198)	X ₁₆ = 3ºSet Te	0,96270 ^{***} (0,14190)	X ₂₄ = 1ºJan Te	-0,19600 [*] (0,08640)
X ₈ = 2ºAgo EVI	0,00016 ^{***} (0,00004)				

(***): 0,001; (**): 0,01; (*): 0,05 níveis de significância; Entre parêntesis os erros padrões.

Entre as variáveis, o Cw é teve mais decêndios selecionados para o ano-safra 2010/2011 em relação às outras. No entanto, também foram selecionadas variáveis que não continham a cultura, como decêndios de agosto e setembro anteriores à semeadura e decêndios de março e abril em que a soja está no estágio fenológico de senescência.

Em relação ao ano-safra 2011/2012, das variáveis selecionadas (Tabela 11), faz-se destaque para a radiação global que teve onze decêndios significativos. No entanto, desses, sete decêndios identificados englobam as fases de início de semeadura até a senescência, e o restante englobando fases fenológicas posteriores. Para as outras vinte e nove variáveis, a seleção também englobou a maioria dos decêndios contidos das fases iniciais até as fases finais da cultura da soja.

Tabela 11 Variáveis selecionadas por *stepwise* para o ano-safra 2011/2012

Variáveis	Estimativa	Variáveis	Estimativa	Variáveis	Estimativa
Intercepto	5,41700* (2,42100)	$X_{10} = 2^{\circ}\text{Fev Gr}$	-0,31010*** (0,05773)	$X_{19} = 2^{\circ}\text{Mar Cw}$	0,00946* (0,00401)
$X_1 = 2^{\circ}\text{Jan Te}$	0,67970*** (0,16150)	$X_{11} = 2^{\circ}\text{Fev Cw}$	-0,01301*** (0,00288)	$X_{20} = 3^{\circ}\text{Set Gr}$	0,18270* (0,08568)
$X_2 = 1^{\circ}\text{Jan EVI}$	0,00023*** (0,00004)	$X_{12} = 3^{\circ}\text{Nov Gr}$	0,11970* (0,04867)	$X_{21} = 2^{\circ}\text{Abr Gr}$	-0,56380*** (0,08102)
$X_3 = 1^{\circ}\text{Fev EVI}$	0,00022*** (0,00005)	$X_{13} = 2^{\circ}\text{Mar Gr}$	-0,26400*** (0,07464)	$X_{22} = 1^{\circ}\text{Ago Te}$	-0,57540*** (0,11230)
$X_4 = 2^{\circ}\text{Nov EVI}$	0,04756* (0,01886)	$X_{13} = 3^{\circ}\text{Abr Gr}$	0,39490*** (0,07084)	$X_{23} = 1^{\circ}\text{Set Cw}$	0,00429** (0,00159)
$X_5 = 3^{\circ}\text{Jan Gr}$	0,35020*** (0,05454)	$X_{14} = 3^{\circ}\text{Mar Gr}$	-0,34940*** (0,09305)	$X_{24} = 2^{\circ}\text{Dez Cw}$	0,00842** (0,00311)
$X_6 = 3^{\circ}\text{Set EVI}$	-0,00023*** (0,00007)	$X_{15} = 3^{\circ}\text{Out Cw}$	0,00802*** (0,00181)	$X_{25} = 1^{\circ}\text{Set Gr}$	0,25420*** (0,06291)
$X_7 = 2^{\circ}\text{Mar Te}$	0,38410* (0,14930)	$X_{16} = 3^{\circ}\text{Dez Gr}$	0,15990** (0,05500)	$X_{26} = 2^{\circ}\text{Dez Te}$	0,29250* (0,11640)
$X_8 = 1^{\circ}\text{Mar EVI}$	0,00011*** (0,00003)	$X_{17} = 2^{\circ}\text{Abr Cw}$	-0,01298*** (0,00265)	$X_{27} = 2^{\circ}\text{Dez Gr}$	0,14610** (0,05615)
$X_9 = 1^{\circ}\text{Fev Te}$	-0,91180*** (0,14560)	$X_{18} = 3^{\circ}\text{Out Gr}$	-0,29590*** (0,06813)	$X_{28} = 1^{\circ}\text{Dez EVI}$	0,04760* (0,01886)
				$X_{29} = 3^{\circ}\text{Nov EVI}$	-0,09507* (0,03773)

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores entre parêntesis apresentam os erros padrões.

Para a seleção do ano-safra 2012/2013, foram obtidos trinta decêndios com variáveis significativas (Tabela 12). Assim como no ano-safra anterior, ressalta-se a variável Gr, que dos vinte e sete decêndios, treze deles foram significativos pela seleção de variáveis. Isso mostra a importância dessa variável durante o ciclo da soja. Outra variável com grande importância é o Cw, que para o ano-safra citado teve apenas três decêndios significativos

(3º decêndio de setembro, 3º de março e 1º de agosto), ou seja, a variável não afetou a produtividade da soja.

Tabela 12 Variáveis selecionadas por *stepwise* para o ano-safra 2012/2013

Variáveis	Estimativa	Variáveis	Estimativa	Variáveis	Estimativa
Intercepto	-2,59000* (3,20500)	$X_{11} = 2^{\circ}\text{Dez EVI}$	0,00008* (0,00003)	$X_{22} = 2^{\circ}\text{Abr EVI}$	-0,00013** (0,00004)
$X_1 = 2^{\circ}\text{Out EVI}$	-0,00096** (0,00017)	$X_{12} = 3^{\circ}\text{Jan EVI}$	0,00009* (0,00004)	$X_{23} = 2^{\circ}\text{Dez Te}$	0,59590** (0,19160)
$X_2 = 3^{\circ}\text{Mar Gr}$	-0,16890** (0,05300)	$X_{13} = 2^{\circ}\text{Fev Gr}$	0,22200** (0,05842)	$X_{24} = 3^{\circ}\text{Abr Cw}$	-0,05351** (0,01260)
$X_3 = 3^{\circ}\text{Set Cw}$	0,00973** (0,00266)	$X_{14} = 1^{\circ}\text{Jan Gr}$	0,16450** (0,05181)	$X_{25} = 3^{\circ}\text{Ago Te}$	0,60080** (0,14440)
$X_4 = 1^{\circ}\text{Dez EVI}$	0,00010* (0,00005)	$X_{15} = 1^{\circ}\text{Mar Gr}$	-0,23560** (0,08336)	$X_{26} = 1^{\circ}\text{Ago Cw}$	0,05363** (0,01582)
$X_5 = 1^{\circ}\text{Out Gr}$	-0,35260** (0,06558)	$X_{16} = 1^{\circ}\text{Out Te}$	0,52120** (0,15310)	$X_{27} = 1^{\circ}\text{Nov Gr}$	0,17970** (0,04843)
$X_6 = 3^{\circ}\text{Out EVI}$	0,00065** (0,00016)	$X_{17} = 1^{\circ}\text{Set Te}$	-0,23920* (0,11540)	$X_{28} = 1^{\circ}\text{Set Gr}$	0,28230** (0,10360)
$X_7 = 3^{\circ}\text{Fev Gr}$	0,26220** (0,08626)	$X_{18} = 2^{\circ}\text{Out Gr}$	0,21600** (0,05874)	$X_{29} = 2^{\circ}\text{Ago Gr}$	0,23060** (0,08708)
$X_8 = 2^{\circ}\text{Nov Gr}$	-0,58820** (0,07146)	$X_{19} = 3^{\circ}\text{Dez Gr}$	-0,18840** (0,05683)	$X_{30} = 1^{\circ}\text{Dez Te}$	0,36450** (0,12750)
$X_9 = 2^{\circ}\text{Abr Gr}$	0,46000** (0,10730)	$X_{20} = 3^{\circ}\text{Mar Cw}$	0,01271** (0,00317)		
$X_{10} = 2^{\circ}\text{Set Te}$	-0,83170** (0,16840)	$X_{21} = 1^{\circ}\text{Jan Te}$	-1,10300** (0,18030)		

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores entre parêntesis apresentam os erros padrões.

Em análise para três anos-safras, das variáveis significativas para a variável EVI, apenas o decêndio 1º de dezembro foi semelhante. Para análise entre 2010/2011 e 2011/2012 e entre 2011/2012 e 2012/2013, o mesmo decêndio de 1º de dezembro em comum, e para 2010/2011 e 2012/2013 verificou-se o 3º decêndio de janeiro. Para a Gr, quando foram analisados os três anos-safras, não houve qualquer decêndio selecionado em comum. Entre os anos-safras 2010/2011 e 2011/2012, foram obtidos os decêndios de 3º de setembro e 2º de dezembro em comum. Para 2010/2011 e 2012/2013, nenhum decêndio e entre 2011/2012 e 2012/2013, foram obtidos os decêndios de 2º de fevereiro, 3º de março, 3º de dezembro, 2º de abril e 1º de setembro. Para a variável Cw, para os três anos-safras, observou-se que nenhum decêndio foi em comum, além de 2012/2013 em relação aos outros anos-safras. Entre 2010/2011 e 2011/2012, foram observados os decêndios 2º de abril, 2º de março, 2º de fevereiro e 1º de setembro. E para a variável Te, nenhum decêndio selecionado em comum para os três anos-safras. Para análise entre 2010/2011 e

2011/2012, apenas o 1º decêndio de agosto, entre 2010/2011 e 2012/2013 somente o 1º decêndio de janeiro e entre 2011/2012 e 2012/2013 em comum o decêndio de 2º de dezembro.

6.4.3.2. Modelos ano-safra 2010/2011

A partir da seleção de variáveis para o ano-safra 2010/2011, e considerando a dependência espacial, foram ajustados os modelos SAR e CAR (Tabela 13). Identificou-se que para o modelo SAR (intercepto significativo ao nível de 5%) foi o que melhor explicou a produtividade da soja foram com sete decêndios, e destaque para o 3º decêndio de janeiro, 1º de dezembro e 1º de novembro de EVI, e 3º decêndio de setembro de Te, contidos em fases de desenvolvimento vegetativas da cultura da soja.

Tabela 13 Resumo do ajuste dos modelos SAR e CAR para o ano-safra 2010/2011

	SAR	CAR		SAR	CAR
Intercepto	3,887* (2,246)	-1,434 ^{NS} (1,653)	2º Fev EVI	-0,00003 ^{NS} (0,000026)	-0,00006*** (0,000021)
3º Jan EVI	0,00008* (0,000026)	0,00009*** (0,000023)	3º Ago EVI	-0,00016* (0,000064)	-0,00013* (0,000054)
2º Nov Cw	0,00628 ^{NS} (0,008)	-0,00600* (0,0023)	2º Fev Cw	0,00053 ^{NS} (0,0031)	-0,00270 ^{NS} (0,0017)
1º Jan Cw	0,00487 ^{NS} (0,0036)	0,01100*** (0,0019)	3º Set Te	0,86403*** (0,32)	0,99500*** (0,16)
1º Ago Cw	0,01372 ^{NS} (0,0075)	0,00450 ^{NS} (0,0024)	3º Out Te	-0,45483 ^{NS} (0,253)	-0,37860*** (0,097)
1º Dez EVI	0,00004* (0,000021)	0,00004* (0,000017)	2º Set Gr	0,24900 ^{NS} (0,144)	0,17022*** (0,058)
2º Abr Cw	0,00090*** (0,0028)	-0,00490*** (0,0015)	3º Ago Cw	0,04009 ^{NS} (0,024)	0,06100*** (0,012)
3º Fev Cw	-0,00176 (0,0034)	-0,00510* (0,0022)	1º Ago Te	-0,33827 ^{NS} (0,203)	-0,34960*** (0,099)
2º Ago EVI	0,00015*** (0,00005)	0,00014*** (0,000039)	1º Set Cw	-0,02881 ^{NS} (0,014)	-0,01500* (0,0061)
1º Nov EVI	-0,00012*** (0,000045)	-0,00015*** (0,000041)	1º Abr Gr	0,14210 ^{NS} (0,095)	0,11990*** (0,037)
1º Fev Gr	-0,04371 ^{NS} (0,049)	-0,07200*** (0,021)	2º Dez Gr	0,03882 ^{NS} (0,088)	0,09770* (0,046)
3º Set Gr	-0,04274 ^{NS} (0,17)	-0,22800*** (0,084)	1º Jan Te	0,03463 ^{NS} (0,156)	-0,12400 ^{NS} (0,089)
2º Mar Cw	-0,00087 ^{NS} (0,0041)	-0,00590* (0,0024)			

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores entre parêntesis apresentam os erros padrões. Em negrito estão os decêndios significativos.

