

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE AGRONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

CARLOS ANTONIO DA SILVA JUNIOR

Estimativa e discriminação de áreas de soja [*Glycine max* L.] no estado do
Paraná com dados mono e multitemporais do sensor MODIS

MARINGÁ – PARANÁ - BRASIL
MARÇO 2014

CARLOS ANTONIO DA SILVA JUNIOR

Estimativa e discriminação de áreas de soja [*Glycine max* L.] no estado do
Paraná com dados mono e multitemporais do sensor MODIS

Dissertação apresentada ao Programa de Pós-graduação em Agronomia, Centro de Ciências Agrárias da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Agronomia.

Área de concentração/Linha de pesquisa:
Solos e Nutrição de Plantas/Sensoriamento Remoto Aplicado à Agricultura.

Orientador: Dr. Marcos Rafael Nanni

MARINGÁ – PARANÁ - BRASIL
MARÇO 2014

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Biblioteca Central - UEM, Maringá – PR., Brasil)

S586e Silva Junior, Carlos Antonio da
Estimativa e discriminação de áreas de soja
[*Glycine max* L.] no estado do Paraná com dados mono
e multitemporais do sensor MODIS / Carlos Antonio da
Silva Junior. -- Maringá, 2014.
xvii, 181 f. : il. col., figs., tabs., mapas

Orientador: Prof. Dr. Marcos Rafael Nanni.
Dissertação (mestrado) - Universidade Estadual de
Maringá, Centro Ciências Agrárias, Departamento de
Agronomia, Programa de Pós-Graduação em Agronomia,
2014.

1. Espectrorradiometria. 2. Geobias. 3. Índices de
vegetação. 4. Redes neurais artificiais. 5.
Sensoriamento remoto. I. Nanni, Marcos Rafael,
orient. II. Universidade Estadual de Maringá. Centro
de Ciências Agrárias. Programa de Pós-Graduação em
Agronomia. III. Título.

CDD 22.ed. 621.3678

FOLHA DE APROVAÇÃO

CARLOS ANTONIO DA SILVA JUNIOR

Estimativa e discriminação de áreas de soja [*Glycine max* L.] no estado do
Paraná com dados mono e multitemporais do sensor MODIS

Dissertação apresentada ao Programa de Pós-Graduação em Agronomia
do Departamento de Agronomia, Centro de Ciências Agrárias da Universidade
Estadual de Maringá, como requisito parcial para obtenção do título de Mestre
em Agronomia pela Comissão Julgadora composta pelos membros:

COMISSÃO JULGADORA

Prof. Dr. Marcos Rafael Nanni

(Presidente – Orientador)

Universidade Estadual de Maringá (UEM)

Departamento de Agronomia

Prof. Dr. Edvard Elias de Souza Filho

Universidade Estadual de Maringá (UEM)

Departamento de Geografia

Prof. Dr. Vitor Matheus Bacani

Universidade Federal de Mato Grosso do Sul (UFMS)

Departamento de Geociências

Aprovada em: 06 de março de 2014.

Local de defesa: Anfiteatro n. II, Bloco J-45, *campus* da Universidade Estadual de Maringá.

DEDICATÓRIA

Aos meus pais, Carlos e Vera,
pelo exemplo e dedicação na
criação dos filhos.

AGRADECIMENTOS

À Deus por iluminar meu caminho e me dar forças para seguir sempre em frente,

À toda minha família, especialmente ao meu pai (Carlos Antonio da Silva), minha mãe (Vera Lucia Capristo Silva) e ao meu irmão (Guilherme Fernando Capristo Silva) pelo apoio, amor, amizade, confiança e incentivo, fatores categóricos para o fechamento de mais esta etapa;

Ao meu orientador e amigo Dr. Marcos Rafael Nanni, pela oportunidade de aperfeiçoamento dos conhecimentos, orientação, compreensão, amizade, companheirismo, liberdade necessária para encontrar quais caminhos trilhar, entre tantas coisas – sempre serei grato;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela concessão da bolsa de mestrado;

À Universidade Estadual de Maringá – UEM, ao Departamento de Agronomia (DAG) e ao Grupo Aplicado ao Levantamento e Espacialização dos Solos - GALeS, que possibilitaram a minha formação;

Aos professores da UEM, os Drs. Cássio Antonio Tormena, Paulo Sérgio Lourenço de Freitas, Antonio Carlos Andrade Gonçalves e Osvaldo Hidalgo da Silva pela paciência e conhecimento transmitido;

Ao professor da Universidade Federal de Mato Grosso do Sul – UFMS, Dr. Vitor Matheus Bacani e ao professor da Universidade Estadual de Maringá – UEM, Dr. Edvard Elias de Souza Filho, pela honra de tê-los em minha banca;

Ao pessoal do PGA, Érika e Reinaldo, que nunca buscaram medir esforços para a minha formação e de todos que passam por esse programa de excelência;

Aos amigos da UEM, Aline Gasparotto, Anderson Antonio da Silva, Caio Staackes, Everson Cezar, Everton Neiro, Franciele Romagnoli, Lucas Maldonado, Marcelo Chicati, Rafael Moreno, Roney Berti, pelas sugestões, discussões e harmonioso convívio, pois mesmos nas conversas ou na hora do café sempre tinham algo a me ensinar;

Aos amigos do INPE, Thiago Frank, Guilherme Mataveli, Bruno Oliveira, Eder Moreira, Gabriel Bertani, Renato Ferreira e Taíssa Rodrigues, pelo ótimo convívio e aprendizagem;

Ao prof. Dr. Laércio Alves de Carvalho pelos ensinamentos, amizade e companheirismo em todas as minhas etapas acadêmicas;

Ao Dr. Márcio de Morisson Valeriano, pela ajuda, aprendizagem e principalmente pelo ensino a verdadeira ciência e de como ser um cientista;

Aos pesquisadores do INPE, os Drs. Antônio Roberto Formaggio, Camilo Daleles Rennó, Flávio Jorge Ponzoni, João Antonio Lorenzetti, Maurício Alves Moreira, que sem sombra de dúvidas me ensinaram muito na pós-graduação em sensoriamento remoto. Muito obrigado;

À Patricia Baia por ser sempre dedicada, companheira, amorosa, me compreender em momentos de angústia e proporcionar muita felicidade;

Enfim, a todos que de alguma maneira contribuíram para a execução desse trabalho e minha formação, seja pela ajuda constante ou por uma palavra de amizade!

Muito Obrigado!!!

EPÍGRAFE

“Podem fazer de tudo para justificar a própria incompetência. Podem me discriminar, criticar, banir ou ferir...

Mas nunca poderão aprisionar as minhas ideias. Não há limites para os meus sonhos e muito menos para aonde eles podem me levar...

Nós estivemos no espaço e iremos ainda mais longe, enquanto eles ficarão, para sempre, presos ao chão pelas correntes da arrogância, da covardia e da mediocridade.”

(MARCOS PONTES)

Estimativa e discriminação de áreas de soja [*Glycine max* L.] no estado do Paraná com dados mono e multitemporais do sensor MODIS

RESUMO

O monitoramento da dinâmica da vegetação, principalmente em atividades agrícolas com a utilização de técnicas de sensoriamento remoto tem não somente alavancado pesquisas, mas também atendendo uma necessidade do reconhecimento dos padrões territoriais de um local. As imagens de satélite, principalmente do sensor MODIS, apresentam potencial relevante no mapeamento de extensas áreas agrícolas no Brasil, uma vez que culturas como a soja são cultivadas na época do verão com constantes presenças de nuvens. Assim, as imagens deste sensor possibilitam por diferentes motivos o mapeamento, tais como: resolução temporal e espectral, faixa de imageamento e disponibilização gratuita. Com isso, o objetivo que norteia este trabalho é verificar o potencial para estimar e mapear áreas cultivadas com a cultura da soja por meio de imagens MODIS com e sem séries-temporais no estado do Paraná. Para caracterização das amostras das áreas de soja foram coletados pontos com GPS distribuídos no Estado. Também foram cultivadas plantas de soja em casa de vegetação para correlacionar leitura espectral laboratorial e orbital. Séries-temporais EVI e PVI de imagens MODIS dos anos-safras 2010/2011 e 2011/2012 foram utilizados para confecção dos mapas de áreas de soja, com algoritmos de rotinas de redes neurais artificiais, análise orientada em geo-objeto, componentes principais, classificação supervisionada, parcialmente não-supervisionada e índices de vegetação. Além disso, foi desenvolvido o índice PCEI (*Perpendicular Crop Enhancement Index*) baseado na linha do solo e determinado por árvore de decisão, para automatizar o mapeamento de áreas com plantas de soja. Os mapas foram avaliados por parâmetros Kappa e Exatidão Global, com comparação feita por teste Z ($\alpha = 0,05$). Os resultados mostraram que o mapeamento realizado pela análise orientada em geo-objeto, redes neurais e PCEI apresentam condições satisfatórias para tal finalidade. A análise da série-temporal utilizada no índice PCEI permitiu distinção de outras culturas agrícolas, sendo analisado desde o preparo do solo até a colheita. O mapeamento e discriminação das áreas de soja no Paraná demonstraram-se viáveis com imagens MODIS, o que na sistematização apresentou resultados dos parâmetros analisados suficientes.

Palavras-chave: Espectrorradiometria. GEOBIA. Índices de vegetação. PCEI. Redes neurais artificiais.

Estimation and discrimination of soybean areas [*Glycine max* L.] in the Paraná State with mono and multi-time data from the MODIS sensor

ABSTRACT

The monitoring of dynamics vegetation, mainly in agricultural activities with the use of techniques of remote sensing not only has increased research, but also answers a need recognition of the territorial patterns of a local. Satellite images, chiefly from MODIS sensor, show a significant potential in the mapping of extensive agricultural areas in Brazil, once crops as the soybeans are cultivated in the summer with constant presence of clouds. Thus, the images from this sensor allows mapping through different reasons, such as: temporal and spectral resolution, swath and free availability. Therewith, the guiding objective of this research is verify the potential to estimate and map cultivated areas with the soybean crop over MODIS images with and without time-series at the Paraná State. For the characterization of samples from soybean areas, were collected points with GPS distributed in the State. Also were cultivated soybean plants in a greenhouse to correlate laboratory and orbital spectral reading. Time-series EVI and PVI of MODIS images from harvests-year 2010/2011 and 2011/2012 were used for confection of the maps of soybean areas, with routines algorithms of artificial neural networks, oriented analysis in geo-object, main components, overseen classification, partially no overseen and vegetation indexes. Furthermore, was developed the PCEI (Perpendicular Crop Enhancement Index) index based on the soil line and determined by decision tree, to automate the mapping of areas with soybean plants. The maps were evaluated through parameters Kappa and Overall Accuracy with comparison done by Z test ($\alpha = 0.05$). The results showed that mapping done over the oriented analysis in geo-object, neural networks and PCEI present satisfactory conditions for this purpose. The analysis of time-series used in PCEI index allows distinction from other agricultural crops, been analyzed since the soil prepare until de harvest. Mapping and discrimination of soybean areas at Paraná demonstrated to be viable with MODIS images what that in systematization showed sufficient results of the analyzed parameters.

Keywords: Spectroradiometry. GEOBIA. Vegetation indices. PCEI. Artificial neural networks.

LISTA DE TABELAS

| | | |
|-----------|---|----|
| Tabela 1 | Principais funções medidas pelos sensores do programa EOS. Fonte: Michael D. King – EOS Senior Project Scientist, 2000..... | 11 |
| Tabela 2 | Características dos dados do sensor MODIS..... | 12 |
| Tabela 3 | Conjunto da configuração do produto MOD13Q1 do sensor MODIS..... | 14 |
| Tabela 4 | Índices de vegetação (IV)..... | 19 |
| Tabela 5 | Descrição das características espectrais e de textura na composição do GEOBIA..... | 32 |
| Tabela 6 | Datas para composição da série-temporal utilizada compreendendo desde o preparo do solo até o estágio final da cultura da soja..... | 39 |
| Tabela 7 | Resumo das variáveis e parâmetros utilizados na segmentação..... | 45 |
| Tabela 8 | Atributos extraídos do eCognition 8.0 para selecionar a classe soja e não-soja | 47 |
| Tabela 9 | Dias Juliano do ano-safra 2010/2011, equações de tendência linear e R^2 para a relação entre as bandas do vermelho e infravermelho próximo, obtidas pelo sensor MODIS..... | 65 |
| Tabela 10 | Dias Juliano do ano-safra 2011/2012, equações de tendência linear e R^2 para a relação entre as bandas do vermelho e infravermelho próximo, obtidas pelo sensor MODIS..... | 65 |
| Tabela 11 | Configurações das redes neurais artificiais aplicadas no mapeamento da soja em dois anos-safras..... | 71 |
| Tabela 12 | Matriz de coeficientes de correlação para imagens do sensor MODIS nos anos-safras 2010/2011 e 2011/2012..... | 76 |
| Tabela 13 | Matriz de covariância para imagens do sensor MODIS nos anos- safras 2010/2011 e 2011/2012..... | 77 |
| Tabela 14 | Matriz de confusão das classificações em função dos diferentes métodos de estimativa de área de soja e seus respectivos valores dos índices κ e EG para o ano-safra 2010/2011..... | 82 |
| Tabela 15 | Matriz de confusão das classificações em função dos diferentes métodos de estimativa de área de soja e seus respectivos valores dos índices κ e EG para o ano-safra 2011/2012..... | 84 |

| | | |
|-----------|--|----|
| Tabela 16 | Erro e precisão do ponto de vista do produtor e do consumidor para as Matrizes de Erros para a classe soja construídas a partir das imagens..... | 85 |
| Tabela 17 | Erro e precisão do ponto de vista do produtor e do consumidor para as Matrizes de Erros para a classe não-soja construídas a partir das imagens..... | 86 |
| Tabela 18 | Teste de hipótese para comparar os resultados de exatidão entre os índices para o ano-safra 2010/2011..... | 87 |
| Tabela 19 | Teste de hipótese para comparar os resultados de exatidão entre os índices para o ano-safra 2011/2012..... | 88 |
| Tabela 20 | Áreas estimadas de soja em hectares por mesorregião do estado do Paraná para o ano-safra 2010/2011..... | 90 |
| Tabela 21 | Áreas estimadas de soja em hectares por mesorregião do estado do Paraná para o ano-safra 2011/2012..... | 91 |
| Tabela 22 | Diferenças entre os mapas de soja e suas classificações para o ano-safra 2010/2011..... | 97 |
| Tabela 23 | Diferenças entre os mapas de soja e suas classificações para o ano-safra 2011/2012..... | 97 |

LISTA DE FIGURAS

| | | |
|-----------|---|----|
| Figura 1 | Curvas espectro-temporal generalizada de <i>pixels</i> puros, com pontos-chaves A, B, C e D das fases fenológicas do trigo de inverno. (Fonte: Pan et al. (2012)). | 6 |
| Figura 2 | Cobertura do Brasil pelos <i>tiles</i> do sensor MODIS (H – horizontal; V – vertical). | 13 |
| Figura 3 | Perfis temporais de NDVI de áreas cultivadas com cereais. | 16 |
| Figura 4 | Gráfico representando o “ <i>Tasseled Cap</i> ” e o PVI. | 18 |
| Figura 5 | Comparação de neurônios artificiais e biológicos. (a) versão de um neurônio artificial que transcreve o neurônio biológico; (b) Estrutura de um neurônio biológico. (Fonte: modificado de Gao (2009)). | 23 |
| Figura 6 | Modelo de um neurônio de uma rede <i>Multi-layer Perceptron</i> (MLP). | 24 |
| Figura 7 | Local da área de estudo, compreendido na região sul do Brasil, estado do Paraná. | 36 |
| Figura 8 | Mapa da distribuição espacial das classes de solos do estado do Paraná. | 37 |
| Figura 9 | Área de estudo representada pelo produto MOD13Q1 e pelos cálculos de mínimos e máximos valores de EVI, além da série-temporal de um ponto de área de soja amostrado, seguido da temporalidade dos estádios fenológicos da soja. | 42 |
| Figura 10 | Fluxograma representativo do processo de desenvolvimento do índice PCEI. | 43 |
| Figura 11 | Fluxograma ilustrando as principais etapas que fazem parte do GEOBIA e mineração de dados e a abordagem proposta para classificar as áreas de soja a partir de imagens de séries-temporais do sensor MODIS. | 44 |
| Figura 12 | Fluxograma representativo do processo de mineração de dados. | 48 |
| Figura 13 | Rotação espectral dos eixos originais com alta correlação para eixos CP descorrelacionados. | 53 |

| | | |
|-----------|--|----|
| Figura 14 | Fluxograma representativo do processo de classificação por meio de imagens MODIS..... | 53 |
| Figura 15 | Plantas de soja cultivadas em vasos experimentais (A) e detalhe da medição espectral da folha (B)..... | 54 |
| Figura 16 | Detalhe do equipamento <i>ASD Plant Probe</i> (A) e visão geral do procedimento da coleta das curvas espectrais das plantas (B)..... | 55 |
| Figura 17 | Curva espectral da folha da soja do espectrorradiômetro (A) e MODIS (B)..... | 56 |
| Figura 18 | Linha do solo obtida pela relação entre a banda do vermelho e infravermelho próximo com dados Terra/MODIS – safra 2010/11 (dias Juliano)..... | 62 |
| Figura 19 | Linha do solo obtida pela relação entre a banda do vermelho e infravermelho próximo com dados Terra/MODIS – safra 2011/12 (dias Juliano)..... | 64 |
| Figura 20 | Exemplos das segmentações realizadas para os anos-safras 2010/2011 (esquerda) e 2011/2012 (direita)..... | 66 |
| Figura 21 | Árvore de decisão gerada pelo algoritmo J48 para o ano-safra 2010/2011..... | 68 |
| Figura 22 | Árvore de decisão gerada pelo algoritmo J48 para o ano-safra 2011/2012..... | 69 |
| Figura 23 | Erro de treinamento e teste para as respectivas configurações (A-1, B-2, C-3, D-4 e E-5) utilizadas em redes neurais artificiais para o ano-safra 2010/2011..... | 73 |
| Figura 24 | Erro de treinamento e teste para as respectivas configurações (A-1, B-2, C-3, D-4 e E-5) utilizadas em redes neurais artificiais para o ano-safra 2011/2012..... | 74 |
| Figura 25 | Descorrelação primeiro e segundo componente principal dos dados pela rotação espectral dos eixos originais dos dois anos-safras 2010/2011 (a) e 2011/2012 (b)..... | 75 |
| Figura 26 | Auto-valores para os componentes realizados das imagens analisadas para os anos-safras 2010/2011 (A) e 2011/2012 (B)..... | 78 |
| Figura 27 | Regressão linear simples entre dados orbital e terrestre para áreas de soja do ano-safra 2010/2011..... | 79 |

| | | |
|-----------|---|-----|
| Figura 28 | Regressão linear simples entre dados orbital e terrestre para áreas de soja do ano-safra 2011/2012..... | 80 |
| Figura 29 | Distribuição espacial de áreas cultivadas com soja no ano-safra 2010/2011 conforme suas respectivas técnicas de classificação..... | 93 |
| Figura 30 | Distribuição espacial de áreas cultivadas com soja no ano-safra 2011/2012 conforme suas respectivas técnicas de classificação..... | 94 |
| Figura 31 | Correlação entre áreas de soja estimadas pelos classificadores e pelo órgão oficial brasileiro para o ano-safra 2010/2011..... | 95 |
| Figura 32 | Correlação entre áreas de soja estimadas pelos classificadores e pelo órgão oficial brasileiro para o ano-safra 2011/2012..... | 96 |
| Figura 33 | Mapas com as respectivas diferenças entre classificadores K-Média x Redes Neurais, K-Média x Componentes Principais, K-Média x GEOBIA, K-Média x CEI, K-Média x PCEI, Redes Neurais x Componentes Principais, Redes Neurais x GEOBIA, Redes Neurais x CEI, Redes Neurais x PCEI, Componentes Principais x GEOBIA, Componentes Principais x CEI, Componentes Principais x PCEI, GEOBIA x CEI, GEOBIA x PCEI e CEI x PCEI (A, B, C, D, E, F, G, H, I, J, K, L, M, N e O, respectivamente) para o ano-safra 2010/2011..... | 100 |
| Figura 34 | Mapas com as respectivas diferenças entre classificadores K-Média x Redes Neurais, K-Média x Componentes Principais, K-Média x GEOBIA, K-Média x CEI, K-Média x PCEI, Redes Neurais x Componentes Principais, Redes Neurais x GEOBIA, Redes Neurais x CEI, Redes Neurais x PCEI, Componentes Principais x GEOBIA, Componentes Principais x CEI, Componentes Principais x PCEI, GEOBIA x CEI, GEOBIA x PCEI e CEI x PCEI (A, B, C, D, E, F, G, H, I, J, K, L, M, N e O, respectivamente) para o ano-safra 2011/2012..... | 103 |

SUMÁRIO

| | | |
|------------|---|-----------|
| 1. | INTRODUÇÃO..... | 1 |
| 2. | OBJETIVOS..... | 3 |
| 2.1. | Objetivo Geral..... | 3 |
| 2.2. | Objetivos Específicos..... | 3 |
| 3. | REVISÃO BIBLIOGRÁFICA..... | 4 |
| 3.1. | Sensoriamento Remoto Aplicado à Agricultura..... | 4 |
| 3.2. | Comportamento Espectro-Temporal de Alvos Agrícolas..... | 5 |
| 3.2.1. | Importância da cultura da soja e seu monitoramento..... | 7 |
| 3.3. | Níveis de Aquisição de Dados..... | 8 |
| 3.4. | Caracterização e Uso do Sensor MODIS do Satélite Terra..... | 10 |
| 3.5. | Índices de Vegetação..... | 15 |
| 3.6. | Métodos de Extração de Informações de Dados de Sensoriamento Remoto..... | 20 |
| 3.6.1. | Técnicas de classificação..... | 20 |
| 3.6.1.1. | redes neurais artificiais (RNA)..... | 22 |
| 3.6.1.2. | GEOBIA (GEographic Object-Based Image Analysis)..... | 27 |
| 3.6.1.2.1. | segmentação em multiresolução..... | 29 |
| 3.6.1.2.2. | mineração de dados..... | 32 |
| 3.6.1.2.3. | processo por árvore de decisão (algoritmo C4.5 – J48)..... | 33 |
| 4. | MATERIAL E MÉTODOS..... | 36 |
| 4.1. | Caracterização e Localização Geográfica..... | 36 |
| 4.2. | Imagens de Sensores Remotos..... | 37 |
| 4.3. | Cálculos dos Índices de Vegetação..... | 39 |
| 4.4. | GEOBIA e Mineração de Dados..... | 43 |
| 4.5. | Métodos de Classificação..... | 48 |
| 4.5.1. | Procedimentos da RNA..... | 48 |
| 4.5.2. | Procedimentos com classificador supervisionado e parcialmente não-supervisionado..... | 51 |
| 4.6. | Avaliação Espectral e Pontos Amostrais de Campo..... | 54 |

| | | |
|------|--|------------|
| 4.7. | Análise Estatística..... | 56 |
| 5. | RESULTADOS E DISCUSSÃO..... | 59 |
| 6. | CONCLUSÕES..... | 105 |
| | REFERÊNCIAS BIBLIOGRÁFICAS..... | 106 |
| | APÊNDICE A..... | 126 |
| | APÊNDICE B..... | 128 |
| | APÊNDICE C..... | 129 |
| | APÊNDICE D..... | 131 |
| | APÊNDICE E..... | 170 |

1. INTRODUÇÃO

O monitoramento da superfície da Terra e da dinâmica de sua vegetação utilizando técnicas de sensoriamento remoto destaca-se nas atividades agrícolas. Hodierno, as culturas agrícolas vêm sendo estudadas principalmente no contexto de avaliações da planta por meio de parâmetros biofísicos (BSAIBES et al., 2009; DUVEILLER et al., 2011) e estimativa de áreas cultivadas (ADAMI et al., 2012; PAN et al., 2012).

Além da dinâmica temporal das culturas agrícolas requererem dados que possibilitem seu acompanhamento, faz-se também necessário o uso de tecnologias e métodos para análise da grandeza desses dados. Estimadores de áreas cultivadas vêm sendo utilizados por meio de imagens de satélites envolvendo conceito de desenho probabilístico, painel de amostragem de áreas e seleção de amostra probabilística (FAO, 1998).

Precedente a estes estimadores, são trabalhados métodos de pré-processamento e classificação das imagens de satélite para estratificação das áreas de interesse (GALLEGO, 2004) o que demanda tempo de trabalho. A título de exemplo utiliza-se, comumente, índices de vegetação, classificações supervisionadas (MaxVer e Redes Neurais Artificiais) e não-supervisionadas¹ (IsoData).

Além desses fatores que precedem o pré-processamento, há possibilidade da presença de cobertura por nuvens da área cultivada, podendo tornar-se impedimento do processo de análise, principalmente durante o período de identificação decisiva da cultura que antecede a colheita, o que poderia surgir com imagens adquiridas do satélite Landsat-5 (LIU et al., 2010) por apresentar resolução temporal de 16 dias.

A obtenção de imagens de satélite é dada de forma sistemática e repetitiva, em faixas do espectro eletromagnético, que permitem diferenciar os alvos da superfície terrestre em função da sua resposta espectral (JENSEN, 2005). Neste contexto, quanto maior for a resolução temporal, maior será a probabilidade de se obter uma imagem livre de cobertura de nuvens (SANO et al., 2007).

A utilização do sensor MODIS (*MODerate-resolution Imaging Spectroradiometer*), a bordo do satélite Terra e Aqua, apresenta-se muito útil para mapeamento de grandes áreas agrícolas (OZDOGAN, 2010; WU e LI, 2012; PENG e GITELSON, 2012). Uma de suas

¹ O termo usual classificação não-supervisionada, seria no presente trabalho após verificação substituído por classificação Parcialmente Não-Supervisionada (PNS), pois após a classificação generalizada aplicada por algoritmo, o usuário terá, em um dado momento, separar as classes para posterior apresentação ou, até mesmo, selecionar os segmentos realizados antes da sua aplicação, como por exemplo, no IsoSeg.

características marcantes para sua escolha deve-se pelo mesmo apresentar resolução temporal quase que diária e produção de imagens com quantização de 12 bits em 36 bandas espectrais. Um dos pontos negativos refere-se a resolução espacial das imagens produzidas sendo no nadir de 250m em duas bandas (0,620 - 0,876 μ m), 500m em cinco bandas (0,459 – 2,155 μ m) e 1000m em 29 bandas (0,405 – 14,385 μ m) (HUETE et al., 1997).

Neste estudo a escolha por se trabalhar com produtos MODIS se deu, basicamente, pela possibilidade de obtenção gratuita das imagens e devido a inexistência de imagens de outros sensores com resolução espacial mais refinada, como, o LISS-III (*Linear Imaging Self-Scanner*) do satélite ResourceSat-1 sem presença de nuvens para o período avaliado.

Com imagens disponíveis advindas de satélites de sensoriamento remoto o desenvolvimento de estudos para identificação e monitoramento de culturas agrícolas é crescente (PENG et al., 2011; SON et al., 2012). Conforme Bernardes et al. (2011), as culturas agrícolas apresentam padrões fenológicos durante algumas fases do seu desenvolvimento que permitem diferenciá-las espectralmente de outras classes vegetais, no qual a utilização de séries temporais de imagens de satélite têm apresentado notoriedade na identificação de alvos agrícolas.

Portanto, o desenvolvimento de mapeamento sistemático de culturas agrícolas no Brasil é um desafio, principalmente devido a sua extensão cultivada e diversos tipos de culturas implantadas. O desafio da sistematização, principalmente no que diz respeito à cultura da soja, é de relevância para o país, pois enorme parte de sua economia é voltada para tal atividade, em que as áreas agrícolas ainda não são conhecidas com exatidão.

Partindo-se desta premissa, a hipótese testada neste trabalho foi a de que o estimador PCEI é superior ou equivalente aos índices existentes para o mapeamento e discriminação sistematizada de culturas agrícolas.

2. OBJETIVOS

2.1. Objetivo Geral

Estimar e mapear áreas cultivadas com a cultura da soja [*Glycine max* (L.) Merr.] por meio de imagens mono e multitemporais MODIS no estado do Paraná.

2.2. Objetivos Específicos

- Comparar e testar a eficiência dos dados de reflectância da soja obtidos nos níveis orbital e terrestre.
- Determinar parâmetros específicos para o desenvolvimento de análise orientada em geo-objeto (GEOBIA) na determinação de áreas de soja;
- Adequar configurações para análise de Redes Neurais Artificiais (RNA), no que diz respeito ao número de camadas e neurônios para determinação de áreas de soja;
- Desenvolvimento de índice de vegetação PCEI (*Perpendicular Crop Enhancement Index*) e determinação de limiar para automatizar a discriminação de áreas de soja;

3. REVISÃO BIBLIOGRÁFICA

3.1. Sensoriamento Remoto Aplicado à Agricultura

O sensoriamento remoto representa, na atualidade, uma tecnologia avançada e em constante aperfeiçoamento, principalmente no que diz respeito à sua aplicação para a agricultura. Por meio desta técnica é possível obter diversas informações das culturas, tais como: índice de área foliar, estimativa de áreas, produção, vigor vegetativo, manejo, dentre outros.

No Brasil, apesar de todo o conhecimento tecnológico, algumas vezes apresenta um modo pessoal de estimar áreas agrícolas, por meio de informações obtidas por profissionais da área. Os chamados “pequenos produtores” são denominados assim por possuírem áreas de pequeno cultivo, porém há um escoamento de sua produção. Uma das grandes dificuldades está presente na estimativa dessas áreas através de imagens de baixa resolução espacial, uma vez que *pixels* mistos não correspondem a uma cultura, dificultando assim sua classificação necessitando das importantes coletas de informações de campo e/ou fornecidas pelos mesmos profissionais da área (WU e LI, 2012).

Para áreas agrícolas com maiores extensões o problema de identificação é minimizado no que se refere a imagens de resolução espacial grosseira e diferentes estágios fenológicos das culturas agrícolas, que podem ser diferenciadas espectralmente através de imagens multitemporais (POTGIETER et al., 2010). Assim, é essencial o conhecimento do calendário agrícola de cada cultura de acordo com a região de cultivo apresentado por um zoneamento agrícola.

As plataformas, ou satélites enviados para a órbita terrestre, são os principais meios para obtenção de dados para estudos de sensoriamento remoto. A bordo destes são acoplados sensores que são capazes de obter informações por meio da radiação eletromagnética (REM) em diferentes faixas ou bandas do espectro eletromagnético. Além disso, periodicamente, esses satélites, segundo suas funcionalidades, revisitam uma mesma área. Para as culturas agrícolas, a REM é integrada e convertida pelos sensores em produtos que possam ser manipuladas, posteriormente pelo usuário. Um dos produtos mais comum refere-se a imagens, expressas em níveis de cinza fornecendo, por exemplo, a relação entre os valores numéricos dos respectivos níveis e algum atributo físico ou morfológico da cultura estudada.

Assim, o sensoriamento remoto na agricultura tem sido atribuído principalmente ao monitoramento e discriminação de áreas agrícolas por meio da utilização de imagens orbitais, em que permite a identificação da cultura agrícola pela interação de diversos tipos de dados em distintas épocas (GIANNOTTI, 2001; SILVA JUNIOR et al., 2013).

O sensoriamento remoto, por meio de imagens multiespectrais, apresenta papel fundamental na composição dos cenários agrícolas, uma vez que o potencial na discriminação das principais culturas se dá pela temporalidade observada da área. Além da discriminação, as informações atualizadas da distribuição da ocupação pela agricultura, bem como informações sobre as proporções de suas mudanças, são cada vez mais necessárias (MATHER, 1999), principalmente para a economia de um país. Desse modo, a necessidade de atualização constante de mensurações de áreas agrícolas e suas tendências e cenários se faz necessário (TONIAL, 2003).

Neste sentido, a utilização de técnicas de sensoriamento remoto tem sido uma alternativa objetiva à identificação de áreas agrícolas no Brasil. As imagens dos sensores TM (*Thematic Mapper*) e ETM+ (*Enhanced Thematic Mapper Plus*) são de resolução espacial intermediária (30 m) e representam os alvos agrícolas em escalas compatíveis para análise ou fins de estimativas de áreas (SANTOS, 2012). A única desvantagem das imagens dos sensores citados para o mapeamento de culturas de verão é a presença contínua de nuvens em suas imagens, sendo a única alternativa a utilização de imagens com resolução espacial menos refinadas, como as do sensor MODIS a bordo dos satélites Terra e Aqua.

3.2. Comportamento Espectro-Temporal de Alvos Agrícolas

As características espectrais de uma vegetação verde sadia são dadas, especialmente, por pigmentos foliares do mesófilo paliçádico (clorofilas *a* e *b*, β -caroteno etc.) na porção visível do espectro eletromagnético (0,4 – 0,7 μ m), espalhamento no mesófilo esponjoso que ocorre no infravermelho próximo (0,7 – 1,2 μ m) e conteúdo de água foliar no infravermelho médio (1,4 – 2,6 μ m), ocorrendo pontos de inflexão (JENSEN, 2009).

Estudos realizados em regiões da China por Pan et al. (2012), apresentam ciclo fenológico do trigo de inverno e seus picos definitivos que o identifica, através da série-temporal utilizando MODIS EVI (Figura 1). Segundo os autores, os picos de reflectância são observados no período vegetativo T2 e T3 (elongação do colmo) e maior absorção no T1 e T4 (semeadura e colheita), fases essas que o caracteriza distintamente de outras culturas.

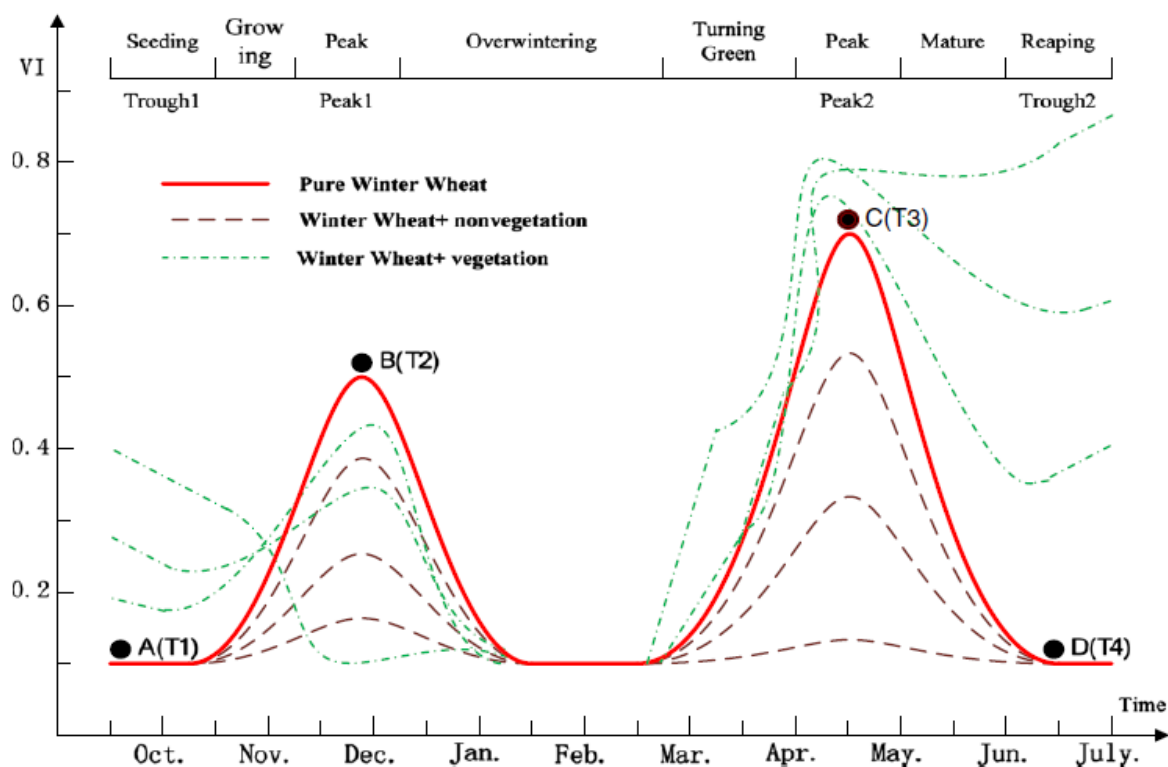


Figura 1. Curvas espectro-temporal gerais de *pixels* puros, com pontos-chaves A, B, C e D das fases fenológicas do trigo de inverno. (Fonte: Pan et al. (2012)).

Além de estimativas de áreas cultivadas tem havido crescente desenvolvimento de trabalhos buscando estimar a produtividade utilizando alguns índices, como área verde (DUVAILLER et al., 2011) e área foliar (GRAY e SONG, 2012). Kouadio et al. (2012) afirmam que há estreita correlação entre a área verde da folha e o rendimento de grãos de trigo aliada a taxa de senescência, o que é preponderante para determinação do rendimento produtivo. Os mesmos autores utilizaram Índice de Área Verde (IAV) por meio de dados espectro-temporais do sensor MODIS, apresentaram alta correlação ($R=0,70$) entre dados oficiais de produção e o cálculo da estimativa, afirmando que esta abordagem será confirmada nos anos agrícolas posteriores.

O comportamento espectro-temporal utilizando sensores multiespectrais (AVHRR, MODIS, ETM+ e IKONOS) com acompanhamento de quatro épocas de cultivo com sensor aerotransportado foi estudado por Seelan et al. (2003), em que o principal objetivo foi o acompanhamento e integração de imagens com agricultura de precisão. Assim, o fator espectral aliado com a temporalidade local, agregou informações continuadas para tomadas de decisões. Os mesmos autores concluíram que a eficácia da aplicação de agrotóxicos por taxa variável foi eficiente, constatado por meio de sensoriamento remoto e imagens multitemporais e espectrais.

Bernardes et al. (2011), avaliaram metodologia de aplicação de séries-temporais com imagens do sensor MODIS de acordo com o comportamento espectral da cultura da soja no estado do Mato Grosso com a utilização de componentes principais. Os mesmos constataram que ao utilizar todas as imagens contendo todo o ciclo da cultura, os resultados apresentaram-se superiores quando utilizado apenas uma única data.

3.2.1. Importância da cultura da soja e seu monitoramento

A soja é a principal oleaginosa produzida e consumida no mundo. Seu primeiro derivado (farelo), por ser rico em proteínas é destinado ao consumo animal por meio de rações. O segundo subproduto se destina ao consumo humano de diversas formas, como óleo, farinha, sabão etc. No Brasil, sua produção iniciou na década de 70 e no decorrer do tempo se consolidou como o segundo maior produtor mundial. A produção brasileira que bateu recordes no final do século XX é um dos principais destaques econômicos do Centro-Sul do Brasil, além de estar presente nas regiões Norte e Nordeste do país (BRUM et al., 2005).

Na região sul do Brasil, mais especificamente estado do Paraná, área de interesse desse estudo, a produção de soja em larga escala pode ser considerada recente, remontando ao ano de 1978, primeiro ano em que constam registros estatísticos sobre esse cultivo no Instituto Brasileiro de Geografia e Estatística (IBGE). Posteriormente, os produtores foram se organizando e na década de 90 a soja já estava consolidada na região expandindo-se para outras localidades do Estado.

A cultura da soja é viável economicamente, pois movimenta boa parte da renda do país, principalmente pelo seu comércio internacional.

O monitoramento das safras não só da soja, mas também de outras atividades agrícolas no país se faz necessário, principalmente os de áreas cultivadas são realizados de formas subjetivas pelos órgãos governamentais. Para Gurgel et al. (2001), nas últimas décadas, o aparecimento do sensoriamento remoto, principalmente o de nível orbital, tornou possível o monitoramento e acompanhamento da evolução espacial e temporal das mudanças da superfície terrestre e que passaram a ser estudadas de forma objetiva.

A importância do sensoriamento remoto é evidente nesta vertente, pois com a obtenção de informações em tempo hábil, sobre a extensão, as condições fenológicas e o potencial de produção das culturas é possível estabelecer estratégias de ação para comercialização, regulação de estoques estratégicos, o que torna de grande importância

econômica para um país (CHEN, 1990). Como o custo das tradicionais técnicas de medidas no campo é oneroso por demandar muito tempo e mão de obra especializada para áreas extensas, a utilização de sensores remotos torna-se assim uma alternativa (THENKABAIL et al., 1994).

Algumas metodologias utilizadas atualmente para estimar áreas de soja com o sensoriamento remoto são apresentados de forma satisfatória com análise por componentes principais (BERNARDES et al., 2011), orientação em geo-objeto (SILVA JUNIOR et al., 2014), índices de vegetação (RIZZI et al., 2009; RISSO et al., 2012), classificação automática (ADAMI et al., 2010) etc.

Além disso, a utilização de sensores remotos para estudos com a cultura da soja podem ser confirmados pelo mundo todo, sendo utilizado para discriminação e quantificação de áreas (SILVA JUNIOR et al., 2014), identificação de estágio fenológico (SAKAMOTO et al., 2010), estimativa de produtividade por teor de clorofila (PENG e GITELSON, 2012), dentre outros.

3.3. Níveis de Aquisição de Dados

Os dados de sensoriamento remoto podem ser obtidos em diferentes níveis, dependendo do veículo ou sistema de suporte para a operação de um sistema sensor. O veículo ou sistema de suporte chama-se plataforma (NOVO, 2010).

O tipo de plataforma a ser definido depende do objetivo e para qual finalidade serão utilizados os dados sensorizados, para que sejam definidos diversos parâmetros como, angulação, altitude, correção de rotação (*roll*, *pitch* e *yaw*), direção de voo, dentre outros.

Em relação ao nível laboratorial, a porção da matéria estudada é reduzida para realizar suas autenticações espectrais. Alguns fatores de angulações e distância são primordiais para esse nível de aquisição. À medida que o sensor se distancia do alvo de estudo, mais complexo será sua leitura espectral.

Neste nível de aquisição de informações pode-se ter o controle do ambiente, como por exemplo, a iluminação e o controle da “atmosfera”. A maneira de caracterização de alvos por este meio pode ser instalada em mastros, barcos, tripés, balões, aeronaves não tripuladas (*vant's*), dentre outros (MOREIRA, 2011).

Os sensores utilizados para caracterizar e medir a radiação refletida ou emitida pelos alvos em campo ou laboratório, geralmente são medidos de acordo com a região do espectro

eletromagnético em que operam. Por exemplo, os radiômetros (ou espectrorradiômetros) são sistemas-sensores que apresentam diversos níveis de aquisição, além de trabalharem em diferentes regiões do espectro. O *range* de variação pode ficar em intervalos de 400-700 nm quando medidos apenas no visível ou até mesmo de 350-2500 nm, compreendendo desde o azul ao infravermelho distante. Todas as caracterizações são mensuradas ao longo do espectro da leitura, apresentando como resultado o fator de reflectância.

A reflectância é representada pela letra grega “ ρ ”, sendo adimensional e expressa a razão entre o fluxo refletido e o incidente, variando de acordo com o alvo estudado, o posicionamento, o sensor e a fonte de iluminação ($\rho(\lambda) = \Phi_r(\lambda) / \Phi_i(\lambda)$).

No nível orbital, considera-se toda aquisição de informações geradas através de sensores a bordo de satélites que orbitam a Terra, sejam eles tripulados ou não. Um exemplo de tripulado em nível orbital é o *Space Shuttle*, que persistiu em diversas espaçonaves com missões espaciais e em seguida retornar a Terra. Dentre eles está o *Shuttle Radar Topography Mission* (SRTM) com a missão de obter o modelo digital do terreno em 11 dias.

Para o estudo do planeta Terra em suas mais diversas áreas são então utilizados satélites artificiais como, por exemplo, a série Landsat, Terra, Aqua, Resourcesat, Formosat, Pleiades, Quickbird, Spot, NOAA, dentre outros inúmeros já lançados.

As principais diferenças dentre os mais diversos satélites são os sensores a bordo e seu objetivo. A órbita é uma das definições que auxiliam no entendimento das distinções entre eles, uma vez que satélites meteorológicos e de comunicação são apenas geossíncronos, observando a Terra constantemente apenas em uma mesma área.

Em relação aos satélites que apresentam imageamento da Terra por completo, tem sua órbita caracterizada principalmente como heliossíncrona e suas distinções variam de acordo com o sensor, podendo diferenciar entre suas resoluções (espectral, espacial, radiométricas e temporal) e o tipo de sistema de varredura (*pushbroom* e *whiskbroom*).

Em estudos agronômicos são as mais diversas áreas que utilizam o nível orbital com diferentes sistemas-sensores. Merlin et al. (2010), utilizando dois sistemas (MODIS e Formosat-2) estudaram a temperatura de superfície de áreas agrícolas. Além disso, Liu et al. (2010) observaram o estresse da cultura do milho avaliando sua massa seca com a utilização do satélite Landsat-5 e 7, com seus respectivos sensores TM e ETM+, aliado com razão de bandas e índices de vegetação.

A relação do campo com estudos a nível orbital é crescente na última década, sendo realizados estudos de discriminação de áreas agrícolas, índice de área foliar, estimativa de produtividade, auxílio na agricultura de precisão, dentre outros.

3.4. Caracterização e Uso do Sensor MODIS do Satélite Terra

No ano de 1999 ocorreu o lançamento do primeiro sensor MODIS (*MODerate resolution Imaging Spectroradiometer*). Devido ao desenvolvimento do sensor MODIS, Huete et al. (1997) propuseram um novo índice de vegetação em que diminuísse o efeito do solo e da atmosfera, denominado EVI (*Enhanced Vegetation Index*), que passou a ser disponibilizado gratuitamente pelo EOS (*Earth Observing System*) juntamente com o NDVI (*Normalized Difference Vegetation Index*; ROUSE et al., 1974). Além do sensor MODIS, o programa EOS lançou diversos sensores a bordo de satélites, com variáveis funcionalidades (Tabela 1) em que o homem pudesse compreender o planeta Terra.

A disponibilização rápida e continuada das imagens MODIS permite análises regulares da vegetação em nível global, incluindo a avaliação de aspectos fenológicos da vegetação e a detecção de mudanças de uso e cobertura do solo (HUETE et al., 2002). A estreita correlação entre a dinâmica espaço-temporal da vegetação e seus índices, corrobora o potencial dos mesmos no monitoramento da cobertura vegetal sobre extensas áreas, como *pixel* de no mínimo 250m (ou seja, 6,25 ha), com resolução temporal de 1-2 dias.

Com o lançamento das plataformas Terra (EOS AM) e Aqua (EOS PM), ambos transportando o sensor MODIS, que fornecem recobrimento global e contínuo diariamente, com resoluções espaciais variando de 250 a 1000m, foi constatado por Coura (2007) que os dados deste sensor podem ser usados também no monitoramento espectral da vegetação a nível regional e para o mapeamento efetivo das classes de uso do solo. Na Tabela 2 está apresentado com maiores detalhes o sensor MODIS (NASA, 2013).

Tabela 1. Principais funcionalidades medidas pelos sensores do programa EOS. Fonte: Michael D. King – EOS Senior Project Scientist, 2000.

| Componente | Funcionalidade | Sensores |
|-----------------------|-------------------------------|---|
| Atmosfera | Propriedade das nuvens | MODIS, GLAS, AMRSR-E, ASTER, SAGE III. |
| | Fluxo de energia radiante | CERES, ACRIM III, MODIS, AMSR-E, GLAS, MISR, AIRS, ASTER, SAGE III. |
| | Precipitação | AMSR-E. |
| | Química da troposfera | TES, MOPITT, SAGE III, MLS, HIRDLS, LIS. |
| | Química da estratosfera | MLS, HIRDLS, SAGE III, OMI, TES. |
| | Propriedades dos aerossóis | SAGE III, MODIS, MISR, OMI, GLASS. |
| | Temperatura da atmosfera | AIRS/AMSU_A/HSB, MLS, HIRDLS, TES, MODIS. |
| | Umidade da atmosfera | AIRS/AMSU_A/B, MLS, SAGE III, HIRDLS, Poseidon 2/JMR/DORIS, MODIS, TES. |
| | Relâmpagos | LIS. |
| Radiação solar | Irradiância solar total | ACRIM III, TIM. |
| | Irradiância espectral do solo | SIM, SOLSTICE. |

Conforme Gao (2009), as bandas MODIS 1 a 7 (0,620 a 2,155 μm) podem ser utilizados para estudar a superfície da terra e os limites e propriedades de aerossóis. As bandas 8 a 16 (0,405 a 0,877 μm) são as mais úteis no estudo de cores do oceano, fitoplâncton e biogeoquímica. Todas as bandas restantes (17 a 36 – 0,890 a 14,385 μm) são adequadas para quantificar o vapor de água atmosférico, superfície e temperatura da nuvem, ozônio, bem como a temperatura da atmosfera. Portanto, os dados MODIS são adequados não só para o estudo da superfície da Terra, mas também da sua atmosfera.

Tabela 2. Características dos dados do sensor MODIS.

| | |
|-------------------------------|--|
| Dimensão do Swath | 2.330 × 10 km (no nadir) |
| Resolução Espacial | 250 m (bandas 1–2) 500 m (bandas 3–7) 1.000 m (bandas 8–36) |
| Resolução Espectral | 36 bandas cobrindo 0,4–14,4 μm |
| Resolução Radiométrica | 12 bits |
| Resolução Temporal | 1–2 dias |
| Cruzamento Equatorial | 10:30 a.m. (Terra) ou 1:30 p.m. (Aqua) |
| Taxa de Dados | 10,6 Mbps (dia de pico); 6,1 Mbps (média orbital) |
| Aplicações | superfície/nuvens/aerossóis Cor de oceanos/fitoplâncton/ Biogeoquímica Vapor d'água da atmosfera, superfície/nuvens Temperatura/propriedades das nuvens/ozônio |

As imagens do sensor MODIS são disponibilizadas em formas de produtos em grades regulares, denominada de *tile*. Esta denominação refere-se a um comprimento x,y que representa uma imagem do sensor. Um total de 460 *tiles* é necessário para o recobrimento de todo o globo terrestre sendo que, para o Brasil, é necessário um total de 16 (Figura 2). Os produtos são separados de acordo como o seu objetivo que, para o estudo da Terra e sua vegetação, podem ser: MOD 09, 11, 12, 13, 14, 15, 16, 17, 43 e 44.




Figura 2. Cobertura do Brasil pelos *tiles* do sensor MODIS (H – horizontal; V – vertical).

Índices globais de vegetação do sensor MODIS foram projetados para fornecer comparações espaciais e temporais consistentes de condições de vegetação. As bandas encontradas no produto MOD13Q1 são o azul, vermelho e o infravermelho próximo, centrados em 469, 645 e 858 nm, respectivamente, são usadas para determinar os índices de vegetação diária.

É encontrado neste produto o NDVI, que dá continuidade para aplicações históricas de séries-temporais e também o EVI que minimiza o fundo de variações de dossel e mantém a sensibilidade sobre as condições de vegetação densa. O EVI também usa a faixa azul para remover a contaminação atmosférica causada pela fumaça e camada fina de nuvens. O sensor

MODIS com o produto MOD13Q1 com os índices NDVI e EVI, são produtos calculados a partir da reflectância de superfície bi-direcional com correção atmosférica que são mascarados por água, nuvens, aerossóis pesados e sombras de nuvens.

Os dados MOD13Q1 são fornecidos a cada 16 dias com 250 metros de resolução espacial como um produto de nível 3 (ou seja, processamentos) e coleção 5.0 (com mudanças científicas, estruturais, regras de processamentos e metadados) em grade na projeção senoidal (Figura 2). Na falta de uma faixa azul 250m, o algoritmo usa o EVI faixa azul 500m para corrigir os efeitos atmosféricos residuais, com artefatos espaciais insignificantes. Na aquisição desse produto, há detalhes sobre cada banda e suas correções para reflectância, conforme a Tabela 3 (NASA, 2013).

Tabela 3. Conjunto da configuração do produto MOD13Q1 do sensor MODIS.

| Conjunto de dados científicos (HDF Layers) | Saída | Quantidade Byte | Intervalo válido | Fator de multiplicação de escala |
|--|--------------|------------------------|-------------------------|---|
| 250m 16 dias NDVI | NDVI | 16 bit | -2000, 10000 | 0,0001 |
| 250m 16 dias EVI | EVI | 16 bit | -2000, 10000 | 0,0001 |
| 250m 16 dias VI Qualidade detalhada | <i>Bits</i> | 16 bit | 0, 65534 | NA |
| 250m 16 dias red Reflectância (Banda 1) | Reflectância | 16 bit | 0, 10000 | 0,0001 |
| 250m 16 dias NIR Reflectância (Banda 2) | Reflectância | 16 bit | 0, 10000 | 0,0001 |
| 250m 16 dias blue Reflectância (Banda 3) | Reflectância | 16 bit | 0, 10000 | 0,0001 |
| 250m 16 dias MIR Reflectância (Banda 7) | Reflectância | 16 bit | 0, 10000 | 0,0001 |
| 250m 16 dias vista ângulo zenital | Graus | 16 bit | -9000, 9000 | 0,01 |
| 250m 16 dias ângulo zenital solar | Graus | 16 bit | -9000, 9000 | 0,01 |
| 250m 16 dias ângulo azimutal relativo | Graus | 16 bit | -3600, 3600 | 0,1 |
| 250m 16 dias composição dias do ano | Dia Juliano | 16 bit | 1, 366 | NA |
| 250m 16 dias confiabilidade resumida do <i>pixel</i> | Posição | 8 bit | 0, 3 | NA |

Embora o sensor MODIS não seja hiperespectral (divisão de imagens em todo o espectro eletromagnético), o mesmo representa um avanço em termos de resolução espectral. Está a uma órbita de 705 km síncrona com o sol, com seu campo de visada de $\pm 55^\circ$ do nadir. Apresenta também um dos mais abrangentes subsistemas de calibração existentes em um instrumento de sensoriamento remoto. Seu hardware de calibração inclui um difusor solar, um monitor de estabilidade do difusor solar, um instrumento de calibração espectrorradiométrica, um corpo negro para o termal e uma abertura para visada do espaço (JENSEN, 2009). Com todas as características mencionadas e seus benefícios, encontram-se as mais diversas pesquisas realizadas com este sensor.

Estudos realizados por Rizzi e Rudorff (2007) utilizando o índice de área foliar (IAF) do sensor MODIS (produto MOD13Q1, coleção 4) tiveram como objetivo estimar a produtividade da cultura da soja no estado do Rio Grande do Sul. Os mesmos autores obtiveram resultados mais detalhados da produtividade ao utilizar o IAF implementado no modelo agrônômico.

Em relação ao estudo global com o sensor MODIS, Pittman et al. (2010) mapearam áreas agricultáveis utilizando a cobertura total terrestre com dados térmicos e NDVI para identificar a fenologia das áreas. Obtiveram como resultado que as melhores culturas a serem mapeadas foram à soja e o milho por apresentarem folhagens intensas.

Além disso, são os mais diversos os estudos de desenvolvimento de modelos que melhor identificam áreas cultiváveis. Gusso et al. (2012), apresentaram o MCDA (*Modis Crop Detection Algorithm*), em que utiliza série-temporal com imagens EVI para estimar áreas de soja. Outro desenvolvimento foi obtido por Rizzi et al. (2009), em que propuseram o índice CEI (*Crop Enhancement Index*), em que também utiliza série-temporal EVI (produto MOD13Q1) e apresenta um limiar de corte acima de 0,28 para representar áreas de soja.

3.5. Índices de Vegetação

Os índices de vegetação foram desenvolvidos para ressaltar o comportamento espectral apenas de áreas em que continham algum tipo de vegetal, com intuito de excluir o solo e demais alvos terrestres.

O monitoramento da superfície terrestre por meio de sensores remotos tem sido utilizado com sucesso na detecção sazonal da dinâmica da vegetação (SAKAMOTO et al., 2005). Assim, o uso de dados de sensoriamento remoto para o monitoramento da dinâmica agrícola necessita como fundamental o imageamento contínuo da vegetação (GOETZ, 1997).

Nas últimas décadas índices espectrais de vegetação como o NDVI (*Normalized Difference Vegetation Index*) e o EVI (*Enhanced Vegetation Index*) apresentaram grande utilidade e potencial no mapeamento agrícola.

Segundo Moreira e Shimabukuro (2004), na literatura são encontrados mais de cinquenta índices de vegetação, sendo quase todos obtidos da razão entre medidas de reflectância nas faixas espectrais do vermelho e infravermelho próximo do espectro eletromagnético. Assim, os índices realçam o comportamento espectral da vegetação correlacionando-os com os parâmetros biofísicos da mesma (ROSA, 2003).

O NDVI foi desenvolvido por Rouse et al. (1974) para produzir um índice que separa vegetação verde do brilho do solo que está presente na mistura espectral na imagem, ao qual foi utilizado primeiramente com dados digitais do Landsat-1 com o sensor MSS (*MultiSpectral Scanner*). Um exemplo é relacionado por Junges (2008), em que os cereais de inverno, aveia, cevada e trigo, apresentam comportamento semelhante pelo comportamento dos valores de NDVI (Figura 3), e que fica difícil à separação entre elas, sendo necessárias máscaras de cultivo.




Figura 3. Perfis temporais de NDVI de áreas cultivadas com cereais.

Os valores numéricos do NDVI podem variar entre -1 a 1 e comumente a vegetação está integrada a valores positivos, uma vez que há maior reflectância no comprimento de onda do infravermelho próximo e menor no vermelho. Alguns alvos, como água e neve, apresentam maior reflectância no comprimento de onda referente ao vermelho (600 – 750 nm) quando comparado ao infravermelho próximo (750 a 1100 nm), apresentando valores negativos de NDVI. Geralmente, solos nus e rochas apresentam reflectância no comprimento de onda referente ao vermelho e do infravermelho próximo praticamente na mesma

intensidade, exibindo seus valores de NDVI próximo de zero (LILLESAND e KIEFER, 1999).

Conforme estudos realizados por Hatfield e Prueger (2010), em que utilizaram diversos índices de vegetação para caracterizar a fenologia de culturas agrícolas (milho, soja, trigo e canola), concluíram que há necessidade de se utilizar diversos índices para melhor captar as características das diversas culturas.

Com o surgimento do sensor MODIS é proposto por Huete et al. (1999) o *Enhanced Vegetation Index* (EVI), que minimiza o efeito do solo e da atmosfera. Ao estudar a cultura da soja utilizando imagem MODIS, Rizzi (2004) constatou que o contraste entre os valores do EVI é maior em relação ao NDVI e que proporciona melhor distinção espectral comparado aos demais alvos.

Outro índice de vegetação é baseado no conceito de linha do solo, obtendo-se o PVI (*Perpendicular Vegetation Index*). Diversos índices de vegetação se baseiam no fato de que solos expostos num gráfico bidimensional formado por uma banda no visível (vermelho) *versus* uma banda no infravermelho próximo ocorrem aproximadamente uma linha denominada linha do solo (NANNI e DEMATTÊ, 2006).

A vegetação estudada em uma imagem será proporcional à distância ortogonal euclidiana no gráfico bidimensional, entre os pontos de vegetação e a linha do solo (HUETE, 1989). Mutuamente, a distância euclidiana baseada nos índices de vegetação tem seu índice ortogonal complementar que está relacionado com as propriedades óticas dos solos para baixas quantidades de vegetação (FUKUHARA et al., 1979).

Essa linha é produzida realizando-se uma regressão linear simples entre as duas bandas, em uma amostra de *pixels* de solo exposto ou uma cena completa. Conhecendo-se a relação, todos os *pixels* desconhecidos em uma imagem que apresentam a mesma relação nos valores das reflectâncias são admitidos como solo exposto. Os *pixels* desconhecidos que apresentam distância da linha do solo por terem valores de reflectância maiores na banda do infravermelho próximo são assumidos como vegetação. Para os que se distanciam da linha do solo por sua reflectância da banda do vermelho são assumidos como água.

A Figura 4 formada pelas linhas tracejadas e sólidas é a de um "*tasseled cap*", tal como referido pela primeira vez por Kauth e Thomas (1976). O ponto D representa um crescimento vegetativo intermediário com o solo a um teor de água intermediária. A distância perpendicular a partir do ponto D para a linha AB representa o PVI de Richardson e Wiegand (1977).

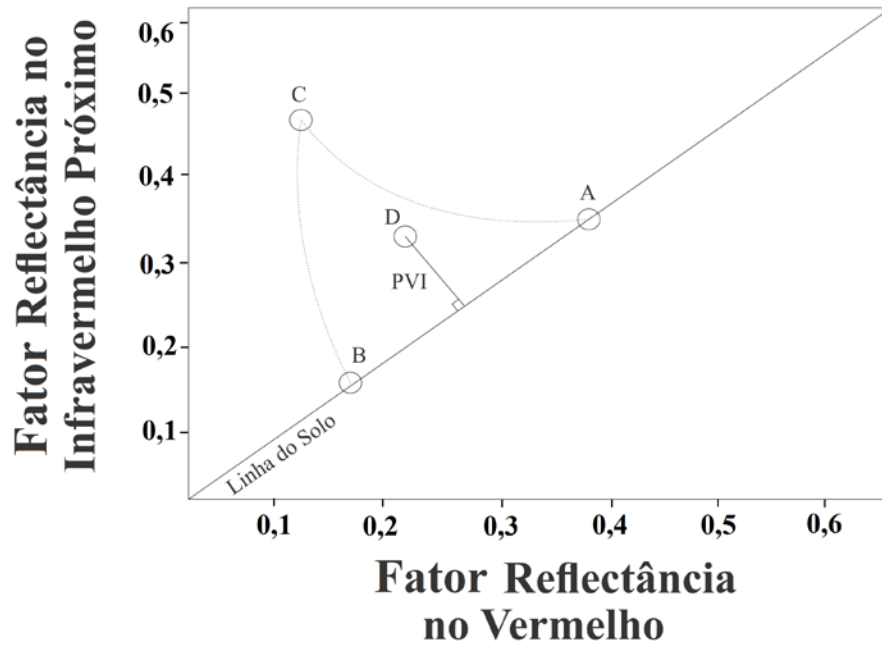


Figura 4. Gráfico representando o “*Tasseled Cap*” e o PVI.

O PVI, como o próprio nome diz, utiliza a distância perpendicular para cada coordenada de *pixel* para a linha de solo. Determina-se a equação da linha do solo pela regressão do fator de reflectância do solo exposto, do vermelho (variável dependente) *versus* infravermelho próximo (variável independente), como descrito na Equação 1. E para determinar a linha perpendicular utiliza-se a Equação 2.

$$Lx = a_0 + a_1 Ly_{IVP} \quad (1)$$

$$\rho_V = b_0 + b_1 \rho_{IVP} \quad (2)$$

sendo: L – reflectância; ρ_{IVP} e ρ_V - reflectâncias na faixa espectral do infravermelho próximo e do vermelho, respectivamente; e o b_0 e b_1 estão apresentados pelas Equações 3 e 4.

$$b_0 = \rho_V - b_1 \rho_{IVP} \quad (3)$$

$$b_1 = \frac{-1}{a_1} \quad (4)$$

em que: a_1 é o coeficiente angular da reta; as intersecções das duas linhas estão apresentados pela Equações 5 e 6.

$$Lx_v = \frac{b_1 a_0 - b_0 a_1}{b_1 - a_1} \quad (5)$$

$$Ly_{IVP} = \frac{a_0 b_0}{b_1 - a_1} \quad (6)$$

Para encontrar a distância entre a intersecção (Lx_v e Ly_{IVP}) e a coordenada do *pixel* (ρ_{IVP} e ρ_v) utiliza-se o Teorema de Pitágoras (Equação 7).

$$\sqrt{(Lx_v - \rho_v)^2 + (Ly_{IVP} - \rho_{IVP})^2} \quad (7)$$

Assim, existem na literatura diversos índices de vegetação para os mais diversos casos estudados ao longo de décadas utilizando diferentes níveis espectrais. O resumo de alguns índices de vegetação e os autores proponentes são relacionados na Tabela 4.

Tabela 4. Índices de vegetação (IV).

| Equação | Índice | Referência |
|---|-------------|-------------------------------|
| (ρ_{IVP}/ρ_v) | RATIO | Pearson e Miller (1972) |
| (ρ_v/ρ_{IVP}) | RVI | Jordan (1969) |
| (ρ_{IVP}/ρ_v) | RVI Inverso | Richardson e Wiegand (1977) |
| $(\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)$ | NDVI | Rouse et al. (1974) |
| $(\rho_{IVP} - c \times \rho_v)$ | WDVI | Clevers (1988) |
| $\sqrt{((\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)) + 0,5}$ | TVI | Rouse et al. (1974) |
| $\sqrt{ ((\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)) + 0,5 }$ | TTVI | Silleos et al. (2006) |
| $((\rho_{IVP}/\rho_v) - 1)/((\rho_{IVP}/\rho_v) + 1)$ | NRVI | Baret & Guyot (1991) |
| $\frac{((\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)) + 0,5}{ ((\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)) + 0,5 \times \sqrt{ ((\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)) + 0,5 }}$ | CTVI | Perry e Lautenschlager (1984) |
| $(\rho_{IVP} - \rho_G)/(\rho_{IVP} + \rho_G)$ | GNDVI | Gitelson et al. (1996) |
| $2,5(\rho_{IVP} - \rho_v)/(\rho_{IVP} + 6\rho_v - 7,5\rho_B + 1)$ | EVI | Huete et al. (1997) |
| $[(\rho_{IVP} - \rho_v)/(\rho_{IVP} + \rho_v)] \times (1 + L)$ | SAVI | Huete (1988) |
| $[(2\rho_{IVP} + 1) - \sqrt{(2\rho_{IVP} + 1)^2 - 8(\rho_{IVP} - \rho_v)}]/2$ | MSAVI 2 | Qi et al. (1994) |
| $a(\rho_{IVP} - a\rho_v - b)/(\rho_v + a\rho_{IVP} - ab)$ | TSAVI | Baret et al. (1989) |
| $(\rho_{IVP} - a\rho_v - b)/(1 + a^2)^{1/2}$ | PVI | Richardson e Wiegand (1977) |

RVI, “ratio vegetation index”; NDVI, “normalized difference vegetation index”; WDVI, “weighted difference vegetation index”; TVI, “transformation vegetation index”; TTVI, “Thiam’s transformed vegetation index”;

NRVI, “normalized ratio vegetation index”; CTVI, “corrected transformed vegetation index; GNDVI, “green normalized difference vegetation index”; EVI, “enhanced vegetation index”; SAVI, “soil adjusted vegetation index”; MSAVI, “modified soil adjusted vegetation index”; TSAVI, “transformed soil adjusted vegetation index”; PVI, “perpendicular vegetation index”.

3.6. Métodos de Extração de Informações de Dados de Sensoriamento Remoto

Na extração de informações obtidas por meio de imagens de sensoriamento remoto há o interesse da discriminação das variações das reflectâncias dos alvos imageados. Como base da extração é a interpretação do analista, uma das formas mais comuns é atribuir cores para integrar o espectro eletromagnético que o olho humano consiga distinguir. Com isso, surgiram as técnicas de classificação digital de imagens, com o intuito de extrair informações anulando a subjetividade da interpretação humana.

3.6.1. Técnicas de classificação

A classificação de imagens está inserida entre os procedimentos metodológicos de rotinas de tratamento digital de imagem, conforme descrito em Jensen (2009) e Novo (2010), que podem ser sintetizadas em três principais etapas: pré-processamento, realce e classificação.

As classificações podem ser divididas em supervisionadas, a qual utiliza informações espectrais de cada *pixel* para achar regiões homogêneas na imagem (Máxima Verossimilhança-MaxVer) ou a informação espectral de cada *pixel* mais a informação espectral que envolve a relação com seus vizinhos (*Bhattacharya*), ambos através de treinamento prévio dos alvos a serem classificados. E o parcialmente não-supervisionado (ISOSEG), que por meio do método exploratório definem-se os limiares de similaridade e área (*pixels*), que classifica em regiões (CUNHA, 2009).

Segundo estudos realizados por Yang et al. (2011), avaliando classificadores de imagens de alta resolução (SPOT 5) e realizando simulações em resoluções espaciais de 20m (SPOT 4) e 30m (Landsat/ETM⁺) para identificação de classes de milho, algodão, sorgo e cana-de-açúcar apresentam que o MaxVer obteve melhor desempenho em relação ao algoritmo utilizando distância Mahalanobis (ISOSEG), corroborando com resultados encontrados por Pan et al. (2012) ao utilizar o MaxVer na identificação de trigo de inverno com imagens MODIS. Apontando ainda para os resultados de Yang et al. (2011), consideram

que não houve diferença no desempenho dos classificadores em relação às diferentes resoluções, no entanto a inclusão da banda SWIR (*Short-Wave InfraRed*) na imagem do SPOT 5 melhorou consideravelmente a identificação das culturas.

Os classificadores tem por objetivo a associação de conjuntos de classes espectrais a específicos objetos da superfície e é feita através de técnicas matemáticas conhecidas por reconhecimento de padrões (NOVO, 2010). Conforme Gao (2009) para se entender a matemática dos classificadores, deve ser descrito a matriz de *pixels* (Equação 8) e a de classes (Equação 9).

$$DN_x = \begin{Bmatrix} DN_1 \\ DN_2 \\ \vdots \\ DN_n \end{Bmatrix} \quad (8)$$

$$u_j = \begin{Bmatrix} C_{1j} \\ C_{2j} \\ \vdots \\ C_{mj} \end{Bmatrix} \quad (9)$$

em que: DN (*Digital Number*, isto é, número digital); n é o número total de bandas espectrais utilizados na classificação e DN_i (i varia de 1 a n) é o número de *pixel* digital X na banda espectral i th. Assim, a matriz DN_x tem uma dimensão de uma coluna por n linhas; m é o número total de classes de informação a ser classificado e C_{ij} é a média de DN na classe j da banda i (j varia de 1 até m).

Os classificadores parcialmente não-supervisionados não requerem, *a priori*, da participação do analista para a classificação da imagem. Este tipo de classificador é praticamente todo automatizado por computador, exceto na fase de atribuição das classes em que se deseja apoiar o estudo. Por meio de padrões classificados, o analista irá proceder a essas atribuições, identificando grupos de *pixels* reconhecidos espectralmente. A maioria desses classificadores busca na imagem similaridade na distância e nos padrões espectrais, também chamado de *clustering*, ou seja, características espectrais similares.

Por outro lado, existem os classificadores supervisionados que requer previamente do conhecimento das classes que se deseja, ou seja, com interesse de pesquisa. Todos os

algoritmos enquadrados nesta categoria necessitam de treinamento e controle na escolha das amostras das áreas desejadas e que sejam bem representadas para não haver confusão em sua aplicação. Na fase de treinamento deve-se buscar boa precisão e o algoritmo que mais se adeque ao estudo, para que as classes representem o mais fielmente possível às categorias identificadas pelo usuário.

3.6.1.1. redes neurais artificiais (RNA)

A ideia precursora de redes neurais artificiais (RNAs), também chamado de redes neurais, foi apresentada pela primeira vez há mais de meio século atrás por McCulloch e Pitts (1943).

Na época não foi encontrada qualquer aplicação até a década de 70. E no final de 1980 as RNAs foram aplicadas à análise de dados de sensoriamento remoto multiespectrais. Conforme Gao (2009), este ressurgimento do interesse em classificação de imagens é atribuído principalmente aos avanços na tecnologia de computação e da descoberta de algoritmos supervisionados. Desde então, grandes esforços têm sido direcionados para a construção de modelos de redes neurais para explorar a sua utilidade na classificação de dados de sensoriamento remoto. Até o presente momento têm-se revelado uma alternativa viável para o mapeamento automático da Terra em escala global, devido à maior precisão e capacidade de fornecer informações adicionais sobre incertezas (GOPAL et al., 1999).

Neurônios artificiais são nós ou unidades que recebem entradas a partir de um número de nós conectados. Todas as conexões entre os nós são análogos aos dendritos de um neurônio biológico. Os sinais de entrada que são alimentados para este nó artificial são combinados linearmente ou não linear para gerar uma saída (soma), por meio de uma função de transferência (limiar) (Figura 5a). A saída passada para outros neurônios artificiais através de outra conexão semelhante a do axônio (Figura 5b). Cada unidade funciona como uma máquina de processamento de reconhecimento de padrões simples em que os dados de entrada são avaliados em relação à força sináptica e uma saída é produzida. Computacionalmente, um neurônio artificial pode ser implantado como uma soma ponderada de todos os sinais de entrada que entram de forma numérica (GAO, 2009).




Figura 5. Comparação de neurônios artificiais e biológicos. (a) versão de um neurônio artificial que transcreve o neurônio biológico; (b) Estrutura de um neurônio biológico. (Fonte: modificado de Gao (2009)).

Conforme menciona Braga et al. (2007), uma das características mais importantes das redes neurais artificiais é a capacidade de aprender com exemplos. O conhecimento é adquirido por meio de intensidades das conexões entre os neurônios. Assim, consistindo em um processo iterativo de ajuste de parâmetros e pesos, que armazenam no final do processo conhecimento do ambiente externo.

A partir do modelo proposto por McCulloch e Pitts (1943) foram derivados vários outros modelos que permitem a produção de uma saída qualquer e com diferentes funções de ativação. As redes neurais são definidas de acordo com a sua arquitetura, sendo que existem modelos que possuem apenas uma única camada e outras possuem diversas.

Uma das arquiteturas de redes neurais amplamente utilizada é a rede multicamada (MLP, *Multi-layer Perceptron*), em que os neurônios são organizados em duas ou mais camadas. As entradas são conectadas aos elementos processadores básicos que são, por sua vez, interconectados com elementos de outras camadas ou a saída da rede (CINTRA, 2010; HAYKIN, 2008).

Os pesos em RNA são gerados de modo que os resultados são dependentes das entradas reais e do estado interno da rede gerando, assim, um modelo para os padrões de aprendizagem. Isto permite usar algoritmos em análises econômicas e estatísticas. Dentre as mais conhecidas é a MLP (MIEHIE et al., 1994; LIM et al., 1999).

A Figura 6 representa um esquema de uma rede *perceptron* múltiplas camadas. Para esse tipo de arquitetura existem duas fases: a *forward* e a *backward*.

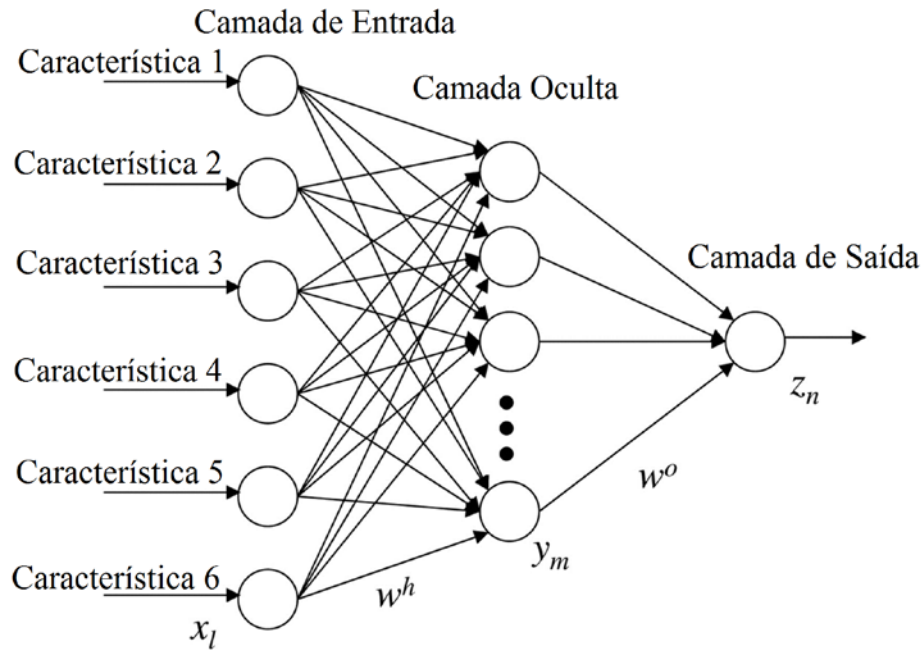


Figura 6. Modelo de um neurônio de uma rede *Multi-layer Perceptron* (MLP).

Na fase *forward* (para frente) os pesos sinápticos são fixos e a resposta da rede é calculada por um conjunto prescrito dos sinais de entrada. Essa fase é análoga ao processo de filtragem do algoritmo de mínimos quadrados (HAYKIN, 2008). Na fase *backward* (retorno), os ajustes dos pesos sinápticos são calculados com o propósito de minimizar uma função custo definida como a soma dos erros quadráticos.

O treinamento com a supervisão do usuário caracterizado por um conjunto de saídas da rede, ao utilizar o algoritmo *backpropagation*, os valores são comparados aos calculados pela própria rede (Equação 10).

$$e_k(n) = d_k(n) - y_k(n) \quad (10)$$

em que: e_k é o erro calculado pela diferença entre d_k (saída desejada); y_k é a saída calculada pela rede no neurônio k da camada de saída; e n é o número do padrão de treinamento comparado naquele momento.

Em continuação a comparação, mede-se a soma dos erros quadráticos da rede (Equação 11).

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (11)$$

sendo: C o conjunto que possui todos os neurônios que fazem parte da camada de saída; n o número padrão do treinamento analisado naquele momento.

Por meio da soma dos erros quadráticos calculado para cada padrão de treinamento, tem-se o EQM (Erro Quadrático Médio) dado pelas médias dos erros quadráticos da rede dos N padrões (Equação 11).

$$\varepsilon_m = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (12)$$

O algoritmo *backpropagation* é definido pela retropropagação e redução do EQM, com a utilização do cálculo de gradiente descendente como critério para o ajuste do conjunto de pesos sinápticos. O ajuste do peso j do neurônio k para um instante $n+1$ é dado pela Equação 13.

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (13)$$

de modo que $\Delta w_{kj}(n)$ é o valor de correção, descrito pela Equação 14.

$$\Delta w_{kj}(n) = \alpha \delta_k(n) y_j(n) \quad (14)$$

em que: α a taxa de aprendizado da rede; $\delta_k(n)$ é o gradiente local do neurônio k ; e $y_j(n)$ é uma das entradas provindas de um neurônio da camada anterior ou uma das entradas da rede (caso k faça parte da primeira camada oculta), isto é, uma das entradas do neurônio k no instante n . Em que o gradiente local é dado pela Equação 15.

$$\delta_k(n) = e_k(n) f'_k(v_k(n)) \quad (15)$$

sendo que: f'_k é a derivada da função de ativação do neurônio k ; $v_k(n)$ é a atividade interna do neurônio k e e_k é o sinal de erro do neurônio k .

O cálculo da correção dos pesos sinápticos depende do erro calculado no neurônio k , quando este faz parte da camada de saída, em que é apresentado o valor desejado. Entretanto, quando o neurônio está na camada oculta (neurônio j), não é possível calcular o erro utilizando os mesmos cálculos para o neurônio de saída k . Assim, o erro do neurônio oculto j é calculado em função dos erros dos neurônios de saída aos quais ele está conectado. A Equação 16 representa o gradiente de um neurônio oculto j (HAYKIN, 2008).

$$\delta_j(n) = f'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (16)$$

desse modo: j é o neurônio oculto e k é um neurônio de saída ao qual j está conectado.

Para ter um equivalente biológico, Konečný et al. (2010) mostram que os neurônios são projetados para o processamento paralelo de dados fornecidos e ao mesmo tempo, podem ser utilizados para tarefas de classificação como, por exemplo, na gestão do conhecimento (SVOBODA, 2007).

Na utilização de redes neurais artificiais na agricultura a visão humana para julgamento de treinamento assume papel importante. A seleção visual na forma de polígonos em processo de criação de amostras é um exemplo de tais julgamentos. As amostras de treinamento em polígonos são importantes porque tem fortes ligações com o rendimento final, ou seja, funciona na percepção de identificação de talhões de áreas agrícolas, reflectância, textura, dentre outros (OIDE et al., 1995).

Redes neurais artificiais classificadoras têm sido utilizadas com sucesso para a solução de vários problemas ligados à atividade agrícola, como o florescimento e a maturação fisiológica da soja (ELIZONDO et al., 1994), predição de produtividade de soja (KAUL et al., 2005), qualidade em grãos de milho (LIAO et al., 1993), classificação de grãos para semente (LUO et al., 1999), produtividade do milho (LIU et al., 1999) e na direção de tratores agrícolas (PINTO et al., 1999).

Para Picoli (2006), a utilização de RNA com a finalidade de estimar a produtividade agrícola da cana-de-açúcar por talhão, utilizando variáveis quantitativas, qualitativas e espectrais apresentou resultados satisfatórios. O mesmo autor utilizou a rede tipo *Multi-layer Perceptron* (MLP), com uma camada oculta em que foi utilizado o algoritmo *backpropagation* para treinamento da rede. Andrade et al. (2003), explicam que os objetos visíveis na imagem podem ser espectralmente muito próximos, e sua discriminação visual pode ser possível quando utilizados outros atributos além dos espectrais, como o exemplo de Martins et al. (2007), em que utilizaram a textura na sua classificação utilizando-se RNA.

3.6.1.2. GEOBIA (GEographic Object-Based Image Analysis)

A capacidade de distinção de alvos devido a estudos urbanos com sensores de alta resolução espacial modificou um dos principais usos do sensoriamento remoto neste contexto, ou seja, o mapeamento da cobertura e uso do solo (RIBEIRO e KUX, 2009).

Para atender novos desafios metodológicos de interpretação de imagens de alta resolução espacial, foi necessário o desenvolvimento de análises orientadas não somente para os valores representados nos níveis de cinza, mas também a forma dos objetos e sua relação para com a vizinhança (SCHIEWE e TUFTE, 2007).

Deste modo, foram desenvolvidos os classificadores que utilizam a técnica GEOBIA (*Geographic Object-Based Image Analysis*) que busca aprimorar e auxiliar o desempenho dos processos automatizados de classificação de imagens. Assim, a modelagem matemática *fuzzy* (lógica “nebulosa”) possui recursos que permitem a sistematização e reprodução do conhecimento do intérprete humano (CARVALHO, 2011).

Assim, a análise GEOBIA implica o uso de redes semânticas que podem conter um ou mais níveis de classificação conectados de modo que se possa simular a visão contextual do analista (ALMEIDA, 2010).

Com isso, para superar os problemas devido à heterogeneidade do *pixel* e, por exemplo, variabilidade de culturas agrícolas nas imagens obtidas por sensores remotos, à técnica baseada em objeto tem sido cada vez mais utilizada em sensoriamento remoto (BLASCHKE, 2010). A ideia básica da análise baseada em objetos da imagem (GEOBIA) é a segmentação e a construção de uma rede hierárquica de objetos homogêneos que, no caso de classificações das culturas, é a de traçar limites. Uma vez que uma imagem é segmentada, utilizam-se simultaneamente diversos tipos de dados como valores de *pixel*, informação

contextual, características de objetos vizinhos e relações hierárquicas (BAATZ e SCHÄPE, 2000). No processo de classificação todos os *pixels* na totalidade do objeto são atribuídos à mesma classe e elimina, assim, o problema da grande variação e mistura espectral. A vantagem da metodologia GEOBIA, são as características dentro de campo que caracterizam cada cultura, assim necessitando de ser identificado e avaliado para ser utilizado no processo de classificação subsequente (PEÑA-BARRAGÁN et al., 2011).

A separação dos objetos por meio de segmentação das imagens de satélite deu-se com o início das altas resoluções espaciais e que agora utilizam também baixas e médias (SILVA JUNIOR et al., 2014). A segmentação decompõe uma imagem em regiões ou objetos formados por *pixels* (GONZALEZ e WOODS, 2007). Segundo Blaschke (2010), define segmentos como regiões geradas por um ou mais critérios de homogeneidade em uma ou mais dimensões do espaço de atributos.

Dessa forma, os objetos gerados pelos algoritmos de segmentação são aproveitados na classificação. Em aplicações específicas com base geográfica, como o uso de imagens de sensoriamento remoto, o termo GEOBIA também é empregado, já que há o enfoque no caráter espacial da análise (JOHANSEN et al., 2010). Assim, o pré-requisito para se proceder com a GEOBIA é gerar objetos pela segmentação (BAATZ e SCHÄPE, 2000). A criação dos objetos permite a determinação de atributos baseados nos próprios objetos como atributos estatísticos, texturais, de forma, topológicos e semânticos. Os últimos ficam disponíveis após uma primeira classificação dos objetos das imagens, por exemplo, parques podem ser considerados áreas florestadas dentro de uma mancha urbana (BENZ et al., 2004) ou até mesmo florestas legais podem ser consideradas em meio à cultura da soja (SILVA JUNIOR et al., 2014).

Vale lembrar que variável é o mesmo que atributo, como é utilizado, no geral, na literatura de GEOBIA. É possível criar diferentes níveis de segmentação em uma abordagem multiresolução, ou seja, imagens distintas. Assim, cada objeto distingue seus objetos vizinhos, o que permite respeitar as bordas de cada um deles pelo analista. Com isso, juntamente com o uso dos diferentes atributos dos objetos, permite a estruturação espacial e semântica do conteúdo de uma imagem pela inserção do conhecimento especialista na rede hierárquica (BENZ et al., 2004).

A utilização da classificação orientada a objeto apresentou resultados satisfatórios na detecção de talhões (bordas) agrícolas em relação às técnicas de classificação não orientadas a objetos (FOCKELMANN, 2013). Lucas et al. (2007), realizaram um trabalho de mapeamento

de áreas agrícolas com imagens multitemporais utilizando classificação baseada em objetos. Os mesmos autores apresentaram que esta classificação forneceu uma aproximação viável para o mapeamento e monitoramento das culturas agrícolas, sendo passível de ser empregado operacionalmente.

Goltz et al. (2008), mencionam resultados positivos na detecção de áreas já mapeadas de reforma agrícola, utilizando rede hierárquica baseada no brilho das imagens índice de vegetação. A utilização do mapeamento de áreas de soja utilizando o GEOBIA foi realizado por Silva Junior et al. (2014), em que obtiveram resultados satisfatórios com aproximação do levantamento obtido por órgãos oficiais.

3.6.1.2.1. segmentação em multiresolução

O critério da segmentação multiresolução se enquadra na abordagem de crescimento de regiões, que é um processo de segmentação interativo no qual regiões (polígonos) adjacentes são agrupadas segundo algum critério de similaridade estabelecido pelo algoritmo utilizado. A diferença entre os valores dos atributos de duas regiões é calculada e testada em relação a um limiar máximo de similaridade fornecido pelo analista. Caso o valor verificado for inferior ao limiar estabelecido, as regiões são agrupadas. Este processo continua até que toda a imagem seja segmentada (FONSECA, 2000).

Além do limiar de similaridade, o analista também estabelece um limite mínimo de tamanho dos objetos. Na segmentação multiresolução, a regra de similaridade é estabelecida a partir do conceito de heterogeneidade interna das regiões. A heterogeneidade se estabelece da diferença entre o atributo de uma provável região e a soma dos valores deste mesmo atributo para as regiões que a compõem. Assim, na segmentação são calculadas as heterogeneidades para os atributos de cor e forma (que são ajustados pelo tamanho dos objetos). A soma ponderada (pesos fornecidos pelo analista) destas duas heterogeneidades forma o critério de similaridade f que é expresso pela Equação 17 (DEFINIENS, 2006).

$$f = w \bullet h_{cor} + (1 - w) \bullet h_{forma} \quad (17)$$

em que: w é o peso do atributo cor no processo de segmentação $[0,1]$; h_{cor} e h_{forma} é a heterogeneidade da cor e da forma, respectivamente.

A cor constitui-se de uma soma ponderada dos desvios padrões de cada banda para uma determinada região. O peso de cada banda é estabelecido pelo analista [0,1]. A Equação 18 representa a cor.

$$cor = \sum_c w_c \cdot \sigma_c \quad (18)$$

sendo: w é o peso atribuído a cada banda multiespectral; σ é o desvio padrão; e c é a nomenclatura para cada banda.

Para a heterogeneidade de cor é dada pela Equação 19.

$$h_{cor} = \sum_c w_c \left(n_{união} \cdot \sigma_c^{união} - \left(n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2} \right) \right) \quad (19)$$

em que: $n_{união}$ é número de *pixels* do possível objeto a ser formado; $\sigma_c^{união}$ é o desvio padrão do possível objeto a ser formado para cada banda c ; n_{obj1} é o número de *pixels* do objeto 1; σ_c^{obj1} é o desvio padrão do objeto 1 para cada banda c ; n_{obj2} é o número de *pixels* do objeto 2; e σ_c^{obj2} é o desvio padrão do objeto 2 para cada banda c .

A forma é um atributo composto, em que para isso necessita-se de compacidade e suavidade (Equação 20). E a suavidade (Equação 21) é a razão entre o perímetro do objeto e o *bounding box*, isto é, retângulo envolvente paralelo às bordas da imagem com menor comprimento possível.

$$cp = \frac{l}{\sqrt{n}} \quad (20)$$

$$sv = \frac{l}{b} \quad (21)$$

desse modo: l o perímetro do objeto; n o tamanho do objeto em número de *pixels*; e b o perímetro do *bounding box*.

Para a heterogeneidade de forma é a soma ponderada das heterogeneidades de compacidade e suavidade, sendo que o peso é estabelecido pelo analista (Equação 22). A Equação 23 expressa a heterogeneidade para a compacidade e para a heterogeneidade para a suavidade é dada pela Equação 24.

$$h_{forma} = w_{cp} \bullet h_{cp} + (1 - w_{cp})h_{sv} \quad (22)$$

$$h_{cp} = n_{união} \bullet cp_{união} - (n_{obj1} \bullet cp_{obj1} + n_{obj2} \bullet cp_{obj2}) \quad (23)$$

$$h_{sv} = n_{união} \bullet sv_{união} - (n_{obj1} \bullet sv_{obj1} + n_{obj2} \bullet sv_{obj2}) \quad (24)$$

sendo que: w_{cp} é o peso atribuído à compacidade [0,1]; h_{cp} e h_{sv} são a heterogeneidade para compacidade e suavidade, respectivamente; $cp_{união}$ é a compacidade do possível objeto a ser formado para cada banda c ; cp_{obj1} e cp_{obj2} são as compacidades do objeto 1 e 2, respectivamente, para cada banda c ; $sv_{união}$ é a compacidade do possível objeto a ser formado para cada banda c ; e sv_{obj1} e sv_{obj2} são as compacidades do objeto 1 e 2, respectivamente, para cada banda c .

Em comparação com métodos baseados em *pixels*, a aplicação da abordagem baseada em objetos oferece a possibilidade de avaliar por meio das características espectrais, texturais, contextuais e recursos hierárquicos. As categorias dos objetos podem ser caracterizadas em dois grandes grupos (Tabela 5): 1) objeto da informação espectral baseada nos valores de média e desvio padrão; 2) objeto da informação textural baseada na matriz de nível de cinza devido sua ocorrência (GLCM) proposto por Haralick et al. (1973) e implementado por Definiens (2006).

Tabela 5. Descrição das características espectrais e de textura na composição do GEOBIA.

| Categoria/Nome | Equação |
|---------------------------|---|
| Espectral | |
| Média | $\frac{1}{\#P_{Obj}} \sum_{(x,y) \in P_{Obj}} C_k(x,y)$ |
| Desvio Padrão | $\sqrt{\frac{1}{\#P_{Obj}} \sum_{(x,y) \in P_{Obj}} \left(c_k(x,y) - \frac{1}{\#P_{Obj}} \sum_{(x,y) \in P_{Obj}} c_k(x,y) \right)^2}$ |
| Textura | |
| GLCM <i>homogeneity</i> | $\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$ |
| GLCM <i>dissimilarity</i> | $\sum_{i,j=0}^{N-1} P_{ij} i - j $ |
| GLCM <i>entropy</i> | $\sum_{i,j=0}^{N-1} P_{ij} (-\ln P_{ij})$ |

em que: $P_{Obj} = \{(x, y) : (x, y) \in Obj\}$ é o conjunto de *pixels* de um objeto de imagem;

$\#P_{Obj}$ = número total de *pixels* contidos em P_{Obj} ;

$c_k(x, y)$ = valor da camada de imagem em *pixels* (x, y) , em que (x, y) são as coordenadas dos *pixels*;

i = número da linha da matriz de co-ocorrência;

j = número da coluna da matriz de co-ocorrência;

$P_{i,j}$ = valor normalizado da célula i, j :
$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}}$$

$V_{i,j}$ = valor da célula i, j da matriz de co-ocorrência;

N = número de linhas ou colunas da matriz de co-ocorrência.

3.6.1.2.2. mineração de dados

Os sistemas que são baseados em conhecimento são aqueles modelados em um ambiente computacional, como, p.e., o conhecimento do foto-intérprete emulando a sua capacidade de combinar dados de diferentes fontes e formatos na análise de imagens de sensores remotos (FEITOSA et al., 2005).

Os sistemas de mineração de dados são empregados para manejar ampla quantidade de informações usando técnicas de aprendizado por computação para extrair ou auxiliar a evidenciar padrões nestes dados e na descoberta de conhecimento (CARVALHO, 2011).

O termo “descoberta de conhecimento” foi criado durante o primeiro workshop sobre *Knowledge Discovery in Databases* (KDD) em 1989 para enfatizar que o conhecimento é o produto final de uma descoberta orientada aos dados. Foi popularizada nos campos da inteligência artificial e da aprendizagem de máquina (FAYYAD et al., 1996).

Descoberta de conhecimento é mais conhecida e utilizada pelo termo “mineração de dados”. No entanto, a mineração de dados é apenas um componente (ainda que seja central) do processo geral de descoberta de conhecimento.

Conforme Carvalho (2011), a mineração de dados envolve a transformação dos mesmos em informações ou fatos sobre o domínio descrito pelo banco de dados. Descoberta de conhecimento é o processo de nível mais elevado de obtenção de informações por meio da mineração de dados e conversão desta informação em conhecimento por meio da interpretação e integração com o conhecimento existente (HAN e KAMBER, 2001).

É antiga a utilização destes sistemas na extração de informações em imagens de sensoriamento remoto. Conforme Bock e Lessing (2000), há diversos sistemas baseados em conhecimentos que são utilizados na interpretação de fotografias aéreas e imagens orbitais de média resolução espacial (30 m), sendo o SPAM (McKCOWN et al., 1985), SIGMA (MATSUYAMA e HWANG, 1990), ERNEST (NIEMANN et al., 1990), MESSIE (CLÉMENT et al., 1993), AIDA (LIEDTKE, 1997) e o geoAIDA (BÜCKNER et al., 2001). Estes sistemas integram, em combinações variadas, os seguintes itens: algoritmos de segmentação, estruturação de classes na forma de redes semânticas, classificação baseada em regras e a possibilidade de integração de imagens multisensores e/ou dados vetoriais (CARVALHO, 2011).

3.6.1.2.3. processo por árvore de decisão (algoritmo C4.5 – J48)

Entre os diversos algoritmos aplicados para classificação de imagens, a utilização de árvores de decisão tem aumentado nos últimos anos, pois apresenta certa vantagem sobre outros métodos. Uma árvore de decisão é um classificador baseado em regras não paramétrico que funciona como uma "caixa branca", porque tanto a sua estrutura (formada por várias divisões) e seus resultados finais (folhas terminais) são fáceis de interpretar (PEÑA-BARRAGÁN et al., 2011). Outras vantagens que se pode destacar são: método de fácil treinamento, de rápida execução, podendo gerenciar dados em diferentes escalas e pode ser utilizado para recurso de seleção/redução (PAL e MATHER, 2003).

As árvores de decisão se adequam favoravelmente no procedimento GEOBIA, uma vez que as saídas de fase de segmentação e inúmeros recursos são relacionados ao objeto da árvore e é bem adequado para classificá-los e dimensionar qual melhor descreve cada classe (LALIBERTE et al., 2007).

Pesquisas utilizando árvores de decisão têm demonstrado bom desempenho no uso de dados remotamente detectados para a análise da cobertura geral da terra (FRIEDL e BRODLEY, 1997), os tipos de cobertura vegetal (BROWN DE COLSTOUN et al., 2003), fatores de ocorrência de fogo (LOZANO et al., 2008), tipos de floresta tropical (SESNIE et al., 2008) e o rendimento das culturas (ZHENG e MOSKAL, 2009). No entanto, os estudos com árvores de decisão ainda não foram amplamente avaliados com culturas agrícolas.

Existem disponíveis, diferentes programas computacionais e algoritmos especializados para a mineração de dados. Entretanto, um dos mais utilizados é a plataforma WEKA (HALL et al., 2009) com o algoritmo C4.5 (QUINLAN, 1993) que faz uso da técnica de mineração de dados pela indução de árvores de decisão. Além do C4.5, existem outros algoritmos que fazem uso desta técnica, tais como o ID3 (precursor do C4.5) e o CART (HAN e KAMBER, 2001).

O algoritmo C4.5 é amplamente utilizado, testado e validado por vários pesquisadores (GOLDSCHMIDT e PASSOS, 2005), o que comprova a sua qualidade. Conforme recomendado por Vieira (2010), o C4.5 possui uma série de parâmetros a se conhecer, como fator de confiança, número mínimo de instâncias por nó-folha, número de ramificações e poda ou não-poda, que podem ser configurados a fim de gerar o melhor resultado.

Esse algoritmo é um dos utilizados na árvore de decisão. Inicialmente o C4.5 é alimentado com um conjunto de amostras de treinamento oriundos da seleção da segmentação. Assim, trabalha com uma medida do valor de informação, que representa o total esperado que seja necessário para fornecer a classe de uma instância (WITTEN et al., 2011). A partir do cálculo é verificado o ganho de informação, que é uma medida da vantagem de se utilizar um atributo correto em vez de outro (VIEIRA, 2010), e mostra o valor informacional de criar um galho a partir de um determinado atributo (WITTEN et al., 2011).

Para o cálculo do algoritmo C4.5 na avaliação da separação dos nós da árvore de decisão, o ganho de informação, considerando a partição da base de dados associada ao nó em análise, está descrita pela Equação 25; a Equação 26 representa o ganho de informação de cada atributo e a Equação 27 a seleção do atributo com maior ganho de informação obtido sobre a partição em análise.

$$\inf o(S) = \sum_{j=1}^k \frac{freq.C_j, S}{|S|} \cdot \log_2 \left(\frac{freq(C_j, S)}{|S|} \right) bits \quad (25)$$

$$\inf o_x(T) = \sum_{i=1}^n \frac{|T_i|}{|T|} \cdot \inf o T_i \quad (26)$$

$$gain(X) = \inf o(T) - \inf o_x(T) \quad (27)$$

sendo: S representa a partição da base de dados; $freq.(C_j, S)$ é o número de vezes em que a classe C_j apresenta em S ; $|S|$ é o número de casos do conjunto S ; k indica o número de classes distintas; T representa a quantidade de ocorrências na partição em análise; e T_i é a quantidade de ocorrências de uma classe contidas no conjunto T .

A construção de uma árvore de decisão C4.5 favorece as classes dominantes com um tamanho considerável de amostra de treinamento, enquanto as anteriores são muitas vezes inferiores a este procedimento. Este efeito pode ser reduzido por meio da relação de ganho. A árvore C4.5 é adequada para a classificação de dados de sensoriamento remoto, em que apenas uma pequena amostra de treinamento está à disposição do algoritmo, mesmo que seja projetado principalmente para análise de uma enorme quantidade de dados numéricos e nominais medidos em centenas de milhares de registros (GAO, 2009).

No mapeamento da vegetação de um parque nacional com 11 categorias, uma árvore de decisão C4.5 apresentou exatidão global de 82,05%, com um coeficiente Kappa de 0,80 a partir de cenas do *Enhanced Thematic Mapper Plus* (BROWN DE COLSTOUN et al., 2003). Tal como acontece com todas as árvores de decisão, em que mesmo utilizando o algoritmo C5.0 a influência é considerável pelo tamanho da amostra de treinamento.

4. MATERIAL E MÉTODOS

4.1. Caracterização e Localização Geográfica

A área de estudo compreendeu o estado do Paraná, na região sul do Brasil, localizado entre as coordenadas geográficas de Latitude 22°29' a 26°43'S e Longitude 48°20' a 54°38'W (Figura 7) com uma área aproximada de 199.314,850 km². A altitude é variável, sendo que 52% do território são superiores a 600m e somente 3% são inferiores a 300m. Para o clima, são caracterizados três tipos predominantes, que segundo a classificação de *Köppen-Geiger* são: Cfa (subtropical com chuvas bem distribuídas durante o ano e verões quentes), Cfb (subtropical com chuvas bem distribuídas durante o ano e verões amenos) e Cwa (subtropical com verões quentes e invernos secos, ocorre no extremo noroeste do Estado).

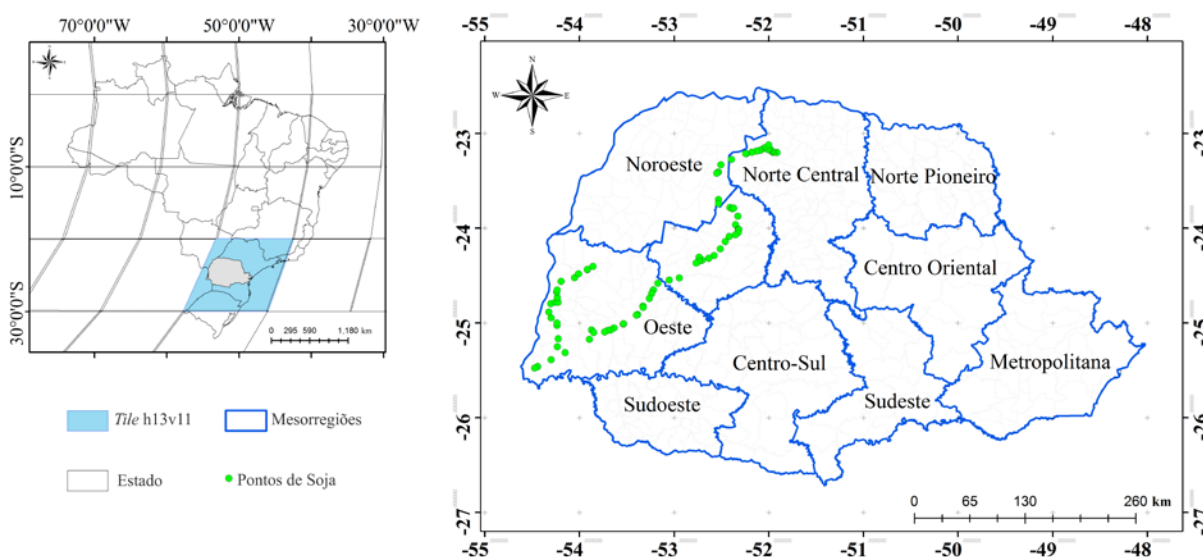


Figura 7. Local da área de estudo, compreendido na região sul do Brasil, estado do Paraná.

Os solos do estado são caracterizados, segundo o sistema brasileiro de classificação (EMBRAPA, 2013), como LATOSSOLOS, ARGISSOLOS, CAMBISSOLOS e NITOSSOLOS, tendo-se o primeiro sua maior porção territorial (Figura 8).

Decorrente das condições climáticas e pela presença de solos férteis, o Estado do Paraná apresenta aptidão para diferentes culturas agrícolas, destacando-se, dentre elas, a cultura da soja.

Segundo dados oficiais da CONAB (Companhia Nacional de Abastecimento), o estado do Paraná apresentou área semeada com a cultura da soja para a safra de 2010/2011 de

4.590.500 ha, 2011/2012 de 4.460.600 ha e 2012/2013 de 4.752.800 ha (CONAB 2011; 2012; 2013).

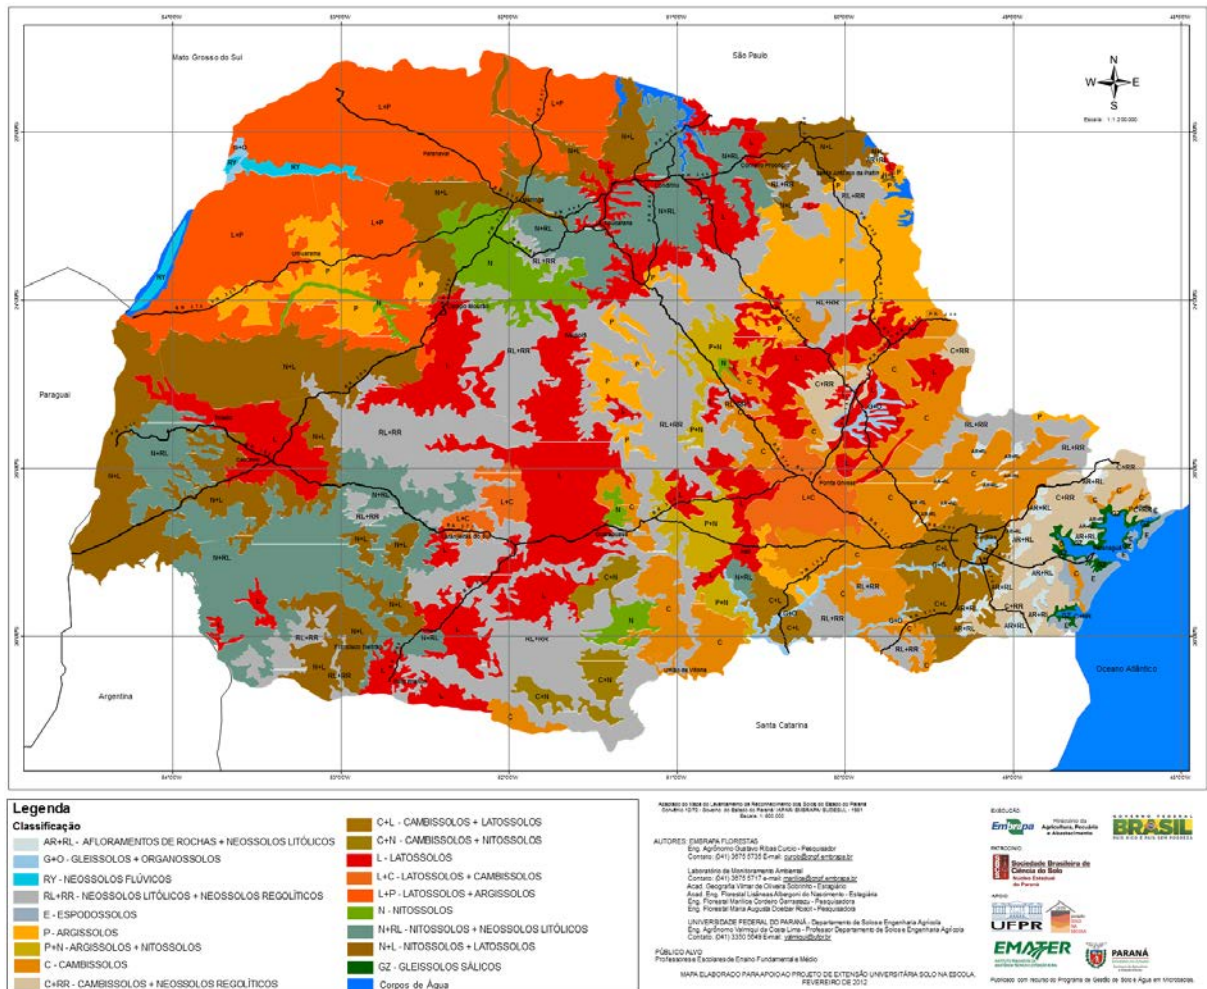


Figura 8. Mapa da distribuição espacial das classes de solos do estado do Paraná.

4.2. Imagens de Sensores Remotos

Devido estas características fenológicas de soja, uma imagem de satélite adquirida em uma determinada data, pode conter áreas com a cultura implantada, tanto de forma precoce como tardia.

Além disso, há áreas ocupadas por cana-de-açúcar, milho verão e aquelas com aveia em estágio final de maturação e colheita. Portanto, faz-se necessário a aquisição de imagens multitemporais, a fim de permitir a maior acuidade possível na classificação de áreas de soja.

Culturas de verão já existentes na área de estudo (arroz, feijão, milho e soja) são plantadas no período compreendido entre o início de outubro e o final de novembro, enquanto

as culturas de inverno (aveia, sorgo e trigo) são plantadas entre abril a maio. Culturas semiperenes e perenes (cana-de-açúcar, café e citros), bem como pastagens e vegetação natural, estão presentes durante o ano todo.

Um dos primeiros aspectos a serem considerados no mapeamento remoto da soja é o fato de que sua fenologia é um processo progressivo. Portanto, a análise de cultivo da soja envolve o uso de uma série-temporal de imagens de satélite. Para este estudo, foram selecionadas imagens com elevada resolução temporal, a fim de contornar os problemas de épocas diferenciadas de plantio e desenvolvimento da cultura, associada a presença de outras culturas de verão e de final de ciclo de inverno, com o objetivo de destacar dinâmica temporal da cultura da soja, permitindo ao mesmo tempo a melhor distinção de outras classes de cobertura do solo.

Para tanto, foram utilizadas imagens do sensor MODIS, em que foram estabelecidos os valores de EVI (*Enhanced Vegetation Index*, Equação 28) do produto MOD13Q1, *tile* H13V11, coleção 5.0, das imagens MODIS compostas de 16 dias (HUETE, 1997) do satélite Terra, com resolução espacial de 250 m, baixados da USGS LP-DAAC.

$$EVI = g \cdot \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + (c_1 \cdot \rho_V) - (c_2 \cdot \rho_A) + 1} \quad (28)$$

sendo: ρ_{IVP} , ρ_V e ρ_A - reflectâncias na faixa espectral do infravermelho próximo, do vermelho e do azul, respectivamente; g - fator de ganho (2,5); c_1 e c_2 são os coeficientes de correção dos efeitos atmosféricos para o vermelho (6) e azul (7,5), respectivamente; l - fator de correção para interferência do solo.