Considerando o modelo CAR (intercepto não significativo), apenas três decêndios não foram acondicionados como significativos (1º decêndio de agosto e 2º de fevereiro de Cw, 1º de janeiro de Te. No entanto, dois desses decêndios estão contidos nas fases vegetativas da soja.

Para as análises realizadas para o modelo GWR (Tabela 14), estão incluídos os valores dos parâmetros globais estimados e dos níveis locais do modelo.

Tabela 14 Ajuste do modelo GWR para o ano-safra 2010/2011

	Mínimo	1º Quartil	Mediana	3º Quartil	Máximo	Global
Intercepto	-0,00007	0,00039	0,00085	0,00189	0,04025	-0,0002*
3º Jan EVI	0,00005	0,00007	0,00008	0,00009	0,00012	0,0001
2º Nov Cw	-0,00972	-0,00819	-0,00705	-0,00643	-0,00322	-0,0060
1º Jan Cw	0,00609	0,00858	0,01077	0,01221	0,01356	0,0111
1º Ago Cw	-0,00162	0,00042	0,00163	0,00242	0,00456	0,0033
1º Dez EVI	0,00001	0,00002	0,00004	0,00005	0,00006	0,0000
2º Abr Cw	-0,00818	-0,00710	-0,00610	-0,00497	-0,00398	-0,0058
3º Fev Cw	-0,01339	-0,01177	-0,00916	-0,00568	-0,00379	-0,0064
2º Ago EVI	0,00010	0,00013	0,00016	0,00017	0,00019	0,0002
1º Nov EVI	-0,00024	-0,00023	-0,00019	-0,00015	-0,00012	-0,0002
1º Fev Gr	-0,12490	-0,09552	-0,06622	-0,04738	-0,03885	-0,0756***
3º Set Gr	-0,29900	-0,26370	-0,24240	-0,21640	-0,11430	-0,2371***
2º Mar Cw	-0,00852	-0,00730	-0,00527	-0,00421	-0,00249	-0,0067
2º Fev EVI	-0,00008	-0,00006	-0,00003	-0,00001	0,00001	-0,0001
3º Ago EVI	-0,00024	-0,00018	-0,00014	-0,00006	-0,00003	-0,0001
2º Fev Cw	-0,00466	-0,00275	-0,00167	0,00027	0,00280	-0,0031
3º Set Te	0,69710	0,86080	0,88240	1,07300	1,23400	1,0215***
3º Out Te	-0,54690	-0,43160	-0,37970	-0,33160	-0,20020	-0,3589***
2º Set Gr	0,03685	0,09031	0,11690	0,14280	0,20530	0,1348***
3º Ago Cw	0,02227	0,05136	0,06827	0,08512	0,09829	0,0646*
1º Ago Te	-0,40110	-0,37780	-0,31380	-0,22800	-0,14520	-0,3591***
1º Set Cw	-0,01656	-0,01340	-0,01183	-0,00583	0,00003	-0,0127
1º Abr Gr	0,08472	0,09588	0,10420	0,11780	0,14960	0,1068
2º Dez Gr	0,02817	0,08780	0,11100	0,17190	0,23130	0,0956***
1º Jan Te	-0,20820	-0,16320	-0,13640	-0,05630	0,01701	-0,1538***

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores em negrito para os decêndios significativos.

Verifica-se dispersão na variação local para oito decêndios, ou seja, a grande amplitude existente entre o valor mínimo e máximo dos parâmetros ajustados. Isto mostra a grande variabilidade das variáveis explicativas e a dificuldade para se modelar a produtividade da soja no Estado do Paraná. Em especial, ressaltam-se os decêndios de 3º de setembro, 3º de outubro e 1º de janeiro de Te além de 2º de setembro e 2º de dezembro de Gr que são períodos em que a cultura da soja está sendo implantada ou em fase de desenvolvimento.

O maior MLL foi utilizado para o critério de seleção do modelo, e os menores AIC e BIC para o melhor ajuste (Tabela 15). Por conseguinte, verifica-se que o modelo GWR tem o melhor ajuste dos parâmetros. Outra forma de se avaliar a qualidade do ajuste do modelo foi através do coeficiente de determinação ajustado. Para este ano-safra 2010/2011, verificou que o modelo GWR foi o que obteve maior R^2 ajustado de 0,77 em relação aos outros modelos, isto é, indica o quanto o modelo foi capaz de explicar os dados

Tabela 15 Critérios de seleção do melhor modelo

Estatística	SAR	CAR	GWR
MLL	163,81	147,42	236,959
Lag coeff. (Rho)	0,23365	-	-
Lag coeff. (Lambda)	-	0,28718	-
AIC	-225,62	-240,85	-362,993
BIC	-27,14	-135,77	-204,62
R^2 ajustado	0,65	0,62	0,77
I Moran Global (resíduos)	-0,0004 (0,453)	0,0042 (0,390)	0,0906 (0,03)

*P-valor entre parenteses.

Foi também possível constatar que o índice global de Moran para esses resíduos foi próximo de zero para os três modelos ajustados, portanto, eliminou a autocorrelação espacial e fez com que a inclinação da reta fosse muito pequena. Portanto, para os três modelos em estudo, foram gerados resíduos distribuídos aleatoriamente por todo o Estado do Paraná, como pode ser observado na Figura 39, que representa o mapa dos resíduos padronizados, gerado pelo método do desvio-padrão, resultante da aplicação do modelo SAR, CAR e GWR.

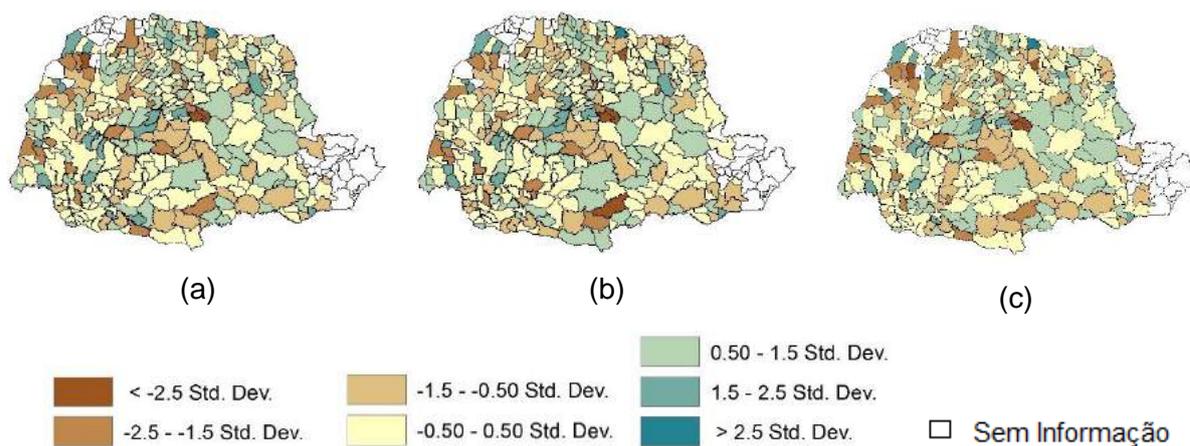


Figura 39 Mapa dos resíduos padronizados para os modelos SAR (a), CAR (b) e GWR (c).

6.4.3.3. Modelos ano-safra 2011/2012

A partir da seleção de variáveis para o ano-safra 2011/2012, e considerando a dependência espacial, ajustaram-se os modelos SAR e CAR (Tabela 16).

Tabela 16 Resumo do ajuste dos modelos SAR e CAR para o ano-safra 2011/2012

	SAR	CAR		SAR	CAR
Intercepto	0,48117 ^{NS} (2,77)	4,9328* (1,95)	3º Out Cw	0,00122 ^{NS} (0,00398)	0,00840*** (0,0015)
2º Jan Te	0,20500 ^{NS} (0,244)	0,7313*** (0,137)	3º Dez Gr	0,11700 ^{NS} (0,123)	0,16590*** (0,044)
1º Jan EVI	0,00026*** (0,00005)	0,00024*** (0,000036)	2º Abr Cw	-0,00927 ^{NS} (0,0052)	-0,01330*** (0,00222)
1º Fev EVI	0,00017*** (0,000052)	0,00024*** (0,000041)	3º Out Gr	-0,45236*** (0,1313)	-0,26790*** (0,0555)
2º Nov EVI	0,04500* (0,0174)	0,05370*** (0,018)	2º Mar Cw	0,00656 ^{NS} (0,0085)	0,00940*** (0,0033)
3º Jan Gr	0,42100*** (0,123)	0,34950*** (0,0437)	3º Set Gr	0,23310 ^{NS} (0,165)	0,19160*** (0,0723)
3º Set EVI	-0,00017* (0,000085)	-0,0003*** (0,000058)	2º Abr Gr	-0,80776*** (0,212)	-0,5458*** (0,065)
2º Mar Te	0,1230 ^{NS} (0,285)	0,3932*** (0,12265)	1º Ago Te	-0,22354 ^{NS} (0,222)	-0,5856*** (0,093)
1º Mar EVI	0,00011*** (0,000032)	0,00011*** (0,000026)	1º Set Cw	0,00708 ^{NS} (0,0039)	0,0044*** (0,0013)
1º Fev Te	-0,2890 ^{NS} (0,268)	-0,9730*** (0,1173)	2º Dez Cw	0,0041 ^{NS} (0,0067)	0,0091*** (0,0025)
2º Fev Gr	-0,3325* (0,139)	-0,2972*** (0,046494)	1º Set Gr	0,20322 ^{NS} (0,192)	0,2411*** (0,0498)

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores entre parêntesis apresentam os erros padrões. Valores em negrito referem-se aos decêndios significativos de cada modelo.

Continua...

Continuação da Tabela 16...