O EVI é um índice que foi desenvolvido para atenuar os efeitos do solo (ajustado pelo SAVI) e da atmosfera (ajustado pelo ARVI) no mapeamento de vegetação. Além do EVI, foram utilizadas para posteriores análises as imagens contidas no produto MOD13Q1: azul, vermelho, infravermelho próximo e o NDVI (Equação 29).

$$NDVI = \frac{\rho_{IVP} - \rho_V}{\rho_{IVP} + \rho_V} \quad (29)$$

em que: ρ_{IVP} e ρ_V - reflectâncias na faixa espectral do infravermelho próximo e do vermelho, respectivamente.

Todas as imagens foram obtidas originalmente no formato HDF (*hierarchical data format*) e projeção sinusoidal, foram processadas de acordo com o desenvolvimento de rotinas de automatização em lote (Apêndice A). Assim, os dados foram reprojatados para coordenadas geográficas (Latitude e Longitude), DATUM WGS-84 (*World Geodetic System 1984*) e automaticamente convertidos para o formato GeoTIFF. As datas correspondentes à série-temporal utilizada estão apresentadas na Tabela 6.

Tabela 6. Datas para composição da série-temporal utilizada compreendendo desde o preparo do solo até o estágio final da cultura da soja.

| Dia Juliano | Data | Ano | |
|--------------------|-------------|------------|------|
| 161 | 10/6 | 2010 | 2011 |
| 177 | 26/6 | 2010 | 2011 |
| 193 | 12/7 | 2010 | 2011 |
| 209 | 28/7 | 2010 | 2011 |
| 225 | 13/8 | 2010 | 2011 |
| 321 | 17/11 | 2010 | 2011 |
| 337 | 3/12 | 2010 | 2011 |
| 353 | 19/12 | 2010 | 2011 |
| 001 | 1/1 | 2011 | 2012 |
| 017 | 17/1 | 2011 | 2012 |
| 033 | 2/2 | 2011 | 2012 |
| 049 | 18/2 | 2011 | 2012 |

4.3. Cálculos dos Índices de Vegetação

Para o cálculo do índice CEI (*Crop Enhancement Index*), desenvolvido por Rizzi et al. (2009), foram necessários obter os valores de máximos e de mínimos do EVI do plantio e do desenvolvimento vegetativo, respectivamente. Para tal, foram utilizadas as datas correspondentes a Tabela 6.

A preferência desses intervalos temporais foi escolhida com base no calendário agrícola da cultura da soja no estado do Paraná, em que consta o início em agosto do preparo do solo (correção e adubação), início do período de semeadura (entre outubro e novembro) e final de março (dessecação e colheita).

Com o resultado destes valores foi então calculado o índice CEI por meio da Equação 30.

$$CEI = g * \frac{(\text{MaxEVI} + S) - (\text{MinEVI} + S)}{(\text{MaxEVI} + S) + (\text{MinEVI} + S)} \quad (30)$$

em que:

MaxEVI - valor máximo de EVI observado no período de máximo desenvolvimento da cultura; MinEVI - valor mínimo de EVI observado no período de pré-plantio e/ou emergência; S - coeficiente de realce (10^2); g - fator de ganho (10^2).

Em seguida, foi definido o índice de vegetação ortogonal PVI (*Perpendicular Vegetation Index*) (Equação 31), que permite anular a reflectância do solo, pois a cultura da soja está na fase inicial do seu desenvolvimento e parte da reflectância registrada pelo sensor refere-se ao solo exposto que pode interferir nos valores obtidos de CEI. Para a execução do PVI foram realizadas as regressões de linha do solo, utilizando-se as bandas espectrais do infravermelho próximo e vermelho, conforme descrito por Nanni e Demattê (2006).

$$PVI = \frac{\rho_{IVP} - a\rho_v - b}{\sqrt{1 + a^2}} \quad (31)$$

sendo: a e b são, respectivamente, a declividade e o intercepto da linha do solo que possui a banda do ρ_{IVP} como variável dependente.

Para o desenvolvimento de um índice que identifique de forma automatizada a cultura da soja com um limiar padrão de fatiamento, levando em consideração a série-temporal desde o preparo até a sua colheita e exclusão do solo para não haver interferência espectral. Neste seguimento foi realizado para as datas apresentadas na Tabela 16, o PVI e seus respectivos valores de máximo e mínimo. Uma vez obtidos tais valores, aprimorou-se o índice CEI, denominado PCEI (*Perpendicular Crop Enhancement Index*), apresentada pela Equação 32 e sintetizada pela Equação 33 (Apêndice B).

$$PCEI = g \cdot \frac{\left(\text{Max} \frac{\rho_{IVP} - a\rho_V - b}{\sqrt{1+a^2}} + S \right) - \left(\text{Min} \frac{\rho_{IVP} - a\rho_V - b}{\sqrt{1+a^2}} + S \right)}{\left(\text{Max} \frac{\rho_{IVP} - a\rho_V - b}{\sqrt{1+a^2}} + S \right) + \left(\text{Min} \frac{\rho_{IVP} - a\rho_V - b}{\sqrt{1+a^2}} + S \right)} \quad (32)$$

$$PCEI = g * \frac{(\text{MaxPVI} + S) - (\text{MinPVI} + S)}{(\text{MaxPVI} + S) + (\text{MinPVI} + S)} \quad (33)$$

em que: MaxPVI - valor máximo de PVI observado no período de máximo desenvolvimento da cultura da soja; MinPVI - valor mínimo de PVI observado no período de pré-plantio e/ou emergência; S - coeficiente de realce (10^2); g - fator de ganho (10^2).

Os valores do índice CEI e PCEI podem variar entre -1 e 1, o que possibilita verificar grandes diferenças positivas entre o máximo e o mínimo do EVI e PVI, respectivamente, observados ao longo do ciclo da soja (Figura 9). Valores elevados de CEI e PCEI indicam probabilidade da reflectância do *pixel* ser o da cultura da soja. Os valores CEI obtidos na Equação 30 foram espacializados, gerando-se um mapa numérico e posteriormente realizado o fatiamento, em que valores superiores ou iguais a 0,28 foram considerados *pixels* decorrentes da soja e abaixo deste valor não-soja, conforme recomenda Rizzi et al. (2009).

Para os valores do PCEI (Equação 32), foi realizada análise orientada em geo-objeto para indicar os polígonos em que a soja estava presente e definido pela mineração de dados o limiar de fatiamento. Para posterior confirmação da classe “soja”, estipulada pelo índice PCEI, foi realizada a comparação entre a análise terrestre com a reflectância da soja obtida por espectrorradiômetro com a imagem do sensor MODIS. Todo o processo realizado para composição do PCEI está apresentado na Figura 10.

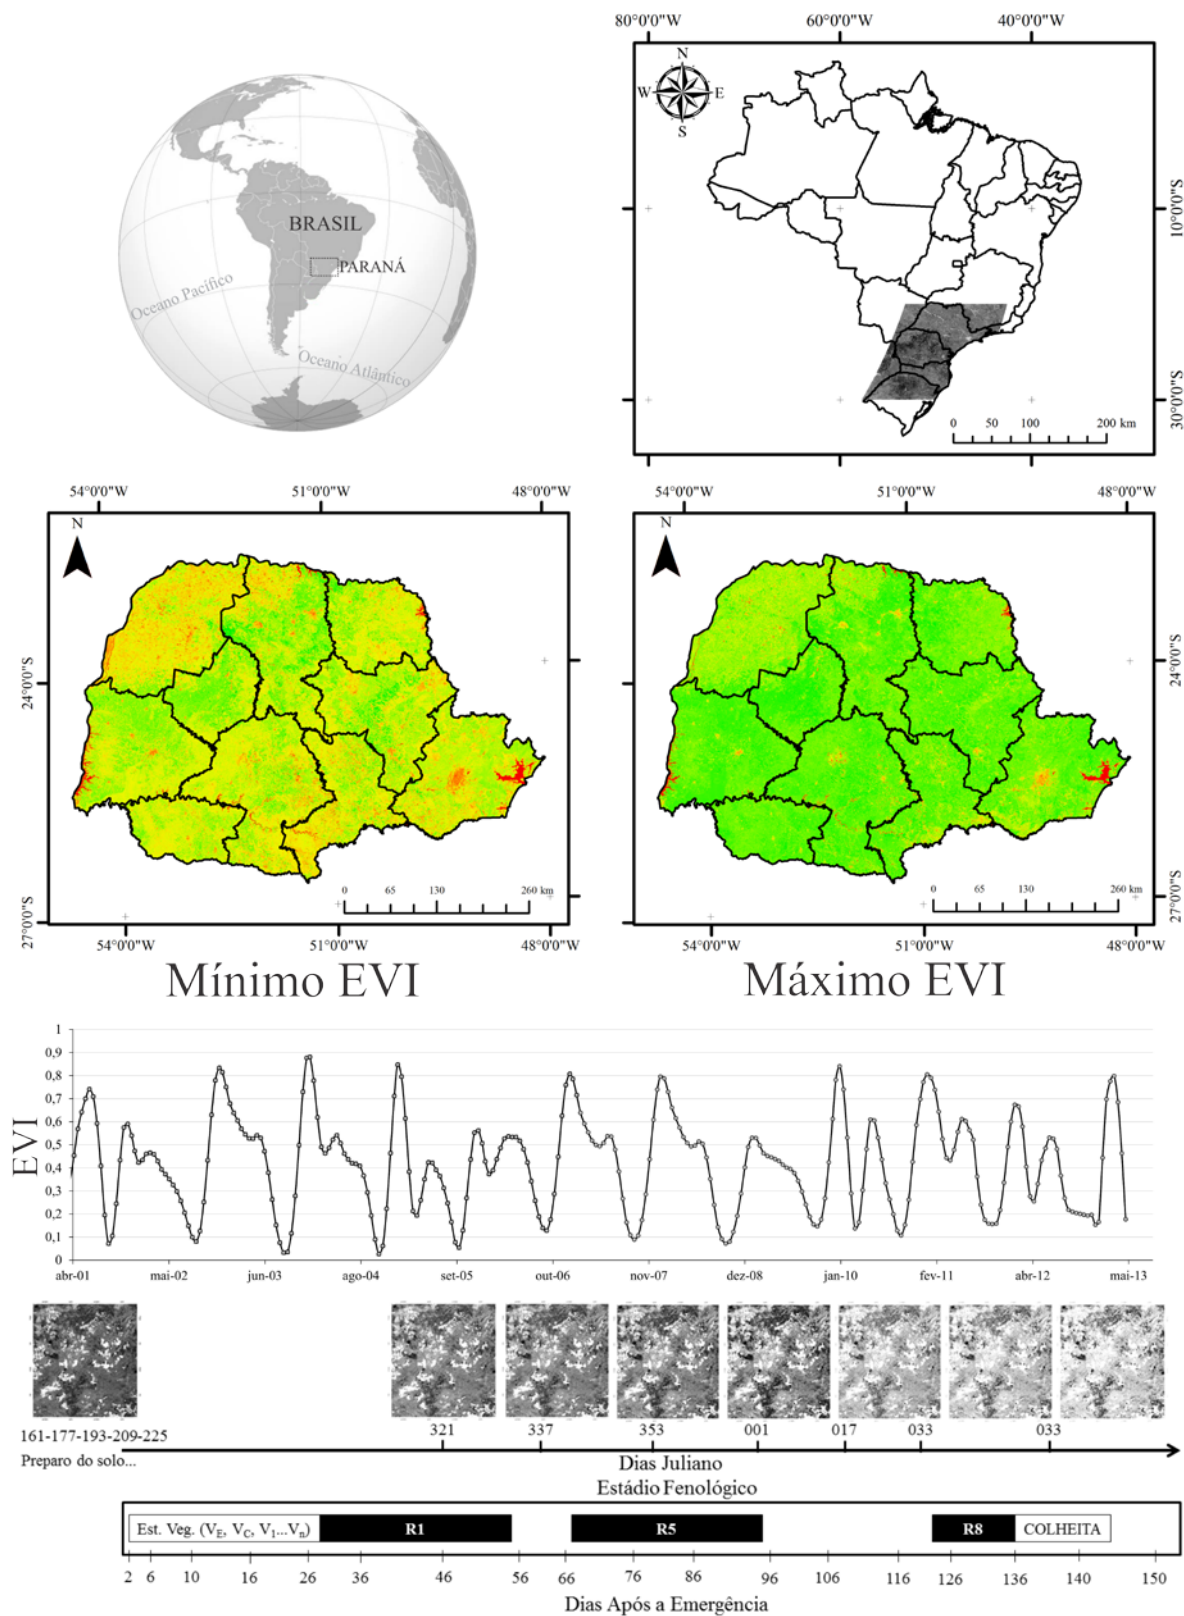


Figura 9. Área de estudo representada pelo produto MOD13Q1 e pelos cálculos de mínimos e máximos valores de EVI, além da série-temporal de um ponto de área de soja amostrado, seguido da temporalidade dos estádios fenológicos da soja.

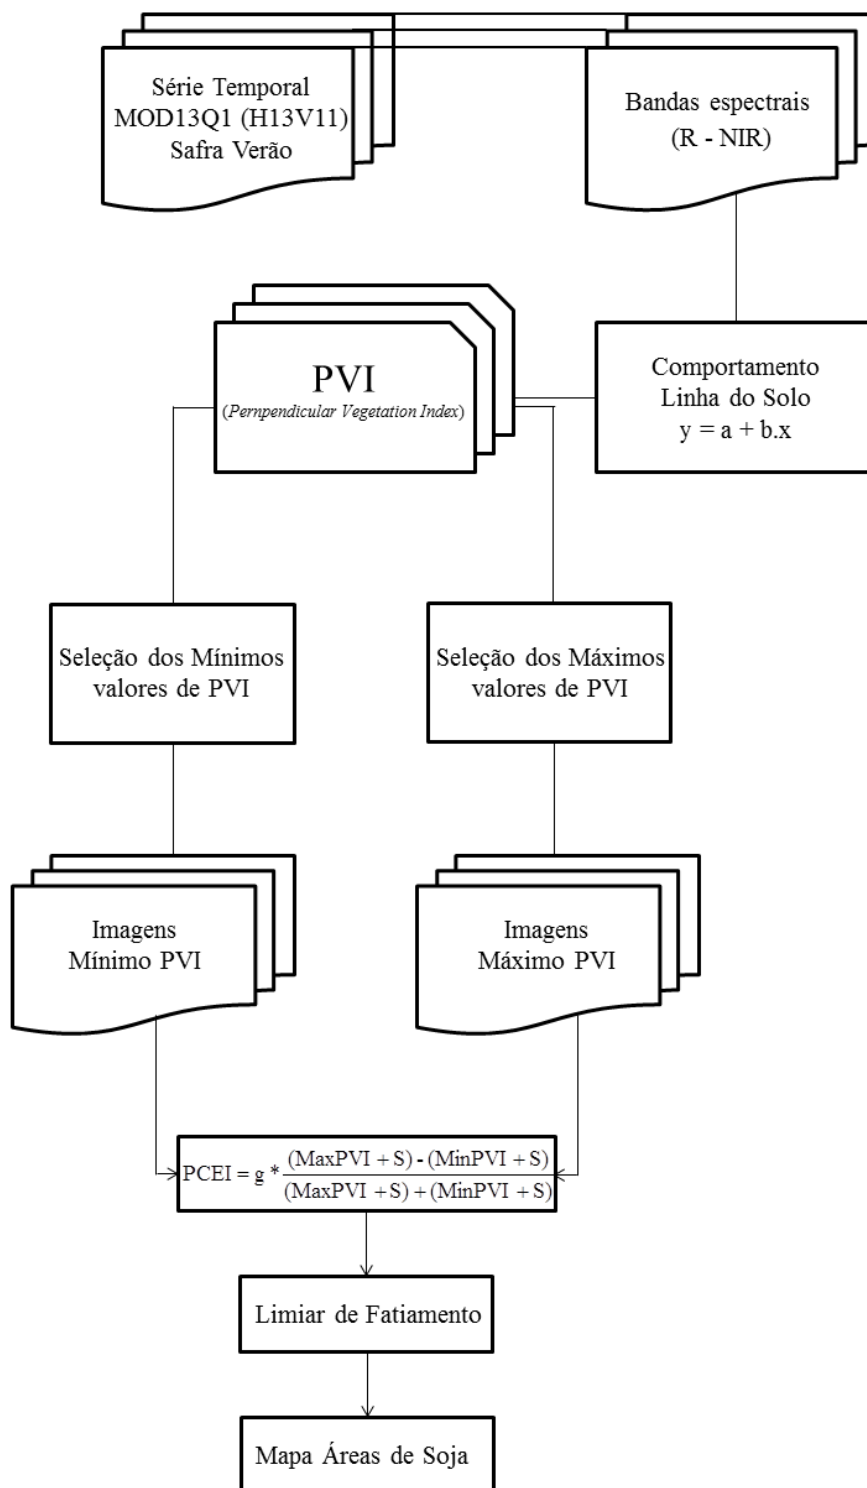


Figura 10. Fluxograma representativo do processo de desenvolvimento do índice PCEI.

4.4. GEOBIA e Mineração de Dados

A sequência das fases necessárias para classificar as áreas de soja está representada na Figura 11. Este tipo de análise denota o GEOBIA e mineração de dados e sua integração ao

serem aplicados a imagens MODIS de séries temporais. A Figura 11 também mostra os ambientes computacionais (eCognition 8.0 - *Definiens Developer* e a plataforma WEKA (*Waikato Environment for Knowledge Analysis*)) para cada etapa do GEOBIA somado a abordagem de mineração de dados.

O eCognition 8.0 é um *software* para análise de imagens baseada em objetos (DEFINIENS, 2006) desenvolvida pela empresa Trimble GeoSpatial, enquanto que o WEKA é um conjunto equipado com algoritmos de aprendizagem para tarefas de mineração de dados desenvolvido pela Universidade de Waikato, Nova Zelândia (GAO, 2009; HALL et al., 2009).

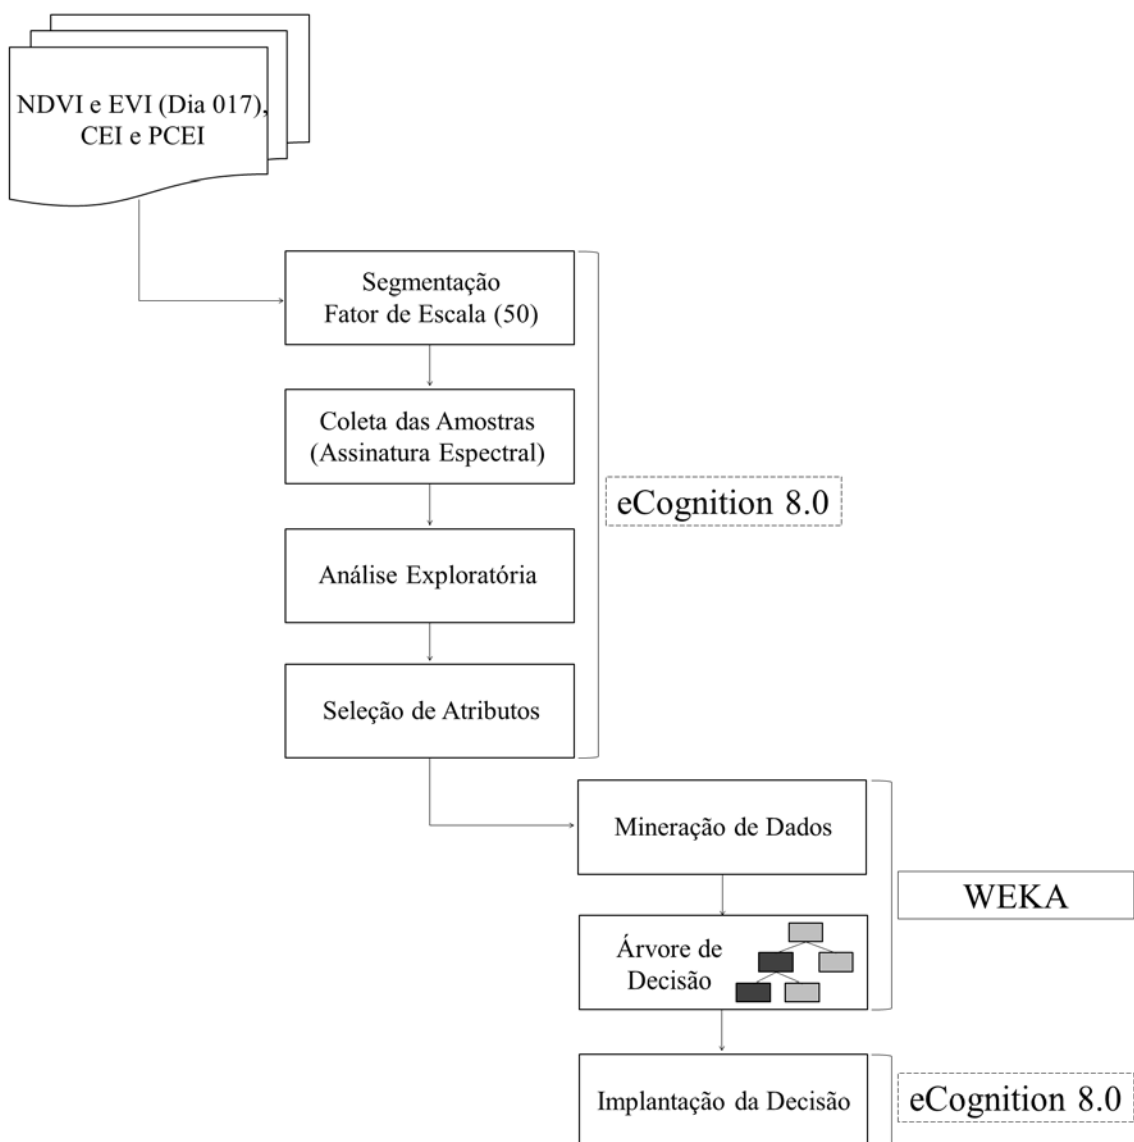


Figura 11. Fluxograma ilustrando as principais etapas que fazem parte do GEOBIA e mineração de dados e a abordagem proposta para classificar as áreas de soja a partir de imagens de séries temporais do sensor MODIS.

A abordagem proposta inclui as seguintes etapas: segmentação de imagens, geração de conjunto de treinamento por meio de seleção de polígonos, mineração de dados, interpretação e avaliação da árvore de decisão, classificação dos dados multitemporais por meio de implantação da decisão e validação da classificação. O processo refere-se à descoberta de conhecimento em bancos de dados, sendo interativo, iterativo, cognitivo e exploratório (FAYYAD et al., 1996).

As unidades básicas de processamento são objetos gerados pelo algoritmo de segmentação proposto por Baatz e Schäpe (2000) e implementado no programa computacional eCognition (DEFINIENS, 2006).

No eCognition 8.0 foi realizado a segmentação multiresolução (*multiresolution*), em que, a geração de objetos (polígonos) é submetida ao critério de heterogeneidade, que pode ser ajustada selecionando o parâmetro de escala, os pesos das bandas espectrais, o fator de forma e o fator de compacidade. Um ajuste no parâmetro de escala, p.e., pode influenciar diretamente no tamanho dos segmentos gerados.

A fim de garantir a homogeneidade dos objetos, entre os quatro índices utilizados (NDVI, EVI, CEI e PCEI), todas as imagens foram processadas ao mesmo tempo durante a segmentação. O resumo das variáveis e parâmetros utilizados na segmentação estão apresentados na Tabela 7.

Tabela 7. Resumo das variáveis e parâmetros utilizados na segmentação.

| Variável da Segmentação | |
|--|-------------|
| Imagem | Peso |
| NDVI – Dia Juliano 017 | 1 |
| EVI – Dia Juliano 017 | 1 |
| CEI – multitemporal | 1 |
| PCEI – multitemporal | 1 |
| Parâmetro de Escala | |
| <i>Scale</i> | 50 |
| Critério da Homogeneidade da Composição | |
| <i>Form</i> | 0,1 |
| <i>Compactness</i> | 0,5 |

Ambas as classes de objetos da amostra (soja e não-soja) foram selecionadas com o auxílio da verificação da reflectância, obtido por meio de sensores remotos laboratoriais e com o limiar do índice CEI ($\geq 0,28$). No total de treino, 260 objetos foram selecionados, dos quais 130 pertenciam à classe soja e 130 a classe não-soja (áreas ocupadas pela vegetação natural ou por outros usos antrópicos).

Depois de construído o conjunto de treino, a plataforma eCognition 8.0 foi utilizada para extrair os atributos (Tabela 8), consideradas como as mais representativas das classes de interesse. Os atributos selecionados foram espectral, espacial e textural, como descrito em Blaschke (2010).

Na classificação foram inseridos todos os processos filhos, sendo utilizado o algoritmo *classification*, em que as regras são inseridas nas próprias classes (soja e não-soja). Após a etapa de classificação foi inserido um processo com o algoritmo *merge region*. Assim, os objetos de cada classe são agrupados em objetos maiores.

A fase de mineração de dados envolve a seleção e aplicação de técnicas inteligentes, a fim de extrair padrões de interesse e desenvolvimento de conhecimento. O termo conhecimento é sinônimo de padrões de comportamento de cada classe (soja e não-soja). O algoritmo utilizado para a árvore de decisão foi o J48 para executar a tarefa de mineração de dados, operado no programa computacional WEKA (WITTEN e FRANK, 2005).

Os algoritmo J48 é uma implementação do C4.5 que escolhe um atributo para dividir os dados em dois subconjuntos, com base no maior ganho de informação normalizada (diferença de entropia). O algoritmo repete este procedimento em cada subconjunto até que todos os casos passem a pertencer à mesma classe. Assim, um nó de folha é criado na árvore de decisão.

Em seguida, após o treinamento e avaliação da árvore de decisão, os atributos extraídos dos índices de vegetação foram classificadas para mapear áreas de soja e não-soja para os anos-safras estudados.

O conjunto de regras definidas pelos atributos e seus respectivos limites identificados pelo algoritmo J48, durante as fases de mineração de dados, constituem a árvore de decisão. A estrutura entre os atributos e os limiares foi implementado manualmente no eCognition 8.0 (DEFINIENS, 2006). No programa computacional da classificação hierárquica é então realizada de acordo com o conjunto de regras da árvore de decisão, gerando um mapa temático com as duas classes de interesse (soja e não-soja). Todo o processo pode ser visualizado e sintetizado pela Figura 12, conforme adaptado de Hsu et al. (2002).

Tabela 8. Atributos extraídos do eCognition 8.0 para selecionar a classe soja e não-soja.

| Tipo | Nome | Características do Intervalo dos Valores |
|---------------|--------------------|---|
| Espectral | Mean | $[C_k^{\min}, C_k^{\max}]$ |
| | Standard deviation | $[0, \frac{1}{2}C_k^{\text{range}}]$ |
| | | C_k^{\min} : darkest possible intensity value |
| | | C_k^{\max} : brightest possible intensity value |
| Espacial | Area | [0, scene size] |
| | Asymmetry | [0, 1] |
| | Border index | [0, ∞], 1 = ideal |
| | Border length | [0, ∞] |
| | Compactness | [0, ∞], 1 = ideal |
| | Density | [0, depended on shaped of image object] |
| | Length | [0, 1] |
| | Main direction | [0, 180] |
| | Rectangular fit | [0, 1], 1=complete fitting, whereas 0=0% fit inside the rectangular approximation |
| | Shape index | [1, ∞] 1 = ideal |
| Textura | GLCM homogeneity | [0, 90] |
| | GLCM contrast | [0, 90] |
| | GLCM dissimilarity | [0, 90] |
| | GLCM entropy | [0, 90] |
| Personalizado | NDVI (017) | [-1, 1] |
| | EVI (017) | [-1, 1] |
| | CEI | [-1, 1] |
| | PCEI | [-1, 1] |

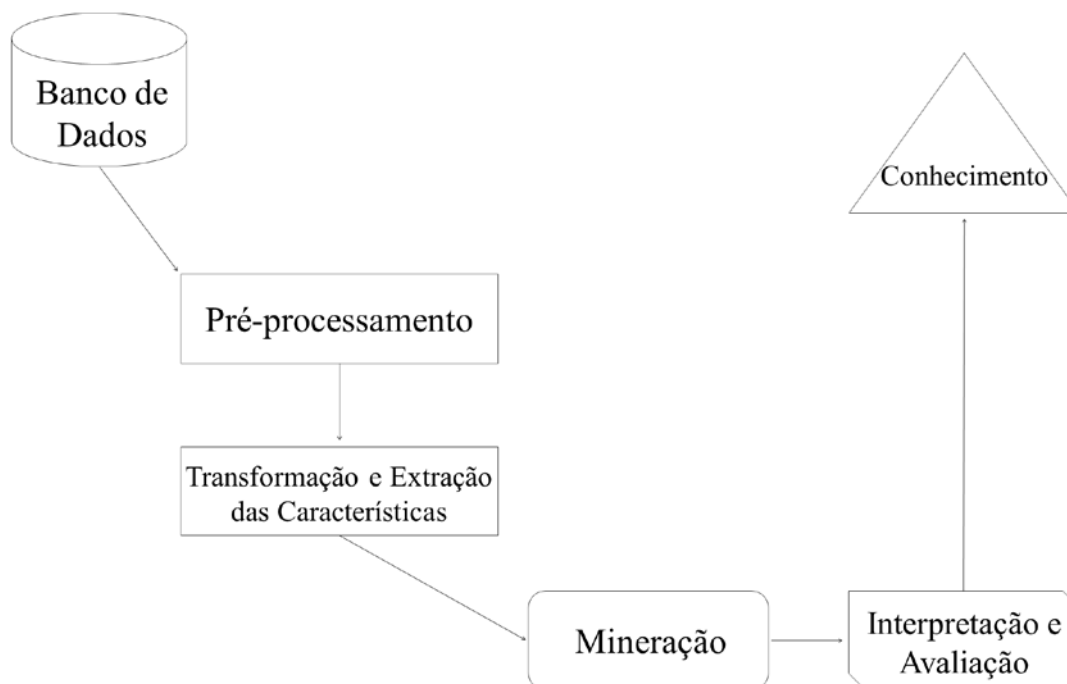


Figura 12. Fluxograma representativo do processo de mineração de dados.

4.5. Métodos de Classificação

4.5.1. Procedimentos da RNA

A metodologia para o desenvolvimento da rede neural artificial (RNA) para o mapeamento de áreas de soja consistiu em duas etapas distintas: pré-processamento e treinamento da RNA para classificação dos índices de vegetação.

O pré-processamento foi realizado de acordo com o tópico 4.3 e 4.4. As imagens utilizadas para o processo da RNA foram os índices NDVI e EVI, ambas do dia Juliano 017 (2011 e 2012) e os índices CEI e PCEI, derivados de séries temporais do produto MOD13Q1 do sensor MODIS do satélite Terra.

Em relação ao treinamento da RNA, foram utilizados os processos de acordo com metodologia proposta por Andrade et al. (2013), assim sendo realizada a definição das amostras e suas respectivas assinaturas espectrais, definição da arquitetura e treinamento da RNA, aplicação da rede e obtenção do mapa classificado.

Todos os processos referentes à RNA foram executados na plataforma IDRISI Selva, desenvolvido pela *Graduate School of Geography* da Universidade de Clark. A plataforma apresenta recursos para gerenciamento ambiental de recursos naturais, com a utilização de séries temporais ou mudanças, análise de decisões por critérios múltiplos e análises de

incertezas. Para o módulo de RNA foi implantado três classificadores, sendo o MLP (*Multi-layer perceptron*), SOM (*Self-organizing map*) e o Fuzzy ARTMAP.

Neste segmento, foram definidos e selecionados entre 50 a 65 polígonos de diversos tamanhos para melhor detalhar as áreas onde estava sendo cultivada a cultura da soja. A plataforma IDRISI Selva não reconheceu apenas duas classes, apresentando erro no mapa final classificado. Portanto, para este processo foram definidas as amostras em polígonos de soja, não-soja e demais usos (principalmente cursos d'água).

Em seguida foram definidos os limiares espectrais de cada imagem pelo módulo *Makesig*, na qual consiste a extração das informações espectrais de cada imagem com base nas amostras selecionadas.

Em relação à arquitetura da RNA, foi executado o módulo de classificação por redes neurais artificiais do tipo MLP (*Multi-layer perceptron*). Os elementos da camada de saída foram definidos com base no número de classes a serem definidas na imagem sendo, neste caso, três nós com valores identificados na criação das amostras e processados pelo módulo *Makesig*.

Para o processo de melhor identificação da configuração da arquitetura para o mapeamento da cultura da soja, foram utilizados alguns testes para as quantidades de camadas, quantidade de neurônios por camada e função de ativação.

A rede neural artificial foi treinada com o uso do algoritmo *backpropagation* (HAYKIN, 2008; FAUSETT, 1994). Estritamente, *backpropagation* refere-se ao método para calcular o gradiente da soma, de acordo com a função de erro quadrático relacionado aos pesos para uma rede *feedforward*, que nada mais é que uma aplicação simples, no entanto eficiente perante a regra da cadeia de cálculo elementar (CHEN, 2005). Para isso, assume-se que existem n classes, m neurônios na camada escondida e um neurônio na camada de saída.

O algoritmo de aprendizagem *backpropagation* é essencialmente um método de otimização que é capaz de encontrar os coeficientes de peso e os limiares para a rede neural e dado conjunto de treinamento. A rede que se presume ser constituído por neurônios do comportamento dos quais é descrito pela Equação 34.

$$y = S\left(\sum_{i=1}^N w_i x_i + \Theta\right) \quad (34)$$

em que a função de saída não linear S é definido pela Equação 35.

$$S(\varphi) = \frac{1}{1 + e^{-\gamma\varphi}} \quad (35)$$

onde: γ determina a inclinação da curva na origem das coordenadas. Os valores de entrada e de saída são considerados no intervalo $[0, 1]$. Nas fórmulas seguintes, o parâmetro S indica a camada de saída, h a camada oculta e i, j os indicadores. O indicador i representa os neurônios de saída e o j os de entrada. O i -th significa o neurônio de saída da camada escondida e o peso de conexão i -th de saída e j -th neurônio da camada escondida anterior.

Para esta etapa foi utilizado o método heurístico, variando a configuração do treinamento dos seguintes parâmetros: taxa de aprendizado, taxa momentum, número de amostras de treinamento (*pixels*) e iterações. Posteriormente, com a rede treinada, foi realizado a separação das classes e identificadas como soja e não-soja para geração de mapa final classificado.

As performances das configurações da rede neural artificial foram avaliadas com base no erro médio quadrático (EMQ) e precisão da previsão e erro padrão de previsão (SEP). Além disso, foi utilizado o coeficiente de correlação (r) entre a saída e preditos, juntamente com a inclinação e intersecção de modelo de regressão linear. O EMQ foi calculada pela Equação 36.

$$EMQ = \sqrt{EMQ} = \sqrt{\frac{SSE}{n - p}} \quad (36)$$

em que, n é o número de observações, p é o número de parâmetros a serem estimados e SSE e EMQ são a soma dos erros ao quadrado e o erro médio quadrático, respectivamente.

Neurônios entre camadas adjacentes que definem a estrutura da rede neural (Figura 6), não são totalmente ligados, devido ao fato de que cada uma das saídas é afetada por alguma entrada específica.

Por exemplo, a primeira saída da rede neural proposta é uma função de quatro entradas, conforme apresentada na Equação 34. Uma função de transferência tangente hiperbólica sigmoide com a Equação 37 é aplicada às camadas escondidas e de saída.

$$f(x) = \frac{2}{1 + e^{-2x}} \quad (37)$$

4.5.2. Procedimentos com classificador supervisionado e parcialmente não-supervisionado

Os procedimentos metodológicos constituíram-se na aplicação de diferentes rotinas de tratamento digital de imagem, que podem ser sintetizadas em três principais etapas: a) Pré-processamento (Tópicos 4.3. e 4.4.), b) Realce: foi atribuído um contraste linear para melhor discriminação dos alvos e c) Classificação:

Após os devidos tratamentos aplicados nas imagens MODIS foi aplicada a classificação supervisionada *pixel-a-pixel*, apoiada no algoritmo da Máxima Verossimilhança (MaxVer-ICM - *Iterated Conditional Modes*) conforme descrito por Moreira (2011) (Equação 38), para o processamento por componentes principais (CP).

$$P_c = [-0,5 \log_e(\text{Det}(V_c))] - [0,5(X - M_c)^T (V_c)^{-1} (X - M_c)] \quad (38)$$

no qual: X = vetor de medidas dos *pixels* desconhecidos; P_c = probabilidade de o vetor X ser assinalado na classe c ; V_c = matriz de covariância da classe c contemplando todas as bandas (K, \dots, L); $\text{Det}(V_c)$ = determinante da matriz de covariância V_c ; M_c = vetor das médias para cada classe c ; e T = matriz transposta.

Além disso, foi aplicada a classificação parcialmente não-supervisionada apoiado no algoritmo K-Médias. A plataforma utilizada nesta etapa foi o *Environment for Visualizing Images* (ENVI versão 5.0) (ENVI, 2004).

Para melhor separação das classes e auxílio na consideração de cada amostra para as classes soja e não-soja, foi utilizado o índice de vegetação CEI, em que o limiar $\geq 0,28$ são considerados *pixels* de soja (Rizzi et al., 2009) e a regressão linear entre as amostras de laboratório (espectrorradiometria) e as imagens MODIS.

Os classificadores *pixel-a-pixel* utilizam apenas as informações espectrais de cada *pixel* para achar regiões homogêneas, enquanto que os classificadores por regiões utilizam a informação espectral de cada *pixel* e mais a informação espectral que envolve a relação com seus vizinhos (CUNHA, 2009).

O classificador por *pixel* Maxver-ICM baseia-se em critérios de média, variância e covariância. Enquanto o classificador Maxver associa classes considerando pontos individuais

da imagem, o classificador Maxver-ICM considera também a dependência espacial na classificação. Assim, a classe atribuída depende tanto do valor observado nesse *pixel*, quanto às classes atribuídas aos seus vizinhos.

Além das classificações supervisionadas e não-supervisionadas, foi realizado a transformação por componentes principais (CP), para a redução da dimensão dos dados obtidos a partir das imagens do produto MOD13Q1, bandas espectrais azul, vermelho, infravermelho próximo, além dos índices de vegetação EVI e PCEI.

Para a classificação selecionou as CP's com maior variância. As duas primeiras componentes (CP1 e CP2) continham mais de 99% da variabilidade das informações espectrais na área. Essa técnica apresenta princípios na estatística para análise de um grande número de variáveis. A vantagem dessa aplicação é a remoção de correlação no conjunto de bandas selecionadas, com simultânea compressão da maioria das informações. A operação da formação de um componente principal é feita para se calcular o novo valor de cada *pixel* na formação de uma nova imagem. A mesma operação é repetida com os demais componentes, sendo calculada pela Equação 39 para a primeira e demais componentes principais (MENESES e ALMEIDA, 2012).

$$CP_1 = 0,05x_{ij1}(B) + 0,12x_{ij2}(R) + 0,41x_{ij3}(NIR) + 0,39x_{ij4}(EVI) + 0,30x_{ij5}(PCEI) \quad (39)$$

em que: CP_{1ij} é o valor do *pixel* na linha i coluna j do primeiro componente principal; $x_{ij1...5}$ é o valor do *pixel* na linha i coluna j de cada uma das bandas originais 1 a 5.

Os novos componentes principais são relacionados aos valores de brilho do conjunto das imagens originais. Segundo Meneses e Almeida (2012), em uma representação hipotética, sendo considerada a distribuição no espaço bidimensional dos valores de brilho dos *pixels* de duas bandas, os *pixels* apresentam na primeira componente (CP_1) ou primeiro eixo principal, maior variância, enquanto que na segunda componente (CP_2) a variância é menor (Figura 13).




Figura 13. Rotação espectral dos eixos originais com alta correlação para eixos CP descorrelacionados.

De posse das imagens processadas e as técnicas aplicadas, foram gerados mapas temáticos de áreas de soja, por meio de componentes principais com o algoritmo Maxver-ICM e K-Médias (EVI Dia Juliano 017). Tais procedimentos foram realizados para se comparar a metodologia usualmente utilizada com as metodologias propostas. A síntese metodológica aplicada está apresentada no fluxograma da Figura 14.

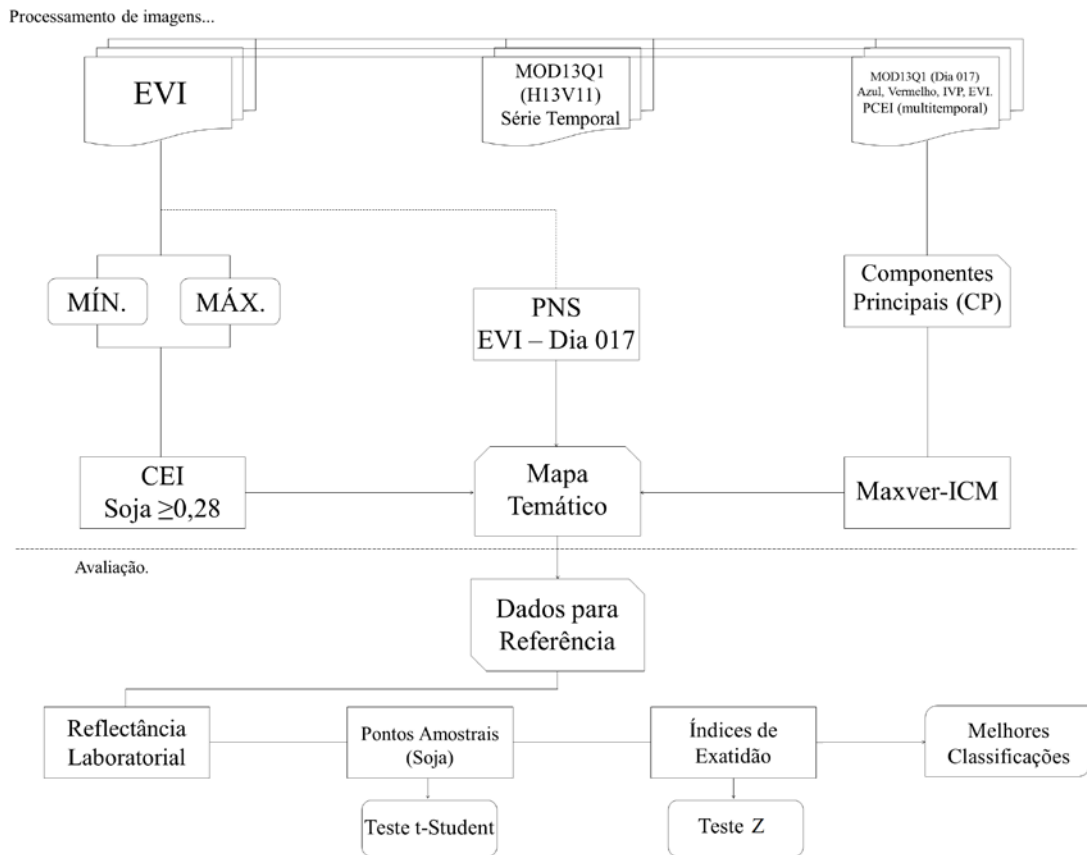


Figura 14. Fluxograma representativo do processo de classificação por meio de imagens MODIS.

Para comparação entre a análise laboratorial e a imagem de satélite referente a plantas de soja foi realizado o teste t ao nível de 5 e 1% de probabilidade.

4.6. Avaliação Espectral e Pontos Amostrais de Campo

Para a avaliação espectral foram cultivados, em casa de vegetação, 10 vasos com plantas de soja (Figura 15). A variedade semeada foi a BMX Potência RR de ciclo semiprecoce, com hábito de crescimento indeterminado, resistente ao acamamento e sua exigência à fertilidade é de média a alta.

As folhas mais jovens (porção superior) foram avaliadas, pois são as que apresentam maior fator de reflectância em imagens de satélite. Foram realizadas leituras espectrais em três pontos diferentes em cada folha por vaso, sempre na parte adaxial, sendo realizadas médias para composição da leitura de um único vaso. Este processo de repetição de leituras é um artifício que pudesse compensar qualquer possível falha ocorrida durante as leituras do sensor (NANNI, 2000).



Figura 15. Plantas de soja cultivadas em vasos experimentais (A) e detalhe da medição espectral da folha (B).

O procedimento de coleta de dados radiométricos foi realizado com a utilização de um espectrorradiômetro FieldSpec 3 (Figura 16b) com intervalo espectral de 350–2500 nm e resolução espectral de 3nm até 700 e de 30 nm de 700-2500nm. Nesta etapa, o procedimento utilizado foi à medição da radiância proveniente do alvo e comparação com a de uma placa de referência branca (BaSO_4) com padrão lambertiano de reflexão máxima. O equipamento foi

programado para realizar 50 leituras por amostra, gerando a curva espectral média de cada amostra de folha analisada (Equação 9).

Na leitura espectral de cada folha foi utilizado o equipamento *ASD Plant Probe* (Figura 16a), utilizado para fins de mensurações em folhas, sendo que sua principal característica é o método não destrutivo e sem interferência da luminosidade do local de leitura.

O *ASD Plant Probe* é projetado para medições espectrais de contato de matérias-primas sólidas. Através desse acessório, é possível minimizar erros associados à luz difusa permitindo, também a análise de amostras através de sacos plásticos transparentes. Apresenta comprimento de 25,4 cm, peso de 0,7 kg e lâmpada 6,5 W.




Figura 16. Detalhe do equipamento *ASD Plant Probe* (A) e visão geral do procedimento da coleta das curvas espectrais das plantas (B).

O propósito da medição da reflectância de plantas de soja em ambiente controlado foi à verificação da concordância entre as imagens do sensor MODIS com a medição *in situ* da própria cultura com espectrorradiômetro.

Esta análise foi realizada para verificar a veracidade do *pixel*, tanto na coleta das amostras (polígonos) para classificação supervisionada, quanto no auxílio da estatística em áreas não visitadas e que foram classificadas como soja no mapa temático final.

Assim, realizou-se a regressão linear entre 10 valores (*pixels* puros de soja) das bandas do Azul (401-525; 459-479 nm), Vermelho (656-725; 620-670 nm), Infravermelho Próximo (726-1100; 841-876 nm), NDVI e EVI, do sensor laboratorial (Figura 17a) e orbital (Figura 17b).

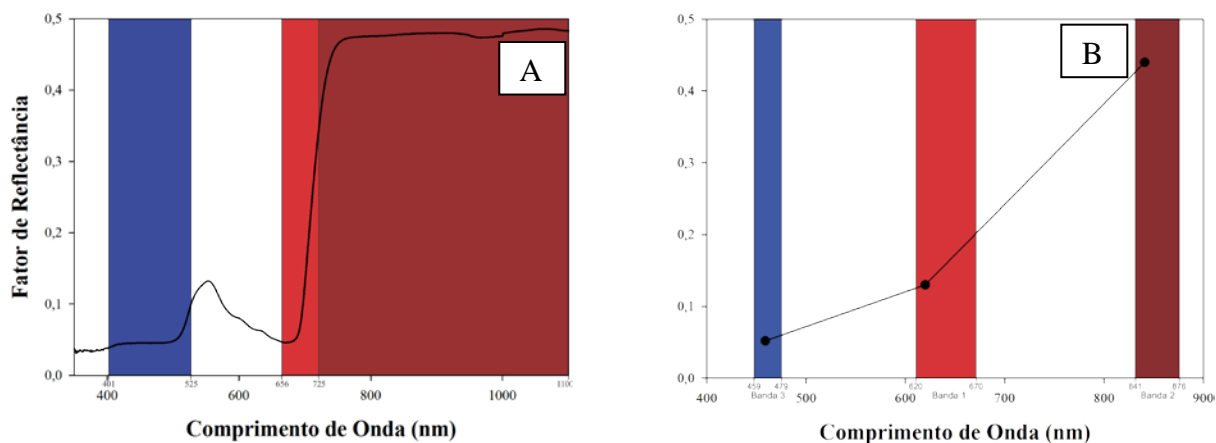


Figura 17. Curva espectral da folha da soja do espectrorradiômetro (A) e MODIS (B).

4.7. Análise Estatística

A avaliação da qualidade dos mapas temáticos dos índices de vegetação (CEI e PCEI), GEOBIA com minerador de dados, redes neurais artificiais (RNA), componentes principais e K-Médias, foi realizada utilizando-se um conjunto de amostras e independente daqueles utilizados para a construção dos modelos. Esta abordagem foi adotada porque permitiu a avaliação entre todos os processos de classificações.

Para gerar o conjunto independente de amostras, percorreram-se diferentes regiões do estado identificando áreas que apresentaram a cultura da soja durante o período escolhido para avaliação das imagens MODIS.

Foram demarcados um total de 172 pontos referenciais da cultura (Figura 7). Para tanto foi utilizado um receptor GPS marca Trimble, modelo GeoExplorer 2008 Series com portadora L1 e precisão melhor que 5 metros após correção dos dados.

Em relação aos pontos de não-soja, foram coletados por meio da interpretação visual de uma série-temporal de imagens MODIS (FREITAS et al., 2011). Estes 346 pontos estavam distribuídos por toda a área e foram gerados aleatoriamente e de forma independente. Para o estabelecimento do conjunto de amostras procedeu-se a análise estabelecida por Congalton e Green (2009), sendo o conjunto considerado satisfatório para as análises.

A qualidade da classificação foi avaliada quantitativamente por meio dos coeficientes de Exatidão Global (EG) e índice Kappa (κ) (Equação 40 e 41, respectivamente), ambos extraídos da matriz de confusão (CONGALTON e GREEN, 2009). Além disso, foram extraídos os erros e a precisão sob os pontos de vista do produtor e do usuário (ANTUNES et al., 2012). Essas métricas permitem avaliar melhor a classificação final das áreas de soja.

$$EG = \left(\frac{\sum_{i=1}^k x_{ii}}{N} \right) \quad (40)$$

$$\kappa = \frac{N \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^k (x_{i+} \cdot x_{+i})} \quad (41)$$

em que: κ - valor estimado Kappa; k = número de linhas; x_{ii} - número de observações na linha i e coluna i ; $\sum_{i=1}^k x_{ii}$ - soma dos elementos da matriz em sua diagonal principal; x_{i+} - soma total das observações para as linhas; x_{+i} - soma total das observações para as colunas; N - número de observações total.

De posse dos valores e sob a hipótese de igualdade entre dois coeficientes de exatidão advindos de classificações diferentes ($\kappa_1 = \kappa_2$), a estatística do teste foi realizada pelas Equações 42, 43 e 44.

$$Z = \frac{(\hat{\kappa}_1 - \hat{\kappa}_2) - (\kappa_1 - \kappa_2)}{\sqrt{\sigma^2(\hat{\kappa}_1) + \sigma^2(\hat{\kappa}_2)}} \sim N(0,1) \quad (42)$$

$$Z = \frac{\hat{\kappa} - \kappa}{\sqrt{\sigma^2(\hat{\kappa})}} \sim N(0,1) \quad (43)$$

$$\sigma^2(\hat{\kappa}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2)^2}{(1-\theta_2)^4} \right] \quad (44)$$

em que:

$$\theta_1 = \frac{\sum_{k=1}^c X_{kk}}{n}; \theta_2 = \frac{\sum_{k=1}^c X_{k+} X_{+k}}{n^2}; \theta_3 = \frac{\sum_{k=1}^c X_{kk} (X_{k+} + X_{+k})}{n^2}; \theta_4 = \frac{\sum_{i=1}^c \sum_{j=1}^c X_{ij} (X_{i+} + X_{+j})}{n^3}.$$

Foi estabelecido como hipótese nula (H0) a igualdade das classificações e o inverso para a suas diferenças (H1), a um nível de 0,05 de significância ($p < 0,05$).

Por fim, a estimativa de área cultivada com soja foi comparada com aquela fornecida pelo Sistema IBGE de Recuperação Automática – SIDRA do Instituto Brasileiro de Geografia e Estatística - IBGE como um parâmetro para verificação da avaliação do mapeamento para os anos-safras 2010/2011 e 2011/2012.

5. RESULTADOS E DISCUSSÃO

Como o fator de reflectância foi extraído em diversos períodos por meio de série-temporal das imagens MODIS, as linhas do solo apresentam-se sob diferentes formas, tanto para o ano-safra 2010/2011 (Figura 18) e 2011/2012 (Figura 19). A circunstância de se obter a série com diversas linhas do solo se dá pelo simples fato do cálculo do índice de vegetação PCEI. A diversidade de alvos presentes em uma imagem de satélite, principalmente as do sensor MODIS por apresentar extensa faixa imageada (2.330 km), é a causa da diferença entre as linhas do solo. Tal fato ocorre para os dois anos-safras estudados uma vez que há, no momento do imageamento, preparo do solo, cultivo e colheita, além de outros temas que contribuem na composição da resposta espectral recebida pelo sensor, como floresta, centros urbanos, diversas culturas não demonstrando, desta forma, uma linha de 45° em relação ao eixo x .

O solo pode ter uma forte influência sobre a determinação de um índice de vegetação, e depende principalmente de suas propriedades espectrais e do tipo e quantidade de vegetação presente (GALVÃO e VITORELLO, 1998). Com isso, todo e qualquer tipo de solo presente no fundo de um dossel irá contribuir para negativar o índice de determinada vegetação.

Todas as linhas do solo obtidas e apresentadas pelas Figuras 18 e 19, foram construídas a partir de mais de 65.000 pontos aleatórios da imagem MODIS somente do estado do Paraná. A semelhança entre elas já era esperada, uma vez que praticamente não há alteração abrupta e em grande escala do uso e ocupação do solo para as datas analisadas.

A ideia de que o solo influencia diretamente em um índice de vegetação é reforçada por Nanni e Demattê (2006), em que obtiveram a linha para diferentes classes de solos em ambiente controlado. Os mesmos autores encontraram valores R^2 próximos a 1,0, ou seja, quase sem dispersão dos dados e com alinhamento em uma abscissa imaginária. No entanto, as Tabelas 9 e 10 para os anos-safras 2010/2011 e 2011/2012, respectivamente, mostram que as equações de tendências resultaram em altos R^2 e com alta significância pelo teste t ($p > 0,01$).

Nota-se que para as datas em que se concentram as culturas de verão, ou seja, os dias Juliano 321, 001, 017, 033 e 049, a tendência dos dados para com a linha do solo é distanciada e apresentando comportamento de vegetação em pleno vigor. Fato esse confirmado pelas equações de tendência (Tabela 9 e 10), em que a partir dos dias que

começam a vigorar as vegetações na imagem próximas do dia 321 há uma queda no R^2 , demonstrando que está presente solo e vegetação.

Assim, os valores dos coeficientes angulares das equações de tendência apresentadas na Tabela 9 apresentam-se para os dias Juliano 225, 321 e 017 com 1,9570, 2,2146 e 2,8146, respectivamente. Isso mostra que há alta probabilidade da presença de solo exposto ainda no dia 225 e com o aumento do coeficiente angular gradativo até o dia 017 mostra o desenvolvimento vegetativo pleno da cultura até sua diminuição na dessecação no dia 049, isto é, próximo à colheita (coeficiente angular de 2,5323). O mesmo ocorreu para o ano safra 2011/2012 (Tabela 10), diferenciando apenas para o do estágio vegetativo final da soja (dia Juliano 049) em que as ocorrências de chuvas no período foram intensas, ocasionando atraso na colheita e apresentado maior coeficiente angular, ou seja, alta probabilidade de presença de vegetação.

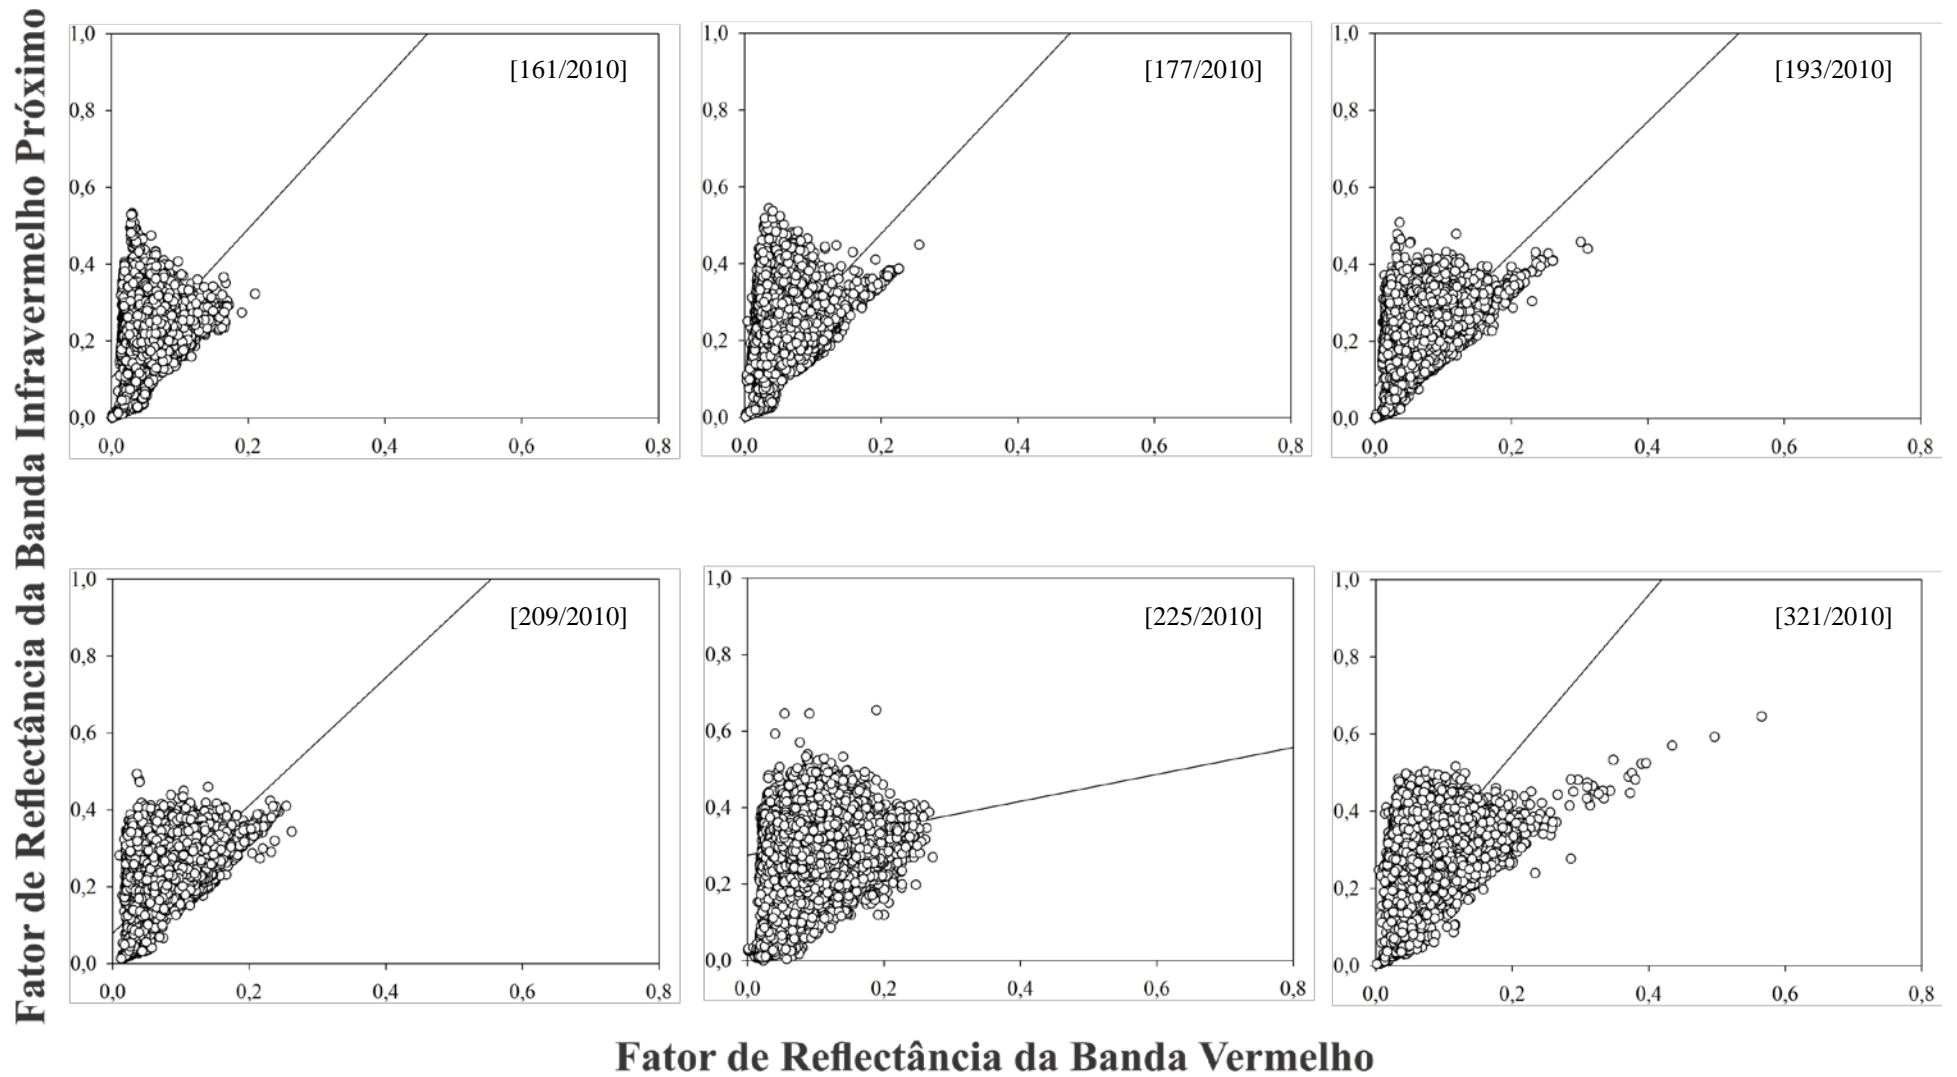



Figura 18. Linha do solo obtida pela relação entre a banda do vermelho e infravermelho próximo com dados Terra/MODIS – safra 2010/11 (dias Juliano).

cont...



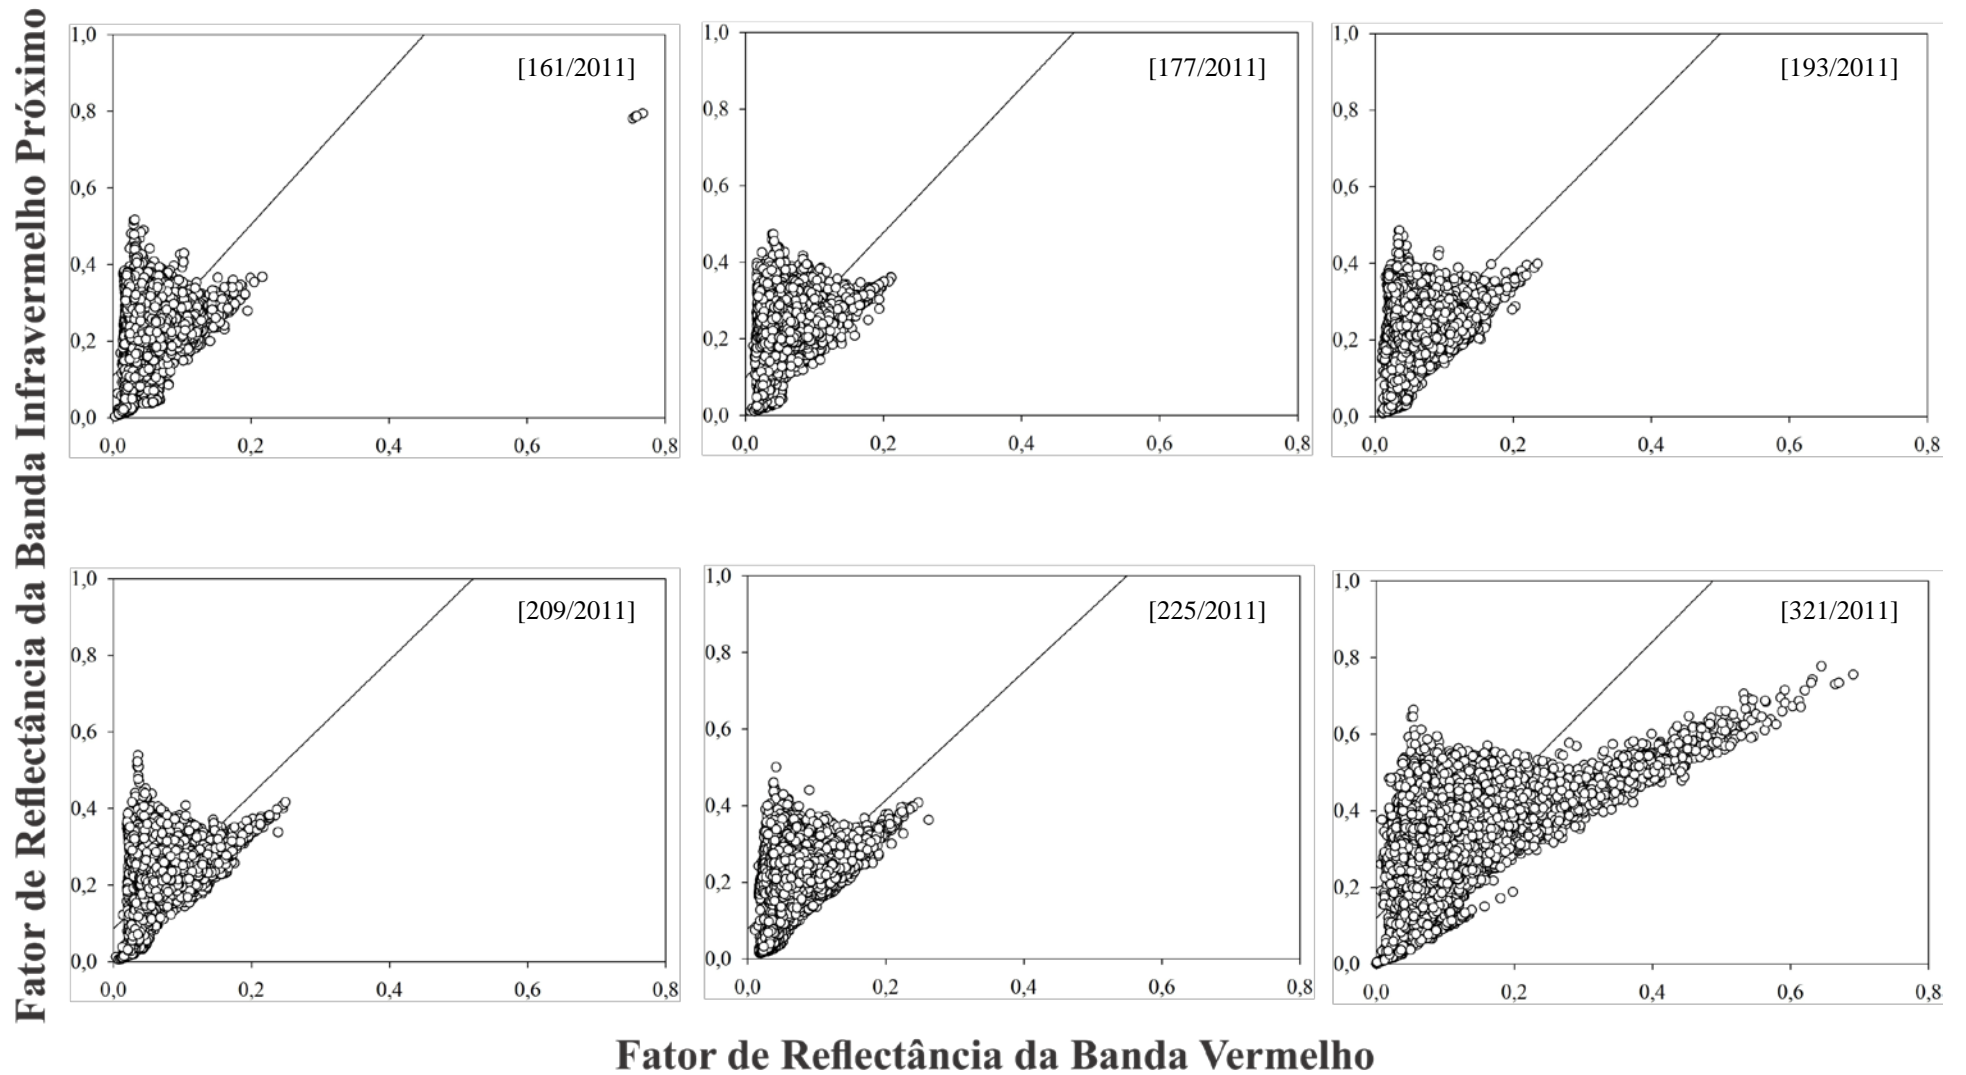


Figura 19. Linha do solo obtida pela relação entre a banda do vermelho e infravermelho próximo com dados Terra/MODIS – safra 2011/12 (dia Juliano).

cont...

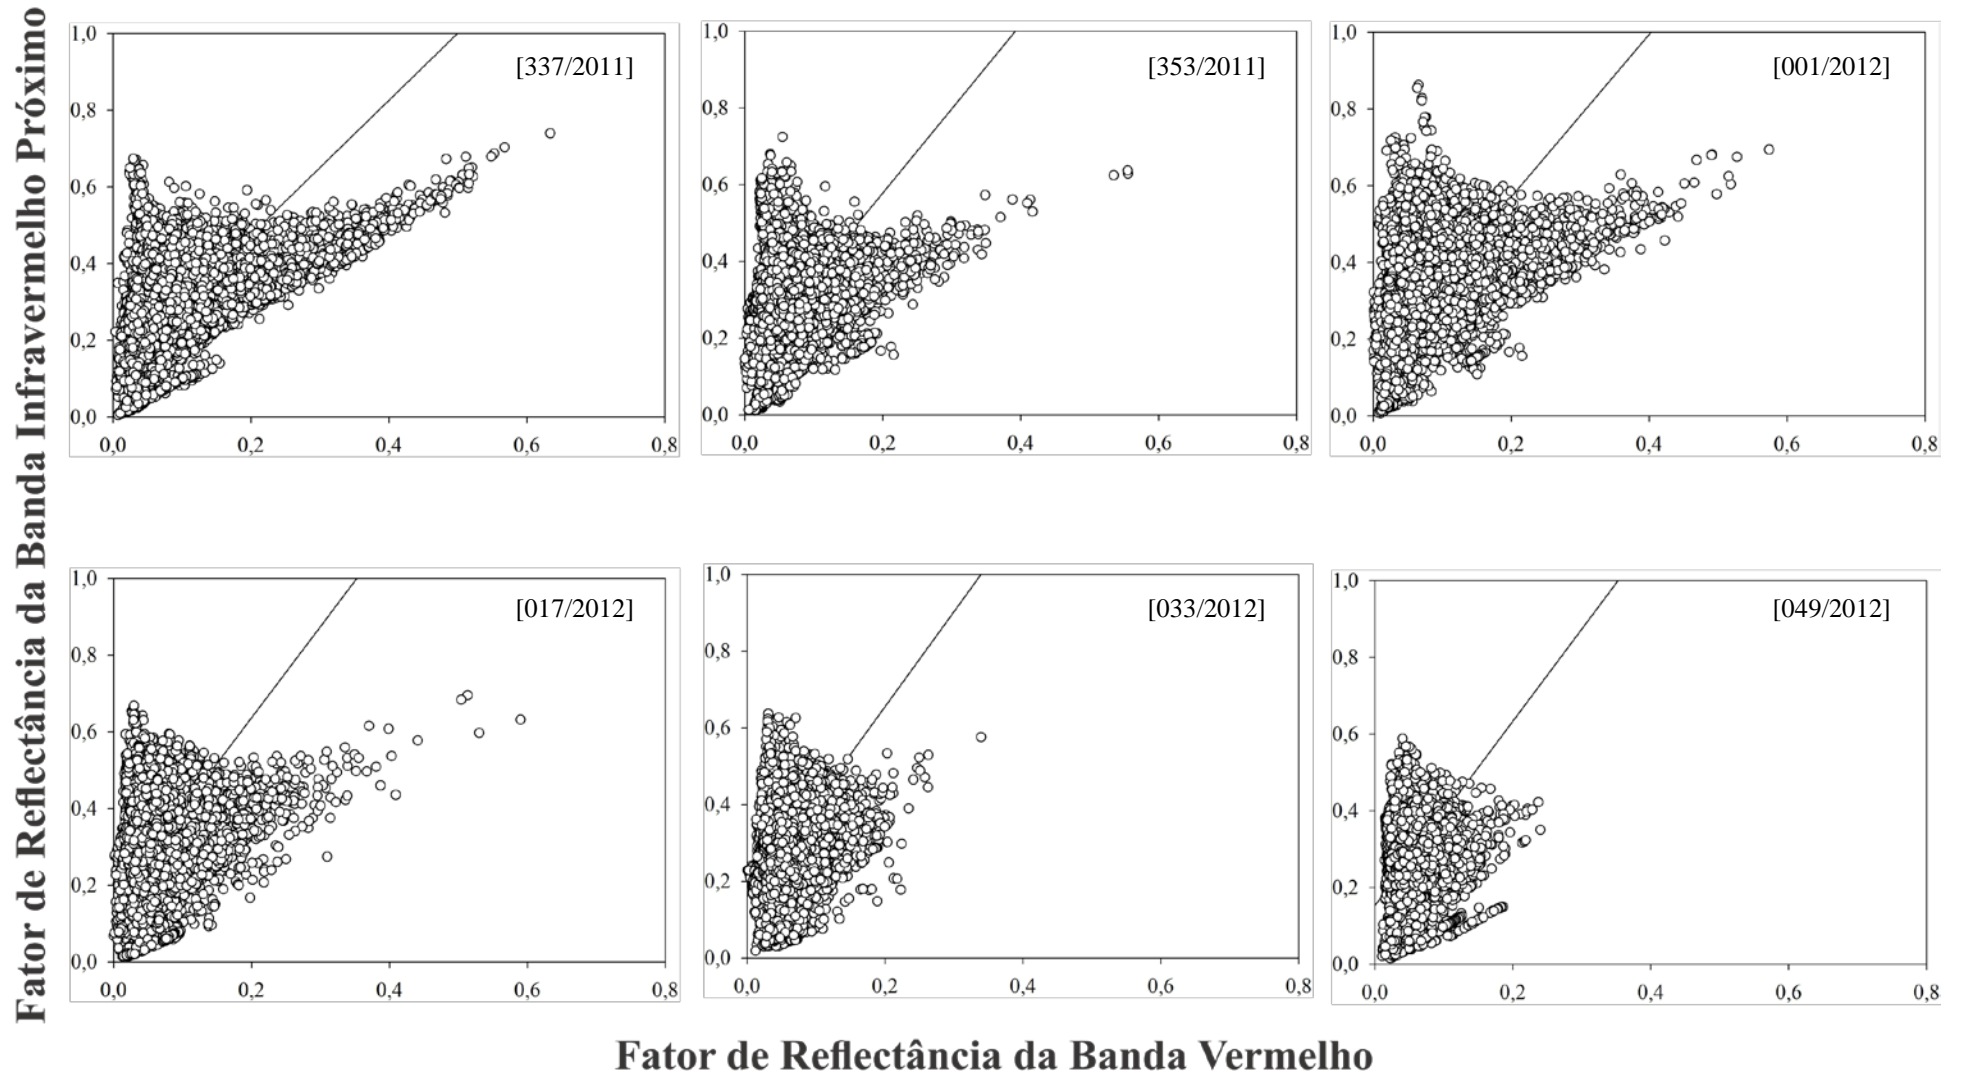


Tabela 9. Dias Juliano do ano-safra 2010/2011, equações de tendência linear e R^2 para a relação entre as bandas do vermelho e infravermelho próximo, obtidas pelo sensor MODIS.

| Dia Juliano | Ano | Equação de Tendência | r | R^2 |
|--------------------|------------|------------------------------|----------|-------------------------|
| 161 | 2010 | $\hat{y} = 2,1978x + 0,1325$ | 0,94 | 0,89 ^{**} |
| 177 | 2010 | $\hat{y} = 2,1753x + 0,1291$ | 0,95 | 0,90 ^{**} |
| 193 | 2010 | $\hat{y} = 2,0211x + 0,1165$ | 0,94 | 0,89 ^{**} |
| 209 | 2010 | $\hat{y} = 1,9913x + 0,1136$ | 0,94 | 0,89 ^{**} |
| 225 | 2010 | $\hat{y} = 1,9570x + 0,1101$ | 0,94 | 0,89 ^{**} |
| 321 | 2010 | $\hat{y} = 2,2146x + 0,1419$ | 0,93 | 0,86 ^{**} |
| 337 | 2010 | $\hat{y} = 2,4782x + 0,1668$ | 0,93 | 0,86 ^{**} |
| 353 | 2010 | $\hat{y} = 2,6999x + 0,1873$ | 0,92 | 0,85 ^{**} |
| 001 | 2011 | $\hat{y} = 2,5631x + 0,1893$ | 0,90 | 0,81 ^{**} |
| 017 | 2011 | $\hat{y} = 2,8146x + 0,1980$ | 0,93 | 0,86 ^{**} |
| 033 | 2011 | $\hat{y} = 2,5323x + 0,1850$ | 0,91 | 0,82 ^{**} |
| 049 | 2011 | $\hat{y} = 2,5323x + 0,1824$ | 0,93 | 0,86 ^{**} |

^{ns} não significativo; ^{*,**} significativo a 5 e 1% de probabilidade, respectivamente pelo teste t.

Tabela 10. Dias Juliano do ano-safra 2011/2012, equações de tendência linear e R^2 para a relação entre as bandas do vermelho e infravermelho próximo, obtidas pelo sensor MODIS.

| Dia Juliano | Ano | Equação de Tendência | r | R^2 |
|--------------------|------------|------------------------------|----------|-------------------------|
| 161 | 2011 | $\hat{y} = 2,1700x + 0,1282$ | 0,95 | 0,91 ^{**} |
| 177 | 2011 | $\hat{y} = 2,0449x + 0,1172$ | 0,94 | 0,89 ^{**} |
| 193 | 2011 | $\hat{y} = 1,9607x + 0,1093$ | 0,94 | 0,89 ^{**} |
| 209 | 2011 | $\hat{y} = 1,9533x + 0,1099$ | 0,93 | 0,88 ^{**} |
| 225 | 2011 | $\hat{y} = 1,9310x + 0,1088$ | 0,93 | 0,87 ^{**} |
| 321 | 2011 | $\hat{y} = 2,1764x + 0,1444$ | 0,92 | 0,84 ^{**} |
| 337 | 2011 | $\hat{y} = 2,3036x + 0,1534$ | 0,92 | 0,85 ^{**} |
| 353 | 2011 | $\hat{y} = 2,4553x + 0,1601$ | 0,94 | 0,88 ^{**} |
| 001 | 2012 | $\hat{y} = 2,5267x + 0,1702$ | 0,93 | 0,87 ^{**} |
| 017 | 2012 | $\hat{y} = 2,5658x + 0,1732$ | 0,93 | 0,86 ^{**} |
| 033 | 2012 | $\hat{y} = 2,5959x + 0,1730$ | 0,94 | 0,88 ^{**} |
| 049 | 2012 | $\hat{y} = 2,6111x + 0,1754$ | 0,94 | 0,88 ^{**} |

^{ns} não significativo; ^{*,**} significativo a 5 e 1% de probabilidade, respectivamente pelo teste t.

A Figura 20 ilustra dois exemplos de segmentação para os dois anos-safras estudados. A segmentação apresentada é um exemplo considerado resultado adequado por causa do número ideal de objetos, principalmente, pelo alto valor adotado para o parâmetro de escala devido à resolução espacial do sensor MODIS (250 m).

Os segmentos foram divididos adequadamente, sendo identificadas as unidades menores e maiores das áreas, principalmente as de soja e outros usos (neste caso floresta). Para um estudo de dados com campos agrícolas são melhores ajustados os segmentos. Assim, se os objetos são muito pequenos, os parâmetros texturais também são frequentemente sujeitos a alto nível de variabilidade.




Figura 20. Exemplos das segmentações realizadas para os anos-safras 2010/2011 (esquerda) e 2011/2012 (direita).

O modelo para definir a soja na imagem e adquirir um limiar para o índice PCEI pode ser visto na forma de árvore de decisão para os anos-safras 2010/2011 e 2011/2012 (Figura 21 e 22, respectivamente) e pela forma de texto (Apêndice C).

Pode-se observar que foi identificada por esse processo a definição de um limiar para o índice de vegetação PCEI no primeiro ramo da árvore (Figura 21), em que a média de $>0,172464$ para valores que variam entre -1 a 1 pode ser considerados como soja. Esse limiar foi auxiliado com a coleta das amostras sobrepostas pelos índices NDVI, EVI e CEI (RIZZI et al., 2009), em que atribuem, a este último índice, um limiar de corte em 0,28 para a cultura da soja.

A Figura 21 apresenta além do limiar de fatiamento do PCEI, a classificação da cultura da soja utilizando a média do índice CEI, sendo $\leq 0,3734$. A mínima dificuldade na execução da árvore de decisão pelo algoritmo J48 foi pelas amostras coletadas com informações adequadas, uma vez que foi dada a “liberdade” para a execução do algoritmo, não resultando em uma extensa e complexa árvore. A consequência de extensos resultados é nada mais que sua replicação no programa computacional eCognition, o que exigiria oneroso trabalho e enorme atenção.

Os atributos escolhidos pela árvore de decisão para o ano-safra 2011/2012 (Figura 22) foram à média, a densidade e o desvio padrão. Também foram escolhidos pelo algoritmo os índices CEI e PCEI, o que denota discriminação adequada dos mesmos em identificar a cultura da soja.

Neste caso, as imagens foram geradas por operações matemáticas (NDVI, EVI, CEI e PCEI), assim o *pixel* não representa um valor espectral e sim um valor resultante de uma operação. Essa técnica foi positiva no momento da coleta de amostras, pois a diferença entre os valores auxiliou nesta fase. Assim, como utilizado pelo algoritmo J48 no processo de elaboração da árvore de decisão, os *pixels* foram denominados como estatísticos, correspondendo à média e desvio padrão, neste caso.

Diferente do valor obtido no *pixel* das imagens, a textura e cor foram fundamentais na decisão de regiões segmentadas como soja, pois a identificação da distribuição espacial pôde ser identificada.

A textura dos alvos em que correspondem à espacialização da variação de valores digitais da imagem é uma das características utilizadas para a identificação de alvos em uma imagem. Alguns autores posicionam-se como a textura é de difícil descrição (MARPU, 2009). Entretanto, as vantagens da aplicação da informação textural para dados de média resolução espacial de observação e monitoramento terrestre já foi demonstrada em diversas pesquisas (DELL’ACQUA e GAMBA, 2003; RIEDEL et al., 2008; SILVA JUNIOR et al., 2014).

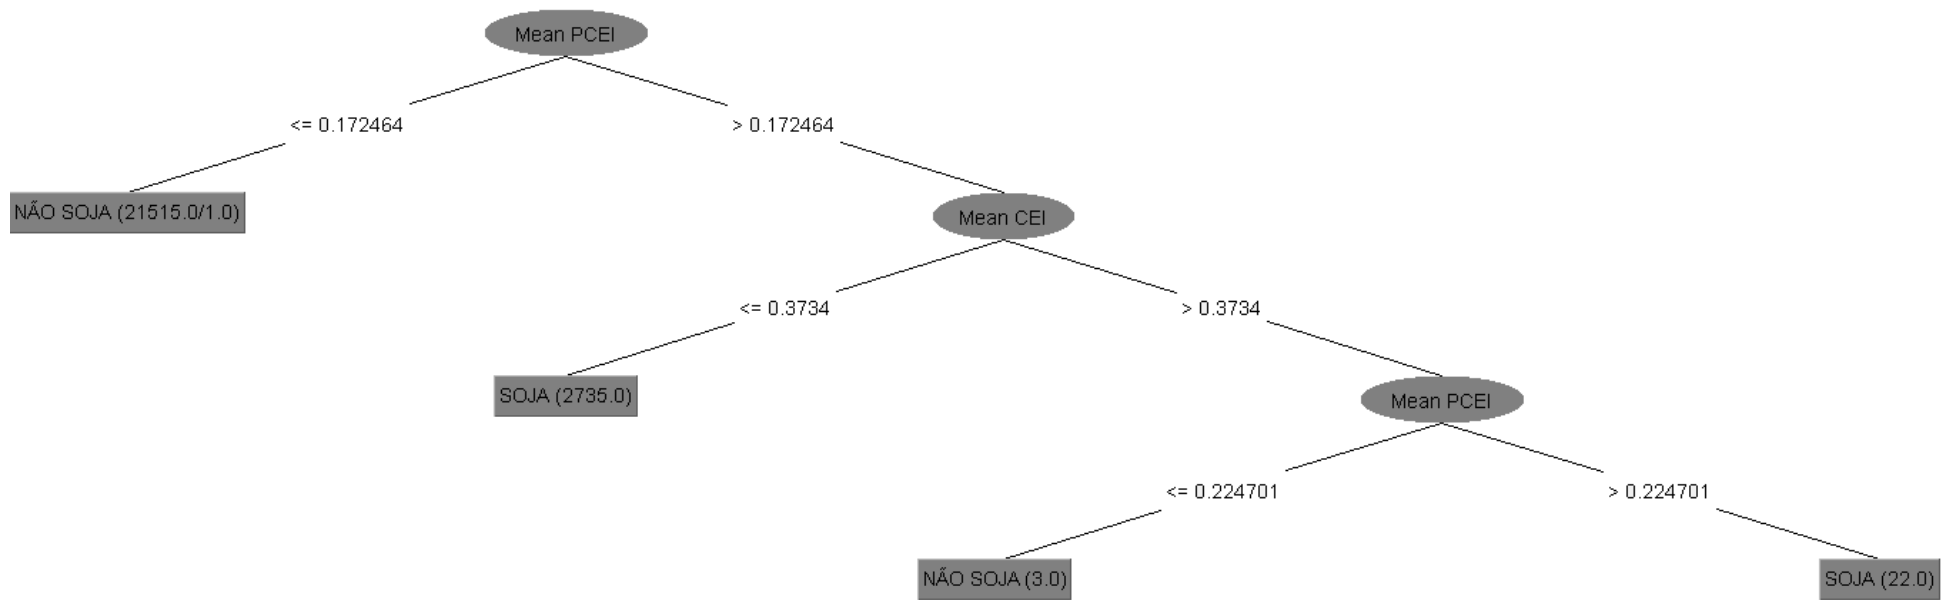


Figura 21. Árvore de decisão gerada pelo algoritmo J48 para o ano-safra 2010/2011.




Figura 22. Árvore de decisão gerada pelo algoritmo J48 para o ano-safra 2011/2012.

O cálculo de métricas texturais através de matrizes de co-ocorrência do valor digital (*Gray Level Cooccurrence Matrix - GLCM*) apresenta 14 parâmetros característicos da textura (HARALICK et al., 1973). Esta métrica extrai a informação de textura pela relação espacial existente entre os valores digitais pelas diferentes direções.

São encontradas na Tabela 11 as configurações utilizadas para o desenvolvimento das redes neurais artificiais. A determinação do número de neurônios é o problema mais fundamental em aprendizado de redes neurais, pois não existe na literatura uma regra geral que determine de forma precisa qual deve ser o número de neurônios de uma RNA para a solução de um determinado problema (BRAGA et al., 2007). Além disso, são escassos os trabalhos científicos com a utilização de RNA para estudos de áreas de soja.

A Tabela 11 mostra as configurações utilizadas para teste na tentativa de obter a rede que melhor classificasse as imagens e em destaque está a arquitetura que apresentou melhor resultado.

A arquitetura que apresentou superior resultado foi a configuração 2 para as duas safras estudadas (Tabela 11), uma rede neural artificial com 7 neurônios em uma única camada escondida. Outros parâmetros definidos foram: um conjunto de mais de 1.400 *pixels* por categoria para o conjunto de teste e treinamento, taxa de aprendizado de 0,01 e fator de momentum de 0,5 para aprimorar a convergência da rede.

Como critério de interrupção do treinamento da RNA foi estabelecido o limite de 10.000 iterações ou erro médio quadrático (EMQ) de 0,0001. A interrupção do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*, resultando em um valor de EMQ de 0,2796 para os dados de treinamento e 0,2832 para os dados de teste do ano-safra 2010/2011. Para a safra posterior o valor de EMQ foi de 0,3195 para os dados de treinamento e 0,3230 para os dados de teste.

A configuração 2 alcançou valores de precisões de 85,01 e 80,20 % (Tabela 11), ou seja, com maiores valores. Porém, quando analisado o resultado final da classificação a arquitetura não teve um bom desempenho na separação das classes soja e não-soja (ou seja, outros usos da terra). Este fato pode ser explicado pela utilização de um número maior de camadas do que o necessário, que leva a rede a ter dificuldades para convergir.

De acordo com a Tabela 11, pode-se relatar que a rede neural teve melhor desempenho com uma camada escondida, variando a quantidade de neurônios na camada e o conjunto de *pixels*. As camadas intermediárias trabalham com estimativas de erro, as quais em maior quantidade levaram a problemas de convergência da rede.

Tabela 11. Configurações das redes neurais artificiais aplicadas no mapeamento da soja em dois anos-safras.

| Configuração | Pixel | Camadas escondidas | Neurônios | | Taxa de Aprendizado | Momentum | Iterações | EMQ | | Precisão (%) |
|------------------|-------------|--------------------|-----------|-----------|---------------------|-------------|--------------|---------------|---------------|--------------|
| | | | 1° Camada | 2° Camada | | | | Trein. | Teste | |
| 2010/2011 | | | | | | | | | | |
| 1 | 1515 | 1 | 6 | - | 0,01 | 0,55 | 10000 | 0,2896 | 0,2903 | 83,32 |
| 2 | 1473 | 1 | 7 | - | 0,01 | 0,50 | 10000 | 0,2796 | 0,2832 | 85,01 |
| 3 | 1457 | 1 | 8 | - | 0,01 | 0,55 | 10000 | 0,3008 | 0,2991 | 82,16 |
| 4 | 1518 | 2 | 10 | 6 | 0,01 | 0,50 | 10000 | 0,2602 | 0,2738 | 83,23 |
| 5 | 1463 | 2 | 6 | 5 | 0,01 | 0,55 | 10000 | 0,2664 | 0,2651 | 85,52 |
| 2011/2012 | | | | | | | | | | |
| 1 | 1490 | 1 | 6 | - | 0,01 | 0,55 | 10000 | 0,3087 | 0,3269 | 79,14 |
| 2 | 1485 | 1 | 7 | - | 0,01 | 0,50 | 10000 | 0,3195 | 0,3230 | 80,20 |
| 3 | 1537 | 1 | 8 | - | 0,01 | 0,55 | 10000 | 0,3210 | 0,3277 | 78,46 |
| 4 | 1505 | 2 | 10 | 6 | 0,01 | 0,50 | 10000 | 0,2978 | 0,3136 | 79,14 |
| 5 | 1486 | 2 | 6 | 5 | 0,01 | 0,55 | 10000 | 0,3018 | 0,3178 | 78,80 |

Observando os resultados obtidos em extensas áreas de soja, percebeu-se que aumentando o número de *pixels* do conjunto de treinamento e teste, a rede produziu melhores resultados com um número de neurônios da primeira camada variando entre 6 e 10. Em áreas menores, a rede que obteve resultados superiores também possuía um número pequeno de neurônios na camada intermediária. O que justifica este resultado é que quanto maior for o número de neurônios na camada, maior será a complexidade da rede e maior será sua abrangência em termos de soluções possíveis (BRAGA et al., 2007).

As Figuras 23 e 24 ilustram o progresso do treinamento de uma MLP, tanto no treinamento e erro de teste em que mostram o número de padrões aprendidos versus formação de iterações. O número total de padrões aprendidos foi de 10.000. Para o aprendizado da configuração 2 (Tabela 11), os parâmetros foram muito mais conservadores, como para a formação dos testes de treinos e erros (Figura 23b e 24b). Por menos de 10.000 vezes de iteração de treinamento, o EMQ para dados de teste foi reduzida para menos de 0,50 e estabilizado nesse nível (Tabela 11 e Figura 23 e 24). A Figura 24D e 24E apresentaram maiores erros médios quadráticos em função das iterações, possivelmente devido a segunda camada de neurônios utilizadas, fazendo com que houvesse confusão conforme as iterações para identificação de padrões de áreas de soja.

A relação das redes neurais artificiais utilizadas na agricultura, principalmente com a cultura da soja ou mapeamento de áreas agrícolas ainda são escassas. No entanto, podemos destacar sua utilização em algumas pesquisas.

Andrade et al. (2013) tiveram como objetivo identificar áreas cultivadas com café em Minas Gerais, em que utilizaram imagens TM/Landsat-5 com RNA do tipo *multi-layer perceptron* (MLP). Os mesmos autores encontraram resultados satisfatórios para o mapeamento automático com a utilização da RNA. Para áreas cafeeiras também foram obtidos resultados semelhantes pesquisados por Vieira et al. (2009).

A avaliação da eficiência das redes neurais artificiais para classificação do uso do solo pode ser encontrada em estudo realizado por Chagas et al. (2009), a partir de imagens de sensoriamento remoto com ênfase nos níveis de degradação das pastagens.

Com a utilização de sensoriamento remoto sub-orbital utilizando aeronaves foi estudado por Pereira Neto et al. (2005), em que realizaram o mapeamento da infestação de plantas invasoras na cultura de soja utilizando a classificação digital de imagens por redes neurais artificiais, sendo classificada como cultura, invasora e entrelinha.

Outro exemplo utilizando RNA pode ser encontrado em Silva et al. (2005), em que propuseram o processamento digital de imagens associado às técnicas multivariadas e redes neurais artificiais, para ser utilizada como ferramenta de apoio na identificação dos estágios iniciais do desenvolvimento da Sigatoka Negra.

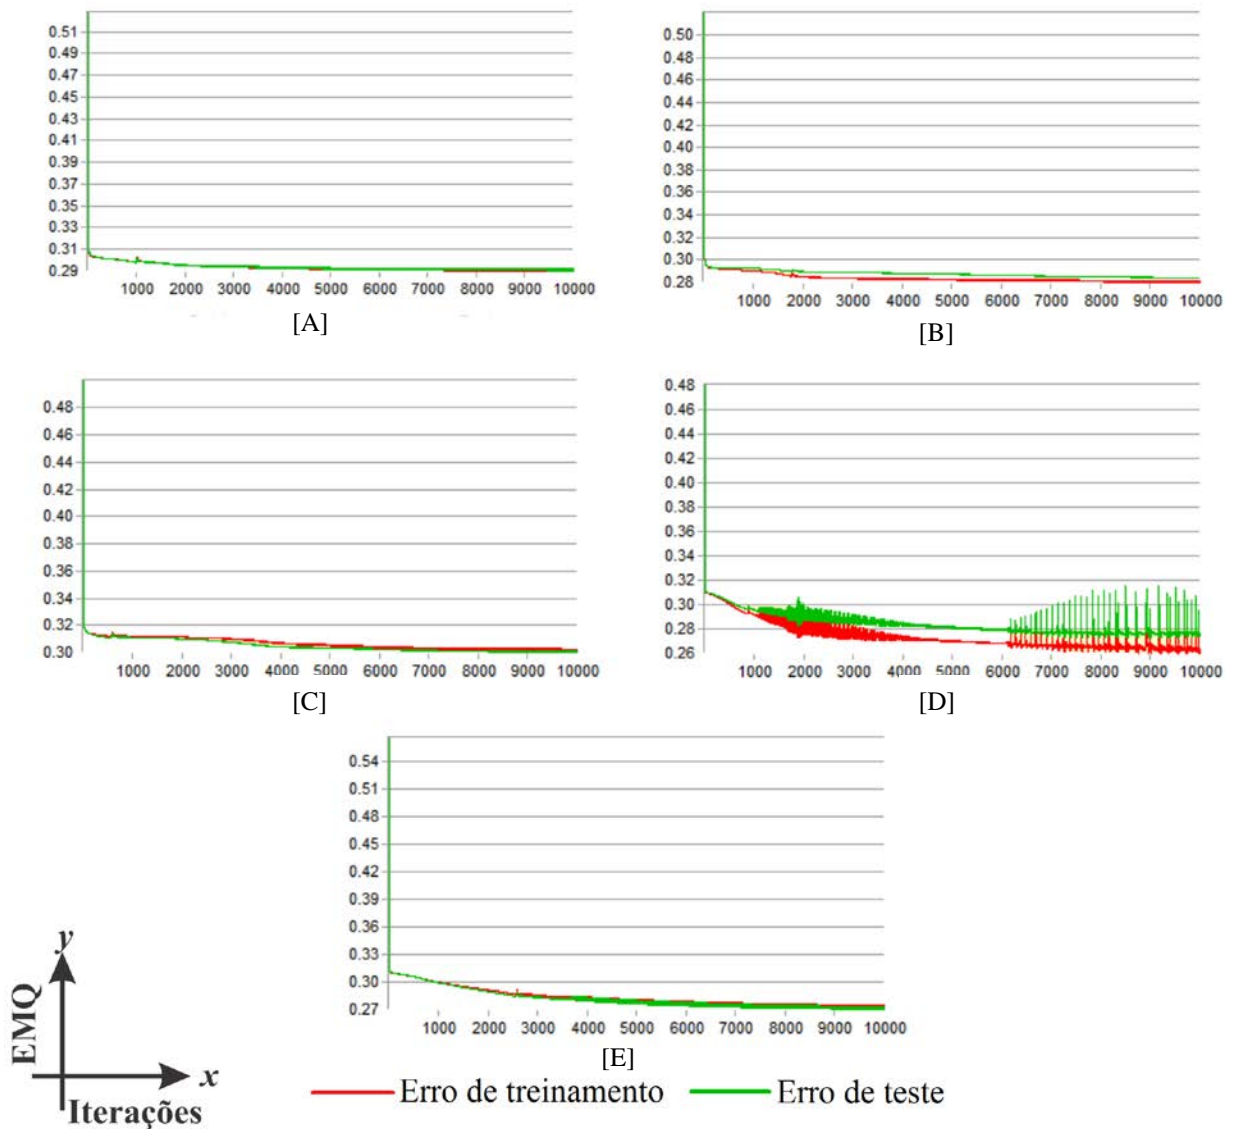


Figura 23. Erro de treinamento e teste para as respectivas configurações (A-1, B-2, C-3, D-4 e E-5) utilizadas em redes neurais artificiais para o ano-safra 2010/2011.

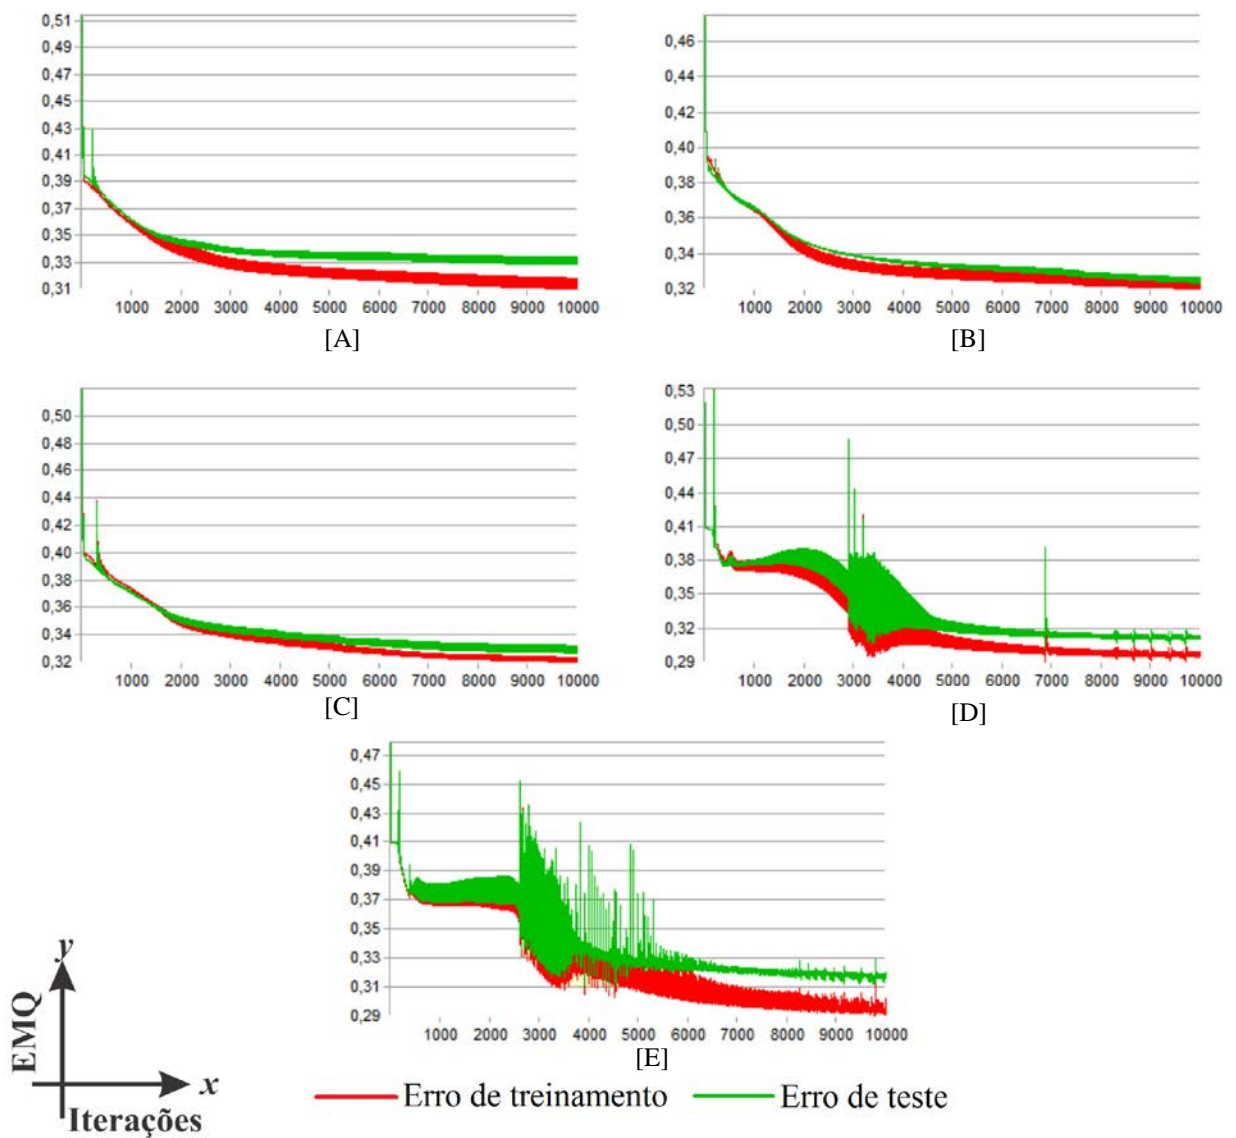


Figura 24. Erro de treinamento e teste para as respectivas configurações (A-1, B-2, C-3, D-4 e E-5) utilizadas em redes neurais artificiais para o ano-safra 2011/2012.

Na Figura 25 é apresentada a transformação por componentes principais no sistema de eixos ou componentes ortogonais rotacionados. O espaço de eixos rotacionados do primeiro componente não tem correlação com o segundo componente, o que mostra perfeitamente a concentração de informações nas primeiras componentes.

Segundo Meneses e Almeida (2012), a variância é uma medida do conteúdo de informação da imagem, o primeiro componente ou primeiro eixo agrega maior quantidade de informação espectral, produzindo uma imagem com maiores informações. Os *pixels* apresentam no primeiro componente (CP1) ou primeiro eixo principal, maior variância, enquanto, que no segundo componente (CP2) a variância é menor.

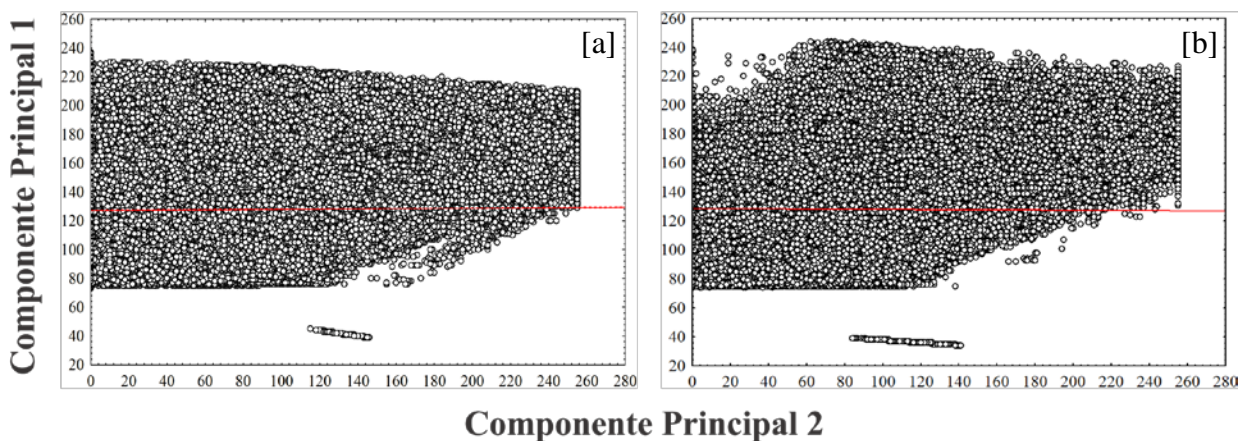


Figura 25. Descorrelação primeiro e segundo componente principal dos dados pela rotação espectral dos eixos originais dos dois anos-safras 2010/2011 (a) e 2011/2012 (b).

Portanto, o componente principal conseguiu definir o número de dimensões que estão presentes no conjunto de dados e fixou os coeficientes que especificam as posições dos eixos que apontem nas direções das mais altas variabilidades dos dados. Assim, foram eliminadas quaisquer correlações existentes entre as imagens, podendo ser notado simetria dos dados (Figura 25).

A Tabela 12 mostra a matriz dos coeficientes de correlação calculada para as cinco imagens nas duas safras estudadas. Todos os coeficientes variaram de -1 a 1. Os altos valores positivos indicam que a correlação é positiva entre as bandas e a correlação diminui quando o coeficiente se aproxima de zero. A Tabela 13 apresenta a matriz de covariância, em relação às bandas que variam conjuntamente para os dois anos-safras.

Na diagonal da matriz pode-se verificar a medida da variância de cada banda. Para ambas as safras a banda do infravermelho próximo e o EVI apresentam a maior variância, ou seja, contém maior informação e maior contraste espectral nos componentes principais.

Tabela 12. Matriz de coeficientes de correlação para imagens do sensor MODIS nos anos-safras 2010/2011 e 2011/2012.

| Correlação | Azul (017) | Vermelho (017) | IVP (017) | EVI (017) | PCEI |
|-----------------------|-------------------|-----------------------|------------------|------------------|-------------|
| 2010/2011 | | | | | |
| Azul (017) | 1,00 | | | | |
| Vermelho (017) | 0,79 | 1,00 | | | |
| IVP (017) | 0,48 | 0,64 | 1,00 | | |
| EVI (017) | 0,42 | 0,53 | 0,98 | 1,00 | |
| PCEI | 0,40 | 0,54 | 0,92 | 0,92 | 1,00 |
| 2011/2012 | | | | | |
| Azul (017) | 1,00 | | | | |
| Vermelho (017) | 0,89 | 1,00 | | | |
| IVP (017) | 0,65 | 0,68 | 1,00 | | |
| EVI (017) | 0,57 | 0,56 | 0,98 | 1,00 | |
| PCEI | 0,58 | 0,61 | 0,91 | 0,90 | 1,00 |

Tabela 13. Matriz de covariância para imagens do sensor MODIS nos anos-safras 2010/2011 e 2011/2012.

| Covariância | Azul (017) | Vermelho (017) | IVP (017) | EVI (017) | PCEI |
|-----------------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 2010/2011 | | | | | |
| Azul (017) | 0,000436 | | | | |
| Vermelho (017) | 0,000455 | 0,000755 | | | |
| IVP (017) | 0,001933 | 0,003379 | 0,037373 | | |
| EVI (017) | 0,002603 | 0,004310 | 0,055934 | 0,086699 | |
| PCEI | 0,000600 | 0,001061 | 0,012685 | 0,019326 | 0,005106 |
| 2011/2012 | | | | | |
| Azul (017) | 0,000197 | | | | |
| Vermelho (017) | 0,000344 | 0,000756 | | | |
| IVP (017) | 0,001586 | 0,003237 | 0,030014 | | |
| EVI (017) | 0,002139 | 0,004099 | 0,045090 | 0,070075 | |
| PCEI | 0,000468 | 0,000958 | 0,009035 | 0,013725 | 0,003302 |

Os autovalores dos componentes principais estão apresentados na Figura 26. Há variância em todas as imagens originais, no entanto após a realização do componente principal a maior variância encontra-se no primeiro componente, com valores sucessivamente menores, diminuindo a dimensionalidade dos dados. Os três primeiros componentes somam mais de 99,5% para as duas safras, praticamente a variância total do conjunto das cinco imagens originais. Assim, dos três primeiros componentes foram formados composição RGB para auxiliar na interpretação da classificação do primeiro componente e o restante foi descartado, o que representavam menos de 0,5% de informação. Comumente a partir do quarto componente as imagens apresentem ruídos, por isso foram desprezadas.




Figura 26. Auto-valores para os componentes realizados das imagens analisadas para os anos-safras 2010/2011 (A) e 2011/2012 (B).