	SAR	CAR		SAR	CAR
2º Fev Cw	-0,0115 ^{NS} (0,0063)	-0,0130*** (0,00234)	2º Dez Te	0,16202 ^{NS} (0,194)	0,3032*** (0,096)
3º Nov Gr	-0,1230 ^{NS} (0,123)	0,1324*** (0,04)	2º Dez Gr	0,17732 ^{NS} (0,151)	0,1384*** (0,044)
2º Mar Gr	0,1640 ^{NS} (0,147)	-0,2935*** (0,062)	1º Dez EVI	0,04495*** (0,017)	0,0537*** (0,0178)
3º Abr Gr	0,4120*** (0,143)	0,4031*** (0,058)	3º Nov EVI	-0,089817* (0,0349)	-0,1074*** (0,0357)
3º Mar Gr	-0,0410 ^{NS} (0,234)	-0,3648*** (0,075)			

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores entre parêntesis apresentam os erros padrões. Valores em negrito referem-se aos decêndios significativos de cada modelo.

Verifica-se que o modelo SAR não foi significativo ao contrário do modelo CAR (significativo ao nível de 5%). Ressaltam-se os decêndios 3º de janeiro, 2º de fevereiro, 3º de outubro, 3º de setembro, 2º de abril e 1º de setembro de Gr para os dois modelos (SAR e CAR) como decêndios com maiores valores dos coeficientes estimados, indicando como a radiação global contribuiu para o cálculo estimação da produtividade para este ano-safra.

De acordo com as análises realizadas para o modelo GWR (Tabela 17), dezesseis decêndios foram obtidos com uma grande amplitude local. Desses, destacam-se 2º janeiro, 1º fevereiro e 2º dezembro de Te, 3º janeiro, 2º fevereiro, 3º novembro, 3º outubro, 3º setembro e 2º dezembro de Gr, mostrando que essas duas variáveis têm grande oscilação no Estado e são essenciais para estimar a produtividade da soja.

Tabela 17 Ajuste do modelo GWR para o ano-safra 2011/2012

	Mínimo	1º Quartil	Mediana	3º Quartil	Máximo	Global
Intercepto	0,0026	0,0109	0,0473	0,0991	0,2533	0,0428***
2º Jan Te	0,6087	0,7105	0,7955	0,8346	0,8532	0,7629***
1º Jan EVI	0,0002	0,0002	0,0003	0,0003	0,0003	0,0002
1º Fev EVI	0,0002	0,0002	0,0002	0,0002	0,0003	0,0002
2º Nov EVI	0,0292	0,0387	0,0449	0,0511	0,0585	0,0445***
3º Jan Gr	0,2949	0,3078	0,3436	0,3830	0,4179	0,3647***
3º Set EVI	-0,0003	-0,0003	-0,0003	-0,0002	-0,0002	-0,0002
2º Mar Te	0,1042	0,1509	0,2394	0,2891	0,3493	0,2764***
1º Mar EVI	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores em negrito decêndios significativos.

Continua...

Continuação da Tabela 17...

	Mínimo	1º Quartil	Mediana	3º Quartil	Máximo	Global
1º Fev Te	-0,8498	-0,8304	-0,7970	-0,7686	-0,7243	-0,8415***
2º Fev Gr	-0,3368	-0,3144	-0,2907	-0,2640	-0,2175	-0,2721***
2º Fev Cw	-0,0150	-0,0136	-0,0110	-0,0084	-0,0055	-0,0102
3º Nov Gr	0,0947	0,1031	0,1231	0,1806	0,2199	0,1346***
2º Mar Gr	-0,3404	-0,3076	-0,2812	-0,2752	-0,2652	-0,3017***
3º Abr Gr	0,2464	0,2878	0,3779	0,4136	0,4352	0,3639***
3º Mar Gr	-0,3387	-0,3253	-0,3086	-0,2856	-0,2436	-0,3098***
3º Out Cw	0,0065	0,0072	0,0076	0,0079	0,0082	0,0074
3º Dez Gr	0,0746	0,1420	0,1718	0,1885	0,1987	0,1518*
2º Abr Cw	-0,0159	-0,0151	-0,0143	-0,0134	-0,0109	-0,0145
3º Out Gr	-0,3047	-0,2681	-0,2218	-0,1985	-0,1479	-0,2321***
2º Mar Cw	0,0088	0,0121	0,0128	0,0138	0,0155	0,0134
3º Set Gr	0,1328	0,2006	0,2242	0,2416	0,2593	0,2258***
2º Abr Gr	-0,6325	-0,6053	-0,5809	-0,5409	-0,3959	-0,5332***
1º Ago Te	-0,8130	-0,7183	-0,5672	-0,5233	-0,5140	-0,6174***
1º Set Cw	0,0034	0,0046	0,0053	0,0068	0,0078	0,0054
2º Dez Cw	0,0076	0,0092	0,0109	0,0122	0,0133	0,0111*
1º Set Gr	0,1674	0,1947	0,2407	0,3401	0,3895	0,2378***
2º Dez Te	0,1748	0,2683	0,2904	0,3458	0,4125	0,3090***
2º Dez Gr	0,1025	0,1520	0,1880	0,2219	0,2586	0,1815***
1º Dez EVI	0,0292	0,0387	0,0449	0,0510	0,0585	0,0445*
3º Nov EVI	-0,1170	-0,1020	-0,0897	-0,0773	-0,0582	-0,0889*

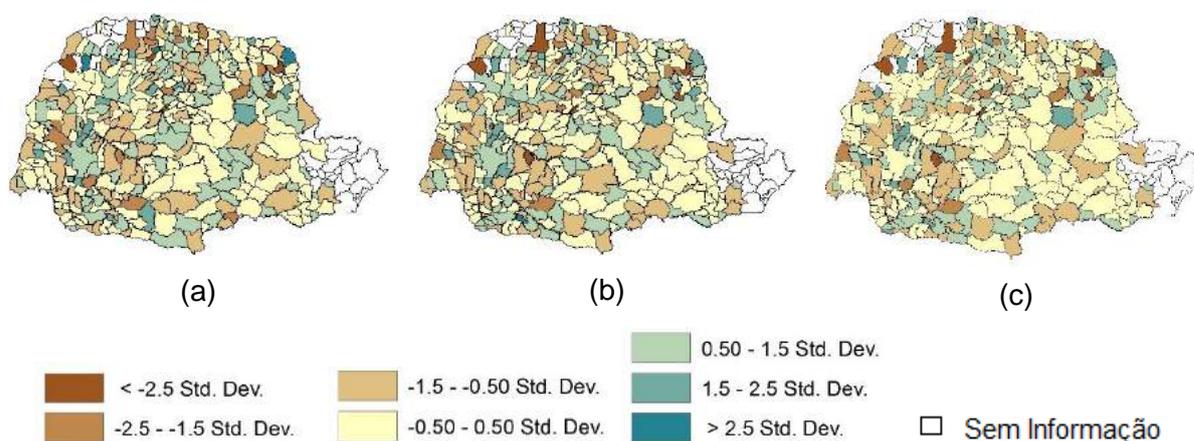
(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores em negrito decêndios significativos.

Para o critério de seleção do modelo do ano-safra 2011/2012 (Tabela 18), verifica-se o modelo GWR com melhor ajuste dos parâmetros, com maior MLL e menores AIC e BIC. Em relação ao R² ajustado, novamente o modelo GWR foi o que melhor explicou os dados em relação aos modelos anteriores. No entanto, os valores para os três modelos foram elevados. Isso mostra a grande proporção que a produtividade da soja foi explicada pelas variáveis. Também constata-se que o índice global de Moran para esses resíduos foi próximo a zero para os três modelos ajustados, portanto, a autocorrelação espacial foi eliminada.

Tabela 18 Critérios de seleção do melhor modelo

	SAR	CAR	GWR
MLL	27,69	3,91	40,4958
Lag coeff. (Rho)	-0,30986	-	-
Lag coeff. (Lambda)	-	-0,28996	-
AIC	70,62	58,19	25,022
BIC	315,62	186,52	80,20
R ² ajustado	0,87	0,85	0,93
I Moran Global (resíduos)	-0,0199 (0,691)	0,0042 (0,39)	-0,0606 (0,97)

De acordo com a ausência da autocorrelação espacial, gerou-se o mapa dos resíduos padronizados (**Figura 40**) para os modelos, e verificou-se que eles foram distribuídos de maneira aleatória.

**Figura 40** Mapa dos resíduos padronizados para os modelos SAR (a), CAR (b) e GWR (c).

6.4.3.4. Modelos ano-safra 2012/2013

A partir da seleção de variáveis para o ano-safra 2012/2013, ajustaram-se os modelos SAR e CAR (Tabela 19). Identificou-se que, para os dois modelos SAR e CAR, o valor estimado para o intercepto não foi significativo. E para o modelo SAR, as variáveis que melhor explicaram a produtividade foram com onze decêndios significativos, com destaque para os decêndios das variáveis Gr e Te em fases vegetativas da cultura da soja e com elevados valores estimados. Considerando o modelo CAR, apenas o decêndio de 1º de dezembro de Te não foi significativo.

Tabela 19 Resumo do ajuste dos modelos SAR e CAR para o ano-safra 2012/2013

	SAR	CAR		SAR	CAR
Intercepto	-6,5255 ^{NS} (4,8111)	-2,7977 ^{NS} (3,0424)	1º Out Te	0,1531 ^{NS} (0,283)	0,7553*** (0,1325)
2º Out EVI	-0,00085*** (0,00019)	-0,0011*** (0,00017)	1º Set Te	0,36168 ^{NS} (0,221)	-0,2238* (0,1095)
3º Mar Gr	-0,01724 ^{NS} (0,131)	-0,1367*** (0,0511)	2º Out Gr	0,1513 ^{NS} (0,117)	0,2230*** (0,0524)
3º Set Cw	0,01085* (0,0052)	0,0088*** (0,0027)	3º Dez Gr	-0,25345 ^{NS} (0,145)	-0,2170*** (0,0576)
1º Dez EVI	0,00012* (0,00005)	0,0007*** (0,00004)	3º Mar Cw	0,01070 ^{NS} (0,0056)	0,0114*** (0,0028)
1º Out Gr	-0,1094 ^{NS} (0,1653)	-0,4254*** (0,0627)	1º Jan Te	-0,47636 ^{NS} (0,340)	-1,0481*** (0,1669)
3º Out EVI	0,00059*** (0,00018)	0,0008*** (0,00015)	2º Abr EVI	-0,00022*** (0,00005)	-0,0002*** (0,00004)
3º Fev Gr	-0,0391 ^{NS} (0,184)	0,1274*** (0,0805)	2º Dez Te	0,53551 ^{NS} (0,394)	0,8015*** (0,1816)
2º Nov Gr	-0,4724*** (0,147)	-0,5372*** (0,0694)	3º Abr Cw	-0,0177 ^{NS} (0,025)	-0,0672*** (0,0112)
2º Abr Gr	0,3409 ^{NS} (0,210)	0,3648*** (0,1028)	3º Ago Te	0,50492* (0,222)	0,5672*** (0,1264)
2º Set Te	-1,0321*** (0,320)	-0,9124*** (0,1652)	1º Ago Cw	0,0360 ^{NS} (0,027)	0,0632*** (0,0153)
2º Dez EVI	0,00008* (0,00004)	0,0001*** (0,00003)	1º Nov Gr	0,26855*** (0,094)	0,1541*** (0,0470)
3º Jan EVI	0,00008* (0,00003)	0,0001*** (0,00003)	1º Set Gr	0,26258 ^{NS} (0,207)	0,4093*** (0,0862)
2º Fev Gr	0,13569 ^{NS} (0,119)	0,1709*** (0,0547)	2º Ago Gr	0,27375 ^{NS} (0,192)	0,2213*** (0,0851)
1º Jan Gr	0,090 ^{NS} (0,122)	0,2022*** (0,0501)	1º Dez Te	0,23768 ^{NS} (0,274)	0,2074 ^{NS} (0,1225)
1º Mar Gr	-0,0676 ^{NS} (0,157)	-0,1897* (0,0797)			

(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores entre parêntesis apresentam os erros padrões. Valores em negrito referem-se aos decêndios significativos para cada modelo.