As Figuras 27 e 28 apresentam as correlações entre os dados obtidos das imagens do sensor MODIS para as safras analisadas e aqueles obtidos por meio do espectrorradiômetro na casa de vegetação.

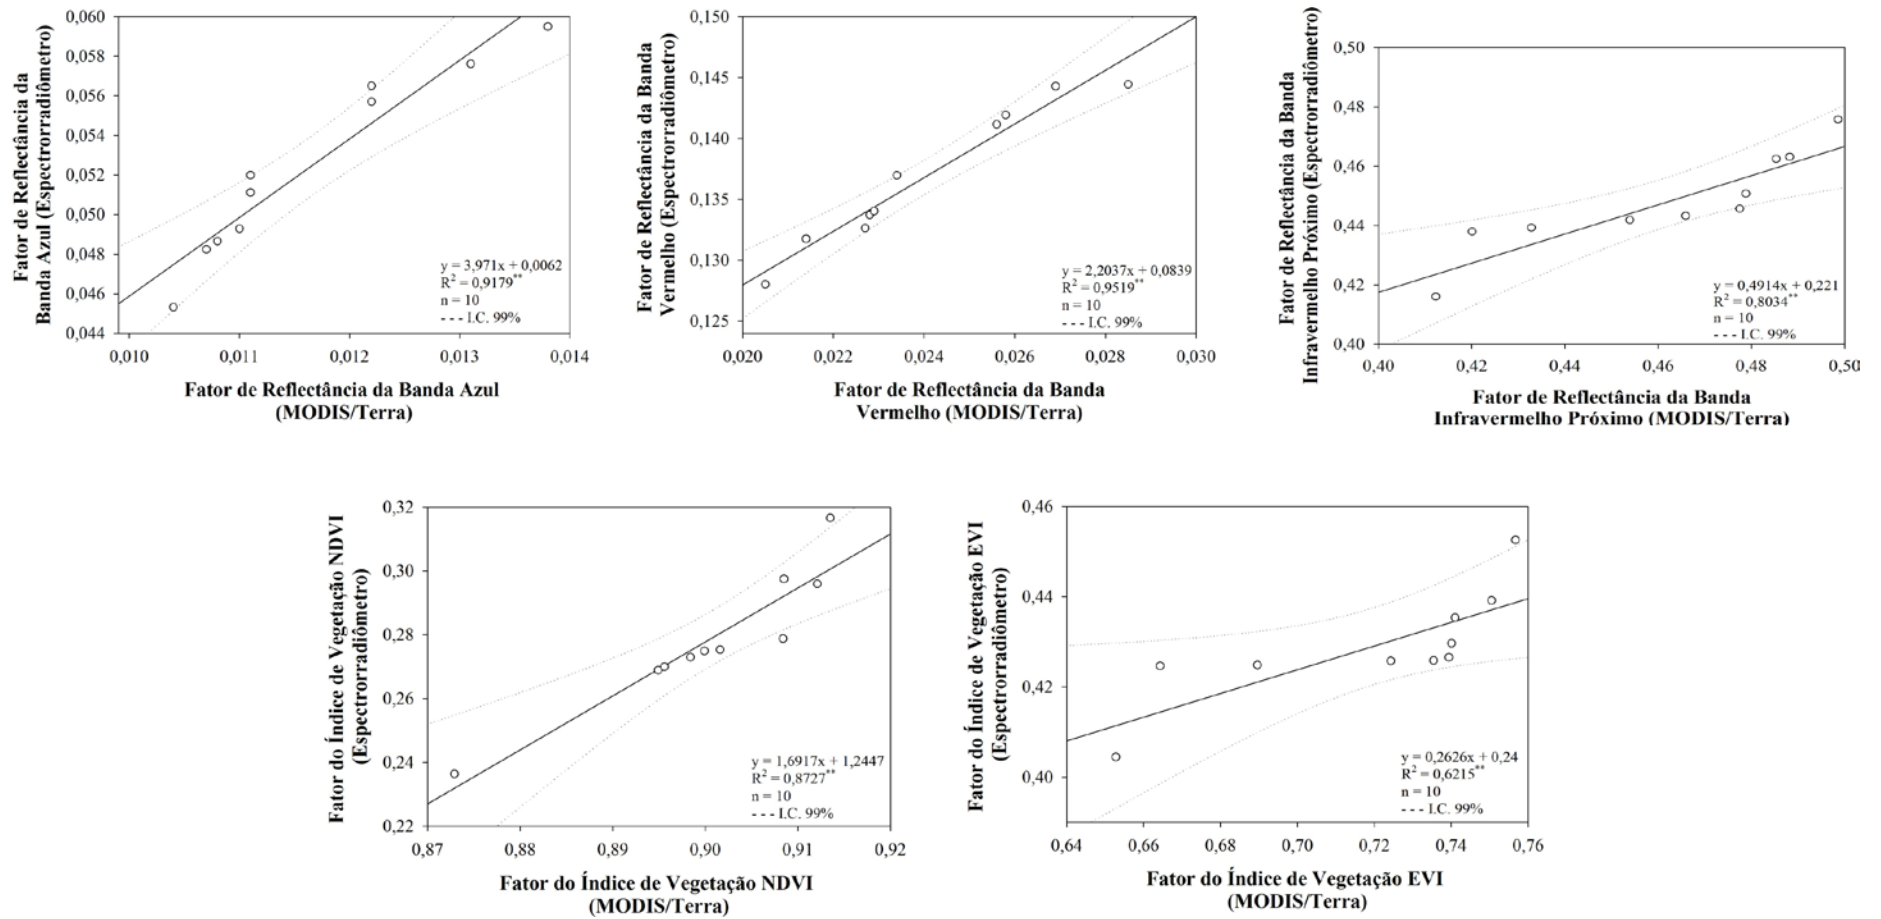


Figura 27. Regressão linear simples entre dados orbital e terrestre para áreas de soja do ano-safra 2010/2011.

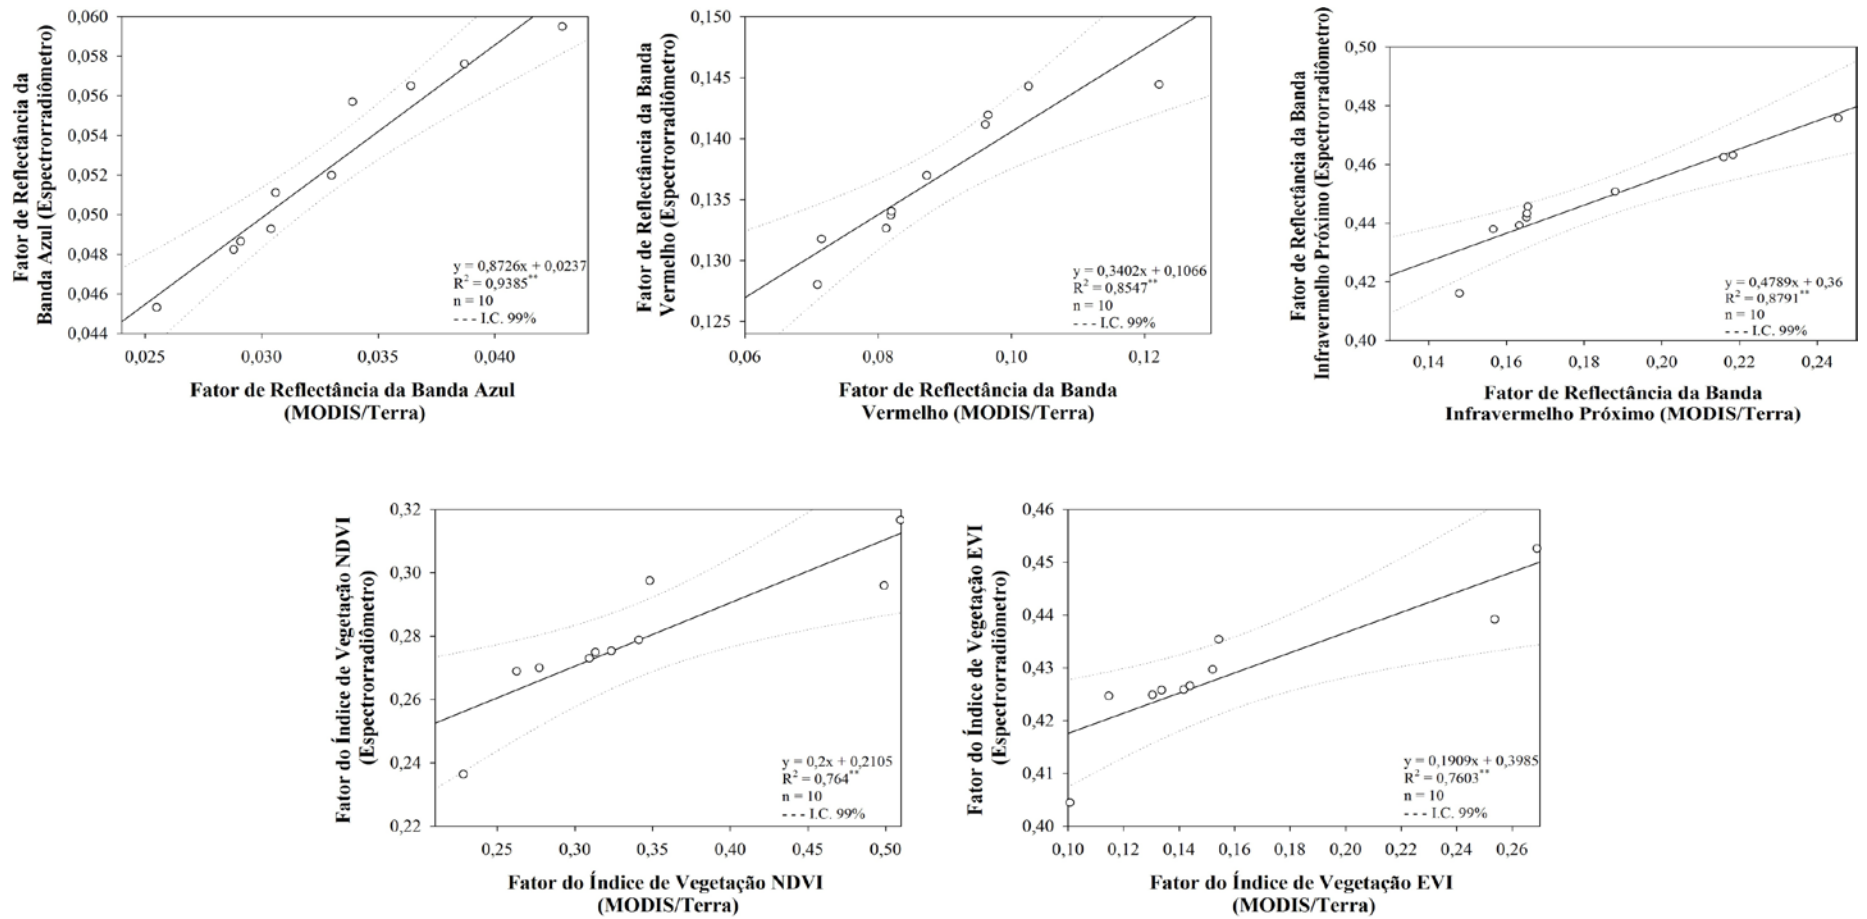


Figura 28. Regressão linear simples entre dados orbital e terrestre para áreas de soja do ano-safra 2011/2012.

As amostras relativas às áreas de soja foram selecionadas nas imagens MODIS após serem processadas pelo algoritmo de obtenção do índice de vegetação PCEI, e correlacionados com os valores de reflectância obtidos com o FieldSpec 3 para as bandas RGB, IVP e os índices NDVI e EVI.

Como os resultados obtidos pela regressão (R^2) foram elevados e significativos pelo teste t ($p > 0,01$), as áreas indicadas pelo índice PCEI apresentam potencial relevante para tal mapeamento automatizado. Todas as bandas espectrais utilizadas na regressão apresentaram-se superiores a 0,80. Apenas os índices de vegetação NDVI e EVI que se mostraram inferiores quando comparadas as bandas individuais. Esse resultado possivelmente é devido aos fatores atmosféricos não inclusos nos cálculos realizados para o nível laboratorial e considerado no orbital.

Notam-se valores superiores quando tratado das imagens espectrais obtidas pelo sensor MODIS, uma vez que é nulo qualquer tipo de interferência atmosférica ou espalhamento pelo espectrorradiômetro, apresentando assim valores íntegros. Além disso, há chances da imagem apresentar mistura espectral na cultura da soja, uma vez que interferências vizinhas podem contribuir na reflectância, o que não ocorre em laboratório.

Ao se analisar os dados obtidos pelos métodos utilizados nas estimativas de áreas de soja constataram-se que as classificações por meio do índice PCEI e análise orientada em geo-objeto (GEOBIA) ficaram em destaque com maiores parâmetros Kappa (κ) e Exatidão Global (EG), ao contrário do classificador K-Média e RNA (Tabela 14). O mesmo fator de piora na classificação ocorreu no algoritmo K-Média para o ano-safra 2011/2012 (Tabela 15), em que apresentou princípio de ausência de treinamento para quaisquer tipos de objeto que se determinou identificar.

A classificação com o índice de vegetação PCEI obteve parâmetros de EG e κ de 0,77 e 0,54, respectivamente (Tabela 14). O valor κ mostra a conformidade da classificação obtida. O índice Kappa apresenta vantagens sobre a Exatidão Global, pois incorpora todos os elementos da matriz de erro, objetos classificados corretamente ou não. Além disso, o κ avalia a exatidão temática porque é mais sensível às variações dos erros do consumidor e produtor e avalia a coincidência espacial entre duas situações (MOREIRA, 2011).

Ainda em relação ao parâmetro de Exatidão Global, todos os acertos foram de até 77% (Tabela 14), ficando abaixo do recomendado por Foody (2002), que ressalta que, para ser desejável, uma classificação deva alcançar índice de acertos superiores a 85%.

Tabela 14. Matriz de confusão das classificações em função dos diferentes métodos de estimativa de área de soja e seus respectivos valores dos índices κ e EG para o ano-safra 2010/2011.

| Referência | | | | | |
|-------------------------------|----------|------|----------|----------|------------------------------|
| CEI | | | | | |
| | | Soja | Não-Soja | Σ | |
| Classificação | Soja | 75 | 07 | 82 | $\kappa = 0,40$ EG = 0,70 |
| | Não-Soja | 97 | 167 | 264 | |
| | Σ | 172 | 174 | 346 | |
| PCEI | | | | | |
| Classificação | Soja | 113 | 20 | 133 | $\kappa = 0,54$ EG = 0,77 |
| | Não-Soja | 59 | 154 | 213 | |
| | Σ | 172 | 174 | 346 | |
| K-MÉDIA | | | | | |
| Classificação | Soja | 113 | 58 | 171 | $\kappa = 0,32$ EG = 0,66 |
| | Não-Soja | 59 | 116 | 175 | |
| | Σ | 172 | 174 | 346 | |
| COMPONENTES PRINCIPAIS | | | | | |
| Classificação | Soja | 97 | 14 | 111 | $\kappa = 0,48$ EG = 0,74 |
| | Não-Soja | 75 | 160 | 235 | |
| | Σ | 172 | 174 | 346 | |
| REDES NEURAIS | | | | | |
| Classificação | Soja | 67 | 08 | 75 | $\kappa = 0,34$ EG = 0,67 |
| | Não-Soja | 105 | 166 | 271 | |
| | Σ | 172 | 174 | 346 | |
| GEOBIA | | | | | |
| Classificação | Soja | 97 | 09 | 106 | $\kappa = 0,51$ EG = 0,76 |
| | Não-Soja | 75 | 165 | 240 | |
| | Σ | 172 | 174 | 346 | |

O índice PCEI e o método GEOBIA apresentaram maiores valores na estimativa de áreas de soja, como observado na Tabela 14 (ano-safra 2010/2011), com parâmetros Kappa superiores aos demais, além do PCEI estar presente na mineração de dados e ser utilizado

como principal atributo na árvore de decisão gerada pelo WEKA 3.6.8. Geralmente a mineração de dados é o processo de análise de dados a partir de diferentes perspectivas com o objetivo de resumi-las em informações úteis, ou seja, é o processo de encontrar correlação ou padrões entre dezenas de campos relacionais em um grande banco de dados (YANG et al., 2008).

O κ , que avalia a concordância ou discordância entre as classificações realizadas variou entre 0,32 (K-Média – Tabela 14 e 15) e 0,66 (CEI – Tabela 15) o que, segundo classificação proposta por Landis e Koch (1977), é de razoável a boa qualidade ($\kappa > 0,21$ e 0,81), respectivamente.

Assim, pode-se dizer que os mapas temáticos gerados para a cultura da soja principalmente quando utilizado o CEI, aproximaram-se dos dados oficiais. Os valores também são significativos quando comparados com trabalhos que utilizaram o mesmo sensor, porém com outra metodologia, como Lamparelli et al. (2008) que, ao estimar cultura da soja com dados MODIS, obtiveram parâmetro Kappa entre 0,60 a 0,80.

O menor valor do parâmetro Kappa e Exatidão Global de outros classificadores principalmente os não-supervisionados (K-Média, IsoSeg e IsoData), podem estar associados a maior confusão na vegetação natural e consequente superestimativa das áreas de soja.

Portanto, a avaliação dos classificadores mostra que aqueles baseados na estrutura *pixel-a-pixel* como, por exemplo, o MaxVer utilizado no componente principal e a RNA que contam com a aquisição de amostras por parte do usuário possuem resultados mais refinados e de boa exatidão. Além disso, a combinação do MaxVer com o ICM apresenta tendência de melhorar os resultados, porque considera a dependência espacial na classificação, ou seja, a classe atribuída depende tanto do valor observado nesse *pixel*, quanto das classes atribuídas aos seus vizinhos (MOREIRA, 2011).

Para o componente principal que utilizou cinco imagens incluindo índices de vegetação, apresentaram para os parâmetros Kappa (0,48 e 0,62) e Exatidão Global (0,74 e 0,81), respectivamente às safras 2010/2011 e 2011/2012 (Tabela 14 e 15).

Esses resultados são semelhantes aos obtidos por Rudorff et al. (2007), no estado do Rio Grande do Sul ao estimar a cultura da soja com sensor MODIS, onde obtiveram parâmetros de Exatidão Global de 76,17% e Kappa de 0,50, considerado por Pax-Lenney e Woodcock (1997) como bom desempenho.

Para medir a precisão de cada categoria (soja e não-soja), utilizou-se o erro do ponto de vista do produtor e do consumidor para os anos-safras estudados (Tabela 16 e 17), por

meio da análise dos erros de inclusão e dos erros de omissão presentes nas classificações (ANTUNES et al., 2012).

Tabela 15. Matriz de confusão das classificações em função dos diferentes métodos de estimativa de área de soja e seus respectivos valores dos índices κ e EG para o ano-safra 2011/2012.

| Referência | | | | | |
|-------------------------------|----------|------|----------|----------|------------------------------|
| CEI | | | | | |
| | | Soja | Não-Soja | Σ | |
| Classificação | Soja | 116 | 3 | 119 | $\kappa = 0,66$ EG = 0,83 |
| | Não-Soja | 56 | 171 | 227 | |
| | Σ | 172 | 174 | 346 | |
| PCEI | | | | | |
| Classificação | Soja | 131 | 29 | 160 | $\kappa = 0,59$ EG = 0,80 |
| | Não-Soja | 41 | 145 | 186 | |
| | Σ | 172 | 174 | 346 | |
| K-MÉDIA | | | | | |
| Classificação | Soja | 101 | 47 | 148 | $\kappa = 0,32$ EG = 0,66 |
| | Não-Soja | 71 | 127 | 198 | |
| | Σ | 172 | 174 | 346 | |
| COMPONENTES PRINCIPAIS | | | | | |
| Classificação | Soja | 115 | 8 | 123 | $\kappa = 0,62$ EG = 0,81 |
| | Não-Soja | 57 | 166 | 223 | |
| | Σ | 172 | 174 | 346 | |
| REDES NEURAIS | | | | | |
| Classificação | Soja | 101 | 3 | 104 | $\kappa = 0,57$ EG = 0,79 |
| | Não-Soja | 71 | 171 | 242 | |
| | Σ | 172 | 174 | 346 | |
| GEOBIA | | | | | |
| Classificação | Soja | 72 | 3 | 75 | $\kappa = 0,40$ EG = 0,70 |
| | Não-Soja | 100 | 171 | 271 | |
| | Σ | 172 | 174 | 346 | |

Ao se analisar os dados dos erros do produtor e consumidor (inclusão e omissão, respectivamente), ressalta-se que o menor valor para o erro de inclusão para a classe soja foi obtido com a classificação por meio do índice PCEI, com erros de 0,34 e 0,24 para o ano-safra 2010/2011 e 2011/2012, respectivamente, enquanto que para essa mesma classe o erro de omissão ocorrida nesta classificação foi de 0,15 e 0,18 (Tabela 16 e 17, respectivamente). Isso significa que para a superior estimativa, 76% das áreas classificadas como soja, 86,32% corresponderam realmente a essa classe para o ano-safra 2011/2012 (Tabela 16). Deste modo, o erro do produtor ocorre quando um objeto é incluído na classe a qual ele não pertence e o erro do consumidor quando um objeto é excluído da classe a qual pertence (JOHANN et al., 2012).

Tabela 16. Erro e precisão do ponto de vista do produtor e do consumidor para as Matrizes de Erros para a classe soja construídas a partir das imagens.

| Método de análise | Produtor | | Consumidor | |
|------------------------|----------|----------|------------|----------|
| | Erro | Precisão | Erro | Precisão |
| 2010/2011 | | | | |
| CEI | 0,56 | 0,44 | 0,08 | 0,91 |
| PCEI | 0,34 | 0,66 | 0,15 | 0,85 |
| K-MÉDIA | 0,34 | 0,66 | 0,34 | 0,66 |
| COMPONENTES PRINCIPAIS | 0,44 | 0,56 | 0,13 | 0,87 |
| REDES NEURAIIS | 0,61 | 0,39 | 0,11 | 0,89 |
| GEOBIA | 0,44 | 0,56 | 0,08 | 0,91 |
| 2011/2012 | | | | |
| CEI | 0,33 | 0,67 | 0,03 | 0,97 |
| PCEI | 0,24 | 0,76 | 0,18 | 0,82 |
| K-MÉDIA | 0,41 | 0,59 | 0,32 | 0,68 |
| COMPONENTES PRINCIPAIS | 0,33 | 0,67 | 0,07 | 0,93 |
| REDES NEURAIIS | 0,41 | 0,59 | 0,03 | 0,97 |
| GEOBIA | 0,58 | 0,42 | 0,04 | 0,96 |

Um dos métodos de análise com o erro do produtor que merece destaque, para a classe soja no ano-safra 2011/2012, foi o índice CEI e componentes principais (Tabela 16), apresentando valores de 0,33. No entanto, do ponto de vista do consumidor a precisão foi de

97 e 93%, respectivamente, sendo assim, mesmo com uma avaliação de 67% das áreas sendo identificadas como cultura de soja, mais de 95% tinha realmente esse uso, ou seja, as áreas de tal classe foram adequadamente classificadas, porém subestimadas.

Por outro lado, no que se refere à classe não-soja (Tabela 17), pode-se destacar o valor obtido no erro do produtor presente nos métodos CEI, RNA e GEOBIA para os dois anos-safras. Em evidência apresentam-se os valores do ano-safra 2011/2012 com valor de 0,02. Em relação ao consumidor não se pode observar o mesmo, uma vez que os erros obtidos foram de 0,25, 0,29 e 0,37 tendo, como consequência, estimativa elevada da classe soja e redução da classe não-soja.

Tabela 17. Erro e precisão do ponto de vista do produtor e do consumidor para as Matrizes de Erros para a classe não-soja construídas a partir das imagens.

| Método de análise | Produtor | | Consumidor | |
|------------------------|----------|----------|------------|----------|
| | Erro | Precisão | Erro | Precisão |
| 2010/2011 | | | | |
| CEI | 0,04 | 0,96 | 0,37 | 0,63 |
| PCEI | 0,11 | 0,88 | 0,28 | 0,72 |
| K-MÉDIA | 0,33 | 0,67 | 0,34 | 0,66 |
| COMPONENTES PRINCIPAIS | 0,08 | 0,92 | 0,32 | 0,68 |
| REDES NEURAIIS | 0,05 | 0,95 | 0,39 | 0,61 |
| GEOBIA | 0,05 | 0,95 | 0,31 | 0,69 |
| 2011/2012 | | | | |
| CEI | 0,02 | 0,98 | 0,25 | 0,75 |
| PCEI | 0,17 | 0,83 | 0,22 | 0,78 |
| K-MÉDIA | 0,27 | 0,73 | 0,36 | 0,64 |
| COMPONENTES PRINCIPAIS | 0,05 | 0,95 | 0,26 | 0,74 |
| REDES NEURAIIS | 0,02 | 0,98 | 0,29 | 0,71 |
| GEOBIA | 0,02 | 0,98 | 0,37 | 0,63 |

Em geral, os resultados superiores foram obtidos para a classe soja com a técnica PCEI, CEI, componentes principais, GEOBIA e RNA, possivelmente devido ao fato de que, diferentemente do K-Média, essas técnicas levaram em consideração diversas imagens, além de série-temporal. Para tanto, o GEOBIA leva em consideração diferentes atributos no

contexto do espaço em que se inseriram os alvos a partir do processo de segmentação. Entretanto, para a classe não-soja, houve uma pequena diferença entre os erros do GEOBIA, RNA, componentes principais e o fatiamento realizado no índice CEI e PCEI, pois o contingente da mistura espectral é maior e generalizado para os classificadores.

Ainda no que se refere à classe não-soja (Tabela 17), pode-se destacar o valor obtido no erro do produtor presente nos métodos CEI e RNA, que foi de 0,04 e 0,05, respectivamente para o ano-safra 2010/2011. Já em relação ao consumidor não se pode observar o mesmo, uma vez que o erro obtido foi de até 0,39 tendo, como consequência, subestimativa da classe soja e aumento da classe não-soja.

Os testes de hipóteses, em função dos resultados dos produtos, estão apresentados na Tabela 18 e 19.

Tabela 18. Teste de hipótese para comparar os resultados de exatidão entre os índices para o ano-safra 2010/2011.

| Kappa ₁ versus Kappa ₂ | Z | valor-p |
|--|-------|----------------------|
| K-MÉDIA x REDES NEURAIAS | -0,32 | 0,3748 ^{ns} |
| K-MÉDIA x COMPONENTES PRINCIPAIS | -2,39 | 0,0084* |
| K-MÉDIA x GEOBIA | -2,86 | 0,0021* |
| K-MÉDIA x CEI | -1,11 | 0,1335 ^{ns} |
| K-MÉDIA x PCEI | -3,26 | 0,0006* |
| REDES NEURAIAS x COMPONENTES PRINCIPAIS | -2,30 | 0,0107* |
| REDES NEURAIAS x GEOBIA | -2,82 | 0,0024* |
| REDES NEURAIAS x CEI | -0,88 | 0,1891 ^{ns} |
| REDES NEURAIAS x PCEI | -3,26 | 0,0006* |
| COMPONENTES PRINCIPAIS x GEOBIA | -0,47 | 0,3189 ^{ns} |
| COMPONENTES PRINCIPAIS x CEI | 1,43 | 0,0757 ^{ns} |
| COMPONENTES PRINCIPAIS x PCEI | -0,94 | 0,1747 ^{ns} |
| GEOBIA x CEI | 1,94 | 0,0262* |
| GEOBIA x PCEI | -0,48 | 0,3159 ^{ns} |
| CEI x PCEI | -2,39 | 0,0084* |

^{ns}Não significativo; *Significativo a 0,05 de probabilidade

Pela análise dos dados obtidos nas estimativas de áreas de soja, foi verificado que algumas classificações apresentaram igualdade perante o teste Z para os parâmetros Kappa (κ)

e Exatidão Global (EG), tais como: K-Média quando comparado ao RNA e índice CEI; RNA com o CEI; componentes principais para com o GEOBIA, CEI e PCEI; e por fim, GEOBIA e PCEI para o ano-safra 2010/2011.

Em relação ao ano-safra 2011/2012 as igualdades foram identificadas na comparação de K-Média com GEOBIA; RNA e componentes principais; RNA com CEI e PCEI; e entre os dois índices citados por último.

Tabela 19. Teste de hipótese para comparar os resultados de exatidão entre os índices para o ano-safra 2011/2012.

| Kappa ₁ versus Kappa ₂ | Z | valor-p |
|--|-------|----------------------|
| K-MÉDIA x REDES NEURAIAS | -3,92 | 0,0000* |
| K-MÉDIA x COMPONENTES PRINCIPAIS | -4,74 | 0,0000* |
| K-MÉDIA x GEOBIA | -1,31 | 0,0944 ^{ns} |
| K-MÉDIA x CEI | -5,37 | 0,0000* |
| K-MÉDIA x PCEI | -4,18 | 0,0000* |
| REDES NEURAIAS x COMPONENTES PRINCIPAIS | -0,92 | 0,1801 ^{ns} |
| REDES NEURAIAS x GEOBIA | 2,93 | 0,0017* |
| REDES NEURAIAS x CEI | -1,55 | 0,0600 ^{ns} |
| REDES NEURAIAS x PCEI | -0,40 | 0,3431 ^{ns} |
| COMPONENTES PRINCIPAIS x GEOBIA | 3,85 | 0,0001* |
| COMPONENTES PRINCIPAIS x CEI | -0,62 | 0,2670 ^{ns} |
| COMPONENTES PRINCIPAIS x PCEI | 0,48 | 0,3149 ^{ns} |
| GEOBIA x CEI | -4,56 | 0,0000* |
| GEOBIA x PCEI | -3,24 | 0,0006* |
| CEI x PCEI | 1,09 | 0,1375 ^{ns} |

^{ns}Não significativo; *Significativo a 0,05 de probabilidade

Por meio do teste Z foi possível verificar que a classificação por redes neurais artificiais (RNA) apresentou valor κ inferior quando comparado ao PCEI e GEOBIA (Tabela 18), possivelmente por alguma confusão ocorrida pelo usuário no treinamento dos neurônios, ou seja, nos polígonos selecionados.

Para o parâmetro κ , a maior parte dos testes resultou em diferença significativa, exceto os comparativos citados anteriormente. Vale ressaltar que, quanto mais próximo de zero o valor-p, maior é a evidência contra a hipótese de igualdade, fato apenas não observado na

comparação entre os parâmetros de algumas classificações, além dos outros comparativos supracitados que obtiveram zero absoluto. Por exemplo, a previsão do índice CEI apresentar igualdade pelo teste Z perante o resultado da RNA era esperado, pois o índice faz parte de um *input layer* da MLP (*Multi-layer Perceptron*).

Para os municípios estudados foram gerados resultados quantificados em hectares do cultivo da soja individualmente, onde estão apresentados na Tabela 20 para o ano-safra 2010/2011 e Tabela 21 para o ano-safra 2011/2012 (Apêndice D).

Ao ser comparado com dados oficiais (SIDRA/IBGE, 2012), a técnica PCEI conseguiu se aproximar dos dados oficiais. Na análise realizada pelo teste Z foi observado pela técnica em questão que todos os valores apresentaram significância de 95% de probabilidade e superioridade quando comparados com os demais parâmetros κ gerados pelas demais classificações.

Tal resultado demonstra que as estimativas apresentadas na Tabela 20 e 21, demonstram proximidade aos dados oficiais.

As áreas de soja estimadas pela Tabela 20 e 21 apresentaram semelhança entre as classificações realizadas pelo índice PCEI, variando em torno daqueles estimados por dados oficiais (SIDRA/IBGE, 2012). Dado em função do índice CEI apresentar melhor parâmetro κ , apresentado pela Tabela 15 e confirmado pela Tabela 19, acabou subestimando a estimativa, quando também utilizado no componente principal.

As superestimativas apresentaram semelhança na classificação não-supervisionadas (K-Média), o que já era esperado pela ausência de treinamento para geração da classificação.

Ressalta-se que essas estimativas são baseadas em métodos objetivos (estatístico) com a utilização de imagens de satélite, com resolução espacial de 250 m, adverso das estimativas do SIDRA/IBGE, que são obtidas de maneira subjetiva por meio de entrevistas com produtores, reuniões com técnicos para verificação de intenção de plantio realizadas por amostragem e quantidade de insumos vendidos para safra.

Tabela 20. Áreas estimadas de soja em hectares por mesorregião do estado do Paraná para o ano-safra 2010/2011.

| MESOREGIÃO | CEI | PCEI | K-MÉDIA | COMPONENTES PRINCIPAIS | REDES NEURAI | GEOBIA |
|-------------------------|---------------------|---------------------|---------------------|-----------------------------------|-------------------------|---------------------|
| NOROESTE | 118.060,84 | 292.838,10 | 442.476,40 | 187.911,78 | 91.782,00 | 158.264,90 |
| CENTRO OCIDENTAL | 274.906,94 | 593.658,09 | 801.032,76 | 497.219,57 | 319.579,23 | 439.892,71 |
| NORTE CENTRAL | 369.490,52 | 886.471,20 | 1364.637,67 | 757.911,49 | 475.709,53 | 594.531,57 |
| NORTE PIONEIRO | 109.441,89 | 373.593,88 | 654.000,81 | 244.122,31 | 116.620,91 | 180.985,85 |
| CENTRO ORIENTAL | 104.039,44 | 355.106,87 | 1.185.586,81 | 281.889,54 | 160.931,76 | 128.779,78 |
| OESTE | 505.982,16 | 989.992,25 | 1.186.485,00 | 737.176,05 | 379.364,49 | 779.769,98 |
| SUDOESTE | 33.220,42 | 234.247,99 | 412.342,58 | 95.083,23 | 32.063,27 | 55.155,69 |
| CENTRO-SUL | 132.288,35 | 504.189,67 | 919.466,69 | 224.086,38 | 104.406,60 | 209.528,43 |
| SUDESTE | 40.302,95 | 191.702,87 | 492.376,00 | 102.890,24 | 52.039,74 | 49.661,19 |
| METROPOLITANA | 19.823,58 | 84.272,07 | 985.650,20 | 29.916,49 | 11.914,92 | 18.690,17 |
| TOTAL | 1.707.557,08 | 4.506.073,00 | 8.444.054,92 | 3.158.207,07 | 1.744.412,45 | 2.615.260,29 |

Tabela 21. Áreas estimadas de soja em hectares por mesorregião do estado do Paraná para o ano-safra 2011/2012.

| MESOREGIÃO | CEI | PCEI | K-MÉDIA | COMPONENTES PRINCIPAIS | REDES NEURAS | GEOBIA |
|-------------------------|--------------|--------------|----------------|-----------------------------------|-------------------------|---------------|
| NOROESTE | 50.883,02 | 178.181,12 | 162.760,70 | 79.587,86 | 39.890,74 | 47.878,88 |
| CENTRO OCIDENTAL | 149.807,29 | 378.627,85 | 508.011,99 | 225.897,61 | 115.306,52 | 180.654,38 |
| NORTE CENTRAL | 199.022,73 | 577.950,37 | 1.111.132,18 | 268.586,38 | 159.444,28 | 270.603,71 |
| NORTE PIONEIRO | 59.526,95 | 282.145,61 | 474.223,22 | 84.596,84 | 44.524,98 | 77.608,00 |
| CENTRO ORIENTAL | 137.759,51 | 563.691,63 | 775.599,07 | 233.560,98 | 117.392,56 | 134.830,31 |
| OESTE | 240.424,91 | 599.466,51 | 456.292,06 | 455.011,71 | 211.070,52 | 316.590,17 |
| SUDOESTE | 11.129,68 | 72.349,19 | 275.038,10 | 12.784,77 | 7.207,44 | 4.340,70 |
| CENTRO-SUL | 168.700,28 | 624.842,44 | 1.287.608,25 | 269.073,54 | 148.808,00 | 183.489,89 |
| SUDESTE | 73.311,02 | 438.704,41 | 580.979,49 | 82.654,45 | 52.550,60 | 57.103,65 |
| METROPOLITANA | 47.747,72 | 379.839,50 | 202.726,38 | 46.823,37 | 20.142,10 | 44.187,72 |
| TOTAL | 1.138.313,11 | 4.095.798,63 | 5.834.371,44 | 1.758.577,51 | 916.337,74 | 1.317.287,41 |

Contudo, métodos objetivos também trazem incertezas, sendo confirmados apenas com dados confiáveis que são representados na realidade sendo que, normalmente, ocorre super ou subestimativas quando relacionados a dados oficiais, como também observado por XIAO et al., 2002; IPPOLITI-RAMILO et al., 2003; LAMPARELLI et al., 2008; OZDOGAN, 2010; PAN et al., 2012; PENG e GITELSON, 2012; WU e LI, 2012, que trabalharam com técnicas de sensoriamento remoto na estimativa de áreas agrícolas.

As Figuras 29 e 30 mostram a distribuição espacial da cultura da soja no estado do Paraná obtidos pelos diferentes sistemas classificadores. Ao observar a distribuição da classe soja, pode-se perceber semelhança entre as áreas na classificação pelos índices PCEI e CEI, RNA, GEOBIA e componentes principais. A única exceção é visualizada pelo classificador K-Média, por apresentar generalidade e superestimar as áreas mapeadas.

Os classificadores que apresentaram subestimativas (Tabela 20 e 21) mostraram-se com mais intensidade as áreas coloridas que estimam as possíveis áreas de soja. As técnicas metodológicas aqui demonstradas e avaliadas apresentam relevante potencial de utilização para mapeamento da cultura da soja podendo, desta forma, serem utilizadas como complemento para órgãos oficiais estaduais e federais no gerenciamento de ações referente à cultura, especializando-a num detalhamento até por município e obtendo, com maior rapidez, estatísticas agrícolas objetivas.

Ao observar a Figura 30, percebe-se semelhança entre a distribuição espacial da estimativa das áreas de soja na classificação com o índice PCEI e componentes principais. Por apresentar subestimativa (Tabela 21), os classificadores RNA, GEOBIA e CEI mostraram-se com menos intensidade as áreas coloridas.

As técnicas que utilizaram série-temporal como o *Perpendicular Crop Enhancement Index* (PCEI) e CEI apresentaram potencial superior aos demais para a finalidade automatização do mapeamento de áreas agrícolas no estado do Paraná.

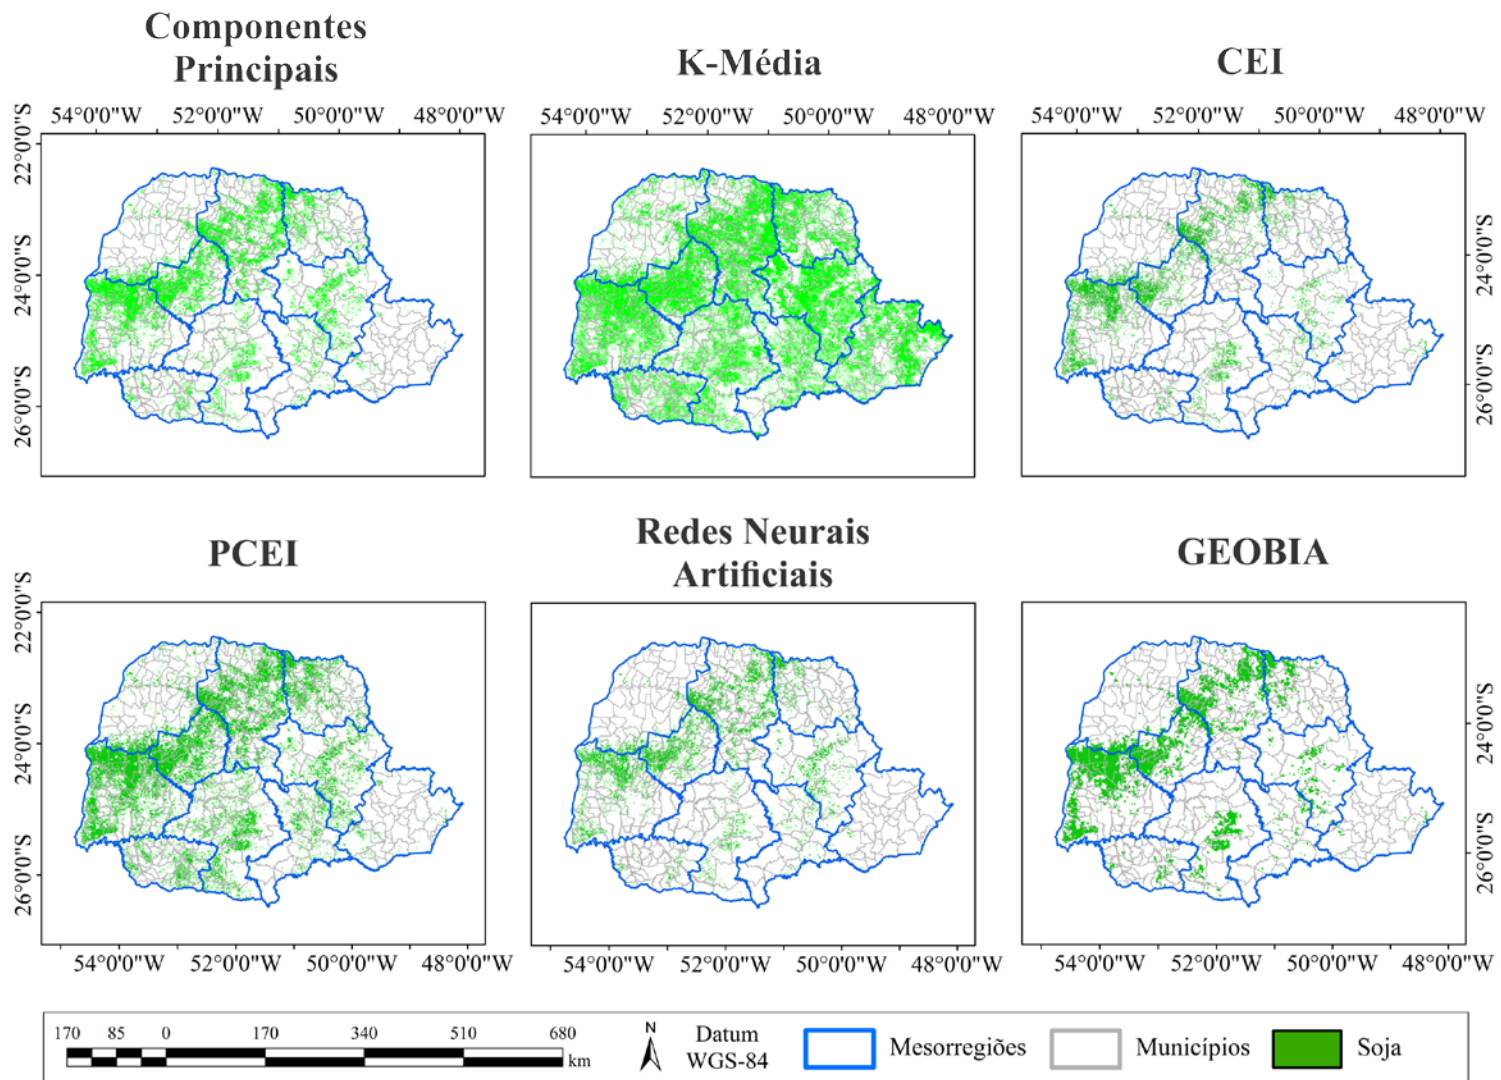


Figura 29. Distribuição espacial de áreas cultivadas com soja no ano-safra 2010/2011 conforme suas respectivas técnicas de classificação.

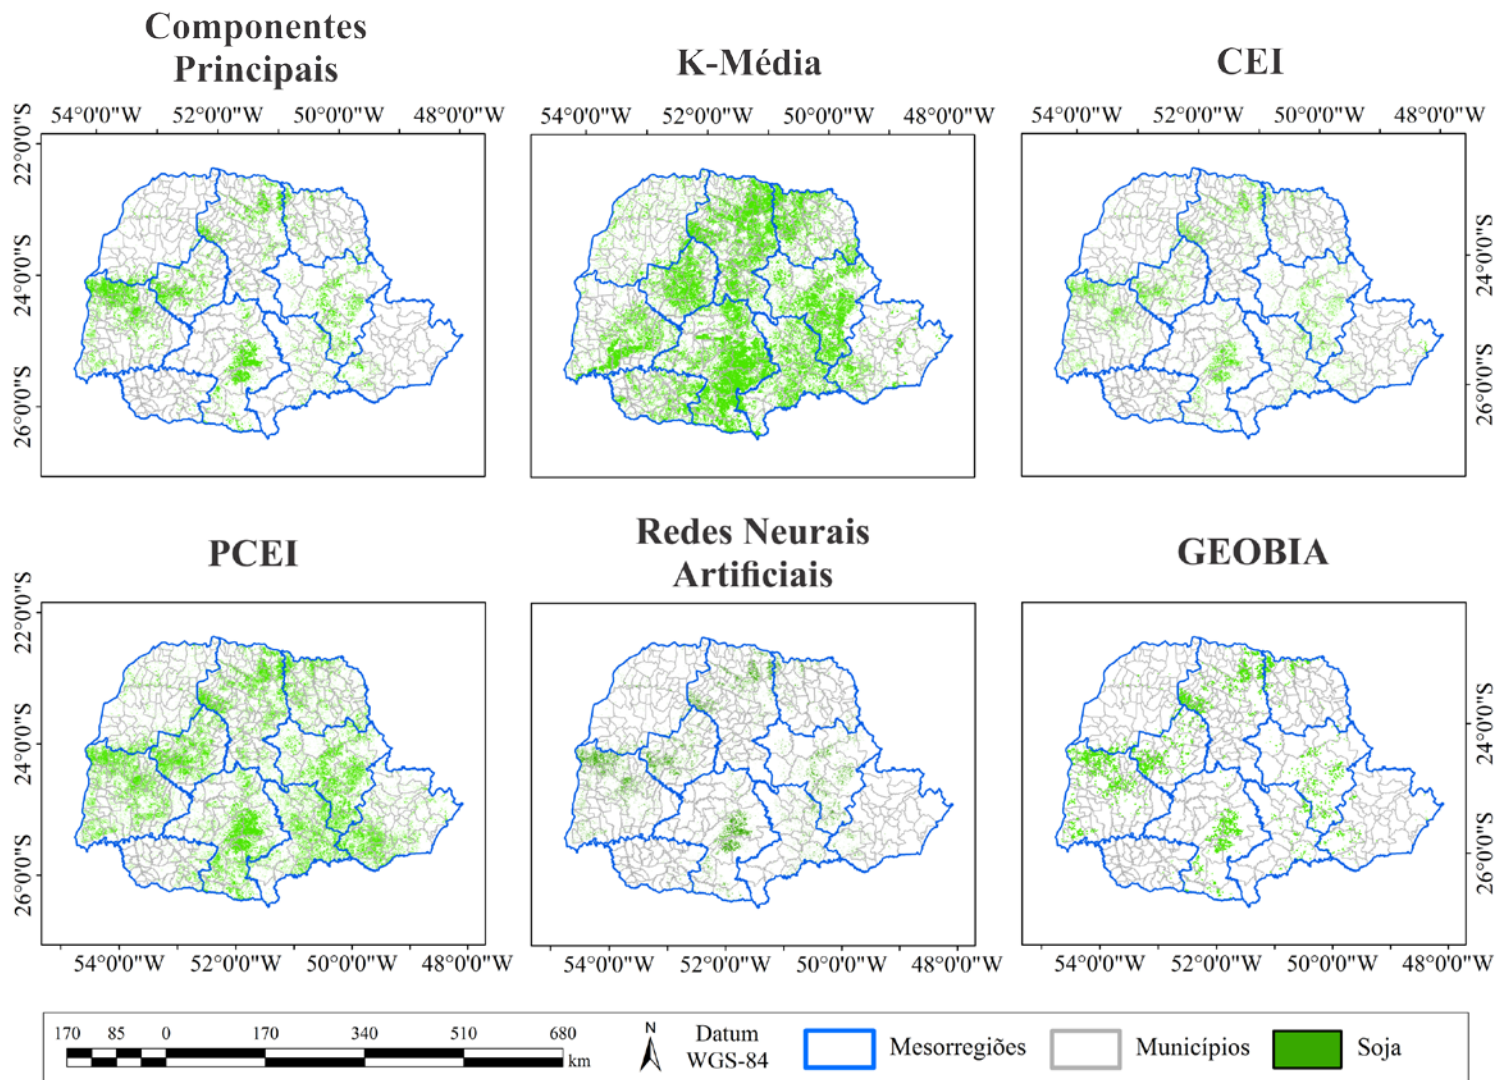
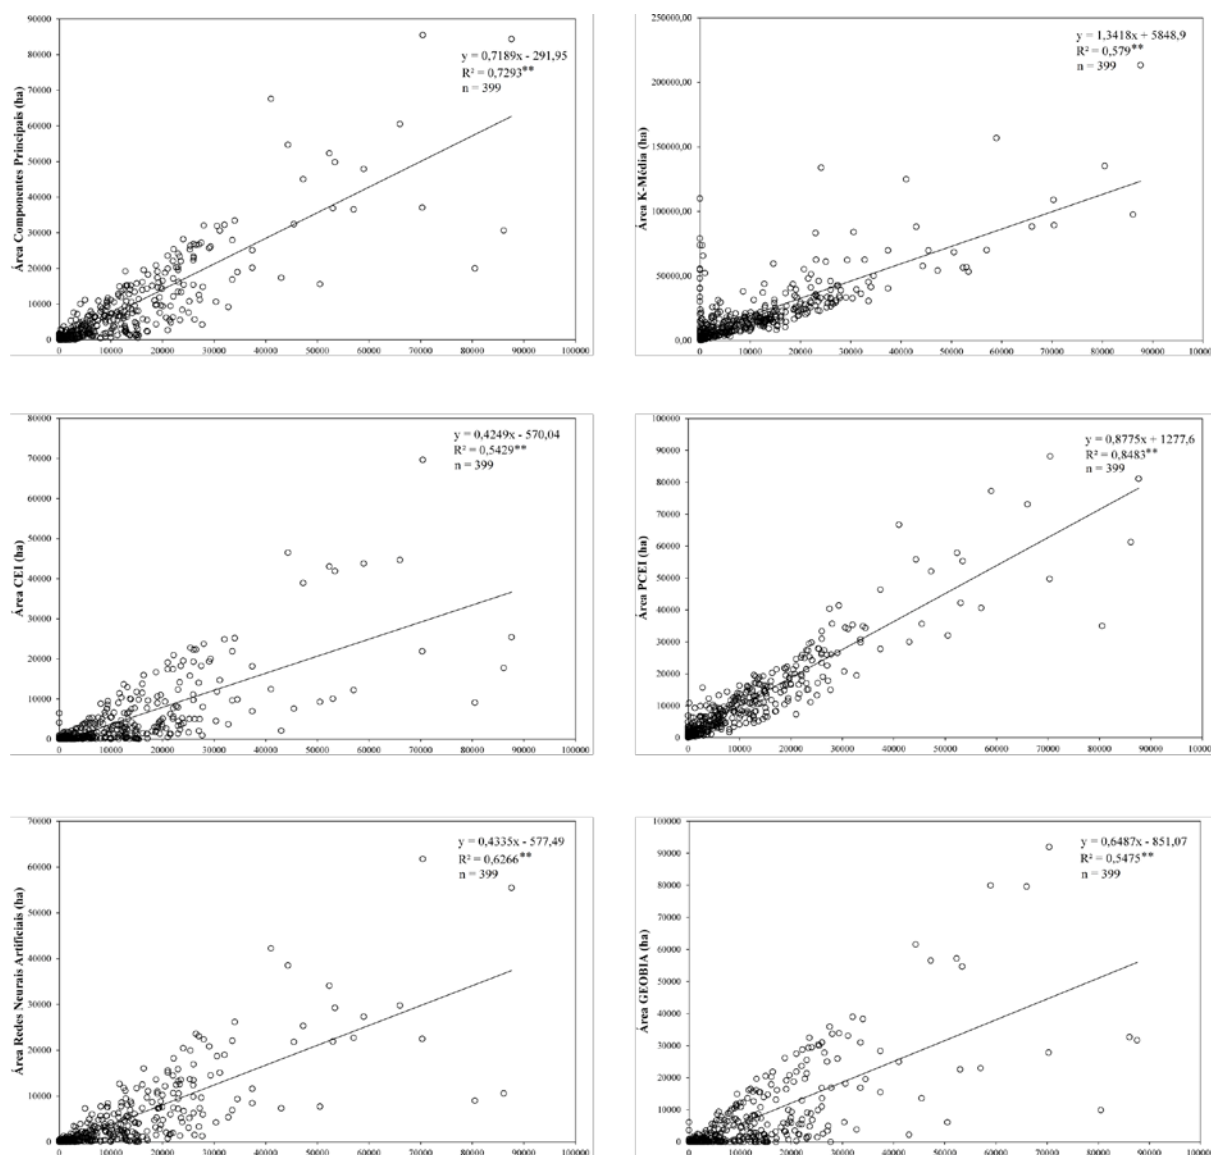


Figura 30. Distribuição espacial de áreas cultivadas com soja no ano-safra 2011/2012 conforme suas respectivas técnicas de classificação

É mostrado na Figura 31 e 32 às áreas dos municípios obtidos por meio das classificações das áreas de soja e sua relação com os dados obtidos por órgãos oficiais brasileiros (Instituto Brasileiro de Geografia e Estatística – IBGE) em hectares. Por mais que a RNA obteve inferioridade no valor do parâmetro Kappa (Tabela 15) em relação ao índice CEI, mostrou-se que os valores discriminados em hectares por município apresentou maior coerência com órgão oficial, com $R^2=0,6266$.



Área IBGE (ha)

Figura 31. Correlação entre áreas de soja estimadas pelos classificadores e pelo órgão oficial brasileiro para o ano-safra 2010/2011.

Todas as correlações realizadas com as classificações e os dados oficiais apresentaram significância pelo teste t com 0,01 de probabilidade. Valores acima de 70% de concordância

apenas são encontrados para o componente principal e o mapeamento realizado pelo limiar de corte do índice PCEI ($R^2 = 0,8483$) conforme a Figura 31.

As correlações realizadas para o ano-safra 2011/2012 (Figura 32) apresentaram-se inferiores quando comparadas com o ano anterior estudado, entretanto todas mantiveram significância e R^2 acima de 0,56, exceto o classificador K-Média por generalizar muito as áreas mapeadas pela ausência de treinamento.

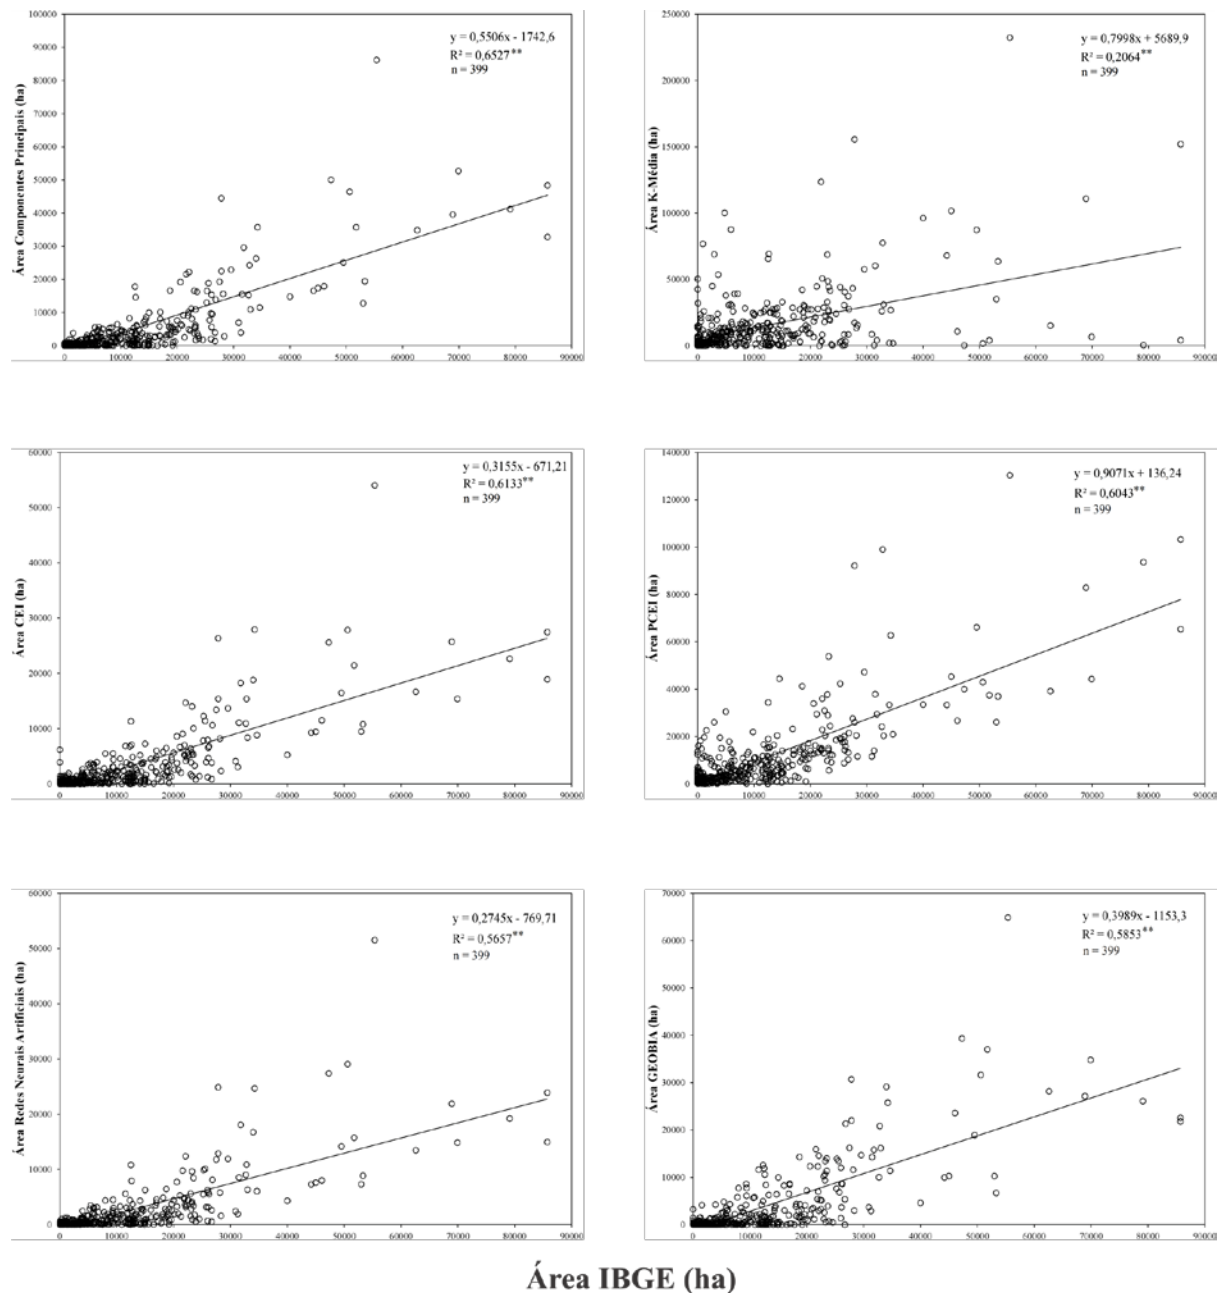


Figura 32. Correlação entre áreas de soja estimadas pelos classificadores e pelo órgão oficial brasileiro para o ano-safra 2011/2012.


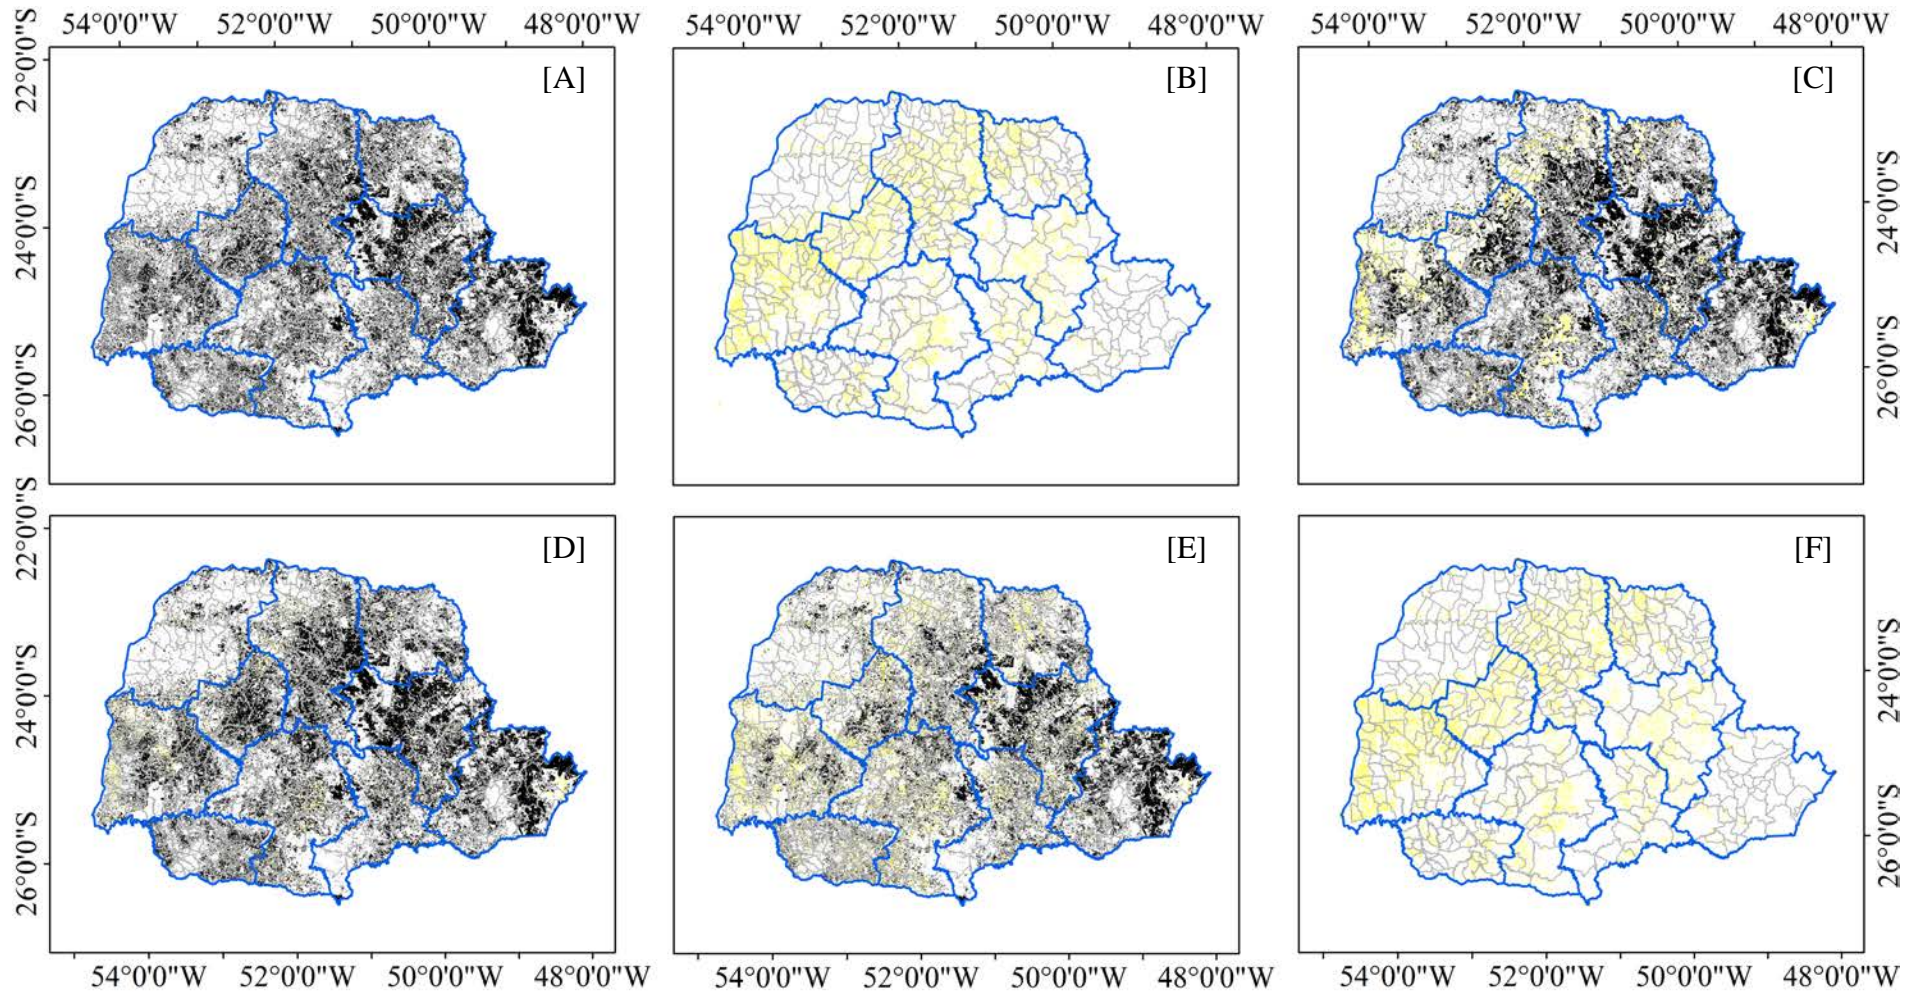
Em complemento à análise quantitativa, foram geradas as discordâncias conforme a Tabela 22 e 23. Além disso, foram confeccionados os mapas referentes a essas discordâncias (Figura 33 e 34). Trata-se de mapas temáticos contendo os *pixels* que os classificadores rotularam a classe soja diferente daquela atribuída por classificador oposto. O mapa de discordância apresentou um total de 147,42 *pixels* para RNA discordando do índice CEI (Tabela 22). Sendo: 36.855,37 hectares, correspondendo a *pixels* com classificação divergente (Figura 33h). Para os dois índices de vegetação (PCEI e CEI) para os dois anos-safras estudados apresentaram semelhança nas discordâncias.

Tabela 22. Diferenças entre os mapas de soja e suas classificações para o ano-safra 2010/2011.


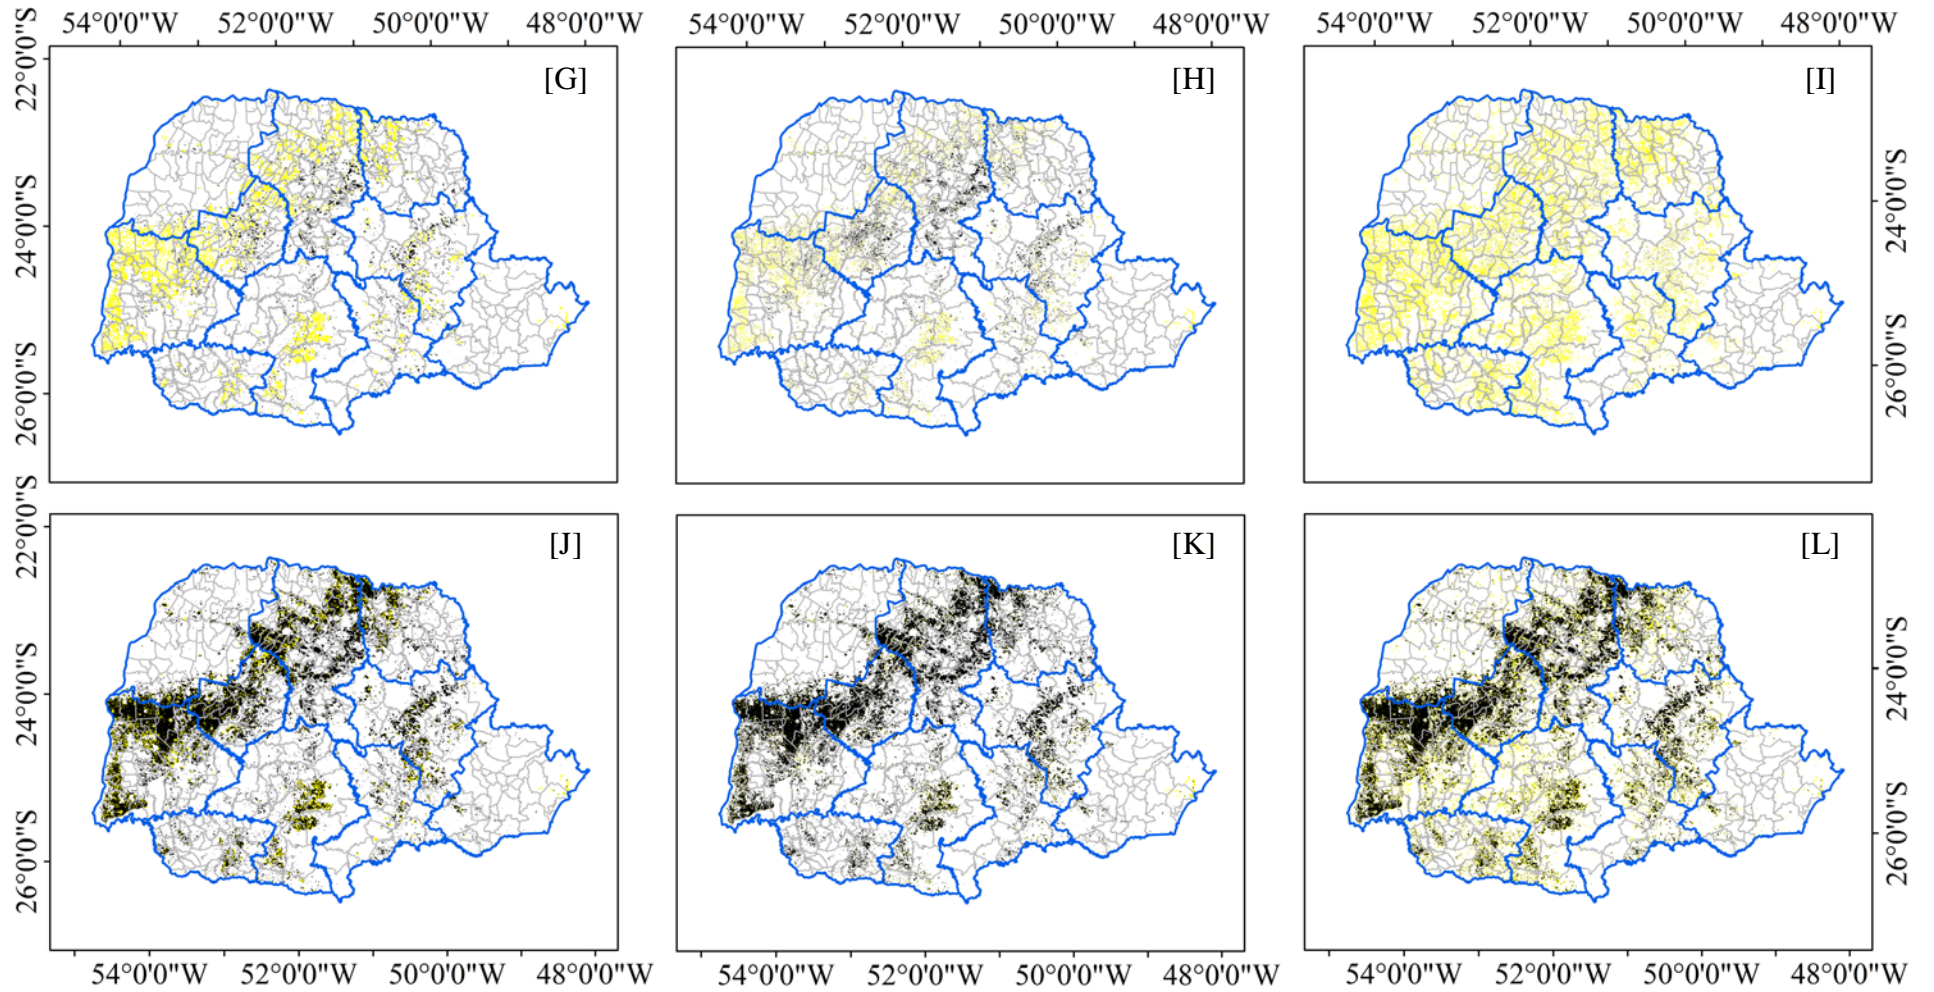
| Classificação A versus B | Área (ha) | Pixels |
|--|------------------|---------------|
| K-Média x Redes Neurais | 6.699.642,47 | 26.798,57 |
| K-Média x Componentes Principais | 5.285.847,85 | 21.143,39 |
| K-Média x GEOBIA | 5.828.794,63 | 23.315,18 |
| K-Média x CEI | 6.736.497,84 | 26945,99 |
| K-Média x PCEI | 3.937.981,92 | 15.751,93 |
| Redes Neurais x Componentes Principais | 1.413.794,62 | 5.655,18 |
| Redes Neurais x GEOBIA | 870.847,84 | 3.483,39 |
| Redes Neurais x CEI | 36.855,37 | 147,42 |
| Redes Neurais x PCEI | 2.761.660,55 | 11.046,64 |
| Componentes Principais x GEOBIA | 542.946,78 | 2.171,79 |
| Componentes Principais x CEI | 1.450.649,99 | 5.802,60 |
| Componentes Principais x PCEI | 1.347.865,93 | 5.391,46 |
| GEOBIA x CEI | 907.703,21 | 3.630,81 |
| GEOBIA x PCEI | 1.890.812,71 | 7.563,25 |
| CEI x PCEI | 2.798.515,92 | 11.194,06 |

Tabela 23. Diferenças entre os mapas de soja e suas classificações para o ano-safra 2011/2012.

| Classificação A versus B | Área (ha) | Pixels |
|--|------------------|---------------|
| K-Média x Redes Neurais | 4.918.033,70 | 19.672,13 |
| K-Média x Componentes Principais | 4.075.793,93 | 16.303,17 |
| K-Média x GEOBIA | 4.517.084,03 | 18.068,34 |
| K-Média x CEI | 4.696.058,33 | 18.784,23 |
| K-Média x PCEI | 1.738.572,81 | 6.954,29 |
| Redes Neurais x Componentes Principais | 842.239,77 | 3.368,95 |
| Redes Neurais x GEOBIA | 400.949,67 | 1.603,80 |
| Redes Neurais x CEI | 221.975,37 | 887,90 |
| Redes Neurais x PCEI | 3.179.460,89 | 12.717,84 |
| Componentes Principais x GEOBIA | 441.290,10 | 1.765,16 |
| Componentes Principais x CEI | 620.264,40 | 2.481,06 |
| Componentes Principais x PCEI | 2.337.221,12 | 9.348,88 |
| GEOBIA x CEI | 178.974,30 | 715,90 |
| GEOBIA x PCEI | 2.778.511,22 | 11.114,04 |
| CEI x PCEI | 2.957.485,52 | 11.829,94 |



cont...



cont...

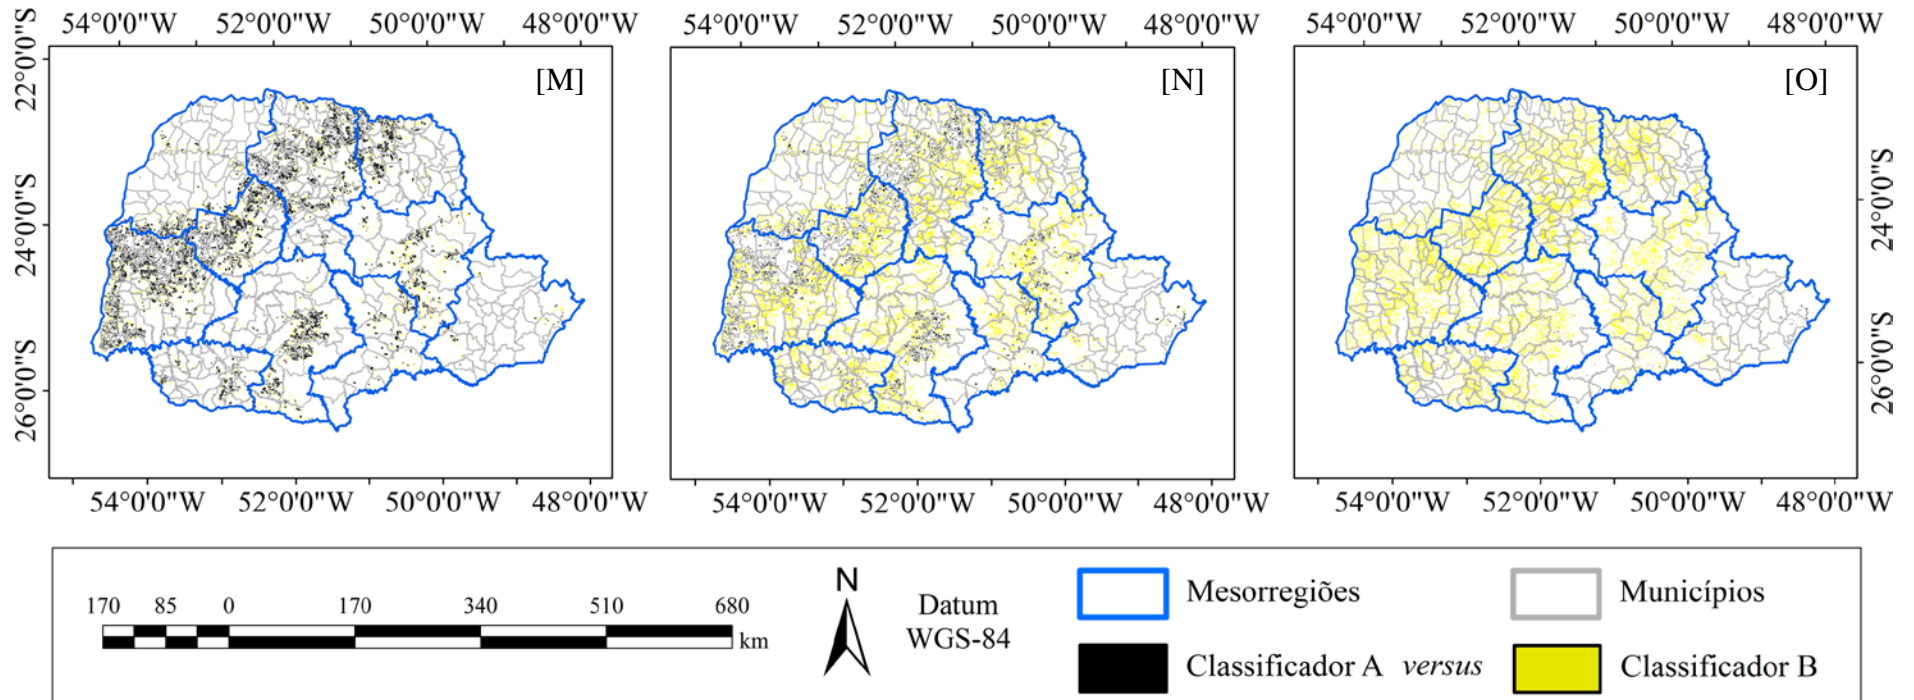

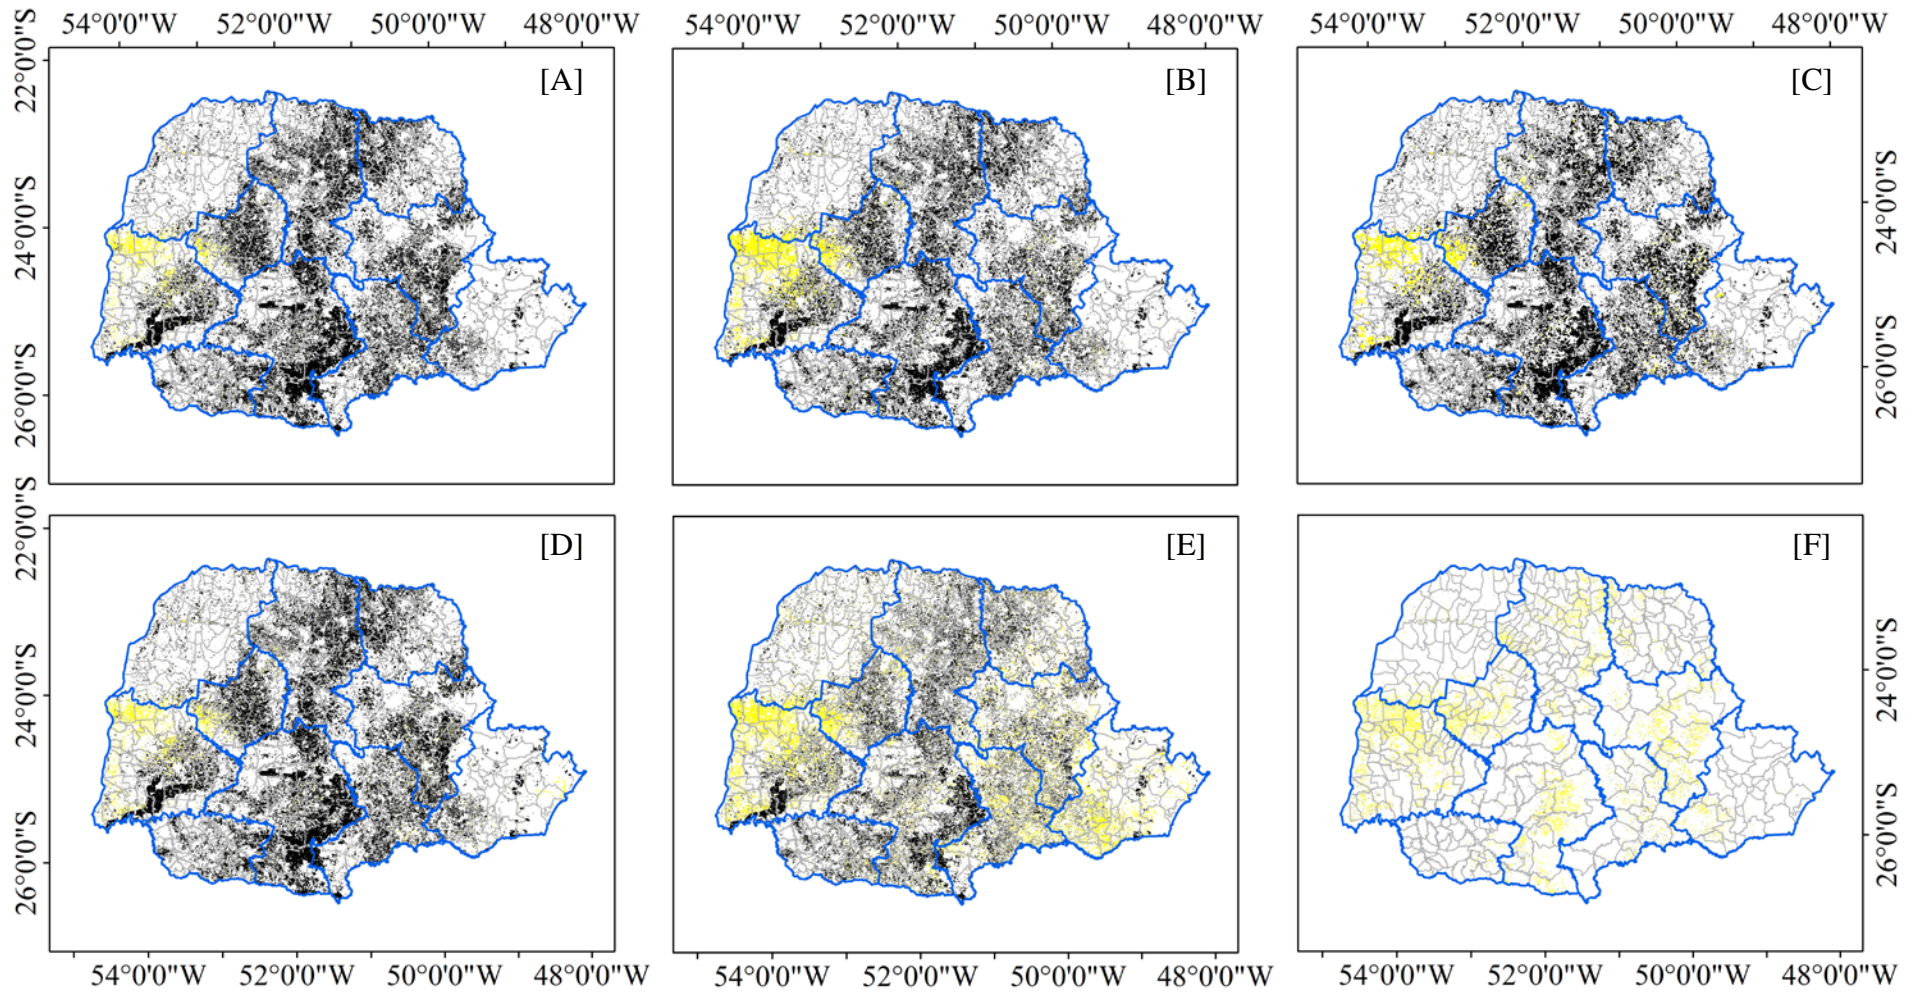

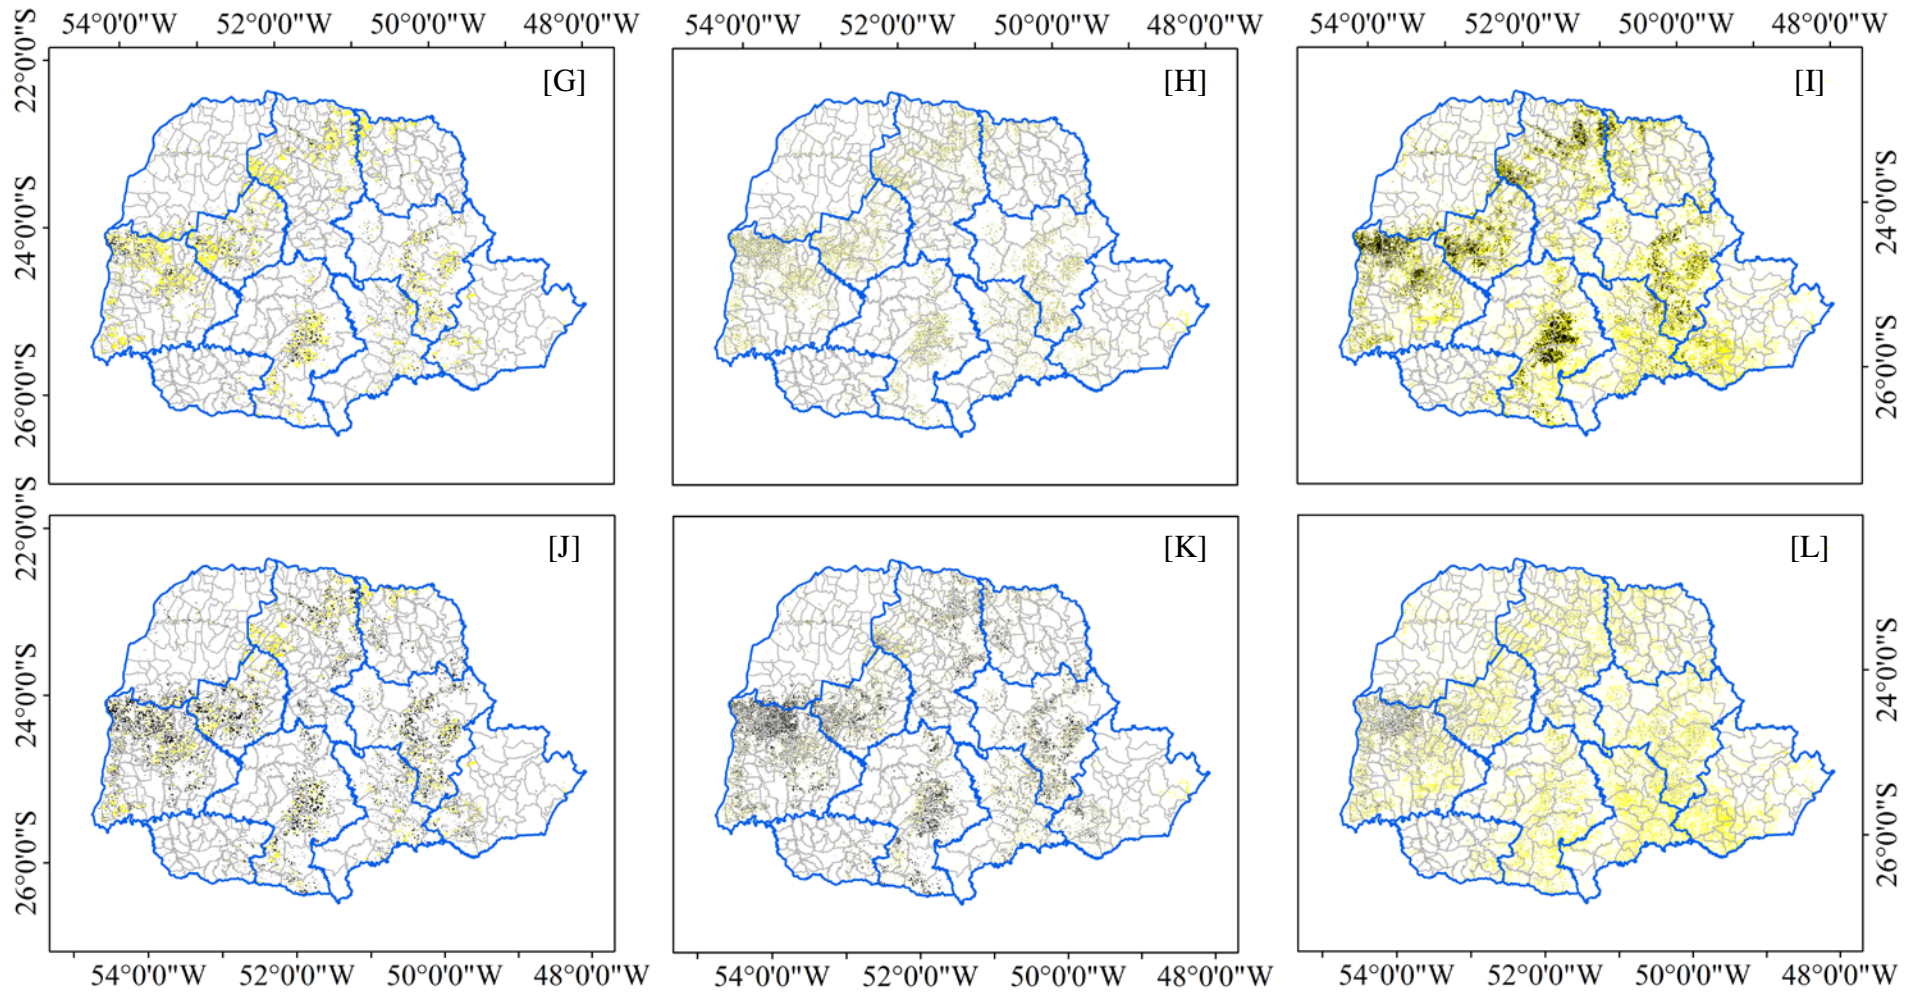


Figura 33. Mapas com as respectivas diferenças entre classificadores K-Média x Redes Neurais, K-Média x Componentes Principais, K-Média x GEOBIA, K-Média x CEI, K-Média x PCEI, Redes Neurais x Componentes Principais, Redes Neurais x GEOBIA, Redes Neurais x CEI, Redes Neurais x PCEI, Componentes Principais x GEOBIA, Componentes Principais x CEI, Componentes Principais x PCEI, GEOBIA x CEI, GEOBIA x PCEI e CEI x PCEI (A, B, C, D, E, F, G, H, I, J, K, L, M, N e O, respectivamente) para o ano-safra 2010/2011.



cont...



cont...

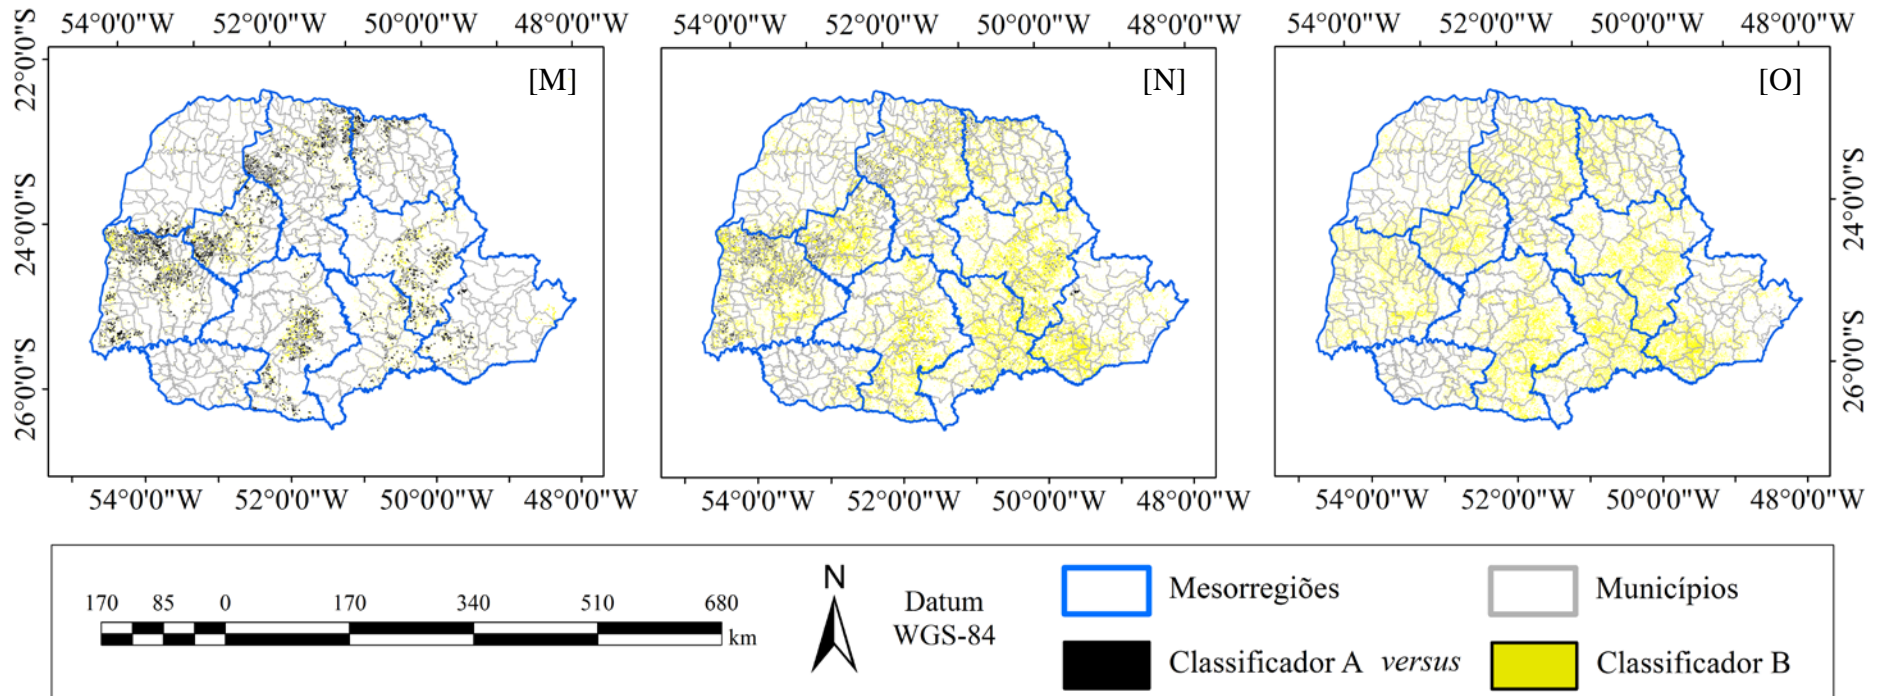


Figura 34. Mapas com as respectivas diferenças entre classificadores K-Média x Redes Neurais, K-Média x Componentes Principais, K-Média x GEOBIA, K-Média x CEI, K-Média x PCEI, Redes Neurais x Componentes Principais, Redes Neurais x GEOBIA, Redes Neurais x CEI, Redes Neurais x PCEI, Componentes Principais x GEOBIA, Componentes Principais x CEI, Componentes Principais x PCEI, GEOBIA x CEI, GEOBIA x PCEI e CEI x PCEI (A, B, C, D, E, F, G, H, I, J, K, L, M, N e O, respectivamente) para o ano-safra 2011/2012.

Com isso, observa-se que a confiabilidade de determinado mapeamento obtido por imagens de satélite é maior quando se trata de maior resolução espacial aumentando assim seu detalhamento (referência). Entretanto, os resultados aqui demonstrados apresentam grande potencial para estimativas de áreas agrícolas cultivadas com a cultura da soja, principalmente em grandes extensões. Tal fato é ponto positivo, pois dados do sensor MODIS além de serem gratuitos uma largura de área é observada e sua resolução temporal é de 1-2 dias, fazendo com que a probabilidade de aquisição de imagens livre de nuvens seja maior, favorecendo assim mapeamento de culturas de verão.

6. CONCLUSÕES

O mapeamento, discriminação e quantificação de áreas de soja no estado do Paraná foram possíveis com a utilização de classificadores e de imagens do sensor MODIS, o que na sistematização apresentou resultados de parâmetros Kappa e Exatidão Global satisfatórios;

As bandas espectrais utilizadas do sensor MODIS de áreas de soja quando comparados com dados laboratoriais da mesma cultura, apresentaram altos valores de coeficiente de correlação, o que indica um mapeamento fidedigno ao terrestre utilizando este sensor orbital;

Os parâmetros utilizados na aplicação de análise orientada em geo-objeto (GEOBIA) na determinação das áreas de soja apresentaram-se viáveis e dentre os atributos utilizados a textura (GLCM) se mostrou de relevante importância para esta pesquisa além da estatística descritiva para seleção dos segmentos;

Verificou-se que o critério de configuração da RNA que obteve superioridade no mapeamento da cultura da soja foi para o limite de 10.000 iterações ou erro médio quadrático (EMQ) de 0,0001 para a parada do treinamento do número de iterações do algoritmo *backpropagation*, com EMQ de 0,2796 para os dados de treinamento e 0,2832 para os dados de teste;

O desenvolvimento do índice *Perpendicular Crop Enhancement Index* (PCEI) apresentou resultados satisfatórios perante os demais índices de vegetação por minimizar a reflectância do solo apoiado em série-temporal, com um limiar de corte de 0,172464 obtido pela árvore de decisão. Assim, valores superiores a este representam a cultura da soja para a composição das imagens propostas.

REFERÊNCIAS BIBLIOGRÁFICAS

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. **Pesquisa Agropecuária Brasileira**, v. 45, n.6, p. 585-592, 2010.

ADAMI, M; RUDORFF, B.F.T.; FREITAS, R.M.; AGUIAR, D.A.; SUGAWARA, L.M.; MELLO, M.P. Remote sensing time series to evaluate direct land use change of recent expanded sugarcane crop in Brazil. **Sustainability**, v.4, n.4, p.574-585, 2012.

ALMEIDA, C.M. Aplicação dos sistemas de sensoriamento remoto por imagens e o planejamento urbano e regional. **Arq.Urb - Revista Eletrônica de Arquitetura e Urbanismo (USJT)**, v.3, n.1, p.98-123, 2010.

ANDRADE, A.F.; BOTELHO, M.F.; CENTENO, J.A.S. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: Simpósio Brasileiro de Sensoriamento Remoto, 11. (SBSR), 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p.265-272.

ANDRADE, L.N.; VIEIRA, T.G.C.; LACERDA, W.S.; VOLPATO, M.M.L.; DAVIS JUNIOR, C.A. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em Machado-MG. **Coffee Science**, v.8, n.1, p.78-90, 2013.

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

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: STROBL, J., BLASCHKE, T. (eds.). **Angewandte Geographische Informationsverarbeitung XII**. Beiträge zum AGIT Symposium Salzburg 2000. Karlsruhe. Herbert Wichmann Verlag, 2000. p.12–23.

BARET, F.; GUYOT, G. Potentials and limits of vegetation indices for LAI and APAR assessment. **Remote Sensing of Environment**, v.3, n.2-3, p.161-73, 1991.

BARET, F.; GUYOT, G.; MAJOR, D.J. TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation' In: **Proceedings of IGARSS '90**. 12th Canadian symposium on remote sensing, Vancouver, Canada, 1989. p.1355-1358.

BENZ, U.C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYEN, M. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, n.3-4, p.239-58, 2004.

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. **Pesquisa Agropecuária Brasileira**, v.46, n.11, p.1530-1537, 2011.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.65, n.1, p.2-16, 2010.

BOCK, M.; LESSING, R. Remote sensing, formation of objects and determination of quality, In: Internationales Symposium "Informatik Für den Umweltschutz" der Gesellschaft Für Informatik (GI), 14, 2000, Bonn. **Proceedings...** Marburg: Metropolis Verlag, 2000. p.581-594.

BRAGA, A.P.; CARVALHO, A.C.P.L.F.; LUDERMIR, T.B. **Redes neurais artificiais: teoria e aplicações**. 2nd ed. Rio de Janeiro: LTC, 2007. p.226.

BROWN DE COLSTOUN, E.C.; STORY, M.H.; THOMPSON, C.; COMMISSO, K.; SMITH, T.G.; IRONS, J.I. National Park vegetation mapping using multitemporal Landsat 7 data and a decision tree classifier. **Remote Sensing of Environment**, v.85 ,n.3, p.316-327, 2003.

BRUM, A.L.; HECK, C.R.; LEMES, C.L.; MÜLLER, P.K. A economia mundial da soja: impactos na cadeia produtiva da oleaginosa no Rio Grande do Sul 1970-2000. Congresso da Sober em Ribeirão Preto, 43, 2005, São Paulo. **Anais...** Brasília: SOBER, 2005. 1 CD-ROM.

BSAIBES, A.; COURAULT, D.; BARET, F.; WEISS, M.; OLIOSO, A.; JACOB, F.; HAGOLLE, O.; MARLOIE, O.; BERTRAND, N.; DESFOND, V.; KZEMIPOUR, F. Albedo and LAI estimates from FORMOSAT-2 data for crop monitoring. **Remote Sensing of Environment**, v.113, n.4, p.716-729, 2009.

BÜCKNER, J.; STAHLHUT, O.; PAHL, M.; LIEDTKE., C.E. GEOAIDA - A knowledge based automatic image data analyser for remote sensing data. In: International ICSC Congress on Computational Intelligence: Methods & Applications, 2., 2001, Bangor, Wales, United Kingdom. **Proceedings...** Millet, Alberta: ICSC, 2001. p.19-22.

CARVALHO, M.V.A. **Classificação da cobertura e uso do solo com imagens Worldview-2 utilizando mineração de dados e análise baseada em objetos.** São José dos Campos. 179p. (INPE-09.05.20.27-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2011.

CHAGAS, C.S.; VIEIRA, C.A.O.; FERNANDES FILHO, E.I.; C. JÚNIOR, W. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.3, p.319-327, 2009.

CHEN, J. **Neural network applications in agricultural economics.** University of Kentucky, Doctoral Dissertations. 2005. Disponível em: <http://uknowledge.uky.edu/gradschool_diss/228>. Acesso em: 20 Novembro 2013.

CHEN, S.C. **Contribuição de dados de satélite no sistema de previsão de safras.** São José dos Campos: INPE, 1990. 7p. (INPE-5087-PRE/1595).

CINTRA, R.S.C. **Assimilação de dados com redes neurais artificiais em modelo de circulação geral da atmosfera.** São José dos Campos. 172p. (INPE-09.20.14.46-TDI). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2010.

CLÉMENT, V.; GIRAUDON, G.; HOUZELLE, S.; SANDAKLY, F. Interpretation of remotely sensed images in a context of mutisensor fusion using a multispecialist archtecture. **IEEE Transactions on Geosciences and Remote Sensing**, v.31, n.4, p. 779-791, 1993.

CLEVERS, J.G.P.W. The derivation of a simplified reflectance model for the estimation of leaf area index. **Remote Sensing of Environment**, v.25, n.1, p.53-69, 1988.

CONAB – COMPANIA NACIONAL DE ABASTECIMENTO. **Acompanhamento de safra brasileira:** grãos, décimo segundo levantamento, setembro 2011. Brasília : Conab, 2011. Disponível em: <
http://www.conab.gov.br/OlalaCMS/uploads/arquivos/11_09_19_09_49_47_boletim_setembro-2011..pdf> Acesso em: 20 Novembro 2013.

CONAB – COMPANIA NACIONAL DE ABASTECIMENTO. **Acompanhamento de safra brasileira:** grãos, décimo segundo levantamento, setembro 2012. Brasília : Conab, 2012. Disponível em: <
http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12_09_06_09_18_33_boletim_graos_-_setembro_2012.pdf> Acesso em: 20 Novembro 2013.

CONAB – COMPANIA NACIONAL DE ABASTECIMENTO. **Acompanhamento de safra brasileira:** grãos, décimo segundo levantamento, setembro 2013. Brasília : Conab, 2013. Disponível em: <
http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_10_16_14_32_01_boletim_portugues_-_setembro_2013.pdf> Acesso em: 20 Novembro 2013.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data:** Principles and practices. (2nd Edition). Boca Raton, FL, USA: CRC Press, 2009. p.183.

COURA, S.M.C. **Mapeamento de vegetação do estado de minas gerais utilizando dados MODIS.** São José dos Campos. 129p. (INPE-14610-TDI/1190). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2007.

CUNHA, K.L. **Uso de imagens Landsat e CBERS no mapeamento da suscetibilidade à erosão na região de Primavera do Leste – MT.** 2009. 63f. Dissertação (Mestrado em Física Ambiental) - Universidade Federal de Mato Grosso, Cuiabá-MT.

DEFINIENS. **Definiens professional 5:** Reference book. Munich, Germany: The Imaging Intelligence Company, 2006. p.122.

DELL'ACQUA F.; GAMBA P. Texture-based characterization of urban environments on satellite SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v.41, n.1, p.153–159, 2003.

DUVEILLER, G.; BARET, F.; DEFOURNY, P. Crop specific green area index retrieval from MODIS data at regional scale by controlling pixel-target adequacy. **Remote Sensing of Environment**, v.115, n.10, p.2686-2701, 2011.

ELIZONDO, D.A.; MCCLENDON, R.W.; HOOGENBOOM, G. Neural network models for predicting flowering and physiological maturity of soybean. **American Society of Agricultural and Biological Engineers**, v.37, n.3, p.981–988, 2004.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Sistema Brasileiro de Classificação de Solos.** 3.ed. Brasília: Embrapa Produção de Informação. Rio de Janeiro: Embrapa Solos, 2013. p.353.

ENVI. **ENVI Users Guide.** Version 4.1, Research Systems, Inc., 2004. p.1150.

FAO. **Multiple frame agricultural surveys:** agricultural survey programmes based on area frame or dual frame (area and list) sample designs. Roma, 1998. v.2, 242p.

FAUSETT, L. **Fundamentals of neural networks:** architectures, algorithms and applications. Ed. Prentice Hall: New Jersey, NJ, 1994; p.461.

FAYYAD, U.; PIATESKY-SHAPIRO, G.; SMYTH, P.; UTHURUSAMY, R. **Advances in knowledge discovery and Data Mining.** Cambridge: MIT Press, 1996. p.560.

FEITOSA, R.Q.; MATTOS, C.; SANTOS, R.V.; REGO, L.F.G.; PEREIRA, A.A.C. Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento do desflorestamento na Amazônia. In: Simpósio Brasileiro de Sensoriamento Remoto, 12. (SBSR), 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p.4065-4072.

FOCKELMANN, R. **Agricultural parcel detection with Definiens e-Cognition**. Disponível em: http://www.ecognition.com/sites/default/files/definiens_agricultural_parcel detection_eCognition.pdf>. Acesso em: 15 Outubro 2013.

FONSECA, L.G.M. **Apostila de Processamento Digital de Imagens**. INPE. Junho, 2000.

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

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

FRIEDL, M.A.; BRODLEY, C. E. Decision tree classification of land cover from remotely sensed data. **Remote Sensing of Environment**, v.61, n.3, p.399–408, 1997.

FUKUHARA, M.; HAYASHI, S.; YASUDA, Y. Extraction of soil information from vegetated areas. In: Machine Processing of the Remotely Sensed Data, 3., West Lafayette, 1979. **Proceedings**. West Lafayette, Purdue University, 1979. p.242-252.

GALLEGO, F.J. Remote sensing and land cover area estimation. **International Journal of Remote Sensing**, v.25, n.15, p.3019-3047, 2004.

GALVÃO, L.S.; VITORELLO, Í. Variability of laboratory measured soil lines of soil from southeastern Brazil. **Remote Sensing of Environment**, v.63, n.2, p.166-181, 1998.

GAO, J. **Digital Analysis of Remotely Sensed Imagery**. Estados Unidos: McGraw-Hill Professional, 2009. 674p.

GIANNOTTI, M.A. **Geotecnologias na análise de impactos sócio-ambientais: o caso da queima de cana-de-açúcar na região de Piracicaba**. São José dos Campos. 147p. (INPE-9821-TDI/864). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, 2001.

GITELSON, A.A.; KAUFMAN, Y.J.; MERZLYAK, M.N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, n.3, p.289-298, 1996.

GOETZ, S.J. Multi-sensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland. **International Journal of Remote Sensing**, v.18, n.1, p.71-94, 1997.

GOLTZ, E.; PINHO, C.M.D.; FONSECA, L.M.G.; RUDORFF, B.F.T.; AGUIAR, D.A. Detecção automática das áreas de reforma dentro das áreas de cana-de-açúcar (Projeto Canasat). In: **Simpósio Latino Americano de Percepção Remota (Selper)**, 09, 2008, Havana – Cuba. Cd ROM.