Para as análises realizadas para o modelo GWR (Tabela 20), a maioria dos decêndios obtidos com grande amplitude local está ligada às variáveis Gr e Te; diferente das variáveis Cw e EVI, que têm valores locais que pouco variam. Destaca-se o valor do intercepto que também tem pouca dispersão.

Tabela 20 Estimativas do ajuste do modelo GWR para o ano-safra 2012/2013

	Mínimo	1º Quartil	Mediana	3º Quartil	Máximo	Global
Intercepto	-0,0068	0,0002	0,0005	0,0011	0,0130	0,0008*
2º Out EVI	-0,0014	-0,0013	-0,0012	-0,0010	-0,0007	-0,0011
3º Mar Gr	-0,2480	-0,2158	-0,1861	-0,1661	-0,0999	-0,2052***
3º Set Cw	0,0042	0,0063	0,0078	0,0088	0,0092	0,0075
1º Dez EVI	0,0001	0,0002	0,0002	0,0002	0,0002	0,0002
1º Out Gr	-0,4944	-0,4540	-0,4359	-0,3933	-0,3144	-0,4182***
3º Out EVI	0,0005	0,0008	0,0009	0,0009	0,0010	0,0008
3º Fev Gr	0,0073	0,1205	0,1656	0,2111	0,2667	0,1135***
2º Nov Gr	-0,6176	-0,5741	-0,5145	-0,4665	-0,4144	-0,4633***
2º Abr Gr	0,2904	0,3749	0,4494	0,5159	0,5766	0,4045***
2º Set Te	-0,7657	-0,7099	-0,5992	-0,5568	-0,3842	-0,6499***
2º Dez EVI	0,0000	0,0000	0,0001	0,0001	0,0001	0,0001
3º Jan EVI	0,0001	0,0001	0,0001	0,0001	0,0002	0,0001
2º Fev Gr	0,0705	0,1103	0,1450	0,1895	0,2339	0,1706***
1º Jan Gr	0,1093	0,1374	0,1829	0,2763	0,3238	0,2053***
1º Mar Gr	-0,3769	-0,3448	-0,3108	-0,1802	-0,1185	-0,2312***
1º Out Te	0,4877	0,5955	0,6228	0,6570	0,6863	0,7272***
1º Set Te	-0,4905	-0,4631	-0,4070	-0,3106	-0,1531	-0,4252***
2º Out Gr	0,2023	0,2553	0,2695	0,2774	0,3131	0,2601***
3º Dez Gr	-0,4023	-0,3494	-0,2888	-0,2503	-0,1603	-0,2413***
3º Mar Cw	0,0092	0,0107	0,0132	0,0144	0,0153	0,0110
1º Jan Te	-1,1430	-1,0700	-0,8655	-0,8378	-0,6988	-0,8747***
2º Abr EVI	-0,0003	-0,0002	-0,0002	-0,0002	-0,0002	-0,0002
2º Dez Te	0,5110	0,7890	0,8374	1,0040	1,0610	0,8273***
3º Abr Cw	-0,0669	-0,0501	-0,0458	-0,0420	-0,0351	-0,0464
3º Ago Te	0,2799	0,4438	0,4846	0,5047	0,5334	0,4367***
1º Nov Gr	0,0086	0,0848	0,1301	0,1900	0,2467	0,0969***
1º Set Gr	0,2558	0,3652	0,4509	0,5311	0,6110	0,4049***
2º Ago Gr	-0,0286	0,0374	0,0827	0,1002	0,1337	0,0806***
1º Dez Te	0,0153	0,0458	0,0745	0,1439	0,2642	0,0329***

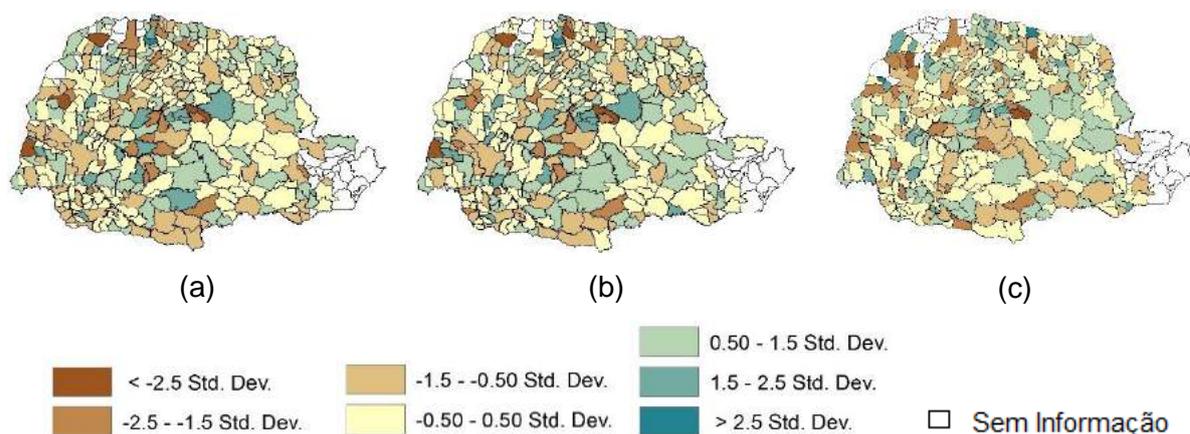
(***): 0,001; (**): 0,01; (*): 0,05 são os níveis de significância; Valores em negrito decêndios significativos.

Verifica-se o modelo GWR com melhor ajuste dos parâmetros para o critério de seleção do modelo do ano-safra 2012/2013 (Tabela 21), porém, com maior MLL e menores AIC e BIC. Em relação ao R² ajustado, verifica-se que a qualidade do ajuste do GWR teve o melhor coeficiente em comparação a SAR e CAR. Também foi possível constatar que o índice global de Moran para esses resíduos foi próximo de zero para os três modelos ajustados, portanto, a autocorrelação espacial foi eliminada.

Tabela 21 Critérios de seleção do melhor modelo

Estatística	SAR	CAR	GWR
MLL	66,454	44,523	116,82
Lag coeff. (Rho)	0,0204	-	-
Lag coeff. (Lambda)	-	0,0903	-
AIC	- 6.909	- 23,047	-106,557
BIC	239,299	105,92	489,71
R ² ajustado	0,75	0,72	0,85
I Moran Global (resíduos)	- 0,0038 (0,496)	0,0048 (0,421)	0,0382 (0,096)

Os resíduos distribuídos aleatoriamente por todo o Estado do Paraná foram gerados para os três modelos em estudo e isso pode ser observado na Figura 41, que representa o mapa dos resíduos padronizados, gerado pelo método do desvio-padrão resultante da aplicação do modelo SAR, CAR e GWR.

**Figura 41** Mapa dos resíduos padronizados para os modelos SAR (a), CAR (b) e GWR (c).

6.4.3.5. Discussão dos modelos para os três anos-safras

A análise dos modelos entre os anos-safras permite que se verifique como as variáveis agrometeorológicas e o EVI foram diferentes para a seleção e significância dos decêndios nos modelos (Tabela 22). Destacam-se o 1º decêndio de janeiro de Te e o 1º decêndio de dezembro de EVI que foram selecionados e significativos por um dos modelos em todos os anos-safras.

6.4.4. Conclusões

Em relação à seleção de variáveis, percebeu-se que não foram as mesmas utilizadas nos três anos-safras estudados e isto se deve a grandes variações climatológicas que ocorreram. Analisaram-se as regressões espaciais e verificou-se que o modelo GWR explicou melhor as produtividades estimadas nos anos-safras.

Agradecimentos

À CAPES, ao CNPq e à Fundação Araucária pelo apoio financeiro.

6.4.5. Referências

AKAIKE, H.. A new look at the statistical model identification. **IEEE Transactions on Automatic Control.**, Boston, v. 19, n. 6, p. 716-723, Dec. 1974

ANSELIN, L. Under the hood: Issues in the specification and interpretation of spatial regression models. **Agricultural Economics.** v. 27. p. 247-267. 2002.

BIVAND, R.S.; PEBESMA, E.J.; GÓMEZ-RUBIO, V. Applied Spatial Data Analysis with R; **Springer**: Heidelberg, Germany, 2008.

BIVAND, R.; YU, D.; NAKAYA, T.; GARCIA-LOPEZ, M. A. **Spgwr**: Geographically Weighted Regression. R Package Version 0.6–19. Available online: <http://cran.r-project.org/web/packages/spgwr/spgwr.pdf> (accessed on 20 Outubro 2015).

BRUNSDON, Chris. **An R Library for Geographically Weighted Regression.** Newcastle upon Tyne, England: Department of Geography, University of Newcastle upon Tyne, 2002.

CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V. Análise Espacial de Área. In: FUCKS, S. D.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. **Análise Espacial de Dados Geográficos.** São José dos Campos: Instituto Nacional de Pesquisas Espaciais – Divisão de Processamento de Imagens, 2002.

CHONG, I. G.; JUN, C. H. Performance of some variable selection methods when multicollinearity is present. **Chemometrics Intelligent Laboratory Systems,** Amsterdam, Holland, v. 78, p. 103-112, 2005.

CRESSIE, N.. Statistics for Spatial Data: Wiley Series in Probability and Statistics; **John Wiley & Sons**: New York, NY, USA, 1993.

FARIAS, J. R. B; NEPOMUCENO, A. L., NEUMAIER, N. **Ecofisiologia da soja.** Londrina: EMBRAPA-CNPSo, 9p. (EMBRAPA-CNPSo. Circular técnica, 48). 2007.

FOTHERINGHAM, A. Stewart; CHARLTON, Martin E.; BRUNSDON, Chris. Two techniques for exploring non-stationarity in geographical data. **Geographical Systems,** v. 4, p. 59-82, 1997.

FOTHERINGHAM, A. S.; BRUNSDON, C.; AND CHARLTON, M. E. **Geographically weighted regression: The analysis of spatially varying relationship**. New York, NY: Wiley. 2002.

FRANCISCO, E. R.. **Indicadores de Renda baseados em Consumo de Energia Elétrica: Abordagens Domiciliar e Regional na Perspectiva da Estatística Espacial**. Tese de Doutorado. 381 f. Escola de Administração de Empresas de São Paulo. 2010.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/MODIS. **Pesq. Agropec. Bras.** v. 47, n. 9, p. 1295-1306. 2012. doi:10.1590/S0100-204X2012000900015.

GOODCHILD, M. F. **Spatial autocorrelation**. *CATMOG*, v. 47, 1986.

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

LOPES, S. B.; BRONDINO, N.C. M.; SILVA, A. N. R. Análise do desempenho de Modelos de Regressão Espacial na previsão de demanda por transportes. In: XIV CONGRESSO PANAMERICANO DE INGENIERÍA DE TRÁNSITO Y TRANSPORTE, 2006. Las Palmas de Gran Canaria. **Anais...** Las Palmas de Gran Canaria: XIV PANAM, 2006.

McBRATNEY, A.; WEBSTER, R. Choosing functions for semi-variograms of soil properties and fitting them to sample estimates. **J. Soil Sci.**, v.37, p. 617-639, 1986.

ROMANI, L. A. S.; SANTOS, E. H. dos; EVANGELISTA, S. R. M.; ASSAD, E.D.; PINTO, H. S. Utilização de estações vizinhas para estimativa de temperatura e precipitação usando o inverso do quadrado da distância. In: **CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA**, 13, 2003, Santa Maria. Situação atual e perspectivas da agrometeorologia: anais. Santa Maria: Unifra: SBA: UFSM, p. 717-718. 2003.

SCHWARZ, G. Estimating the dimensional of a model. **Annals of Statistics**, Hayward, v. 6, n. 2, p. 461-464, Mar. 1978.

SMITH, M. J.; GOODCHILD, M. F.; LONGLEY, P. **Geospatial analysis: a comprehensive guide to principles, techniques and software tools**. Leicester, UK: Matador, 2007.

VALCARCE, E. V.; SERRANO, R. M. **La utilidad de la econometria espacial en el ambito de la ciência regional**. Madrid: Fundación de Estudios de Economía Aplicada, 2000.

7. CONSIDERAÇÕES FINAIS

Considerando que os resultados da tese foram organizados em artigos e que as conclusões foram apresentadas em cada um deles, estão relacionadas abaixo as principais contribuições verificadas no desenvolvimento deste trabalho:

- a) A utilização de dados de EVI do sensor *MODIS* juntamente com o classificador supervisionado SAM proporcionou o mapeamento com a separação e estimativa das áreas cultivadas com culturas da soja e milho, na escala municipal para o Estado do Paraná. É, portanto, uma alternativa objetiva e com baixo custo, e que pode ser utilizada pelos órgãos oficiais, responsáveis pelas estatísticas de produção agrícola do Paraná.
- b) Com a disponibilidade de dados históricos, a calibração dos dados estimados pelo ECMWF e de EVI em dados decendiais e dados de áreas mostrou-se eficaz e pode ser utilizada para estimativa de informações como datas de semeaduras nas diferentes regiões do Estado, além das alterações climáticas durante o ciclo das culturas.
- c) Os decêndios foram identificados em que as variáveis agrometeorológicas tiveram influência direta na produtividade final da cultura pelas análises de autocorrelação espacial bivariada das variáveis em função da produtividade.
- d) Observou-se uma melhora de resultados com o modelo GWR ao serem utilizados modelos de regressão espacial, visto que tal modelo apresenta resultados locais além dos globais.

Futuros trabalhos:

Para as estimativas dos modelos da produtividade da soja, é preciso que sejam realizados procedimentos em que a modelagem seja realizada de acordo com as áreas mapeadas (pixels) a fim de encontrar a estimativa da produtividade em $t\ ha^{-1}$.

APÊNDICE A

Nome dos Municípios do Estado do Paraná, referente a Figura 4.

0 = Foz do Iguaçu; 1 = Santa Terezinha de Itaipu; 2 = Itaipulândia; 3 = Santa Helena; 4 = Missal; 5 = São Miguel do Iguaçu; 6 = Guaíra; 7 = Entre Rios do Oeste; 8 = Marechal Cândido Rondon; 9 = Pato Bragado; 10 = Mercedes; 11 = Diamante D'Oeste; 12 = São José das Palmeiras; 13 = Medianeira; 14 = Ramilândia; 15 = Terra Roxa; 16 = Altônia; 17 = Serranópolis do Iguaçu; 18 = Nova Santa Rosa; 19 = São Jorge do Patrocínio; 20 = São Pedro do Iguaçu; 21 = Ouro Verde do Oeste; 22 = Vera Cruz do Oeste; 23 = Toledo; 24 = Alto Paraíso; 25 = Quatro Pontes; 26 = Matelândia; 27 = Francisco Alves; 28 = Capanema; 29 = Iporã; 30 = Palotina; 31 = Céu azul; 32 = Maripá; 33 = Planalto; 34 = Esperança Nova; 35 = Pérola do Oeste; 36 = Pranchita; 37 = Pérola; 38 = Icaraíma; 39 = Xambê; 40 = Santo Antônio do Sudoeste; 41 = Santa Tereza do oeste; 42 = Bela Vista da Caroba; 43 = Cascavel; 44 = Assis Chateaubriand; 45 = Querência do Norte; 46 = Capitão Leônidas Marques; 47 = Cafezal do Sul; 48 = Bom Jesus do Sul; 49 = Lindoeste; 50 = Brasilândia do Sul; 51 = Umuarama; 52 = Barracão; 53 = Realeza; 54 = Santa Lúcia; 55 = Ampére; 56 = Tupãssi; 57 = Pinhal de São Bento; 58 = Ivatú; 59 = Salgado Filho; 60 = Perobal; 61 = Boa Vista da Aparecida; 62 = Alto Piquiri; 63 = Santa Izabel do Oeste; 64 = Santa Cruz do Monte Castelo; 65 = Nova Prata do Iguaçu; 66 = Manfrinópolis; 67 = Flor da Serra do Sul; 68 = Jesuítas; 69 = Formosa do Oeste; 70 = Cafelândia; 71 = Nova Aurora; 72 = Corbélia; 73 = Porto Rico; 74 = Salto do Lontra; 75 = Iracema do Oeste; 76 = Francisco Beltrão; 77 = Três Barras do Paraná; 78 = Douradina; 79 = Nova Esperança do Sudoeste; 80 = Maria Helena; 81 = Santa Isabel do Ivaí; 82 = Catanduvas; 83 = Mariluz; 84 = Boa Esperança do Iguaçu; 85 = Quarto Centenário; 86 = São Pedro do Paraná; 87 = Loanda; 88 = Dois Vizinhos; 89 = Goioerê; 90 = Enéas Marques; 91 = Tapira; 92 = Anahy; 93 = Cruzeiro do Oeste; 94 = Cruzeiro do Iguaçu; 95 = Braganey; 96 = Marmeleiro; 97 = Santa Mônica; 98 = Ubiratã; 99 = Quedas do Iguaçu; 100 = Iguatu; 101 = Moreira Sales; 102 = São Jorge d'Oeste; 103 = Marilena; 104 = Nova Olímpia; 105 = Campo Bonito; 106 = Ibema; 107 = Verê; 108 = Renascença; 109 = Rancho Alegre D'Oeste; 110 = Guaraniaçu; 111 = Tapejara; 112 = Cidade Gaúcha; 113 = Nova Londrina; 114 = Planaltina do Paraná; 115 = Tuneiras do Oeste; 116 = Diamante do Norte; 117 = Campina da Lagoa; 118 = Itapejara d'Oeste; 119 = Rondon; 120 = Juranda; 121 = Vitorino; 122 = Bom Sucesso do Sul; 123 = São João; 124 = Itaúna do Sul; 125 = Guaporema; 126 = Amaporã; 127 = Espigão Alto do Iguaçu; 128 = Janiópolis; 129 = Altamira do Paraná; 130 = Guairaçá; 131 = Boa Esperança; 132 = Mirador; 133 = Nova Laranjeiras; 134 = Coronel Vivida; 135 = Terra Rica; 136 = Pato Branco; 137 = Diamante do Sul; 138 = Rio Bonito do Iguaçu; 139 = Sulina; 140 = Farol; 141 = Paraíso do Norte; 142 = Mamborê; 143 = Araruna; 144 = Chopinzinho; 145 = Indianópolis; 146 =

Paranavaí; 147 = Cianorte; 148 = Mariópolis; 149 = Nova Cantu; 150 = Saudade do Iguaçu; 151 = Nova Aliança do Ivaí; 152 = Laranjal; 153 = São Tomé; 154 = São Manuel do Paraná; 155 = Japurá; 156 = Honório Serpa; 157 = Clevelândia; 158 = Laranjeiras do Sul; 159 = São Carlos do Ivaí; 160 = Porto Barreiro; 161 = Jussara; 162 = Campo Mourão; 163 = Tamboara; 164 = Luiziana; 165 = Roncador; 166 = Terra Boa; 167 = Peabiru; 168 = Engenheiro Beltrão; 170 = Candói; 171 = Marquinho; 172 = São Jorge do Ivaí; 173 = Floraí; 174 = Nova Esperança; 175 = Alto Paraná; 176 = Mangueirinha; 177 = São João do Caiuá; 178 = Santo Antônio do Caiuá; 179 = Mato Rico; 180 = Virmond; 181 = Ourizona; 182 = Doutor Camargo; 183 = Cantagalo; 184 = Iretama; 185 = Inajá; 186 = Cruzeiro do Sul; 187 = Quinta do Sol; 188 = Ivatuba; 189 = Foz do Jordão; 190 = Parancity; 191 = Corumbataí do Sul; 192 = Presidente Castelo Branco; 193 = Barbosa Ferraz; 194 = Coronel Domingo Soares; 195 = Paiçancu; 196 = Palmas; 197 = Goioxim; 198 = Reserva do Iguaçu; 199 = Floresta; 200 = Uniflor; 201 = Mandaguaçu; 202 = Paranaponema; 203 = Santa Maria do Oeste; 204 = Fênix; 205 = Atalaia; 206 = Jardim Olinda; 207 = Pitanga; 208 = Itambú; 209 = Maringá; 210 = Lobato; 211 = Colorado; 212 = Nova Tebas; 213 = Pinhão; 214 = Marialva; 215 = Guarapuava; 216 = Itaguajé; 217 = Godoy Moreira; 218 = São Pedro do Ivaí; 219 = Flórida; 220 = São João do Ivaí; 221 = Ângulo; 222 = Jardim Alegre; 223 = Bom Sucesso; 224 = Santa Inês; 225 = Arapuã; 226 = Iguaraçu; 227 = Sarandi; 228 = Campina do Simão; 229 = Santa Fé; 230 = Lunardelli; 231 = Santo Inácio; 232 = Astorga; 233 = Nossa Senhora das Graças; 234 = Manoel Ribas; 235 = Mandaguari; 236 = Bituruna; 237 = Turvo; 238 = Boa Ventura do São Roque; 239 = Kaloré; 240 = Jandaia do Sul; 241 = Munhoz de Melo; 242 = Marumbi; 243 = Ivaiporã; 244 = Cafeara; 245 = Guaraci; 246 = Borrazópolis; 247 = Jaguapitã; 248 = Lindianópolis; 249 = Lupianópolis; 250 = Ariranha do Ivaí; 251 = Sabáudia; 252 = Cruz Machado; 253 = General Carneiro; 254 = Centenário do Sul; 255 = Cambira; 256 = Apucarana; 257 = Cruzmaltina; 258 = Pitangueiras; 259 = Nova Itacolomi; 260 = Arapongas; 261 = Grandes Rios; 262 = Rolândia; 263 = Cândido Abreu; 264 = Miraselva; 265 = Rio Bom; 266 = Porecatu; 267 = Rio Branco do Ivaí; 268 = Prado Ferreira; 269 = Florestópolis; 270 = Faxinal; 271 = Inácio Martins; 272 = Marilândia do Sul; 273 = Califórnia; 274 = Prudentópolis; 275 = Cambé; 276 = Ortigueira; 277 = Rosário do Ivaí; 278 = Porto Vitória; 279 = União da Vitória; 280 = Alvorada do Sul; 281 = Bela Vista do Paraíso; 282 = Londrina; 283 = Mauá da Serra; 284 = Reserva; 285 = Tamarana; 286 = Irati; 287 = Primeiro de Maio; 288 = Ibiporã; 289 = Sertanópolis; 290 = Mallet; 291 = Paula Freitas; 292 = Rio Azul; 293 = Ivaí; 294 = Assaí; 295 = Sertaneja; 296 = Guamiranga; 297 = Rancho Alegre; 298 = Jataizinho; 299 = Paulo Frontin; 300 = São Jerônimo da Serra; 301 = Imbaú; 302 = Tibagi; 303 = Uraí; 304 = Santa Cecília do Pavão; 305 = Ipiranga; 306 = Imbituva; 307 = Nova Santa Bárbara; 308 = Rebouças; 309 = Leópolis; 310 = Sapopema; 311 = Cornélio Procópio; 312 = São Sebastião da Amoreira; 313 = Nova América da Colina; 314 =