GONZALES, R.C.; WOODS, R.E. **Digital Image Processing**. Upper Saddle River, New Jersey: Pearson Prentice Hall, 2007. p.976.

GOPAL, V.; BRIEBA, L.G.; GUAJARDO, R.; MCALLISTER, W.T.; SOUSA, R. Characterization of structural features important for T7 RNAP elongation complex stability reveals competing complex conformations and a role for the non-template strand in RNA displacement. **Journal of Molecular Biology**, v.290, n.2, p.411-431, 1999.

GRAY, J.; SONG, C. Mapping leaf area index using spatial, spectral, and temporal information from multiple sensors. **Remote Sensing of Environment**, v.119, n.1, p.173-183, 2012.

GURGEL, H.C.; FERREIRA, N.J.; LUIZ, A.J.B. Análise da variabilidade espacial e temporal do NDVI sobre o Brasil. In: Simpósio Brasileiro de Sensoriamento Remoto, 10., 2001, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2001. 1 CD-ROM.

GUSSO, A.; FORMAGGIO, A.R.; RIZZI, R.; ADAMI, M.; RUDORFF, B.F.T. Soybean crop area estimation by Modis/Evi data. **Pesquisa Agropecuária Brasileira**, v.47, n.3, p.425-435, 2012.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. The WEKA data mining software: An update. **ACM SIGKDD Explorations Newsletter**, v.11, n.1, p.10–18, 2009.

HAN, J.; KAMBER, M. **Data mining: concepts and techniques**. San Francisco: Morgan Kaufmann Publishers, 2001. p.744.

HARALICK, R.M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, v.SMC-3, n.6, p.610-621, 1973.

HATFIELD, J.L.; PRUEGER, J.H. Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. **Remote Sensing**, v.2, n.2, p.562-578, 2010.

HAYKIN, S. **Redes Neurais: princípios e prática**. Trad. Paulo Martins Engel. 2nd ed. Porto Alegre: Bookman, 2008. p.893.

HSU, W.; LEE, M.; ZHANG, J. Image Mining: Trends and Developments. **Journal of Intelligent Information Systems**, v.19, n.1, p.7–23, 2002.

HUETE, A.R.; LIU, H.Q.; BATCHILY, K.; LEEUWEN, W. Van. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v.59, n.3, p.440-451, 1997.

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

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v.25, n.3, p.295-309, 1988.

HUETE, A.R. Soil influences in remotely sensed vegetation canopy spectra. In: ASRAR, G., ed. **Theory and application of optical remote sensing**. New York, Wiley Interscience, 1989. p.107-141.

HUETE, A.; JUSTICE, C.; VAN LEEUWEN, W. **MODIS Vegetation Index: Algorithm Theoretical Basis Document (ATBD), Version 3, 1999**. Disponível em: <http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf>. Acesso em: 10 maio 2013.

IBGE - Instituto Brasileiro de Geografia e Estatística. **SIDRA - Sistema IBGE de recuperação automática**. Disponível em: <<http://www.sidra.ibge.gov.br>>. Acesso em: 10 Novembro 2013.

IPPOLITI-RAMILO, G.; EPIPHANIO, J.C.N.; SHIMABUKURO, Y.E. Landsat-5 thematic mapper data for pre-planting crop area evaluation in tropical countries. **International Journal of Remote Sensing**, v.24, n.7, p.1521-1534, 2003.

JENSEN, J.R. **Introductory digital image processing: a remote sensing perspective**. 3ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2005. 526p.

JENSEN, J.R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2ed. New Jersey: Prentice Hall, 2009. 608p.

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

JOHANSEN, K.; BARTOLO, R.; PHINN, S. Geographic object-based image analysis. **Journal of Spatial Science**, v. 55, n.1, p.3-7, 2010.

JORDAN, C.F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v.50, n.4, p.663-666, 1969.

JUNGES, A. H. **Modelo Agrometeorológico-espectral de Estimativa de Rendimento de Grãos de Trigo no Rio Grande do Sul**. Porto Alegre. 125p. Dissertação (Mestrado em Fitotecnia). Programa de Pós-graduação em Fitotecnia da Universidade Federal do Rio Grande do Sul, 2008.

KAUL, M.; HILL, R.L.; WALTHALL, C. Artificial neural networks for corn and soybean yield prediction. **Agricultural Systems**, v.85, n.1, p.1-18, 2005.

KAUTH, R.J.; THOMAS, J.S. The tasseled cap - A graphic description of the spectral temporal development of agricultura crops as seen by Landsat. In: Machine Processing of the Remotely Sensed Data, 1., West Lafayette, 1976. **Proceedings**. West Lafayette, Purdue University, 1976. p.41-51.

KING, M.D.; PLATNICK, S.; MENZEL, W.P.; KAUFMAN, Y.J.; ACKERMAN, S.; TANRÉ, D.; GAO, B.C. **Early Results from the MODIS Atmosphere Algorithms**, 2000. Disponível em: <http://modis.gsfc.nasa.gov/sci_team/meetings/200101/Presentations/g_king_atmos.pdf>. Acesso em: 25 maio 2013.

KONEČNÝ, V.; TRENZ, O.; SVOBODOVÁ, E. **Classification of companies with assistance of self-learning neural networks**. Agricultural Economics: Czech, 2010. Volume 56, p.51-58.

KOUADIO, L.; DUVEILLER, G.; DJABY, B.; EL JARROUNDI, M.; DEFOURNY, P.; TYCHON, B. Estimating regional wheat yield from the shape of decreasing curves of green area index temporal profiles retrieved from MODIS data. **International Journal of Applied Earth Observation and Geoinformation**, v.18, n.1, p.111-118, 2012.

LALIBERTE, A.; FREDRICKSON, E.; RANGO, A. Combining decision trees with hierarchical object-oriented image analysis for mapping arid rangelands. **Photogrammetric Engineering and Remote Sensing**, v.73, n.2, p.197-207, 2007.

LAMPARELLI, R. A.C.; WASTE, M.O.C; MARCANTE, E. Mapeamento de semeaduras de soja (*Glycine max* (L.) Merr.) mediante dados MODIS/Terra e TM/Landsat 5: Um comparativo. **Engenharia Agrícola**, v.28, n.2, p.334-344, 2008.

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

LIAO, K.; PAULSEN, M.R.; REID, J.F.; NI, B.C.; BONIFACIO-MAGHIRANG, E.P. Corn kernel breakage classification by machine vision using a neural network classifier. **American Society of Agricultural and Biological Engineers**, v.36, n.6, p.1949-1953, 1993.

LIEDTKE, C.E. AIDA: a system for the knowledge based interpretation of remote sensing data. In: International Airborne Remote Sensing Conference & Exhibit, 3., 1997, Copenhagen, Denmark. **Proceedings...** Copenhagen, Denmark, 1997. p.313-320.

LILLESSAND, T.M.; KIEFER, R.W. **Remote sensing and image interpretation**. 4ed. New York: John Wiley & Sons, 1999. 724p.

LIM, T.; LOH, W.Y.; SNIH, Y. **A comparison of prediction accuracy, complexity and training time of thirty-three old and new classification algorithms**. 1999. Disponível em: <<http://www.stat.wisc.edu/~limt/mach1317.pdf>>. Acesso em: 18 Novembro 2013.

LIU, J.; GOERING, C.E.; TIAN, L. Neural network for setting target corn yields. **American Society of Agricultural and Biological Engineers**, v.44, n.3, p.705-713, 1999.

LIU, J.; PATTEY, E.; MILLER, J.R.; MCNAIRN, H.; SMITH, A.; HU, B. Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model. **Remote Sensing of Environment**, v.114, n.6, p.1167-1177, 2010.

LOZANO, F.J.; SUÁREZ-SEOANE, S.; KELLY, M.; LUIS, E. A multi-scale approach for modeling fire occurrence probability using satellite data and classification trees: A case study in a mountainous Mediterranean region. **Remote Sensing of Environment**, v.112, n.3, p.708–719, 2008.

LUCAS, R.; ROWLANDS, A.; BROWN, A.; KEYWORTH, S.; BUNTING, P. Rule-based classification of multi-temporal satellite imagery for habitat and agricultural land cover mapping. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.62, n.3, p.165-185, 2007.

LUO, X.Y.; JAYAS, D.S.; SYMONS, S.J. Comparison of statistical and neural network methods for classification of cereal grains using machine vision. **American Society of Agricultural and Biological Engineers**, v.42, n.2, p.413-419, 1999.

MARPU, P.R. **Geographic Object-based Image Analysis**. Freiberg, 121f. Tese (Doutorado em Engenharia) - Faculty of Geosciences, Geo-Engineering and Mining Technische Universität Bergakademie Freiberg, 2009.

MARTINS, A.C.G.; SIMÕES, A.S.; PRADO, G.I. Classificação de texturas usando redes neurais artificiais e o modelo de Spot Noise. In: **Proceedings of the National Conference on Artificial Intelligence**, Rio de Janeiro, RJ, Brazil; IME: Rio de Janeiro, RJ, Brazil, 2007.

MATHER, P.M. **Computer processing of remotely-sensed images: an introduction**. New York: John Wiley & Sons, 1999. 292p.

MATSUYAMA, T.; HWANG, V. **SIGMA, a knowledge-based aerial image understanding system**. New York: Plenum, 296 p., 1990.

McCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v.5, n.4, p.115-133, 1943.

McKEOWN, D.M.; HARVEY, W.A.; McDERMOTT, J. Rule Based interpretation of aerial imagery. **IEEE Transactions in Pattern Analysis and Machine Intelligence**, v.7, n.5, p.570- 585, 1985.

MENESES, P.R.; ALMEIDA, T. (org.) **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: CNPq, 2012. p.266.

MERLIN, O.; DUCHEMIN, B.; HAGOLLE, O.; JACOB, F.; COUDERT, B.; CHEHBOUNI, G.; DEDIEU, G.; GARATUZA, J.; KERR, Y. Disaggregation of MODIS surface temperature over an agricultural area using a time series of Formosat-2 images. **Remote Sensing of Environment**, v.114, n.11, p.2500-2512, 2010.

MIEHIE, D.; SPIEGELHALTER, D.J.; TAYLOR, C.C. **Machine Learning, Neural and Statistical Classification**. New York: Ellis Horwood, 1994.

MOREIRA, M.A. **Fundamentos do Sensoriamento Remoto e metodologias de Aplicação**. 4a.ed. Viçosa: Editora UFV, 2011. 422p.

MOREIRA, M.A.; SHIMABUKURO, Y.E. Cálculo do índice de vegetação a partir do sensor AVHRR In: **Aplicações ambientais brasileiras dos satélites NOAA e TIROS-N**. São Paulo, Oficina de Textos, 2004, cap.4: 79-101.

NANNI, M.R. **Dados radiométricos obtidos em laboratório e no nível orbital na caracterização e mapeamento dos solos**. Piracicaba. 366p. Tese (Doutorado em Solos e Nutrição de Plantas) – Escola Superior de Agricultura —Luiz de Queiroz – Universidade de São Paulo, 2000.

NANNI, M.R.; DEMATTÊ, J.A.M. Comportamento da linha do solo obtida por espectrorradiometria laboratorial para diferentes classes de solo. **Revista Brasileira de Ciência do Solo**, v.30, n.6, p.1031-1038, 2006.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). **Specifications: MODIS**. Disponível em: <<http://modis.gsfc.nasa.gov/about/specifications.php>>. Acesso em: 10 Abril 2013.

NIEMANN, H.; SAGERER, G.; SCHRÖDER, S.; ERNEST, F.K. A semantic network system for pattern understanding. **IEEE Transactions PAMI**, v.12, n.9, p.883-905, 1990.

NOVO, E.M.L.M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Blucher, 363p. 2008.

OIDE, M.; NINOMIYA, S.; TAKAHASHI, N. Perceptron neural network to evaluate soybean plant shape. **Proceedings of 1995 1st IEEE International Conference on Neural Networks**, Perth, Australia, 27-1 November-December 1995. p.560-563.

OZDOGAN, M. The spatial distribution of crop types from MODIS data: Temporal unmixing using Independent Component Analysis. **Remote Sensing of Environment**, v.114, n.6, p.1190-1204, 2010.

PAL, M.; MATHER, P.M. An assessment of the effectiveness of decision tree methods for land cover classification. **Remote Sensing of Environment**, v.86, n.4, p.554–565, 2003.

PAN, Y.; LI, L.; ZHANG, J.; LIANG, S.; ZHU, X.; SULLA-MENASHE, D. Winter wheat area estimation from MODIS-EVI time series data using the Crop Proportion Phenology Index. **Remote Sensing of Environment**, v.119, n.1, p.232-242, 2012.

PAX-LENNEY, M.; WOODCOCK, C. E. The effect of spatial resolution on the ability to monitor the status of agricultural lands. **Remote Sensing of Environment**, v.61, n.2, p.210-220, 1997.

PEARSON, R.L.; MILLER, L.D. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie, Pawnee National Grassland, Colorado. In: International Symposium on Remote Sensing of the Environment, 8., Ann Arbor, 1972. **Proceedings...** Ann Arbor, 1972. v.2, p.1355-1379.

PEÑA-BARRAGÁN, J.M.; NGUGI, M.K.; PLANT, R.E.; SIX, J. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, v.115, n.6, p.1301-1316, 2011.

PENG, D.; HUETE, A.R.; HUANG, J.; WANG, F.; SUN, H. Detection and estimation of mixed paddy rice cropping patterns with MODIS data. **International Journal of Applied Earth Observation and Geoinformation**, v.13, n.1, p.13-23, 2011.

PENG, Y.; GITELSON, A.A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sensing of Environment**, v.117, n.1, p.440-448, 2012.

PEREIRA NETO, O.C.; JORGE, L.A.C.; GUIMARÃES, M.F. Quantificação de plantas daninhas em soja através de classificador digital por redes neurais. In: **Congresso Brasileiro de Agroinformática**, 5., 2005, Londrina. SBI-AGRO, 2005. v.1.

PERRY, C.R.; LAUTENSCHLAGER, L.F. Functional equivalence of spectral vegetation indices. **Remote Sensing of Environment**, v.14, n.1-3, p.169-182, 1984.

PICOLI, M.C.A. **Estimativa da produtividade agrícola da cana: Estudo de caso Usina Catanduva**. São José dos Campos. 90p. (INPE-14669-TDI/1222). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2006.

PINTO, F.A.C.; REID, J.F.; ZHANG, Q.; NOGUCHI, N. Guidance parameter determination using artificial neural network classifier. **Proceedings of 1999 ASAE/CSAE-SCGR Annual International Meeting**, Toronto, Canada, 18-21 July 1999. p.1-14.

PITTMAN, K.; HANSEN, M.C.; BECKER-RESHEF, I.; POTAPOV, P.V.; JUSTICE, C.O. estimating global cropland extent with multi-year MODIS data. **Remote Sensing**, v.2, n.7, p.1844-1863, 2010.

POTGIETER, A.B.; APAN, A.; HAMMER, G.; DUNN, P. Early-season crop area estimates for winter crops in NE Australia using MODIS satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n.4, p.380-387, 2010.

QI, J.; CHEHBOUNI, A.; HUETE A.R.; KERR, Y.H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v.48, n.2, p.119-126, 1994.

QUINLAN, R. **C4.5: Programs for machine learning**. San Francisco, CA, USA: Morgan Kaufmann, 1993. p.316.

RIBEIRO, B.M.G.; KUX, H.J.H. Classificação orientada a objeto para mapeamento do uso do solo - métodos de análise de expansão urbana. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p.7893-7900.

RICHARDSON, A.J.; WIEGAND, C.L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v.1, n.43, p.1541-1552, 1977.

RIEDEL, T.; THIEL, C.; SCHMULLIUS, C. Fusion of multispectral optical and SAR images towards operational land cover mapping in Central Europe. In: BLASCHKE, T.; LANG, S.; HAY, G. J. **Object-Based Image Analysis Spatial Concepts for Knowledge-Driven Remote Sensing Applications**. Springer, Berlin, Germany, 2008. p.493-511.

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. **Pesquisa Agropecuária Brasileira**, v. 47, n.9, p. 1317-1326, 2012.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. 2004. 212 p. (INPE-12271-TDI/983). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2004.

RIZZI, R.; RISSO, J.; EIPHANIO, 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. **Anais...** São José dos Campos: INPE, 2009. p.387-394.

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

ROSA, R. **Introdução ao Sensoriamento Remoto**, Uberlândia: EDUFU, 2003. 136p.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W.; HARLAN, J.C. **Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation**. Greenbelt: NASA, 1974. 371p. (NASA/GSFC. Final report).

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W.; HARLAN, J.C. **Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation**. Greenbelt: NASA, 1974. 371p. (NASA/GSFC. Final report).

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

SAKAMOTO, T.; BRIAN D. WARDLOWA, B.D.; GITELSON, A.A.; VERMA, S.B.; SUYKER, A.E.; ARKEBAUER, T.J. A Two-Step Filtering approach for detecting maize and soybean phenology with time-series MODIS data. **Remote Sensing of Environment**, v.114, n.10, p.2146-2159, 2010.

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

SANO, E.E.; FERREIRA, L.G.; ASNER, G.P.; STEINKE, E.T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v.28, n.12, p.2739-2752, 2007.

SANTOS, P.S. **Expansão agrícola de 1984 a 2006 e estimativas agrícolas por sensoriamento remoto e SIG no município de Luís Eduardo Magalhães-BA**. São José dos Campos. 84p. (INPE-09.03.17.55-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2012.

SCHIEWE, J.; TUFTE, L. O potencial de procedimentos baseados em regiões para a avaliação integrada de dados de SIG e sensoriamento remoto. In: BLASCHKE, T.; KUX, H. (Orgs.). **Sensoriamento remoto e SIG avançados**. São Paulo: Editora Oficina de Textos, 2007. Cap. 05, p.56-65.

SEELAN, S.K.; LAGUETTE, S.; CASADY, G.M.; SEIELSTAD, G.A. Remote sensing applications for precision agriculture: a learning community approach. **Remote Sensing of Environment**, v.88, n.1-2, p.157-169, 2003.

SESNIE, S.E.; FINEGAN, B.; GESSLER, P.; RAMOS, Z. Landscape-scale environmental and floristic variation in Costa Rican old-growth rain forest remnants. **Biotropica**, v.41, n.1, p. 16–26, 2009.

SILLEOS, N.G.; ALEXANDRIDIS, T.K.; GITAS, I.Z.; PERAKIS, K. Vegetation indices: advances made in biomass estimation and vegetation monitoring in the last 30 years. **Geocarto International**, v.21, n.4, p.21-28, 2006.

SILVA JUNIOR, C.A.; BACANI, V.M.; CARVALHO, L.A. Rotinas de tratamento digital de imagem Landsat 5/TM para a identificação de queimadas em lavouras canavieiras. **Bioscience Journal**, v.29, n.5, p. 1514-1523, 2013.

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

SILVA, S.H.M.G.; MORAES, W.; MARQUE, E.S.H.; JORGE, L.A.C. Processamento digital de imagens para identificação da Sigatoka Negra. In: **Congresso Brasileiro de Agroinformática**, 5., 2005, Londrina. SBI-AGRO, 2005. v.1.

SON, N.T.; CHEN, C.F.; CHEN, C.R.; CHANG, L.Y.; MINH, V.Q. Monitoring agricultural drought in the Lower Mekong Basin using MODIS NDVI and land surface temperature data. **International Journal of Applied Earth Observation and Geoinformation**, v.18, n.1, p.417-427, 2012.

SVOBODOVÁ, E. **Knowledge-management in managerial work of business management**. Agricultural Economics: Czech, 2007. Volume 53, p.298–303.

THENKABAIL, P.S.; WARD, A.D.; LYON, J.G.; MERRY, C.J. Thematic mapper vegetation indices for determining soybean and corn growth parameters. **Photogrammetric Engineering and Remote Sensing**, v.60, n.4, p. 437-442, 1994.

TONIAL, T.M. **Dinâmica da paisagem na região noroeste do Estado do Rio Grande do Sul**. 2003. 331p. Tese (Doutorado em Ecologia e Recursos Naturais) – Universidade Federal de São Carlos, São Carlos. 2003.

VIEIRA, M.A. **Análise de imagem orientada a objeto e mineração de dados aplicadas ao mapeamento da cultura da cana-de-açúcar**. São José dos Campos. 110p. (INPE-04.08.17.43-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2010.

VIEIRA, T.G.C.; LACERDA, W.S.; BOTELHO, T.G. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: estudo de caso na região de Três Pontas, Minas Gerais. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p.7947-7954.

WITTEN, I.; FRANK, E. **Data Mining: Practical machine learning tools and techniques** (2nd. Edition). San Francisco, CA, USA: Morgan Kaufmann Publishers, 2005. p.524.

WITTEN, I.H.; FRANK, E.; HALL, M.A. **Data Mining: Practical Machine Learning Tools and Techniques**. San Francisco, CA, USA: Morgan Kaufmann Publishers, 2011. p.560.

WU, B.; LI, Q. Crop planting and type proportion method for crop acreage estimation of complex agricultural landscapes. **International Journal of Applied Earth Observation and Geoinformation**, v.16, n.1, p.101-112, 2012.

XIAO, X.; BOLES, S.; FROLKING, S.; SALAS, W.; MOORE, B.; LI, C.; HE, L.; ZHAO, R. Landscape-scale characterization of cropland in China using Vegetation sensor data and Landsat TM imagery. **International Journal of Remote Sensing**, v.23, n.18, p.3579-3594, 2002.

YANG, C.; EVERITT, J.H.; MURDEN, D. Evaluating high resolution SPOT 5 satellite imagery for crop identification. **Computers and Electronics in Agriculture**, v.75, n.2, p.347-354, 2011.

YANG, T.L.; BAI, P.; GONG, Y.S. Spatial Data Mining Features between general Data Mining. **International Workshop on ETT and GRS**, v.2, n.1, p.541-544, 2008.

ZHENG, G.; MOSKAL, L. Retrieving Leaf Area Index (LAI) Using Remote Sensing: Theories, Methods and Sensors. **Sensors**, v.9, n.4, p.2719-2745, 2009.

APÊNDICE A

```
dir /a /-p /o:n /s /b *.hdf >lista_arquivos_hdf.txt
```

```
set MRTDATADIR=c:\\Modis\\bin\\Reprojetadas
```

```
resample -i MOD13Q1.A2010161.h13v11.005.2010178153342.hdf -p parameters.prm -o  
161_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010177.h13v11.005.2011015150516.hdf -p parameters.prm -o  
177_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010193.h13v11.005.2010212135837.hdf -p parameters.prm -o  
193_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010209.h13v11.005.2010239003744.hdf -p parameters.prm -o  
209_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010225.h13v11.005.2010254023252.hdf -p parameters.prm -o  
225_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010321.h13v11.005.2010339192619.hdf -p parameters.prm -o  
321_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010337.h13v11.005.2010356034631.hdf -p parameters.prm -o  
337_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2010353.h13v11.005.2011006195107.hdf -p parameters.prm -o  
353_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2011001.h13v11.005.2011025025807.hdf -p parameters.prm -o  
001_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2011017.h13v11.005.2011040212448.hdf -p parameters.prm -o  
017_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2011033.h13v11.005.2011059042146.hdf -p parameters.prm -o  
033_2010_16DAYS.tif
```

```
resample -i MOD13Q1.A2011049.h13v11.005.2011075173016.hdf -p parameters.prm -o  
049_2010_16DAYS.tif
```

continua...

cont...

parameters.prm

INPUT_FILENAME =

C:\Modis\bin\Reprojetadas\MOD13Q1.A2010161.h13v11.005.2010178153342.hdf

SPECTRAL_SUBSET = (1 1 0 1 1 0 0 0 0 0 0)

SPATIAL_SUBSET_TYPE = INPUT_LAT_LONG

SPATIAL_SUBSET_UL_CORNER = (-19.999999998 -53.208888618)

SPATIAL_SUBSET_LR_CORNER = (-29.999999997 -46.18802153)

OUTPUT_FILENAME = C:\Modis\bin\Reprojetadas\161_2010_16DAYS.tif

RESAMPLING_TYPE = NEAREST_NEIGHBOR

OUTPUT_PROJECTION_TYPE = GEO

OUTPUT_PROJECTION_PARAMETERS = (

0.0 0.0 0.0

0.0 0.0 0.0

0.0 0.0 0.0

0.0 0.0 0.0

0.0 0.0 0.0)

DATUM = WGS84

OUTPUT_PIXEL_SIZE = 0.002245

APÊNDICE B

Run Macro

```
overlay x 8*161_PVI*177_PVI*temp1
overlay x 8*temp1*193_PVI*temp2
overlay x 8*temp2*209_PVI*temp3
overlay x 8*temp3*225_PVI*temp4
scalar x temp4*min_2011_PCEI*1*1000000
overlay x 9*321_PVI*337_PVI*temp1
overlay x 9*temp1*353_PVI*temp2
overlay x 9*temp2*001_PVI*temp3
overlay x 9*temp3*017_PVI*temp4
overlay x 9*temp4*033_PVI*temp5
overlay x 9*temp5*049_PVI*temp6
scalar x temp6*max_2011_PCEI*1*1000000
overlay x 5*max_2011_PCEI*min_2011_PCEI*pcei_2011
scalar x temp1*pcei_2011_x*3*1000000
reclass x I*PCEI_2011_X*soja_2011_2745*2*0*-
100000000*2745*1*2745*100000000001*-.9999
filter x soja_2011_2745*soja_2011_2745_FT*3*5
```

APÊNDICE C

2010/2011

J48 pruned tree

Mean PCEI \leq 0.172464: NÃO SOJA (21515.0/1.0)

Mean PCEI $>$ 0.172464

| Mean CEI \leq 0.3734: SOJA (2735.0)

| Mean CEI $>$ 0.3734

| | Mean PCEI \leq 0.224701: NÃO SOJA (3.0)

| | Mean PCEI $>$ 0.224701: SOJA (22.0)

Number of Leaves : 4

Size of the tree : 7

Time taken to build model: 0.72 seconds

==== Stratified cross-validation ====

==== Summary ====

| | | |
|----------------------------------|----------|-----------|
| Correctly Classified Instances | 24271 | 99.9835 % |
| Incorrectly Classified Instances | 4 | 0.0165 % |
| Kappa statistic | 0.9992 | |
| Mean absolute error | 0.0002 | |
| Root mean squared error | 0.0105 | |
| Relative absolute error | 0.1157 % | |
| Root relative squared error | 4.0407 % | |
| Total Number of Instances | 24275 | |

continua...

cont...

2011/2012

J48 pruned tree

Mean CEI_12 <= 0.21965: Não_Soja (167.0)

Mean CEI_12 > 0.21965

| Standard deviation CEI_12 <= 0.085305

| | Standard deviation PCEI_12 <= 0.03428: Soja (127.0)

| | Standard deviation PCEI_12 > 0.03428

| | | Density <= 1.610996: Não_Soja (2.0)

| | | Density > 1.610996: Soja (21.0/1.0)

| Standard deviation CEI_12 > 0.085305: Não_Soja (9.0/1.0)

Number of Leaves : 5

Size of the tree : 9

Time taken to build model: 0 seconds

=== Stratified cross-validation ===

=== Summary ===

| | | |
|----------------------------------|-----------|----------|
| Correctly Classified Instances | 314 | 96.319 % |
| Incorrectly Classified Instances | 12 | 3.681 % |
| Kappa statistic | 0.9258 | |
| Mean absolute error | 0.0409 | |
| Root mean squared error | 0.1857 | |
| Relative absolute error | 8.2578 % | |
| Root relative squared error | 37.3045 % | |
| Total Number of Instances | 326 | |

APÊNDICE D**Ano-safra 2010/2011**

| MUNICÍPIO | CEI | PCEI | K-MÉDIA | COMPONENTES PRINCIPAIS | REDES NEURAIS | GEOBIA |
|---------------------|------------|-------------|----------------|-----------------------------------|--------------------------|---------------|
| Abatiá | 287,30 | 5227,58 | 7551,47 | 1886,18 | 559,98 | 55,44 |
| Adrianópolis | 0,00 | 4934,03 | 79096,41 | 980,56 | 282,76 | 5,54 |
| Agudos do Sul | 0,00 | 499,65 | 3881,08 | 124,91 | 22,18 | 5,54 |
| Almirante Tamandaré | 0,00 | 674,53 | 8410,86 | 43,72 | 0,00 | 0,00 |
| Altamira do Paraná | 199,86 | 6314,32 | 6298,44 | 918,11 | 5,54 | 0,00 |
| Alto Paraíso | 662,04 | 2335,86 | 4873,53 | 1043,02 | 515,63 | 754,04 |
| Alto Paraná | 206,11 | 3054,11 | 2716,76 | 362,25 | 77,62 | 0,00 |
| Alto Piquiri | 17462,74 | 25169,82 | 25764,83 | 22078,25 | 14481,97 | 23674,59 |
| Altônia | 10986,03 | 18818,03 | 23192,23 | 14652,21 | 8837,77 | 20813,68 |
| Alvorada do Sul | 1817,47 | 4946,53 | 8216,80 | 2804,28 | 914,83 | 1591,24 |
| Amaporã | 449,68 | 4546,81 | 6132,11 | 1686,32 | 438,01 | 232,86 |
| Ampére | 718,25 | 6108,21 | 7035,84 | 3934,74 | 853,84 | 1868,46 |
| Anahy | 2616,91 | 6801,47 | 11049,99 | 3928,49 | 1912,82 | 1768,66 |
| Andirá | 3878,53 | 6901,40 | 6226,36 | 5364,98 | 2727,84 | 6908,32 |
| Ângulo | 930,60 | 1486,46 | 55676,87 | 0 | 0,00 | 853,84 |
| Antonina | 174,88 | 3528,77 | 12352,92 | 1361,54 | 304,94 | 0,00 |
| Antônio Olinto | 2904,21 | 16394,74 | 39492,76 | 14708,42 | 7329,70 | 2284,29 |

| | | | | | | |
|-------------------------|----------|----------|----------|----------|----------|----------|
| Apucarana | 3597,47 | 16875,65 | 28254,26 | 14277,47 | 7612,46 | 7523,75 |
| Arapongas | 3303,93 | 21360,00 | 83321,25 | 19592,49 | 9419,94 | 1513,62 |
| Arapoti | 81,19 | 8369,12 | 14409,90 | 6620,35 | 3914,35 | 864,93 |
| Arapuã | 9774,39 | 26562,60 | 32573,35 | 22940,14 | 13495,07 | 13617,05 |
| Araruna | 331,02 | 3984,70 | 20547,55 | 1461,47 | 332,66 | 0,00 |
| Araucária | 1498,95 | 5858,39 | 14299,01 | 4478,11 | 2323,10 | 2761,11 |
| Ariranha do Ivaí | 11123,44 | 26075,44 | 33022,45 | 22284,35 | 12402,82 | 16827,25 |
| Assaí | 69669,82 | 88156,84 | 89331,38 | 85502,45 | 61770,16 | 91976,05 |
| Assis Chateaubriand | 9636,98 | 21416,21 | 26840,44 | 18287,16 | 11088,80 | 16173,02 |
| Astorga | 2698,11 | 5271,30 | 6270,72 | 3984,7 | 2262,12 | 2916,35 |
| Atalaia | 149,89 | 1780,00 | 11931,55 | 487,16 | 127,52 | 0,00 |
| Balsa Nova | 2773,05 | 16600,84 | 15951,24 | 7488,49 | 2217,76 | 3648,22 |
| Bandeirantes | 2329,61 | 13777,82 | 21844,94 | 7482,25 | 2744,48 | 4424,43 |
| Barbosa Ferraz | 0,00 | 399,72 | 1868,46 | 43,72 | 11,09 | 11,09 |
| Barra do Jacaré | 1174,18 | 3934,74 | 4607,40 | 2392,07 | 1042,35 | 2140,14 |
| Barracão | 199,86 | 1804,98 | 3847,81 | 799,44 | 299,40 | 565,53 |
| Bela Vista da Caroba | 11760,49 | 16394,74 | 20192,71 | 15801,4 | 11715,32 | 20547,55 |
| Bela Vista do Paraíso | 118,67 | 2704,35 | 3199,12 | 112,42 | 16,63 | 0,00 |
| Bituruna | 14065,12 | 25988,00 | 29535,02 | 26693,75 | 23097,97 | 25021,88 |
| Boa Esperança | 0,00 | 1167,93 | 3437,53 | 62,46 | 0,00 | 0,00 |
| Boa Esperança do Iguaçu | 1255,37 | 10561,33 | 36703,93 | 5533,61 | 2317,56 | 0,00 |

| | | | | | | |
|--------------------------|----------|----------|----------|----------|----------|----------|
| Boa Ventura de São Roque | 337,26 | 3054,11 | 4452,15 | 899,37 | 249,50 | 0,00 |
| Boa Vista da Aparecida | 249,82 | 612,07 | 40679,26 | 0 | 0,00 | 0,00 |
| Bocaiúva do Sul | 0,00 | 599,58 | 1075,61 | 12,49 | 0,00 | 0,00 |
| Bom Jesus do Sul | 724,49 | 6532,91 | 17681,09 | 5346,25 | 1829,65 | 698,59 |
| Bom Sucesso | 2947,93 | 10948,56 | 12003,63 | 6545,4 | 2062,52 | 8211,26 |
| Bom Sucesso do Sul | 3041,61 | 17144,21 | 25631,76 | 15158,1 | 9480,92 | 8216,80 |
| Borrazópolis | 1780,00 | 14783,37 | 23763,30 | 9724,42 | 3193,57 | 3371,00 |
| Braganey | 16707,02 | 21797,19 | 24406,45 | 20866,6 | 13628,14 | 26158,48 |
| Brasilândia do Sul | 337,26 | 1773,75 | 2578,15 | 537,12 | 166,33 | 704,14 |
| Cafeara | 5202,60 | 11110,95 | 22970,45 | 8400,35 | 4302,45 | 8893,22 |
| Cafelândia | 1723,79 | 4009,68 | 3759,10 | 2011,09 | 637,61 | 1496,99 |
| Cafezal do Sul | 149,89 | 3741,12 | 8233,43 | 1998,6 | 526,72 | 0,00 |
| Califórnia | 3422,60 | 10867,37 | 12297,48 | 5633,54 | 1757,57 | 3132,59 |
| Cambará | 25182,32 | 34925,47 | 41444,39 | 33464 | 26175,11 | 38328,44 |
| Cambé | 1973,61 | 9705,68 | 15274,82 | 11142,18 | 7307,52 | 5444,60 |
| Cambira | 9661,96 | 30759,65 | 45375,37 | 16906,88 | 6930,50 | 16866,07 |
| Campina da Lagoa | 1480,21 | 7076,28 | 15213,83 | 2360,84 | 1480,35 | 876,02 |
| Campina do Simão | 0,00 | 418,46 | 30355,59 | 0 | 0,00 | 0,00 |
| Campina Grande do Sul | 437,19 | 7338,60 | 20414,48 | 2698,11 | 726,32 | 321,58 |
| Campo Bonito | 449,68 | 3147,79 | 8294,42 | 1773,75 | 687,51 | 399,20 |
| Campo do Tenente | 0,00 | 2304,63 | 52272,60 | 81,19 | 11,09 | 0,00 |

| | | | | | | |
|--------------------------|----------|----------|-----------|----------|----------|----------|
| Campo Largo | 0,00 | 424,70 | 13145,77 | 0 | 0,00 | 0,00 |
| Campo Magro | 10067,93 | 42214,10 | 56763,57 | 36899,09 | 21922,56 | 22604,52 |
| Campo Mourão | 830,67 | 14433,61 | 37158,57 | 6083,23 | 2528,25 | 1491,44 |
| Cândido de Abreu | 18168,49 | 46386,17 | 69837,26 | 25132,35 | 11593,34 | 28331,88 |
| Candói | 980,56 | 13784,07 | 18424,04 | 3022,88 | 1369,47 | 1430,46 |
| Cantagalo | 162,39 | 8319,16 | 14481,97 | 2242,18 | 349,30 | 1070,07 |
| Capanema | 149,89 | 7694,60 | 7623,55 | 2298,39 | 205,14 | 476,82 |
| Capitão Leônidas Marques | 7719,58 | 19286,46 | 41067,37 | 17162,95 | 10645,25 | 12907,36 |
| Carambeí | 99,93 | 2042,32 | 4989,96 | 299,79 | 60,99 | 0,00 |
| Carlópolis | 17731,30 | 61281,96 | 97603,62 | 30665,96 | 10600,89 | 32695,33 |
| Cascavel | 9093,61 | 35006,67 | 135272,28 | 20048,42 | 8998,56 | 9902,30 |
| Castro | 1292,84 | 13727,86 | 26663,02 | 4852,84 | 1779,75 | 2273,20 |
| Catanduvas | 1592,63 | 6333,05 | 9586,27 | 3859,79 | 1907,27 | 2273,20 |
| Centenário do Sul | 818,18 | 6345,54 | 65645,70 | 2729,33 | 526,72 | 526,72 |
| Cerro Azul | 2036,07 | 22584,14 | 31009,83 | 12584,91 | 3332,18 | 3437,53 |
| Céu Azul | 905,61 | 14964,49 | 34591,51 | 4247,02 | 1275,21 | 0,00 |
| Chopinzinho | 3659,93 | 11354,53 | 18701,26 | 7419,79 | 3276,74 | 5427,97 |
| Cianorte | 149,89 | 1130,46 | 2799,92 | 268,56 | 88,71 | 11,09 |
| Cidade Gaúcha | 5015,23 | 19074,10 | 29374,23 | 5683,51 | 1541,34 | 2544,88 |
| Clevelândia | 0,00 | 24,98 | 4357,90 | 0 | 0,00 | 0,00 |
| Colombo | 137,40 | 1848,70 | 3814,55 | 343,51 | 55,44 | 404,74 |

| | | | | | | |
|-------------------------|---------|----------|----------|----------|---------|----------|
| Colorado | 2117,26 | 11104,70 | 14032,88 | 4859,09 | 1896,18 | 2190,04 |
| Congonhinhas | 455,93 | 3297,68 | 11094,34 | 2460,77 | 925,91 | 194,05 |
| Conselheiro Mairinck | 112,42 | 3759,86 | 11903,83 | 1973,61 | 365,93 | 0,00 |
| Contenda | 6957,61 | 27786,74 | 40368,78 | 20204,56 | 8460,75 | 15513,23 |
| Corbélia | 8038,11 | 26069,19 | 32939,28 | 14839,58 | 5987,95 | 16893,79 |
| Cornélio Procópio | 2242,18 | 14446,10 | 25570,77 | 4565,54 | 1524,71 | 548,90 |
| Coronel Domingos Soares | 4509,33 | 20785,40 | 32711,96 | 10686,25 | 4258,10 | 6159,83 |
| Coronel Vivida | 12,49 | 2966,67 | 4047,41 | 1317,82 | 670,87 | 332,66 |
| Corumbataí do Sul | 0,00 | 1411,51 | 3958,70 | 118,67 | 16,63 | 0,00 |
| Cruz Machado | 2104,77 | 6832,70 | 5982,41 | 3410,11 | 864,93 | 1230,86 |
| Cruzeiro do Iguaçu | 1692,56 | 4172,07 | 2833,19 | 2179,72 | 1291,85 | 2361,91 |
| Cruzeiro do Oeste | 362,25 | 2267,16 | 17004,68 | 62,46 | 22,18 | 0,00 |
| Cruzeiro do Sul | 3591,23 | 12634,88 | 22005,72 | 12010,32 | 7739,98 | 7246,53 |
| Cruzmaltina | 0,00 | 43,72 | 803,94 | 0 | 0,00 | 0,00 |
| Curitiba | 380,98 | 6464,21 | 31287,05 | 4184,56 | 1641,14 | 426,92 |
| Curiúva | 306,04 | 2741,82 | 8033,84 | 1773,75 | 260,59 | 327,12 |
| Diamante d'Oeste | 0,00 | 3791,09 | 6193,09 | 380,98 | 0,00 | 0,00 |
| Diamante do Norte | 424,70 | 4147,09 | 6819,61 | 1217,89 | 316,03 | 16,63 |
| Diamante do Sul | 212,35 | 5770,95 | 14127,13 | 1561,4 | 515,63 | 277,22 |
| Dois Vizinhos | 424,70 | 1623,86 | 6791,89 | 612,07 | 343,75 | 232,86 |
| Douradina | 8612,70 | 10505,12 | 9941,11 | 9274,74 | 7612,46 | 10983,46 |

| | | | | | | |
|------------------------|----------|----------|----------|----------|----------|----------|
| Doutor Camargo | 0,00 | 868,14 | 2522,70 | 49,96 | 0,00 | 0,00 |
| Doutor Ulysses | 18262,17 | 29454,32 | 30533,01 | 22028,28 | 13556,06 | 32495,73 |
| Enéas Marques | 0,00 | 156,14 | 293,85 | 0 | 0,00 | 0,00 |
| Engenheiro Beltrão | 3803,58 | 6876,42 | 6303,98 | 4759,16 | 2156,77 | 5843,80 |
| Entre Rios do Oeste | 306,04 | 4640,49 | 7229,90 | 1167,93 | 205,14 | 0,00 |
| Esperança Nova | 7956,91 | 21484,91 | 26729,55 | 20316,98 | 13245,57 | 21345,94 |
| Espigão Alto do Iguaçu | 3716,14 | 19604,98 | 43906,10 | 19205,26 | 11177,51 | 5816,08 |
| Farol | 0,00 | 468,42 | 2228,85 | 37,47 | 0,00 | 0,00 |
| Faxinal | 10355,23 | 15514,10 | 17065,66 | 13602,95 | 8599,36 | 16522,31 |
| Fazenda Rio Grande | 2273,40 | 10798,67 | 18346,42 | 6564,14 | 2716,76 | 2944,08 |
| Fênix | 81,19 | 986,81 | 7451,67 | 505,89 | 332,66 | 66,53 |
| Fernandes Pinheiro | 7569,68 | 12178,95 | 14321,19 | 10892,35 | 7667,91 | 11787,39 |
| Figueira | 193,61 | 2004,84 | 7058,02 | 599,58 | 194,05 | 5,54 |
| Flor da Serra do Sul | 13665,40 | 15095,65 | 13689,12 | 14071,37 | 11781,85 | 15740,55 |
| Floraí | 2223,44 | 5096,42 | 7063,57 | 3191,51 | 1657,78 | 3930,98 |
| Floresta | 1517,68 | 2972,91 | 1890,64 | 1636,35 | 626,52 | 2539,34 |
| Florestópolis | 6345,54 | 19186,53 | 19477,48 | 15301,75 | 5727,37 | 16173,02 |
| Flórida | 5964,56 | 11229,61 | 17353,97 | 6770,25 | 3332,18 | 7301,98 |
| Formosa do Oeste | 10061,68 | 16819,44 | 16472,41 | 14058,88 | 6941,59 | 15502,14 |
| Foz do Iguaçu | 468,42 | 8319,16 | 16954,78 | 1761,26 | 404,74 | 0,00 |
| Foz do Jordão | 3753,61 | 9106,11 | 12779,84 | 5358,74 | 3038,33 | 6425,96 |

| | | | | | | |
|-------------------|----------|----------|-----------|----------|----------|----------|
| Francisco Alves | 0,00 | 530,88 | 12785,39 | 56,21 | 27,72 | 5,54 |
| Francisco Beltrão | 399,72 | 2735,58 | 3321,10 | 1142,95 | 371,47 | 243,95 |
| General Carneiro | 23745,82 | 35712,42 | 38910,60 | 32071,23 | 22371,65 | 33698,86 |
| Godoy Moreira | 1648,84 | 14364,91 | 31580,90 | 8069,33 | 4280,28 | 2212,22 |
| Goioerê | 312,28 | 3291,44 | 12552,52 | 2104,77 | 648,69 | 271,68 |
| Goioxim | 24901,26 | 35356,42 | 36204,93 | 32271,09 | 19017,29 | 39004,86 |
| Grandes Rios | 0,00 | 1043,02 | 803,94 | 31,23 | 0,00 | 0,00 |
| Guaira | 193,61 | 2666,88 | 7130,10 | 1043,02 | 354,84 | 0,00 |
| Guairaçá | 443,44 | 3172,77 | 3193,57 | 1211,65 | 144,15 | 177,42 |
| Guamiranga | 74,95 | 811,93 | 681,96 | 6,25 | 0,00 | 0,00 |
| Guapirama | 918,11 | 1792,49 | 2167,86 | 980,56 | 659,78 | 770,67 |
| Guaporema | 181,12 | 15239,30 | 29124,73 | 1142,95 | 66,53 | 0,00 |
| Guaraci | 43812,98 | 77289,47 | 156928,70 | 47916,35 | 27339,44 | 79972,43 |
| Guaraniaçu | 6457,96 | 6932,63 | 110023,08 | 668,28 | 199,60 | 6148,74 |
| Guarapuava | 0,00 | 2710,60 | 73890,22 | 699,51 | 255,04 | 0,00 |
| Guaraqueçaba | 5096,42 | 19879,79 | 23663,50 | 9430,88 | 4806,99 | 9386,67 |
| Guaratuba | 830,67 | 10067,93 | 21917,01 | 7188,7 | 1774,21 | 1973,81 |
| Honório Serpa | 181,12 | 2554,46 | 6814,07 | 374,74 | 171,88 | 0,00 |
| Ibaiti | 7744,56 | 15064,42 | 22066,71 | 14314,95 | 9691,61 | 13156,86 |
| Ibema | 343,51 | 2260,91 | 3254,56 | 518,39 | 27,72 | 632,06 |
| Ibiporã | 7557,19 | 11704,28 | 10107,44 | 9699,44 | 5666,38 | 11393,74 |

| | | | | | | |
|-------------------|----------|----------|----------|----------|----------|----------|
| Icaraíma | 499,65 | 4421,89 | 5211,74 | 2510,74 | 687,51 | 493,45 |
| Iguaraçu | 218,60 | 1342,81 | 18967,39 | 593,33 | 205,14 | 0,00 |
| Iguatu | 3060,35 | 16669,54 | 34674,68 | 9893,05 | 5305,99 | 3232,39 |
| Imbaú | 0,00 | 911,86 | 25920,07 | 156,14 | 271,68 | 0,00 |
| Imbituva | 0,00 | 786,95 | 5477,87 | 293,54 | 0,00 | 0,00 |
| Inácio Martins | 287,30 | 630,81 | 1496,99 | 268,56 | 188,51 | 0,00 |
| Inajá | 5621,05 | 17824,98 | 51446,49 | 12160,21 | 7462,76 | 7013,67 |
| Indianópolis | 6732,77 | 18293,40 | 20248,15 | 12791,02 | 5427,97 | 8749,06 |
| Ipiranga | 2548,21 | 5302,53 | 6963,77 | 4821,61 | 2993,98 | 5228,37 |
| Iporã | 3572,49 | 25319,72 | 46118,32 | 13384,35 | 5256,09 | 4884,62 |
| Iracema do Oeste | 68,70 | 7188,70 | 23147,87 | 3422,6 | 643,15 | 0,00 |
| Irati | 31,23 | 1386,53 | 6825,16 | 312,28 | 155,24 | 5,54 |
| Iretama | 6714,03 | 12584,91 | 9602,90 | 8131,79 | 2517,16 | 10506,64 |
| Itaguajé | 2816,77 | 7138,74 | 9857,94 | 3072,84 | 737,41 | 4790,36 |
| Itaipulândia | 13771,58 | 17700,07 | 18789,97 | 16163,65 | 12502,62 | 20281,42 |
| Itambaracá | 1305,33 | 8212,98 | 10456,74 | 2417,05 | 754,04 | 3165,85 |
| Itambé | 0,00 | 880,63 | 15097,40 | 106,18 | 0,00 | 0,00 |
| Itapejara d'Oeste | 0,00 | 674,53 | 3165,85 | 306,04 | 33,27 | 0,00 |
| Itaperuçu | 368,49 | 7969,40 | 18601,46 | 4852,84 | 2173,40 | 0,00 |
| Itaúna do Sul | 393,47 | 13178,25 | 27200,83 | 10836,14 | 5505,59 | 881,56 |
| Ivaí | 256,07 | 1511,44 | 3093,78 | 580,84 | 94,25 | 0,00 |

| | | | | | | |
|----------------|----------|----------|----------|----------|----------|----------|
| Ivaiporã | 8837,54 | 9312,21 | 7983,94 | 7963,16 | 7751,07 | 9480,92 |
| Ivaté | 43,72 | 1417,75 | 3088,23 | 880,63 | 210,69 | 127,52 |
| Ivatuba | 299,79 | 4009,68 | 10883,66 | 1567,65 | 332,66 | 0,00 |
| Jaboti | 3809,82 | 10423,93 | 12380,65 | 6189,4 | 3221,30 | 6780,80 |
| Jacarezinho | 3453,82 | 19280,21 | 59585,67 | 13440,56 | 6087,75 | 2422,90 |
| Jaguapitã | 137,40 | 6464,21 | 14104,95 | 7619,65 | 3443,07 | 959,18 |
| Jaguariaíva | 9343,44 | 21372,49 | 24278,93 | 18786,81 | 12158,87 | 18795,52 |
| Jandaia do Sul | 712,00 | 2323,37 | 3964,25 | 1136,7 | 188,51 | 0,00 |
| Janiópolis | 4178,32 | 7313,61 | 11892,74 | 6589,12 | 3393,17 | 5766,18 |
| Japira | 156,14 | 9137,33 | 18468,40 | 6963,86 | 3881,08 | 377,02 |
| Japurá | 1174,18 | 2248,42 | 7202,18 | 2092,28 | 997,99 | 1469,27 |
| Jardim Alegre | 1680,07 | 4702,95 | 8970,84 | 3847,3 | 1885,10 | 3709,20 |
| Jardim Olinda | 3378,88 | 16207,37 | 17864,06 | 12353,82 | 5378,07 | 6703,18 |
| Jataizinho | 0,00 | 824,42 | 4901,25 | 81,19 | 0,00 | 0,00 |
| Jesuítas | 412,21 | 5571,09 | 12452,72 | 1967,37 | 288,31 | 0,00 |
| Joaquim Távora | 19367,65 | 26537,61 | 33321,85 | 25731,93 | 20841,40 | 25981,06 |
| Jundiá do Sul | 6607,86 | 11922,88 | 15568,68 | 10567,58 | 6121,02 | 12242,04 |
| Juranda | 2510,74 | 11566,88 | 15413,43 | 10411,44 | 5732,91 | 7102,38 |
| Jussara | 3684,91 | 19505,05 | 62612,91 | 9199,79 | 5400,25 | 3886,62 |
| Kaloré | 112,42 | 9312,21 | 12652,32 | 968,07 | 88,71 | 0,00 |
| Lapa | 262,32 | 14733,40 | 22926,09 | 3722,39 | 776,22 | 1308,48 |

| | | | | | | |
|-------------------------|----------|----------|-----------|----------|----------|----------|
| Laranjal | 4378,18 | 11535,65 | 22183,15 | 11891,65 | 7457,22 | 9957,74 |
| Laranjeiras do Sul | 880,63 | 7026,32 | 10013,19 | 5071,44 | 2251,03 | 432,46 |
| Leópolis | 662,04 | 8912,49 | 13001,62 | 2629,4 | 798,39 | 521,17 |
| Lidianópolis | 112,42 | 2791,79 | 9891,21 | 986,81 | 33,27 | 0,00 |
| Lindoeste | 2398,32 | 5889,61 | 3515,15 | 2654,39 | 1397,19 | 3553,96 |
| Loanda | 12453,75 | 66728,14 | 124904,25 | 67602,52 | 42259,42 | 24960,89 |
| Lobato | 7600,91 | 35681,19 | 69754,10 | 32458,46 | 21822,76 | 13628,14 |
| Londrina | 112,42 | 4534,32 | 9924,48 | 2679,37 | 892,65 | 482,36 |
| Luiziana | 799,44 | 2579,44 | 4524,23 | 1523,93 | 931,46 | 609,88 |
| Lunardelli | 487,16 | 4615,51 | 20553,09 | 1280,35 | 632,06 | 1646,69 |
| Lupionópolis | 12235,16 | 40640,21 | 70086,76 | 36593,05 | 22720,95 | 23003,72 |
| Mallet | 5065,19 | 11691,79 | 14021,79 | 8587,72 | 4867,98 | 10179,52 |
| Mamborê | 749,47 | 9174,81 | 29618,19 | 10049,19 | 3903,26 | 1973,81 |
| Mandaguaçu | 68,70 | 1536,42 | 15274,82 | 999,3 | 377,02 | 0,00 |
| Mandaguari | 0,00 | 149,89 | 438,01 | 0 | 0,00 | 0,00 |
| Mandirituba | 9886,81 | 34400,84 | 50132,47 | 18980,42 | 9353,40 | 19588,37 |
| Manfrinópolis | 1349,05 | 17038,03 | 35766,93 | 13446,81 | 7235,44 | 1075,61 |
| Mangueirinha | 18268,42 | 40371,65 | 42608,72 | 27243,37 | 9669,43 | 35938,80 |
| Manoel Ribas | 199,86 | 1992,35 | 2289,84 | 337,26 | 138,61 | 0,00 |
| Marechal Cândido Rondon | 14177,54 | 27287,09 | 33892,92 | 23371,09 | 12596,88 | 29363,14 |
| Maria Helena | 2966,67 | 16632,07 | 29623,73 | 16532,14 | 10196,15 | 5976,86 |

| | | | | | | |
|-------------------|----------|----------|----------|----------|----------|----------|
| Marialva | 0,00 | 1530,18 | 4457,70 | 705,75 | 5,54 | 255,04 |
| Marilândia do Sul | 9949,26 | 18899,23 | 18224,44 | 15214,32 | 8804,51 | 15585,31 |
| Marilena | 19542,53 | 29785,33 | 32867,20 | 28192,7 | 20481,01 | 29523,93 |
| Mariluz | 930,60 | 5227,58 | 9220,34 | 1224,14 | 255,04 | 1840,74 |
| Maringá | 19105,33 | 24595,23 | 24539,52 | 23570,95 | 15141,76 | 27500,22 |
| Mariópolis | 74,95 | 6676,56 | 15823,72 | 1380,28 | 144,15 | 0,00 |
| Maripá | 174,88 | 9936,77 | 8233,43 | 1573,89 | 615,43 | 138,61 |
| Marmeleiro | 31,23 | 3853,54 | 10423,47 | 2716,84 | 565,53 | 615,43 |
| Marquinho | 3460,07 | 14102,60 | 19433,12 | 7856,98 | 2228,85 | 7728,89 |
| Marumbi | 149,89 | 199,86 | 4308,00 | 74,95 | 0,00 | 288,31 |
| Matelândia | 774,46 | 8687,65 | 17886,23 | 3959,72 | 2056,97 | 737,41 |
| Matinhos | 143,65 | 1873,68 | 5627,57 | 2710,6 | 1474,81 | 0,00 |
| Mato Rico | 5121,40 | 13034,60 | 16965,86 | 9018,67 | 3487,43 | 7479,40 |
| Mauá da Serra | 3510,03 | 9699,44 | 10695,15 | 6308,07 | 2295,38 | 6924,96 |
| Medianeira | 512,14 | 4172,07 | 5516,68 | 1330,32 | 110,89 | 88,71 |
| Mercedes | 112,42 | 443,44 | 948,09 | 237,33 | 77,62 | 0,00 |
| Mirador | 9874,32 | 16001,26 | 11698,68 | 11385,75 | 4091,77 | 14714,84 |
| Miraselva | 4665,47 | 10854,88 | 11698,68 | 8369,12 | 3847,81 | 4834,72 |
| Missal | 93,68 | 568,35 | 54806,40 | 87,44 | 0,00 | 0,00 |
| Moreira Sales | 2910,46 | 5077,68 | 4751,55 | 3079,09 | 1691,04 | 3975,33 |
| Morretes | 986,81 | 2104,77 | 1258,58 | 855,65 | 582,16 | 920,37 |