Telêmaco Borba; 315 = São Mateus do Sul; 316 = Curiúva; 317 = Santo Antônio do Paraíso; 318 = Fernandes Pinheiro; 319 = Nova Fátima; 320 = Congonhinhas; 321 = Teixeira Soares; 322 = Santa Mariana; 323 = São João do Triunfo; 324 = Itambaracá; 325 = Ribeirão do Pinhal; 326 = Ponta Grossa; 327 = Figueira; 328 = Ibaiti; 329 = Abatiá; 330 = Santa Amélia; 331 = Bandeirantes; 332 = Palmeira; 333 = Carambeí; 334 = Ventania; 335 = Andirá; 336 = Antônio Olinto; 337 = Jundiá do Sul; 338 = Lapa; 339 = Castro; 340 = Japira; 341 = Barra do Jacaré; 342 = Piraí do Sul; 343 = Arapoti; 344 = Santo Antônio da Platina; 345 = Conselheiro Mairinck; 346 = Cambará; 347 = Jaboti; 348 = Pinhalão; 349 = Guapirama; 350 = Jacarezinho; 351 = Tomazina; 352 = Porto Amazonas; 353 = Quatiguá; 354 = Joaquim Távora; 355 = Rio Negro; 356 = Jaguariaíva; 357 = Wescleslau Braz; 358 = Siqueira Campos; 359 = Campo Largo; 360 = Ribeirão Claro; 361 = Balsa Nova; 362 = Campo do Tenente; 363 = Carlópolis; 364 = Salto do Itararú; 365 = São José da Boa Vista; 366 = Santana do Itararé; 367 = Quitndinha; 368 = Contenda; 369 = Doutor Ulysses; 370 = Araucária; 371 = Itaperuçu; 372 = Sengés; 373 = Piên; 374 = Campo Magro; 375 = Rio Branco do Sul; 376 = Cerro Azul; 377 = Mandirituba; 378 = Almirante Tamandaré; 379 = Agudos do Sul; 380 = Curitiba; 381 = Fazenda Rio Grande; 382 = Tijucas do Sul; 383 = São José dos Pinhais; 384 = Colombo; 385 = Bocaiúva do Sul; 386 = Pinhais; 387 = Piraquara; 388 = Campina Grande do Sul; 389 = Quatro Barras; 390 = Adrianópolis; 391 = Tunas do Paraná; 392 = Guaratuba; 393 = Morretes; 394 = Antonina; 395 = Paranaguá; 396 = Matinhos; 398 = Guaraqueçaba; 399 = Pontal do Paraná.

APÊNDICE B

Apêndice referente aos resultados do artigo 2.

Tabela 23 Valores dos Índices de Moran e Geary univariado médios decendiais do Estado do Paraná para as variáveis agrometeorológicas e EVI

Decêndio	Índice de Moran 2010/2011								Índice de Geary 2010/2011							
	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti
1º Ago	0,779	0,977	0,980	0,921	0,949	0,955	0,950	0,952	0,207	0,024	0,021	0,073	0,044	0,042	0,045	0,044
2º Ago	0,833	0,960	0,978	0,948	0,942	0,959	0,956	0,953	0,171	0,037	0,022	0,048	0,048	0,038	0,039	0,043
3º Ago	0,886	0,955	0,942	0,955	0,900	0,967	0,955	0,966	0,140	0,039	0,041	0,039	0,087	0,031	0,039	0,033
1º Set	0,910	0,952	0,959	0,931	0,924	0,957	0,952	0,953	0,127	0,047	0,042	0,062	0,063	0,039	0,042	0,045
2º Set	0,918	0,943	0,961	0,947	0,915	0,963	0,961	0,959	0,126	0,053	0,037	0,048	0,074	0,034	0,034	0,038
3º Set	0,856	0,930	0,930	0,940	0,903	0,957	0,958	0,956	0,198	0,067	0,066	0,055	0,085	0,039	0,037	0,041
1º Out	0,836	0,965	0,965	0,938	0,950	0,953	0,955	0,950	0,222	0,034	0,034	0,056	0,043	0,043	0,041	0,047
2º Out	0,805	0,968	0,973	0,947	0,947	0,957	0,954	0,957	0,250	0,030	0,025	0,049	0,049	0,040	0,041	0,040
3º Out	0,783	0,937	0,917	0,940	0,901	0,956	0,953	0,959	0,266	0,052	0,069	0,054	0,084	0,040	0,042	0,038
1º Nov	0,735	0,899	0,892	0,915	0,822	0,953	0,947	0,959	0,290	0,099	0,106	0,078	0,162	0,044	0,049	0,038
2º Nov	0,716	0,815	0,920	0,926	0,923	0,953	0,950	0,954	0,322	0,171	0,079	0,066	0,063	0,044	0,044	0,042
3º Nov	0,720	0,960	0,956	0,964	0,968	0,950	0,956	0,949	0,321	0,040	0,046	0,031	0,026	0,045	0,039	0,046
1º Dez	0,746	0,971	0,972	0,938	0,942	0,955	0,952	0,955	0,215	0,029	0,028	0,056	0,052	0,041	0,042	0,041
2º Dez	0,769	0,924	0,909	0,962	0,972	0,947	0,940	0,947	0,190	0,072	0,087	0,035	0,025	0,049	0,055	0,048
3º Dez	0,764	0,967	0,972	0,930	0,929	0,943	0,943	0,938	0,188	0,034	0,029	0,065	0,062	0,053	0,052	0,057
1º Jan	0,696	0,885	0,874	0,928	0,867	0,947	0,939	0,951	0,218	0,109	0,120	0,065	0,124	0,048	0,054	0,046
2º Jan	0,617	0,928	0,908	0,954	0,960	0,946	0,947	0,946	0,236	0,068	0,087	0,045	0,040	0,049	0,050	0,048
3º Jan	0,608	0,928	0,905	0,953	0,937	0,949	0,957	0,942	0,250	0,069	0,092	0,040	0,052	0,046	0,040	0,053
1º Fev	0,617	0,820	0,824	0,863	0,853	0,930	0,917	0,941	0,294	0,178	0,174	0,127	0,146	0,063	0,076	0,055
2º Fev	0,721	0,875	0,878	0,911	0,897	0,946	0,945	0,945	0,251	0,101	0,099	0,079	0,096	0,049	0,051	0,050
3º Fev	0,732	0,830	0,801	0,946	0,951	0,952	0,954	0,948	0,258	0,169	0,197	0,049	0,044	0,044	0,042	0,048

Valores significativos ao nível de 5% de probabilidade. Continua....

Continuação da **Tabela 23...**

Decêndio	Índice de Moran 2010/2011								Índice de Geary 2010/2011							
	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti
1º Mar	0,696	0,918	0,909	0,961	0,968	0,943	0,942	0,948	0,299	0,069	0,078	0,035	0,029	0,053	0,054	0,047
2º Mar	0,633	0,854	0,768	0,943	0,922	0,953	0,952	0,949	0,335	0,131	0,210	0,052	0,070	0,043	0,044	0,046
3º Mar	0,526	0,890	0,894	0,948	0,925	0,951	0,948	0,947	0,391	0,104	0,100	0,048	0,066	0,045	0,048	0,049
1º Abr	0,653	0,879	0,844	0,943	0,940	0,959	0,962	0,953	0,278	0,109	0,140	0,052	0,055	0,037	0,035	0,042
2º Abr	0,713	0,851	0,803	0,959	0,950	0,958	0,957	0,952	0,236	0,136	0,185	0,037	0,043	0,038	0,038	0,044
3º Abr	0,754	0,866	0,844	0,951	0,940	0,955	0,954	0,954	0,209	0,131	0,152	0,047	0,056	0,040	0,041	0,042

Valores significativos ao nível de 5% de probabilidade.

Tabela 24 Valores dos Índices de Moran e Geary univariado médios decendiais do estado do Paraná para as variáveis agrometeorológicas e EVI

Decêndio	Índice de Moran 2011/2012								Índice de Geary 2011/2012							
	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti
1º Ago	0,825	0,957	0,953	0,951	0,965	0,956	0,956	0,947	0,195	0,037	0,040	0,047	0,033	0,040	0,039	0,050
2º Ago	0,840	0,968	0,975	0,935	0,943	0,958	0,956	0,956	0,195	0,031	0,024	0,061	0,053	0,038	0,040	0,041
3º Ago	0,836	0,946	0,938	0,948	0,941	0,959	0,958	0,959	0,209	0,047	0,055	0,047	0,053	0,037	0,037	0,037
1º Set	0,861	0,975	0,975	0,936	0,946	0,959	0,959	0,957	0,213	0,026	0,025	0,061	0,051	0,037	0,037	0,040
2º Set	0,893	0,936	0,912	0,944	0,935	0,959	0,958	0,957	0,189	0,058	0,083	0,050	0,056	0,037	0,037	0,039
3º Set	0,892	0,929	0,934	0,939	0,923	0,956	0,956	0,953	0,184	0,067	0,065	0,056	0,069	0,041	0,040	0,044
1º Out	0,894	0,871	0,872	0,943	0,921	0,960	0,957	0,961	0,210	0,124	0,122	0,053	0,075	0,036	0,039	0,036
2º Out	0,866	0,914	0,908	0,951	0,946	0,958	0,960	0,957	0,256	0,083	0,088	0,041	0,045	0,038	0,036	0,038
3º Out	0,871	0,858	0,855	0,958	0,912	0,963	0,957	0,962	0,230	0,135	0,135	0,038	0,079	0,033	0,038	0,035
1º Nov	0,841	0,918	0,854	0,934	0,907	0,957	0,953	0,954	0,229	0,075	0,129	0,062	0,091	0,039	0,042	0,042
2º Nov	0,837	0,872	0,873	0,942	0,936	0,963	0,962	0,963	0,222	0,118	0,120	0,052	0,057	0,034	0,034	0,033
3º Nov	0,771	0,913	0,930	0,928	0,761	0,955	0,952	0,948	0,301	0,079	0,066	0,063	0,222	0,041	0,042	0,048

Valores significativos ao nível de 5% de probabilidade. Continua....

Continuação da Tabela 24...

Decêndio	Índice de Moran 2011/2012								Índice de Geary 2011/2012							
	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti
1º Dez	0,642	0,882	0,818	0,933	0,924	0,952	0,950	0,950	0,402	0,104	0,163	0,059	0,067	0,044	0,044	0,045
2º Dez	0,621	0,958	0,944	0,963	0,934	0,959	0,960	0,950	0,322	0,043	0,057	0,036	0,061	0,037	0,037	0,045
3º Dez	0,664	0,884	0,843	0,947	0,940	0,961	0,959	0,963	0,288	0,096	0,128	0,050	0,053	0,036	0,037	0,035
1º Jan	0,705	0,946	0,919	0,961	0,951	0,960	0,960	0,953	0,262	0,049	0,074	0,035	0,042	0,037	0,036	0,042
2º Jan	0,777	0,939	0,927	0,961	0,963	0,941	0,942	0,943	0,218	0,057	0,068	0,036	0,036	0,054	0,054	0,052
3º Jan	0,795	0,913	0,899	0,938	0,929	0,952	0,951	0,949	0,227	0,079	0,093	0,054	0,064	0,044	0,045	0,049
1º Fev	0,802	0,958	0,942	0,952	0,930	0,954	0,951	0,947	0,245	0,040	0,055	0,045	0,067	0,041	0,045	0,048
2º Fev	0,808	0,963	0,961	0,952	0,922	0,957	0,957	0,952	0,226	0,035	0,038	0,043	0,069	0,040	0,041	0,044
3º Fev	0,763	0,867	0,856	0,923	0,933	0,942	0,940	0,945	0,273	0,131	0,141	0,070	0,065	0,053	0,055	0,051
1º Mar	0,693	0,774	0,869	0,920	0,811	0,953	0,952	0,947	0,333	0,202	0,123	0,071	0,176	0,043	0,045	0,050
2º Mar	0,650	0,894	0,871	0,921	0,930	0,952	0,949	0,954	0,368	0,088	0,108	0,071	0,067	0,044	0,048	0,042
3º Mar	0,696	0,838	0,846	0,913	0,899	0,953	0,955	0,948	0,315	0,152	0,147	0,084	0,093	0,043	0,043	0,049
1º Abr	0,745	0,889	0,888	0,920	0,926	0,956	0,955	0,951	0,259	0,104	0,104	0,077	0,068	0,041	0,042	0,046
2º Abr	0,765	0,957	0,960	0,942	0,947	0,956	0,958	0,952	0,237	0,046	0,043	0,056	0,049	0,042	0,040	0,045
3º Abr	0,776	0,918	0,916	0,895	0,924	0,958	0,961	0,956	0,222	0,079	0,080	0,099	0,070	0,039	0,036	0,041

Valores significativos ao nível de 5% de probabilidade.

Tabela 25 Valores dos Índices de Moran e Geary univariado médios decendiais do estado do Paraná para as variáveis agrometeorológicas e EVI

Decêndio	Índice de Moran 2012/2013								Índice de Geary 2012/2013							
	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti
1º Ago	0,788	0,948	0,824	0,957	0,950	0,965	0,957	0,958	0,251	0,046	0,154	0,039	0,041	0,034	0,038	0,042
2º Ago	0,802	0,948	0,886	0,946	0,925	0,963	0,958	0,958	0,250	0,054	0,103	0,051	0,066	0,035	0,038	0,042
3º Ago	0,817	0,948	0,924	0,951	0,946	0,953	0,952	0,948	0,246	0,044	0,065	0,045	0,046	0,045	0,042	0,051
1º Set	0,854	0,938	0,895	0,947	0,944	0,963	0,957	0,959	0,238	0,056	0,096	0,048	0,049	0,034	0,037	0,041

Valores significativos ao nível de 5% de probabilidade. Continua....

Continuação da Tabela 25...

Decêndio	Índice de Moran 2012/2013								Índice de Geary 2012/2013							
	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti	EVI	Cw	Ra	Et	Gr	Te	Ta	Ti
2º Set	0,868	0,922	0,880	0,920	0,873	0,962	0,958	0,959	0,241	0,076	0,118	0,077	0,118	0,035	0,038	0,040
3º Set	0,864	0,948	0,941	0,941	0,940	0,957	0,956	0,954	0,256	0,048	0,056	0,055	0,051	0,040	0,042	0,042
1º Out	0,756	0,956	0,960	0,948	0,941	0,960	0,953	0,958	0,359	0,042	0,041	0,048	0,051	0,037	0,041	0,041
2º Out	0,738	0,894	0,900	0,929	0,892	0,958	0,952	0,958	0,381	0,099	0,095	0,066	0,099	0,039	0,043	0,038
3º Out	0,703	0,952	0,943	0,969	0,971	0,966	0,965	0,965	0,408	0,045	0,053	0,029	0,027	0,031	0,031	0,034
1º Nov	0,651	0,926	0,938	0,897	0,876	0,952	0,948	0,952	0,440	0,066	0,056	0,092	0,112	0,044	0,047	0,045
2º Nov	0,663	0,926	0,905	0,939	0,935	0,960	0,961	0,957	0,406	0,066	0,083	0,055	0,057	0,037	0,036	0,039
3º Nov	0,761	0,898	0,907	0,903	0,876	0,953	0,944	0,957	0,306	0,099	0,088	0,093	0,118	0,043	0,051	0,040
1º Dez	0,812	0,954	0,944	0,949	0,901	0,957	0,956	0,957	0,234	0,045	0,056	0,046	0,089	0,040	0,041	0,041
2º Dez	0,810	0,949	0,948	0,945	0,928	0,947	0,928	0,954	0,218	0,048	0,048	0,050	0,068	0,049	0,068	0,042
3º Dez	0,816	0,839	0,829	0,956	0,920	0,954	0,947	0,956	0,206	0,157	0,168	0,040	0,069	0,043	0,049	0,041
1º Jan	0,794	0,886	0,907	0,931	0,897	0,952	0,946	0,954	0,206	0,111	0,090	0,062	0,090	0,044	0,050	0,042
2º Jan	0,750	0,897	0,879	0,940	0,930	0,952	0,950	0,946	0,185	0,093	0,111	0,052	0,060	0,043	0,046	0,048
3º Jan	0,724	0,883	0,765	0,931	0,906	0,950	0,945	0,952	0,288	0,104	0,208	0,065	0,088	0,046	0,052	0,043
1º Fev	0,824	0,891	0,873	0,966	0,976	0,950	0,953	0,946	0,228	0,104	0,121	0,031	0,024	0,045	0,043	0,049
2º Fev	0,854	0,951	0,948	0,956	0,964	0,948	0,946	0,948	0,184	0,050	0,052	0,041	0,034	0,046	0,049	0,048
3º Fev	0,809	0,876	0,883	0,937	0,936	0,948	0,944	0,950	0,238	0,112	0,107	0,059	0,056	0,048	0,053	0,046
1º Mar	0,735	0,890	0,813	0,951	0,955	0,957	0,955	0,955	0,312	0,099	0,170	0,046	0,041	0,039	0,042	0,041
2º Mar	0,659	0,942	0,948	0,925	0,924	0,949	0,949	0,947	0,366	0,060	0,053	0,069	0,069	0,046	0,046	0,047
3º Mar	0,616	0,862	0,772	0,952	0,956	0,953	0,953	0,951	0,401	0,134	0,223	0,044	0,040	0,043	0,044	0,045
1º Abr	0,653	0,944	0,943	0,821	0,944	0,952	0,948	0,956	0,377	0,056	0,057	0,180	0,053	0,044	0,048	0,041
2º Abr	0,733	0,881	0,892	0,934	0,938	0,955	0,955	0,952	0,295	0,122	0,110	0,062	0,055	0,041	0,041	0,044
3º Abr	0,735	0,938	0,845	0,945	0,939	0,954	0,957	0,948	0,300	0,054	0,128	0,050	0,053	0,042	0,040	0,048

Valores significativos ao nível de 5% de probabilidade.

Tabela 26 Autocorrelação Bivariada (Lee) da Produtividade da soja com as variáveis EVI e agrometeorológicas.

2010/2011	Produtividade X					
	EVI	Ra	Cw	Et	Gr	Te
1º Ago	-0,272 (0,001)	-0,277 (0,001)	-0,281 (0,001)	0,252 (0,001)	0,193 (0,001)	0,167 (0,001)
2º Ago	-0,293 (0,001)	-0,024 (0,065)	-0,179 (0,001)	0,261 (0,001)	0,038 (0,001)	0,303 (0,001)
3º Ago	-0,248 (0,001)	-0,024 (0,059)	-0,341 (0,001)	0,350 (0,001)	0,004 (0,284)	0,365 (0,001)
1º Set	-0,247 (0,001)	-0,233 (0,001)	-0,252 (0,001)	0,198 (0,001)	0,097 (0,001)	0,279 (0,001)
2º Set	-0,241 (0,001)	0,147 (0,001)	-0,078 (0,001)	0,263 (0,001)	-0,039 (0,001)	0,253 (0,001)
3º Set	-0,207 (0,001)	0,098 (0,001)	0,079 (0,001)	0,137 (0,001)	0,077 (0,001)	0,237 (0,001)
1º Out	-0,193 (0,001)	-0,089 (0,001)	-0,114 (0,001)	0,172 (0,001)	0,100 (0,001)	0,241 (0,001)
2º Out	-0,175 (0,001)	0,114 (0,001)	0,057 (0,002)	0,168 (0,001)	0,016 (0,123)	0,292 (0,001)
3º Out	-0,092 (0,001)	-0,275 (0,001)	-0,286 (0,001)	0,180 (0,001)	-0,139 (0,001)	0,266 (0,001)
1º Nov	0,013 (0,924)	0,219 (0,001)	0,116 (0,001)	0,144 (0,001)	-0,392 (0,001)	0,254 (0,001)
2º Nov	0,186 (0,001)	0,074 (0,001)	-0,051 (0,001)	0,210 (0,001)	0,011 (0,200)	0,317 (0,001)
3º Nov	0,257 (0,001)	-0,097 (0,001)	-0,172 (0,001)	0,327 (0,001)	0,264 (0,001)	0,334 (0,001)
1º Dez	0,195 (0,001)	-0,097 (0,001)	-0,152 (0,001)	0,338 (0,001)	0,295 (0,001)	0,340 (0,001)
2º Dez	0,145 (0,001)	0,040 (0,018)	-0,037 (0,022)	0,257 (0,001)	0,195 (0,001)	0,355 (0,001)
3º Dez	0,079 (0,001)	0,276 (0,001)	0,236 (0,001)	0,133 (0,001)	-0,011 (0,285)	0,325 (0,001)
1º Jan	0,041 (0,001)	-0,058 (0,001)	-0,070 (0,001)	0,172 (0,001)	0,050 (0,001)	0,189 (0,001)
2º Jan	-0,168 (0,001)	0,062 (0,001)	0,073 (0,001)	-0,106 (0,001)	-0,098 (0,001)	-0,030 (0,068)
3º Jan	-0,174 (0,001)	-0,029 (0,127)	-0,040 (0,055)	0,077 (0,002)	0,087 (0,001)	-0,054 (0,002)
1º Fev	-0,122 (0,001)	-0,199 (0,001)	-0,202 (0,001)	0,202 (0,001)	0,210 (0,001)	0,090 (0,001)
2º Fev	-0,405 (0,001)	0,136 (0,001)	0,125 (0,001)	0,032 (0,058)	0,058 (0,007)	-0,003 (0,584)

Nota: Entre parênteses estão os p-valores. Em negrito estão os valores não significativos. Continua...

Continuação da Tabela 26...

2010/2011	Produtividade X					
	EVI	Ra	Cw	Et	Gr	Te
3º Fev	-0,276 (0,001)	-0,076 (0,001)	-0,110 (0,001)	0,124 (0,001)	0,128 (0,001)	-0,029 (0,040)
1º Mar	-0,063 (0,001)	0,110 (0,001)	0,128 (0,001)	-0,194 (0,001)	-0,176 (0,001)	-0,168 (0,001)
2º Mar	0,067 (0,146)	0,167 (0,001)	0,177 (0,001)	-0,161 (0,001)	-0,160 (0,001)	-0,042 (0,032)
3º Mar	0,230 (0,001)	-0,145 (0,001)	-0,143 (0,001)	0,042 (0,006)	0,116 (0,001)	-0,025 (0,130)
1º Abr	0,363 (0,001)	-0,022 (0,104)	0,022 (0,237)	-0,079 (0,001)	-0,052 (0,035)	-0,034 (0,067)
2º Abr	0,379 (0,001)	0,017 (0,161)	0,009 (0,744)	0,020 (0,184)	0,107 (0,001)	-0,116 (0,001)
3º Abr	0,380 (0,001)	-0,005 (0,397)	-0,010 (0,373)	0,023 (0,152)	-0,005 (0,314)	0,022 (0,089)

Nota: Entre parênteses estão os p-valores. Em negrito estão os valores não significativos.

Tabela 27 Autocorrelação Bivariada (Lee) da Produtividade da soja com as variáveis EVI e agrometeorológicas

2011/2012	Produtividade X					
	EVI	Ra	Cw	Et	Gr	Te
1º Ago	-0,565 (0,001)	-0,023 (0,086)	-0,030 (0,040)	0,063 (0,005)	0,041 (0,018)	0,018 (0,263)
2º Ago	-0,541 (0,001)	-0,081 (0,001)	-0,084 (0,001)	0,077 (0,001)	0,116 (0,001)	0,064 (0,001)
3º Ago	-0,489 (0,001)	-0,096 (0,001)	-0,105 (0,001)	0,115 (0,001)	0,100 (0,001)	0,147 (0,001)
1º Set	-0,524 (0,001)	-0,020 (0,222)	-0,054 (0,007)	0,191 (0,001)	0,126 (0,001)	0,145 (0,001)
2º Set	-0,554 (0,001)	-0,055 (0,009)	-0,069 (0,001)	0,078 (0,001)	0,085 (0,001)	0,058 (0,010)
3º Set	-0,574 (0,001)	-0,162 (0,001)	-0,194 (0,001)	0,178 (0,001)	0,156 (0,001)	0,150 (0,001)
1º Out	-0,509 (0,001)	-0,110 (0,001)	-0,107 (0,001)	0,023 (0,026)	0,031 (0,006)	0,001 (0,449)
2º Out	-0,402 (0,001)	0,116 (0,001)	0,089 (0,001)	0,069 (0,001)	0,031 0,121	0,108 (0,001)
3º Out	-0,317 (0,001)	-0,065 (0,003)	-0,078 (0,001)	0,075 (0,001)	0,047 (0,003)	0,111 (0,001)
1º Nov	-0,242 (0,001)	0,026 (0,173)	-0,045 (0,016)	0,089 (0,001)	0,064 (0,002)	0,059 (0,014)
2º Nov	0,303 (0,001)	-0,105 (0,001)	-0,109 (0,001)	0,065 (0,001)	0,101 (0,001)	0,024 (0,119)

Nota: Entre parênteses estão os p-valores. Em negrito estão os valores não significativos. Continua...

Continuação da Tabela 27...

2011/2012	Produtividade X					
	EVI	Ra	Cw	Et	Gr	Te
3º Nov	0,295 (0,001)	0,206 (0,001)	0,259 (0,001)	-0,142 (0,001)	-0,265 (0,001)	0,054 (0,012)
1º Dez	0,248 (0,001)	0,164 (0,001)	0,153 (0,001)	-0,085 (0,001)	-0,097 (0,001)	-0,006 (0,156)
2º Dez	-0,068 (0,001)	-0,056 (0,013)	-0,052 (0,016)	0,027 (0,115)	0,066 (0,001)	-0,043 (0,007)
3º Dez	-0,272 (0,001)	-0,105 (0,001)	-0,090 (0,001)	0,023 (0,114)	-0,001 (0,446)	-0,063 (0,001)
1º Jan	-0,382 (0,001)	-0,477 (0,001)	-0,532 (0,001)	0,568 (0,001)	0,372 (0,001)	0,688 (0,001)
2º Jan	-0,535 (0,001)	-0,017 (0,175)	-0,090 (0,001)	0,314 (0,001)	0,063 (0,001)	0,690 (0,001)
3º Jan	-0,598 (0,001)	-0,056 (0,005)	-0,225 (0,001)	0,661 (0,001)	0,552 (0,001)	0,696 (0,001)
1º Fev	-0,641 (0,001)	-0,619 (0,001)	-0,664 (0,001)	0,669 (0,001)	0,482 (0,001)	0,700 (0,001)
2º Fev	-0,665 (0,001)	-0,117 (0,001)	-0,244 (0,001)	0,467 (0,001)	0,232 (0,001)	0,703 (0,001)
3º Fev	-0,634 (0,001)	0,286 (0,001)	0,213 (0,001)	0,349 (0,001)	-0,085 (0,001)	0,687 (0,001)
1º Mar	-0,482 (0,001)	0,484 (0,001)	0,060 (0,002)	0,558 (0,001)	-0,131 (0,001)	0,700 (0,001)
2º Mar	0,301 (0,001)	0,001 (0,556)	-0,150 (0,001)	0,391 (0,001)	-0,133 (0,001)	0,693 (0,001)
3º Mar	0,561 (0,001)	0,292 (0,001)	0,072 (0,001)	0,543 (0,001)	0,262 (0,001)	0,538 (0,001)
1º Abr	0,667 (0,001)	0,210 (0,001)	-0,033 (0,016)	0,435 (0,001)	0,075 (0,001)	0,675 (0,001)
2º Abr	0,687 (0,001)	0,208 (0,001)	0,097 (0,001)	0,414 (0,001)	0,281 (0,001)	0,602 (0,001)
3º Abr	0,677 (0,001)	0,114 (0,001)	0,074 (0,001)	0,258 (0,001)	0,146 (0,001)	0,526 (0,001)

Nota: Entre parênteses os p-valores. Em negrito estão os valores não significativos.

Tabela 28 Autocorrelação Bivariada (Lee) da Produtividade da soja com as variáveis EVI e agrometeorológicas

2012/2013	Produtividade X					
	EVI	Ra	Cw	Et	Gr	Te
1º Ago	0,605 (0,001)	-0,225 (0,001)	-0,583 (0,001)	0,605 (0,001)	0,411 (0,001)	0,664 (0,001)
2º Ago	-0,604 (0,001)	-0,150 (0,001)	-0,575 (0,001)	0,601 (0,001)	0,275 (0,001)	0,672 (0,001)
3º Ago	-0,595 (0,001)	-0,316 (0,001)	-0,492 (0,001)	0,578 (0,001)	0,410 (0,001)	0,539 (0,001)

Nota: Entre parênteses os p-valores. Em negrito estão os valores não significativos. Continua...

Continuação da Tabela 28...

2012/2013	Produtividade X					
	EVI	Ra	Cw	Et	Gr	Te
1º Set	-0,539 (0,001)	-0,125 (0,001)	-0,433 (0,001)	0,497 (0,001)	0,216 (0,001)	0,636 (0,001)
2º Set	-0,537 (0,001)	0,000 (0,491)	-0,314 (0,001)	0,465 (0,001)	-0,036 (0,125)	0,532 (0,001)
3º Set	-0,523 (0,001)	0,002 (0,360)	-0,155 (0,001)	0,550 (0,001)	0,235 (0,001)	0,639 (0,001)
1º Out	-0,465 (0,001)	-0,094 (0,001)	-0,268 (0,001)	0,493 (0,001)	0,036 (0,015)	0,630 (0,001)
2º Out	-0,443 (0,001)	-0,055 (0,007)	-0,253 (0,001)	0,528 (0,001)	0,189 (0,001)	0,647 (0,001)
3º Out	-0,402 (0,001)	0,013 (0,227)	-0,080 (0,001)	0,426 (0,001)	0,305 (0,001)	0,553 (0,001)
1º Nov	-0,128 (0,001)	0,194 (0,001)	0,067 (0,001)	0,448 (0,001)	0,001 (0,479)	0,625 (0,001)
2º Nov	0,151 (0,001)	-0,377 (0,001)	0,068 (0,001)	0,511 (0,001)	0,262 (0,001)	0,656 (0,001)
3º Nov	0,367 (0,001)	0,221 (0,001)	0,099 (0,001)	0,229 (0,001)	-0,328 (0,001)	0,619 (0,001)
1º Dez	0,467 (0,001)	-0,519 (0,001)	-0,573 (0,001)	0,641 (0,001)	0,507 (0,001)	0,627 (0,001)
2º Dez	0,442 (0,001)	-0,050 (0,006)	-0,125 (0,001)	0,641 (0,001)	0,381 (0,001)	0,694 (0,001)
3º Dez	0,484 (0,001)	0,100 (0,001)	-0,091 (0,001)	0,606 (0,001)	0,433 (0,001)	0,657 (0,001)
1º Jan	0,455 (0,001)	0,373 (0,001)	0,286 (0,001)	0,566 (0,001)	0,345 (0,001)	0,667 (0,001)
2º Jan	0,041 (0,005)	-0,160 (0,001)	-0,255 (0,001)	0,466 (0,001)	0,178 (0,001)	0,655 (0,001)
3º Jan	-0,407 (0,001)	-0,056 (0,001)	-0,340 (0,001)	0,432 (0,001)	0,234 (0,001)	0,632 (0,001)
1º Fev	-0,639 (0,001)	-0,054 (0,004)	-0,219 (0,001)	0,572 (0,001)	0,421 (0,001)	0,682 (0,001)
2º Fev	-0,688 (0,001)	0,262 (0,001)	0,202 (0,001)	0,371 (0,001)	0,156 (0,001)	0,642 (0,001)
3º Fev	-0,658 (0,001)	0,390 (0,001)	0,289 (0,001)	0,534 (0,001)	0,279 (0,001)	0,665 (0,001)
1º Mar	-0,525 (0,001)	-0,287 (0,001)	-0,374 (0,001)	0,425 (0,001)	0,142 (0,001)	0,645 (0,001)
2º Mar	-0,162 (0,001)	0,566 (0,001)	0,546 (0,001)	0,481 (0,001)	0,353 (0,001)	0,644 (0,001)
3º Mar	0,132 (0,001)	-0,305 (0,001)	-0,501 (0,001)	0,529 (0,001)	0,408 (0,001)	0,608 (0,001)
1º Abr	0,443 (0,001)	0,481 (0,001)	0,471 (0,001)	0,012 (0,272)	-0,566 (0,001)	0,616 (0,001)
2º Abr	0,746 (0,001)	0,331 (0,001)	0,202 (0,001)	0,570 (0,001)	0,353 (0,001)	0,602 (0,001)
3º Abr	0,756 (0,001)	-0,186 (0,001)	-0,502 (0,001)	0,526 (0,001)	0,287 (0,001)	0,672 (0,001)

Nota: Entre parênteses estão os p-valores. Em negrito estão os valores não significativos.