| | | | | | | |
|----------------------------|----------|----------|-----------|----------|----------|----------|
| Munhoz de Melo | 43,72 | 2011,09 | 4036,32 | 699,51 | 22,18 | 0,00 |
| Nossa Senhora das Graças | 562,11 | 3528,77 | 6187,55 | 2092,28 | 931,46 | 465,73 |
| Nova Aliança do Ivaí | 14702,18 | 34094,81 | 39503,85 | 30622,24 | 15080,77 | 33100,07 |
| Nova América da Colina | 3834,81 | 22234,39 | 33532,53 | 16082,46 | 7429,50 | 5816,08 |
| Nova Aurora | 555,86 | 3940,98 | 5971,32 | 1530,18 | 377,02 | 742,95 |
| Nova Cantu | 0,00 | 674,53 | 1685,50 | 12,49 | 0,00 | 0,00 |
| Nova Esperança | 2198,46 | 13983,93 | 13567,15 | 6520,42 | 1923,91 | 6337,25 |
| Nova Esperança do Sudoeste | 387,23 | 13303,16 | 18202,27 | 1973,61 | 177,42 | 0,00 |
| Nova Fátima | 474,67 | 1692,56 | 6936,04 | 1205,4 | 465,73 | 681,96 |
| Nova Laranjeiras | 143,65 | 231,09 | 587,71 | 93,68 | 27,72 | 0,00 |
| Nova Londrina | 918,11 | 3853,54 | 5594,30 | 2635,65 | 1269,67 | 2400,73 |
| Nova Olímpia | 12947,16 | 17063,02 | 14692,66 | 15295,51 | 8083,74 | 19665,99 |
| Nova Prata do Iguaçu | 0,00 | 6495,44 | 11022,27 | 1274,11 | 60,99 | 0,00 |
| Nova Santa Bárbara | 237,33 | 12228,91 | 22294,03 | 4746,67 | 1330,66 | 210,69 |
| Nova Santa Rosa | 106,18 | 2235,93 | 7146,73 | 1573,89 | 404,74 | 643,15 |
| Nova Tebas | 4009,68 | 24270,46 | 133936,07 | 15420,42 | 6730,90 | 6869,51 |
| Novo Itacolomi | 11429,47 | 15895,09 | 15507,69 | 14964,49 | 12646,78 | 16156,38 |
| Ortigueira | 968,07 | 5621,05 | 16699,73 | 2985,4 | 920,37 | 759,58 |
| Ourizona | 9455,86 | 13109,54 | 13295,47 | 11660,56 | 8377,59 | 14931,07 |
| Ouro Verde do Oeste | 5071,44 | 19836,07 | 30566,28 | 6314,32 | 1951,63 | 5500,04 |
| Paiçandu | 9274,74 | 32008,77 | 68462,25 | 15614,03 | 7723,35 | 6115,47 |

| | | | | | | |
|---------------------|----------|----------|----------|----------|----------|----------|
| Palmas | 306,04 | 15682,74 | 19094,91 | 1517,68 | 194,05 | 0,00 |
| Palmeira | 46523,58 | 55854,52 | 57706,12 | 54717,82 | 38544,67 | 61587,20 |
| Palmital | 1292,84 | 4609,26 | 4823,63 | 2560,7 | 1042,35 | 1907,27 |
| Palotina | 549,61 | 3085,33 | 3448,62 | 643,3 | 304,94 | 748,49 |
| Paraíso do Norte | 4084,63 | 3472,56 | 20614,08 | 324,77 | 38,81 | 3664,85 |
| Paranacity | 749,47 | 1730,04 | 7074,65 | 1092,98 | 731,86 | 0,00 |
| Paranaguá | 886,88 | 10836,14 | 21612,07 | 2810,53 | 349,30 | 0,00 |
| Paranapoema | 3560,00 | 7120,00 | 5760,63 | 4253,26 | 809,48 | 5644,20 |
| Paranavaí | 2385,82 | 15095,65 | 23447,27 | 5527,37 | 1358,38 | 1729,85 |
| Pato Bragado | 1136,70 | 7675,86 | 17420,51 | 6651,58 | 2511,61 | 1496,99 |
| Pato Branco | 343,51 | 4652,98 | 14365,54 | 3366,39 | 1241,95 | 11,09 |
| Paula Freitas | 8250,46 | 24944,98 | 33759,85 | 20292 | 12474,90 | 19704,80 |
| Paulo Frontin | 3853,54 | 8344,14 | 10162,89 | 6408 | 3498,52 | 3759,10 |
| Peabiru | 143,65 | 430,95 | 892,65 | 262,32 | 33,27 | 0,00 |
| Perobal | 362,25 | 4677,96 | 9591,81 | 1780 | 410,29 | 670,87 |
| Pérola | 81,19 | 1055,51 | 5810,53 | 843,16 | 149,70 | 232,86 |
| Pérola d'Oeste | 0,00 | 62,46 | 438,01 | 0 | 0,00 | 0,00 |
| Piên | 293,54 | 1780,00 | 5899,24 | 1136,7 | 293,85 | 221,78 |
| Pinhais | 0,00 | 793,19 | 1097,79 | 56,21 | 5,54 | 0,00 |
| Pinhal de São Bento | 20010,95 | 41420,91 | 62363,41 | 26144,14 | 14531,87 | 33887,37 |
| Pinhalão | 11816,70 | 34513,26 | 84008,75 | 31933,82 | 18717,89 | 18169,00 |

| | | | | | | |
|---------------------------|----------|----------|-----------|----------|----------|----------|
| Pinhão | 0,00 | 99,93 | 7629,09 | 0 | 0,00 | 0,00 |
| Piraf do Sul | 2079,79 | 30010,17 | 88150,42 | 17387,79 | 7357,42 | 2256,57 |
| Piraquara | 3766,11 | 8219,23 | 8843,32 | 6576,63 | 4152,76 | 8649,26 |
| Pitanga | 412,21 | 1480,21 | 4019,69 | 455,93 | 27,72 | 293,85 |
| Pitangueiras | 168,63 | 6214,39 | 12425,00 | 2054,81 | 532,26 | 0,00 |
| Planaltina do Paraná | 21915,86 | 49752,56 | 109041,72 | 37086,46 | 22499,18 | 27888,33 |
| Planalto | 68,70 | 87,44 | 2633,59 | 0 | 0,00 | 0,00 |
| Ponta Grossa | 868,14 | 2385,82 | 5134,11 | 999,3 | 499,00 | 499,00 |
| Pontal do Paraná | 1492,70 | 5015,23 | 10850,39 | 4178,32 | 2328,65 | 2838,73 |
| Porecatu | 712,00 | 8237,96 | 15590,85 | 4040,91 | 1258,58 | 438,01 |
| Porto Amazonas | 74,95 | 1692,56 | 6802,98 | 1523,93 | 210,69 | 0,00 |
| Porto Barreiro | 0,00 | 249,82 | 2129,05 | 24,98 | 0,00 | 0,00 |
| Porto Rico | 5190,11 | 7263,65 | 9503,10 | 6745,26 | 4940,06 | 9442,11 |
| Porto Vitória | 4240,77 | 10786,18 | 16633,20 | 8500,28 | 4934,52 | 7396,23 |
| Prado Ferreira | 74,95 | 1667,58 | 3576,14 | 543,37 | 127,52 | 0,00 |
| Pranchita | 17450,25 | 22521,68 | 27677,65 | 19967,23 | 15613,03 | 21922,56 |
| Presidente Castelo Branco | 2666,88 | 20017,19 | 55277,67 | 6214,39 | 2062,52 | 3537,33 |
| Primeiro de Maio | 22752,77 | 27855,44 | 28830,88 | 26344 | 19959,84 | 29973,03 |
| Prudentópolis | 0,00 | 281,05 | 3393,17 | 0 | 0,00 | 0,00 |
| Quarto Centenário | 81,19 | 24,98 | 10040,91 | 0 | 0,00 | 0,00 |
| Quatiguá | 5527,37 | 8718,88 | 8549,47 | 7182,46 | 3603,86 | 10961,28 |

| | | | | | | |
|-----------------------|----------|----------|----------|----------|----------|----------|
| Quatro Barras | 331,02 | 9299,72 | 18385,23 | 1605,12 | 227,32 | 0,00 |
| Quatro Pontes | 3866,03 | 10311,51 | 13866,54 | 4421,89 | 1896,18 | 3576,14 |
| Quedas do Iguaçu | 10630,03 | 19517,54 | 25038,51 | 17419,02 | 10545,45 | 19172,54 |
| Querência do Norte | 0,00 | 868,14 | 10390,21 | 249,82 | 33,27 | 0,00 |
| Quinta do Sol | 362,25 | 3385,12 | 7512,66 | 986,81 | 360,39 | 88,71 |
| Quitandinha | 6489,19 | 10355,23 | 13317,65 | 8013,12 | 4840,26 | 12652,32 |
| Ramilândia | 15945,05 | 20304,49 | 22743,13 | 19586,25 | 16039,95 | 21861,57 |
| Rancho Alegre | 1442,74 | 11779,23 | 15552,04 | 5814,67 | 1131,06 | 2384,09 |
| Rancho Alegre d'Oeste | 3122,81 | 12816,00 | 23353,01 | 8044,35 | 4030,78 | 5394,70 |
| Realeza | 5040,21 | 17144,21 | 25731,56 | 10817,4 | 5211,74 | 9880,12 |
| Rebouças | 1698,81 | 13309,40 | 61099,29 | 7613,4 | 3093,78 | 1447,09 |
| Renascença | 7713,33 | 16326,03 | 22216,41 | 9599,51 | 4174,93 | 13994,07 |
| Reserva | 68,70 | 1405,26 | 13849,91 | 362,25 | 127,52 | 0,00 |
| Reserva do Iguaçu | 1274,11 | 12566,18 | 12519,26 | 5240,07 | 2190,04 | 1480,35 |
| Ribeirão Claro | 331,02 | 6214,39 | 19250,16 | 1742,53 | 1563,52 | 1912,82 |
| Ribeirão do Pinhal | 168,63 | 3684,91 | 10889,20 | 2941,68 | 1108,88 | 0,00 |
| Rio Azul | 106,18 | 10605,05 | 17243,08 | 1461,47 | 199,60 | 0,00 |
| Rio Bom | 1117,96 | 9193,54 | 19937,66 | 7950,67 | 3692,57 | 1607,88 |
| Rio Bonito do Iguaçu | 0,00 | 1605,12 | 40174,72 | 87,44 | 11,09 | 0,00 |
| Rio Branco do Ivaí | 343,51 | 1892,42 | 16849,43 | 999,3 | 499,00 | 0,00 |
| Rio Branco do Sul | 12347,58 | 27436,98 | 34857,64 | 24183,02 | 15868,07 | 25543,05 |

| | | | | | | |
|-----------------------------|----------|----------|----------|----------|----------|----------|
| Rio Negro | 4996,49 | 17781,26 | 42475,65 | 11210,88 | 7357,42 | 4973,33 |
| Rolândia | 6,25 | 1755,02 | 7523,75 | 524,63 | 155,24 | 66,53 |
| Roncador | 0,00 | 943,09 | 16500,13 | 399,72 | 138,61 | 0,00 |
| Rondon | 4353,19 | 10180,35 | 16123,12 | 9187,3 | 5633,11 | 8737,97 |
| Rosário do Ivaí | 0,00 | 193,61 | 382,56 | 0 | 0,00 | 0,00 |
| Sabáudia | 0,00 | 1130,46 | 9020,74 | 949,33 | 349,30 | 5,54 |
| Salgado Filho | 405,96 | 3403,86 | 8549,47 | 905,61 | 393,65 | 0,00 |
| Salto do Itararé | 287,30 | 2891,72 | 3853,36 | 1080,49 | 99,80 | 615,43 |
| Salto do Lontra | 412,21 | 4265,75 | 7357,42 | 2741,82 | 859,38 | 1563,52 |
| Santa Amélia | 2698,11 | 4952,77 | 8349,87 | 2704,35 | 1391,64 | 2406,27 |
| Santa Cecília do Pavão | 4272,00 | 9612,00 | 7046,93 | 5708,49 | 1779,75 | 6725,36 |
| Santa Cruz de Monte Castelo | 22303,09 | 33357,82 | 26430,16 | 23346,1 | 6303,98 | 31070,82 |
| Santa Fé | 293,54 | 1024,28 | 3088,23 | 512,14 | 243,95 | 0,00 |
| Santa Helena | 1505,19 | 2516,98 | 5738,45 | 793,19 | 432,46 | 1214,22 |
| Santa Inês | 1486,46 | 11210,88 | 14892,26 | 6408 | 2090,24 | 2788,83 |
| Santa Isabel do Ivaí | 774,46 | 4409,40 | 4308,00 | 1948,63 | 188,51 | 704,14 |
| Santa Izabel do Oeste | 380,98 | 12453,75 | 31386,85 | 3597,47 | 1164,32 | 0,00 |
| Santa Lúcia | 15795,16 | 27905,40 | 33743,22 | 25338,46 | 13683,58 | 30355,59 |
| Santa Maria do Oeste | 1761,26 | 4702,95 | 11820,66 | 3716,14 | 1314,02 | 1674,41 |
| Santa Mariana | 730,74 | 5146,39 | 15069,68 | 4702,95 | 2162,32 | 0,00 |
| Santa Mônica | 4596,77 | 18374,60 | 19527,38 | 9699,44 | 3681,48 | 6509,13 |

| | | | | | | |
|---------------------------|----------|----------|----------|----------|----------|----------|
| Santa Tereza do Oeste | 11541,89 | 16001,26 | 17825,25 | 14008,91 | 7379,60 | 17902,87 |
| Santa Terezinha de Itaipu | 480,91 | 8163,02 | 14426,53 | 2385,82 | 343,75 | 0,00 |
| Santana do Itararé | 293,54 | 2029,82 | 6220,82 | 1448,98 | 271,68 | 0,00 |
| Santo Antônio da Platina | 1767,51 | 8306,67 | 10966,82 | 6626,6 | 3204,66 | 5078,67 |
| Santo Antônio do Caiuá | 693,26 | 7594,67 | 15197,20 | 2922,95 | 831,66 | 99,80 |
| Santo Antônio do Paraíso | 349,75 | 1411,51 | 2129,05 | 512,14 | 66,53 | 227,32 |
| Santo Antônio do Sudoeste | 1580,14 | 5477,40 | 8244,52 | 3709,89 | 1729,85 | 1513,62 |
| Santo Inácio | 3010,39 | 16307,30 | 43734,23 | 11023,51 | 4762,64 | 5904,79 |
| São Carlos do Ivaí | 1286,60 | 12385,05 | 21617,62 | 5521,12 | 1630,05 | 2450,62 |
| São Jerônimo da Serra | 0,00 | 830,67 | 1624,51 | 43,72 | 0,00 | 0,00 |
| São João | 8962,46 | 21572,35 | 26180,66 | 19099,09 | 11016,72 | 16483,50 |
| São João do Caiuá | 405,96 | 4553,05 | 15646,30 | 1598,88 | 654,24 | 171,88 |
| São João do Ivaí | 0,00 | 4147,09 | 10046,45 | 593,33 | 77,62 | 0,00 |
| São João do Triunfo | 22359,30 | 27387,02 | 28276,44 | 26587,58 | 23591,42 | 27821,80 |
| São Jorge d'Oeste | 0,00 | 274,81 | 559,98 | 0 | 0,00 | 5,54 |
| São Jorge do Ivaí | 1080,49 | 8337,89 | 14354,45 | 3853,54 | 1314,02 | 1025,71 |
| São Jorge do Patrocínio | 393,47 | 2454,53 | 2993,98 | 736,98 | 116,43 | 0,00 |
| São José da Boa Vista | 0,00 | 1224,14 | 23962,90 | 593,33 | 127,52 | 0,00 |
| São José das Palmeiras | 2629,40 | 4140,84 | 5638,65 | 3878,53 | 3237,93 | 2733,39 |
| São José dos Pinhais | 6264,35 | 16632,07 | 48008,96 | 9443,37 | 6004,59 | 5527,77 |
| São Manoel do Paraná | 38928,91 | 52107,16 | 54246,41 | 45049,61 | 25337,91 | 56569,51 |

| | | | | | | |
|---------------------------|----------|----------|----------|----------|----------|----------|
| São Mateus do Sul | 2516,98 | 11772,98 | 16222,91 | 7138,74 | 2117,96 | 2001,53 |
| São Miguel do Iguaçu | 5408,70 | 14358,67 | 16278,36 | 10911,09 | 4818,08 | 8898,76 |
| São Pedro do Iguaçu | 87,44 | 786,95 | 4119,49 | 124,91 | 83,17 | 0,00 |
| São Pedro do Ivaí | 3047,86 | 12947,16 | 16500,13 | 9449,61 | 4463,24 | 8333,23 |
| São Pedro do Paraná | 799,44 | 2429,54 | 6741,99 | 1480,21 | 493,45 | 1192,05 |
| São Sebastião da Amoreira | 224,84 | 6589,12 | 17614,56 | 893,12 | 44,36 | 166,33 |
| São Tomé | 5352,49 | 7369,82 | 7995,03 | 7232,42 | 6032,31 | 7756,62 |
| Sapopema | 0,00 | 705,75 | 2811,01 | 87,44 | 0,00 | 0,00 |
| Sarandi | 1380,28 | 6120,70 | 38051,22 | 1598,88 | 354,84 | 620,97 |
| Saudade do Iguaçu | 9012,42 | 14827,09 | 14853,45 | 12884,7 | 6309,53 | 13650,31 |
| Sengés | 21903,37 | 29860,28 | 30693,80 | 27955,37 | 22088,89 | 31009,83 |
| Serranópolis do Iguaçu | 19286,46 | 31003,23 | 39315,34 | 26856,14 | 16949,23 | 30987,65 |
| Sertaneja | 87,44 | 1261,61 | 12652,32 | 980,56 | 304,94 | 0,00 |
| Sertanópolis | 49,96 | 1030,53 | 3443,07 | 337,26 | 55,44 | 0,00 |
| Siqueira Campos | 1942,39 | 14177,54 | 40629,36 | 15151,86 | 8688,08 | 4607,40 |
| Sulina | 31,23 | 2748,07 | 3176,94 | 655,79 | 60,99 | 0,00 |
| Tamarana | 574,60 | 3497,54 | 4551,95 | 1630,11 | 643,15 | 271,68 |
| Tamboara | 74,95 | 1211,65 | 7812,06 | 380,98 | 11,09 | 0,00 |
| Tapejara | 9736,91 | 23439,79 | 46040,70 | 15414,18 | 9874,58 | 11033,36 |
| Tapira | 68,70 | 1592,63 | 73734,98 | 318,53 | 11,09 | 121,98 |
| Teixeira Soares | 7482,25 | 13671,65 | 20192,71 | 10580,07 | 8305,51 | 10833,76 |

| | | | | | | |
|-----------------------|----------|----------|-----------|----------|----------|----------|
| Telêmaco Borba | 262,32 | 3391,37 | 4363,44 | 562,11 | 27,72 | 5,54 |
| Terra Boa | 43063,51 | 57928,07 | 56441,99 | 52325,75 | 34081,43 | 57212,67 |
| Terra Rica | 25419,65 | 81111,79 | 213309,71 | 84372 | 55449,55 | 31680,70 |
| Terra Roxa | 143,65 | 1936,14 | 9680,52 | 249,82 | 33,27 | 0,00 |
| Tibagi | 44668,63 | 73142,38 | 88333,38 | 60538,74 | 29773,43 | 79623,13 |
| Tijucas do Sul | 1567,65 | 6582,88 | 26164,02 | 5627,3 | 2422,90 | 554,44 |
| Toledo | 124,91 | 7975,65 | 8355,41 | 524,63 | 22,18 | 0,00 |
| Tomazina | 0,00 | 555,86 | 33743,22 | 0 | 0,00 | 0,00 |
| Três Barras do Paraná | 5340,00 | 16282,32 | 16500,13 | 11135,93 | 4213,74 | 12197,68 |
| Tunas do Paraná | 20935,30 | 25969,26 | 29174,63 | 25407,16 | 18246,62 | 28758,80 |
| Tuneiras do Oeste | 87,44 | 4446,88 | 21007,73 | 1155,44 | 343,75 | 0,00 |
| Tupãssi | 41895,58 | 55311,16 | 53392,57 | 49840 | 29257,80 | 54689,96 |
| Turvo | 143,65 | 2972,91 | 5477,87 | 786,95 | 171,88 | 493,45 |
| Ubiratã | 206,11 | 1236,63 | 11094,34 | 224,84 | 205,14 | 820,57 |
| Umuarama | 649,54 | 1611,37 | 1785,30 | 1024,28 | 637,61 | 0,00 |
| União da Vitória | 2429,54 | 7713,33 | 15008,69 | 5502,39 | 2761,11 | 4856,89 |
| Uniflor | 699,51 | 8369,12 | 20974,47 | 5496,14 | 2456,17 | 0,00 |
| Uraí | 4459,37 | 15020,70 | 62568,56 | 16232,35 | 10573,17 | 9114,99 |
| Ventania | 1324,07 | 12366,32 | 19205,80 | 7569,68 | 2860,91 | 715,23 |
| Vera Cruz do Oeste | 1236,63 | 6926,39 | 10817,12 | 2504,49 | 815,03 | 2849,82 |
| Verê | 356,00 | 2841,75 | 3614,95 | 518,39 | 105,34 | 216,23 |

| | | | | | | |
|----------------|---------|----------|----------|---------|---------|---------|
| Virmond | 93,68 | 3403,86 | 48191,93 | 1061,75 | 155,24 | 0,00 |
| Vitorino | 99,93 | 8206,74 | 9774,78 | 1473,96 | 94,25 | 0,00 |
| Wenceslau Braz | 2079,79 | 10448,91 | 16705,28 | 4353,19 | 1530,25 | 3359,91 |
| Xambrê | 0,00 | 343,51 | 914,83 | 0 | 0,00 | 0,00 |

Ano-safra 2011/2012

| MUNICÍPIO | CEI | PCEI | K-MÉDIA | COMPONENTES PRINCIPAIS | REDES NEURAIIS | GEOBIA |
|---------------------|------------|-------------|----------------|-----------------------------------|---------------------------|---------------|
| Abatiá | 149,89 | 2054,81 | 39303,65 | 81,19 | 56,21 | 0,00 |
| Adrianópolis | 93,68 | 2610,67 | 13740,35 | 0,00 | 0,00 | 0,00 |
| Agudos do Sul | 587,09 | 6514,18 | 0,00 | 12,49 | 31,23 | 0,00 |
| Almirante Tamandaré | 49,96 | 1767,51 | 32139,93 | 6,25 | 0,00 | 0,00 |
| Altamira do Paraná | 74,95 | 774,46 | 137,40 | 74,95 | 18,74 | 0,00 |
| Alto Paraíso | 68,70 | 843,16 | 861,89 | 137,40 | 56,21 | 0,00 |
| Alto Paraná | 212,35 | 1217,89 | 14620,98 | 93,68 | 112,42 | 0,00 |
| Alto Piquiri | 5108,91 | 15039,44 | 3222,74 | 10080,42 | 3603,72 | 6976,35 |
| Altônia | 5633,54 | 13958,95 | 9199,79 | 7607,16 | 4434,39 | 7188,70 |
| Alvorada do Sul | 930,60 | 2791,79 | 25938,03 | 836,91 | 580,84 | 936,84 |
| Amaporã | 112,42 | 643,30 | 30709,68 | 37,47 | 74,95 | 0,00 |
| Ampére | 574,60 | 2260,91 | 100229,61 | 668,28 | 318,53 | 1099,23 |
| Anahy | 2848,00 | 9268,49 | 27686,81 | 2435,79 | 1986,11 | 6283,09 |
| Andirá | 836,91 | 2791,79 | 2223,44 | 562,11 | 580,84 | 424,70 |

| | | | | | | |
|-----------------------|----------|----------|----------|----------|----------|----------|
| Ângulo | 1355,30 | 5140,14 | 1942,39 | 218,60 | 24,98 | 0,00 |
| Antonina | 1998,60 | 17899,93 | 1742,53 | 2435,79 | 1311,58 | 1199,16 |
| Antônio Olinto | 1811,23 | 9380,91 | 2872,98 | 3347,65 | 1473,96 | 1836,21 |
| Apucarana | 3129,05 | 12222,67 | 30697,19 | 5315,02 | 2410,81 | 4296,98 |
| Arapongas | 5689,75 | 30965,75 | 17887,44 | 11217,12 | 4521,82 | 3297,68 |
| Arapoti | 468,42 | 4921,54 | 0,00 | 2348,35 | 462,18 | 99,93 |
| Arapuã | 3847,30 | 13253,19 | 8487,79 | 3984,70 | 2623,16 | 5371,23 |
| Araruna | 2048,56 | 19536,28 | 1086,74 | 1992,35 | 1049,26 | 4247,02 |
| Araucária | 574,60 | 4378,18 | 6501,68 | 1324,07 | 462,18 | 524,63 |
| Ariranha do Ivaí | 3947,23 | 17593,89 | 287,30 | 7738,32 | 3179,02 | 6870,18 |
| Assaí | 15395,44 | 44281,40 | 6714,03 | 52731,72 | 14852,07 | 34794,31 |
| Assis Chateaubriand | 5783,44 | 14670,95 | 3172,77 | 7382,32 | 4890,32 | 4365,68 |
| Astorga | 1498,95 | 3778,60 | 10879,86 | 1249,12 | 1142,95 | 1605,12 |
| Atalaia | 2004,84 | 13440,56 | 4371,93 | 3303,93 | 1274,11 | 2510,74 |
| Balsa Nova | 537,12 | 4771,65 | 9143,58 | 418,46 | 287,30 | 530,88 |
| Bandeirantes | 393,47 | 2104,77 | 480,91 | 387,23 | 168,63 | 399,72 |
| Barbosa Ferraz | 6,25 | 137,40 | 18,74 | 0,00 | 6,25 | 0,00 |
| Barra do Jacaré | 587,09 | 2766,81 | 10011,72 | 655,79 | 424,70 | 587,09 |
| Barracão | 6,25 | 199,86 | 24095,58 | 6,25 | 12,49 | 0,00 |
| Bela Vista da Caroba | 7263,65 | 13990,18 | 33001,82 | 9936,77 | 6289,33 | 9980,49 |
| Bela Vista do Paraíso | 624,56 | 14845,82 | 424,70 | 530,88 | 187,37 | 24,98 |

| | | | | | | |
|--------------------------|----------|----------|----------|----------|----------|----------|
| Bituruna | 6807,72 | 15782,67 | 3172,77 | 9549,54 | 5552,35 | 8625,19 |
| Boa Esperança | 31,23 | 156,14 | 19492,56 | 0,00 | 6,25 | 0,00 |
| Boa Esperança do Iguaçu | 2086,04 | 12591,16 | 7444,77 | 2860,49 | 1636,35 | 231,09 |
| Boa Ventura de São Roque | 124,91 | 868,14 | 7532,21 | 343,51 | 81,19 | 0,00 |
| Boa Vista da Aparecida | 212,35 | 7013,82 | 649,54 | 0,00 | 6,25 | 0,00 |
| Bocaiúva do Sul | 0,00 | 137,40 | 174,88 | 0,00 | 0,00 | 0,00 |
| Bom Jesus do Sul | 405,96 | 2123,51 | 1311,58 | 124,91 | 231,09 | 131,16 |
| Bom Sucesso | 705,75 | 3253,96 | 1236,63 | 580,84 | 362,25 | 549,61 |
| Bom Sucesso do Sul | 549,61 | 3816,07 | 1305,33 | 393,47 | 299,79 | 612,07 |
| Borrazópolis | 2248,42 | 7919,44 | 7975,65 | 3129,05 | 1380,28 | 2011,09 |
| Braganey | 6489,19 | 15301,75 | 25126,10 | 16613,33 | 6470,46 | 14314,95 |
| Brasilândia do Sul | 156,14 | 1068,00 | 2467,02 | 162,39 | 124,91 | 0,00 |
| Cafeara | 7032,56 | 14152,56 | 3603,72 | 9068,63 | 4827,86 | 12310,10 |
| Cafelândia | 462,18 | 1767,51 | 2460,77 | 1436,49 | 524,63 | 0,00 |
| Cafezal do Sul | 187,37 | 1642,60 | 12772,28 | 124,91 | 112,42 | 6,25 |
| Califórnia | 1936,14 | 7607,16 | 4634,25 | 1286,60 | 1080,49 | 1948,63 |
| Cambará | 18824,28 | 33357,82 | 1954,88 | 26319,02 | 16769,47 | 29129,54 |
| Cambé | 580,84 | 3834,81 | 13396,84 | 980,56 | 455,93 | 237,33 |
| Cambira | 10936,07 | 24201,75 | 26025,47 | 15226,81 | 9024,91 | 10024,21 |
| Campina da Lagoa | 2129,75 | 13521,75 | 30147,58 | 5608,56 | 1780,00 | 3104,07 |
| Campina do Simão | 87,44 | 3366,39 | 42563,86 | 0,00 | 6,25 | 0,00 |

| | | | | | | |
|--------------------------|----------|----------|----------|----------|----------|----------|
| Campina Grande do Sul | 1505,19 | 10530,10 | 12628,63 | 3447,58 | 1161,68 | 1598,88 |
| Campo Bonito | 2960,42 | 14633,47 | 31203,09 | 4521,82 | 2217,19 | 1455,23 |
| Campo do Tenente | 480,91 | 19723,65 | 8494,03 | 181,12 | 87,44 | 1436,49 |
| Campo Largo | 0,00 | 2167,23 | 12947,16 | 31,23 | 0,00 | 0,00 |
| Campo Magro | 9487,09 | 26075,44 | 35131,58 | 12816,00 | 7338,60 | 10267,79 |
| Campo Mourão | 574,60 | 18955,44 | 2404,56 | 949,33 | 343,51 | 0,00 |
| Cândido de Abreu | 27955,37 | 62762,17 | 26849,89 | 35724,91 | 24682,67 | 25769,40 |
| Candói | 730,74 | 4740,42 | 7357,33 | 199,86 | 393,47 | 0,00 |
| Cantagalo | 68,70 | 1280,35 | 8156,77 | 31,23 | 24,98 | 0,00 |
| Capanema | 268,56 | 2029,82 | 9455,86 | 780,70 | 193,61 | 0,00 |
| Capitão Leônidas Marques | 8606,46 | 33926,17 | 6532,91 | 19236,49 | 7750,81 | 12341,33 |
| Carambeí | 81,19 | 2429,54 | 206,11 | 87,44 | 37,47 | 0,00 |
| Carlópolis | 18930,46 | 65379,09 | 4203,30 | 32801,96 | 14958,25 | 22559,16 |
| Cascavel | 22640,35 | 93652,98 | 487,16 | 41189,82 | 19224,00 | 26119,16 |
| Castro | 2523,23 | 16257,33 | 21459,93 | 6101,96 | 1973,61 | 3235,23 |
| Catanduvas | 1661,33 | 6108,21 | 39097,54 | 2610,67 | 1411,51 | 955,58 |
| Centenário do Sul | 56,21 | 3741,12 | 21122,67 | 37,47 | 6,25 | 418,46 |
| Cerro Azul | 830,67 | 12166,46 | 387,23 | 2179,72 | 599,58 | 680,77 |
| Céu Azul | 861,89 | 10286,53 | 37348,77 | 1374,04 | 549,61 | 0,00 |
| Chopinzinho | 2404,56 | 8281,68 | 0,00 | 1773,75 | 1667,58 | 1523,93 |
| Cianorte | 68,70 | 474,67 | 3522,53 | 24,98 | 37,47 | 0,00 |

| | | | | | | |
|-------------------------|---------|----------|----------|----------|---------|----------|
| Cidade Gaúcha | 3054,11 | 14015,16 | 337,26 | 3978,46 | 1954,88 | 2904,21 |
| Clevelândia | 0,00 | 868,14 | 3241,47 | 0,00 | 0,00 | 0,00 |
| Colombo | 343,51 | 1498,95 | 9487,09 | 299,79 | 256,07 | 99,93 |
| Colorado | 1018,04 | 7451,02 | 18462,03 | 1299,09 | 868,14 | 0,00 |
| Congonhinhas | 187,37 | 1842,46 | 7825,75 | 318,53 | 124,91 | 0,00 |
| Conselheiro Mairinck | 1917,40 | 22621,61 | 1648,84 | 3822,32 | 1011,79 | 4159,58 |
| Contenda | 8837,54 | 20947,79 | 1817,47 | 11510,67 | 6076,98 | 11398,25 |
| Corbélia | 2329,61 | 11598,10 | 15514,10 | 2829,26 | 1605,12 | 3004,14 |
| Cornélio Procópio | 3597,47 | 44393,82 | 380,98 | 8606,46 | 2910,46 | 3878,53 |
| Coronel Domingos Soares | 1224,14 | 8806,32 | 8394,11 | 1998,60 | 693,26 | 1380,28 |
| Coronel Vivida | 249,82 | 1255,37 | 9580,77 | 437,19 | 193,61 | 224,84 |
| Corumbataí do Sul | 12,49 | 362,25 | 44949,68 | 12,49 | 0,00 | 0,00 |
| Cruz Machado | 293,54 | 2679,37 | 10280,28 | 362,25 | 206,11 | 0,00 |
| Cruzeiro do Iguaçu | 943,09 | 2429,54 | 21004,00 | 699,51 | 724,49 | 405,96 |
| Cruzeiro do Oeste | 905,61 | 18237,19 | 23539,72 | 118,67 | 99,93 | 0,00 |
| Cruzeiro do Sul | 999,30 | 4128,35 | 6201,89 | 986,81 | 730,74 | 487,16 |
| Cruzmaltina | 12,49 | 1542,67 | 14995,72 | 0,00 | 6,25 | 0,00 |
| Curitiba | 474,67 | 6776,49 | 9474,60 | 855,65 | 362,25 | 0,00 |
| Curiúva | 256,07 | 849,40 | 2698,11 | 199,86 | 174,88 | 0,00 |
| Diamante d'Oeste | 12,49 | 886,88 | 0,00 | 0,00 | 0,00 | 0,00 |
| Diamante do Norte | 162,39 | 730,74 | 53574,88 | 380,98 | 93,68 | 0,00 |

| | | | | | | |
|------------------------|---------|----------|-----------|---------|---------|----------|
| Diamante do Sul | 137,40 | 1055,51 | 24951,23 | 243,58 | 106,18 | 0,00 |
| Dois Vizinhos | 624,56 | 2086,04 | 76796,07 | 524,63 | 455,93 | 824,42 |
| Douradina | 5508,63 | 8856,28 | 17506,46 | 6457,96 | 4515,58 | 8593,96 |
| Doutor Camargo | 18,74 | 218,60 | 1842,46 | 12,49 | 6,25 | 0,00 |
| Doutor Ulysses | 3303,93 | 9137,33 | 1011,79 | 2997,89 | 1761,26 | 3916,00 |
| Enéas Marques | 199,86 | 424,70 | 50320,91 | 212,35 | 174,88 | 0,00 |
| Engenheiro Beltrão | 1299,09 | 3378,88 | 1005,54 | 2248,42 | 993,05 | 761,96 |
| Entre Rios do Oeste | 256,07 | 1517,68 | 87657,19 | 243,58 | 143,65 | 0,00 |
| Esperança Nova | 5271,30 | 14608,49 | 123588,21 | 9106,11 | 4628,00 | 5421,19 |
| Espigão Alto do Iguaçu | 1573,89 | 15389,19 | 25094,88 | 5845,89 | 1261,61 | 580,84 |
| Farol | 218,60 | 2448,28 | 12022,81 | 106,18 | 131,16 | 0,00 |
| Faxinal | 1829,96 | 6464,21 | 1892,42 | 2154,74 | 886,88 | 4209,54 |
| Fazenda Rio Grande | 3366,39 | 15539,09 | 69245,12 | 3959,72 | 2492,00 | 2641,89 |
| Fênix | 212,35 | 1174,18 | 2254,67 | 249,82 | 174,88 | 0,00 |
| Fernandes Pinheiro | 4396,91 | 8456,56 | 11585,61 | 3859,79 | 3047,86 | 7769,54 |
| Figueira | 6,25 | 818,18 | 5408,70 | 0,00 | 0,00 | 0,00 |
| Flor da Serra do Sul | 6782,74 | 11766,74 | 11441,96 | 5352,49 | 4428,14 | 12603,65 |
| Floraí | 2285,89 | 5202,60 | 8968,70 | 2766,81 | 1942,39 | 2285,89 |
| Floresta | 237,33 | 693,26 | 1736,28 | 37,47 | 99,93 | 324,77 |
| Florestópolis | 643,30 | 3141,54 | 0,00 | 3154,04 | 474,67 | 930,60 |
| Flórida | 2167,23 | 6514,18 | 11541,89 | 1992,35 | 1192,91 | 1517,68 |

| | | | | | | |
|-------------------|----------|-----------|-----------|----------|----------|----------|
| Formosa do Oeste | 2204,70 | 6976,35 | 849,40 | 7819,51 | 2217,19 | 3528,77 |
| Foz do Iguaçu | 68,70 | 1192,91 | 12172,70 | 62,46 | 31,23 | 0,00 |
| Foz do Jordão | 3934,74 | 9855,58 | 12722,32 | 3953,47 | 3191,51 | 4321,96 |
| Francisco Alves | 318,53 | 2866,74 | 18505,75 | 37,47 | 24,98 | 0,00 |
| Francisco Beltrão | 137,40 | 599,58 | 2367,09 | 56,21 | 74,95 | 0,00 |
| General Carneiro | 8200,49 | 20479,37 | 13577,96 | 15626,53 | 5808,42 | 11598,10 |
| Godoy Moreira | 1948,63 | 12453,75 | 27736,77 | 3859,79 | 1448,98 | 1686,32 |
| Goioerê | 318,53 | 1792,49 | 5183,86 | 574,60 | 268,56 | 0,00 |
| Goioxim | 18274,67 | 29479,30 | 4122,11 | 29616,70 | 18068,56 | 15807,65 |
| Grandes Rios | 49,96 | 924,35 | 1686,32 | 18,74 | 24,98 | 0,00 |
| Guaira | 268,56 | 3622,46 | 6126,95 | 224,84 | 224,84 | 0,00 |
| Guairaçá | 206,11 | 1892,42 | 1711,30 | 199,86 | 118,67 | 0,00 |
| Guamiranga | 49,96 | 443,44 | 0,00 | 18,74 | 31,23 | 6,25 |
| Guapirama | 911,86 | 1661,33 | 2666,88 | 1111,72 | 911,86 | 418,46 |
| Guaporema | 87,44 | 5877,12 | 23552,21 | 193,61 | 68,70 | 0,00 |
| Guaraci | 54049,54 | 130333,47 | 232368,06 | 86176,98 | 51513,82 | 64891,93 |
| Guaraniaçu | 6183,16 | 12428,77 | 5827,16 | 455,93 | 43,72 | 1448,98 |
| Guarapuava | 537,12 | 13640,42 | 5683,51 | 31,23 | 6,25 | 0,00 |
| Guaraqueçaba | 3135,30 | 13546,74 | 27287,09 | 2716,84 | 1886,18 | 3841,05 |
| Guaratuba | 1174,18 | 11292,07 | 9462,11 | 2442,04 | 986,81 | 1130,46 |
| Honório Serpa | 187,37 | 3060,35 | 5664,77 | 174,88 | 68,70 | 24,98 |

| | | | | | | |
|-------------------|---------|----------|----------|---------|---------|---------|
| Ibaiti | 4877,82 | 14121,33 | 22253,12 | 8063,09 | 4022,18 | 8668,91 |
| Ibema | 593,33 | 4759,16 | 6607,86 | 674,53 | 530,88 | 0,00 |
| Ibiporã | 3091,58 | 6945,12 | 10605,05 | 3728,63 | 2541,96 | 4184,56 |
| Icaraíma | 312,28 | 1561,40 | 324,77 | 868,14 | 218,60 | 224,84 |
| Iguaraçu | 443,44 | 2947,93 | 3909,75 | 343,51 | 293,54 | 0,00 |
| Iguatu | 4759,16 | 17081,75 | 27605,61 | 4959,02 | 3778,60 | 1124,21 |
| Imbaú | 668,28 | 7226,18 | 68964,07 | 218,60 | 124,91 | 0,00 |
| Imbituva | 31,23 | 399,72 | 755,72 | 0,00 | 12,49 | 0,00 |
| Inácio Martins | 12,49 | 343,51 | 0,00 | 37,47 | 12,49 | 0,00 |
| Inajá | 6676,56 | 29473,05 | 44724,84 | 9218,53 | 5290,03 | 3535,02 |
| Indianópolis | 1636,35 | 6876,42 | 2054,81 | 4765,40 | 1555,16 | 1174,18 |
| Ipiranga | 87,44 | 1186,67 | 362,25 | 549,61 | 62,46 | 0,00 |
| Iporã | 3903,51 | 41271,02 | 42145,40 | 5708,49 | 2841,75 | 2916,70 |
| Iracema do Oeste | 480,91 | 3591,23 | 11797,96 | 299,79 | 262,32 | 243,58 |
| Irati | 31,23 | 493,40 | 368,49 | 0,00 | 6,25 | 87,44 |
| Iretama | 2235,93 | 6882,67 | 349,75 | 2448,28 | 1342,81 | 2698,11 |
| Itaguajé | 3091,58 | 9830,60 | 14939,51 | 2679,37 | 1904,91 | 5802,18 |
| Itaipulândia | 4509,33 | 9711,93 | 11248,35 | 2498,25 | 2648,14 | 8275,44 |
| Itambaracá | 462,18 | 2629,40 | 6195,65 | 718,25 | 256,07 | 37,47 |
| Itambé | 449,68 | 3709,89 | 1030,53 | 0,00 | 6,25 | 3260,21 |
| Itapejara d'Oeste | 43,72 | 218,60 | 243,58 | 0,00 | 12,49 | 0,00 |

| | | | | | | |
|----------------|----------|----------|----------|----------|----------|----------|
| Itaperuçu | 1730,04 | 12522,46 | 12890,95 | 2048,56 | 1486,46 | 424,70 |
| Itaúna do Sul | 1180,42 | 9905,54 | 27480,70 | 4234,53 | 1024,28 | 1455,23 |
| Ivaí | 143,65 | 1217,89 | 1811,23 | 162,39 | 74,95 | 0,00 |
| Ivaiporã | 5483,65 | 7775,79 | 9137,33 | 5296,28 | 4396,91 | 7725,82 |
| Ivaté | 56,21 | 924,35 | 1186,67 | 37,47 | 31,23 | 6,25 |
| Ivatuba | 693,26 | 4403,16 | 2972,91 | 724,49 | 480,91 | 0,00 |
| Jaboti | 3528,77 | 9605,75 | 17768,77 | 4877,82 | 3104,07 | 2966,67 |
| Jacarezinho | 5190,11 | 20441,89 | 28511,23 | 7169,96 | 4340,70 | 1804,98 |
| Jaguapitã | 243,58 | 1580,14 | 5202,60 | 174,88 | 156,14 | 0,00 |
| Jaguariaíva | 3753,61 | 12728,56 | 18437,05 | 6439,23 | 3291,44 | 2148,49 |
| Jandaia do Sul | 262,32 | 1948,63 | 3110,32 | 387,23 | 168,63 | 49,96 |
| Janiópolis | 343,51 | 1711,30 | 2160,98 | 68,70 | 81,19 | 187,37 |
| Japira | 449,68 | 3972,21 | 15882,60 | 1292,84 | 374,74 | 0,00 |
| Japurá | 249,82 | 830,67 | 2042,32 | 249,82 | 187,37 | 262,32 |
| Jardim Alegre | 1224,14 | 4684,21 | 8181,75 | 2142,25 | 905,61 | 2254,67 |
| Jardim Olinda | 493,40 | 2604,42 | 1723,79 | 1486,46 | 306,04 | 0,00 |
| Jataizinho | 93,68 | 2548,21 | 874,39 | 112,42 | 74,95 | 0,00 |
| Jesuítas | 299,79 | 2941,68 | 4234,53 | 462,18 | 237,33 | 649,54 |
| Joaquim Távora | 15401,68 | 25994,24 | 17306,60 | 22496,70 | 12903,44 | 21997,05 |
| Jundiaí do Sul | 4578,03 | 9168,56 | 14333,68 | 4215,79 | 3316,42 | 5664,77 |
| Juranda | 181,12 | 1817,47 | 6408,00 | 31,23 | 31,23 | 81,19 |

| | | | | | | |
|--------------------|----------|----------|-----------|----------|----------|----------|
| Jussara | 15395,44 | 99024,21 | 77526,80 | 24314,17 | 10879,86 | 20841,61 |
| Kaloré | 49,96 | 2504,49 | 3054,11 | 18,74 | 24,98 | 0,00 |
| Lapa | 480,91 | 7713,33 | 19224,00 | 543,37 | 324,77 | 0,00 |
| Laranjal | 1311,58 | 6370,53 | 13790,32 | 1261,61 | 899,37 | 2185,96 |
| Laranjeiras do Sul | 662,04 | 2979,16 | 9949,26 | 1111,72 | 562,11 | 574,60 |
| Leópolis | 593,33 | 12997,12 | 25894,32 | 2579,44 | 474,67 | 306,04 |
| Lidianópolis | 855,65 | 3828,56 | 6614,11 | 799,44 | 599,58 | 874,39 |
| Lindoeste | 1380,28 | 3166,53 | 4984,00 | 1005,54 | 1124,21 | 936,84 |
| Loanda | 9437,12 | 45330,67 | 101772,28 | 17400,28 | 7613,40 | 10267,79 |
| Lobato | 9280,98 | 33351,58 | 68077,19 | 16607,09 | 7313,61 | 9974,25 |
| Londrina | 312,28 | 2242,18 | 10686,25 | 368,49 | 268,56 | 174,88 |
| Luiziana | 505,89 | 2629,40 | 5121,40 | 861,89 | 412,21 | 168,63 |
| Lunardelli | 1523,93 | 15264,28 | 32252,35 | 1755,02 | 880,63 | 0,00 |
| Lupionópolis | 10792,42 | 36949,05 | 63630,31 | 19461,33 | 8881,26 | 6707,79 |
| Mallet | 1486,46 | 4621,75 | 9187,30 | 868,14 | 761,96 | 1854,95 |
| Mamborê | 387,23 | 2891,72 | 5814,67 | 162,39 | 312,28 | 99,93 |
| Mandaguaçu | 530,88 | 10848,63 | 680,77 | 99,93 | 93,68 | 0,00 |
| Mandaguari | 0,00 | 593,33 | 1755,02 | 0,00 | 0,00 | 0,00 |
| Mandirituba | 11079,72 | 37860,91 | 60345,12 | 15507,86 | 8556,49 | 14289,96 |
| Manfrinópolis | 1730,04 | 9786,88 | 33026,81 | 3834,81 | 1555,16 | 1217,89 |
| Mangueirinha | 6576,63 | 17656,35 | 549,61 | 15357,96 | 5902,11 | 8675,16 |

| | | | | | | |
|-------------------------|---------|----------|----------|----------|---------|----------|
| Manoel Ribas | 424,70 | 2591,93 | 2335,86 | 487,16 | 312,28 | 0,00 |
| Marechal Cândido Rondon | 5202,60 | 15101,89 | 27018,53 | 5402,46 | 3822,32 | 9380,91 |
| Maria Helena | 2292,14 | 13128,28 | 29516,77 | 5827,16 | 1811,23 | 3122,81 |
| Marialva | 12,49 | 262,32 | 0,00 | 0,00 | 6,25 | 0,00 |
| Marilândia do Sul | 3791,09 | 10167,86 | 7444,77 | 6245,61 | 2816,77 | 2985,40 |
| Marilena | 5302,53 | 12441,26 | 19367,65 | 3853,54 | 3428,84 | 11379,51 |
| Mariluz | 1080,49 | 4053,40 | 4453,12 | 1330,32 | 855,65 | 405,96 |
| Maringá | 9062,39 | 15126,88 | 0,00 | 21584,84 | 9786,88 | 15945,05 |
| Mariópolis | 81,19 | 886,88 | 9868,07 | 62,46 | 31,23 | 0,00 |
| Maripá | 12,49 | 8225,47 | 20972,77 | 836,91 | 0,00 | 0,00 |
| Marmeleiro | 187,37 | 2342,11 | 6801,47 | 106,18 | 106,18 | 0,00 |
| Marquinho | 1292,84 | 8312,91 | 24682,67 | 2460,77 | 1311,58 | 2029,82 |
| Marumbi | 68,70 | 149,89 | 0,00 | 37,47 | 56,21 | 0,00 |
| Matelândia | 462,18 | 7276,14 | 13534,25 | 949,33 | 331,02 | 0,00 |
| Matinhos | 349,75 | 1761,26 | 4471,86 | 943,09 | 243,58 | 562,11 |
| Mato Rico | 1286,60 | 5870,88 | 2129,75 | 1748,77 | 1011,79 | 412,21 |
| Mauá da Serra | 2329,61 | 5471,16 | 0,00 | 5052,70 | 2273,40 | 786,95 |
| Medianeira | 331,02 | 1317,82 | 999,30 | 274,81 | 206,11 | 0,00 |
| Mercedes | 49,96 | 337,26 | 1136,70 | 24,98 | 31,23 | 0,00 |
| Mirador | 1623,86 | 4609,26 | 0,00 | 3047,86 | 999,30 | 549,61 |
| Miraselva | 1080,49 | 4346,95 | 8094,32 | 1555,16 | 730,74 | 649,54 |

| | | | | | | |
|----------------------------|---------|----------|----------|----------|---------|----------|
| Missal | 399,72 | 5720,98 | 7095,02 | 112,42 | 12,49 | 0,00 |
| Moreira Sales | 2679,37 | 4721,68 | 6664,07 | 3147,79 | 2504,49 | 1311,58 |
| Morretes | 736,98 | 1673,82 | 1680,07 | 980,56 | 743,23 | 587,09 |
| Munhoz de Melo | 74,95 | 543,37 | 512,14 | 31,23 | 37,47 | 0,00 |
| Nossa Senhora das Graças | 199,86 | 1661,33 | 4396,91 | 349,75 | 143,65 | 0,00 |
| Nova Aliança do Ivaí | 4109,61 | 11610,60 | 8618,95 | 6963,86 | 2435,79 | 3691,16 |
| Nova América da Colina | 2560,70 | 12603,65 | 27268,35 | 5058,95 | 1948,63 | 886,88 |
| Nova Aurora | 662,04 | 2554,46 | 4403,16 | 224,84 | 287,30 | 31,23 |
| Nova Cantu | 0,00 | 168,63 | 1324,07 | 0,00 | 0,00 | 0,00 |
| Nova Esperança | 462,18 | 3784,84 | 15920,07 | 468,42 | 256,07 | 0,00 |
| Nova Esperança do Sudoeste | 187,37 | 4690,46 | 17793,75 | 74,95 | 99,93 | 0,00 |
| Nova Fátima | 74,95 | 543,37 | 549,61 | 68,70 | 31,23 | 0,00 |
| Nova Laranjeiras | 99,93 | 356,00 | 193,61 | 131,16 | 81,19 | 0,00 |
| Nova Londrina | 574,60 | 3622,46 | 6470,46 | 1886,18 | 462,18 | 955,58 |
| Nova Olímpia | 7088,77 | 11548,14 | 0,00 | 14608,49 | 7938,18 | 10598,81 |
| Nova Prata do Iguaçu | 43,72 | 568,35 | 2260,91 | 31,23 | 18,74 | 0,00 |
| Nova Santa Bárbara | 231,09 | 3310,18 | 13296,91 | 218,60 | 174,88 | 249,82 |
| Nova Santa Rosa | 24,98 | 849,40 | 4222,03 | 0,00 | 18,74 | 0,00 |
| Nova Tebas | 3853,54 | 28992,14 | 48634,60 | 5708,49 | 2860,49 | 2591,93 |
| Novo Itacolomi | 6863,93 | 11779,23 | 14920,77 | 8294,18 | 5596,07 | 11610,60 |
| Ortigueira | 1898,67 | 4702,95 | 1092,98 | 3597,47 | 1536,42 | 1755,02 |

| | | | | | | |
|---------------------|----------|----------|----------|----------|----------|----------|
| Ourizona | 3060,35 | 6795,23 | 10617,54 | 2498,25 | 2154,74 | 6145,68 |
| Ouro Verde do Oeste | 6401,75 | 37767,23 | 68720,49 | 16569,61 | 5633,54 | 10236,56 |
| Paçandu | 16482,17 | 66134,81 | 87319,93 | 25132,35 | 14177,54 | 18930,46 |
| Palmas | 131,16 | 2492,00 | 4740,42 | 31,23 | 12,49 | 0,00 |
| Palmeira | 25600,77 | 40021,89 | 249,82 | 50027,37 | 27405,75 | 39322,38 |
| Palmital | 930,60 | 2972,91 | 1686,32 | 1161,68 | 811,93 | 612,07 |
| Palotina | 343,51 | 1561,40 | 1467,72 | 237,33 | 237,33 | 0,00 |
| Paraíso do Norte | 3909,75 | 4434,39 | 187,37 | 443,44 | 149,89 | 199,86 |
| Paranacity | 337,26 | 1130,46 | 2779,30 | 299,79 | 256,07 | 0,00 |
| Paranaguá | 1361,54 | 5046,46 | 8150,53 | 1205,40 | 999,30 | 393,47 |
| Paranapoema | 1261,61 | 3503,79 | 143,65 | 2442,04 | 1155,44 | 1424,00 |
| Paranavaí | 2017,33 | 13265,68 | 27792,98 | 2541,96 | 1486,46 | 1161,68 |
| Pato Bragado | 3878,53 | 16663,30 | 25669,47 | 4421,89 | 3091,58 | 2235,93 |
| Pato Branco | 2448,28 | 16488,42 | 24276,70 | 3022,88 | 1829,96 | 1199,16 |
| Paula Freitas | 4759,16 | 13034,60 | 28823,51 | 4528,07 | 3584,98 | 5233,82 |
| Paulo Frontin | 693,26 | 3872,28 | 1655,09 | 1580,14 | 343,51 | 387,23 |
| Peabiru | 49,96 | 331,02 | 193,61 | 93,68 | 24,98 | 0,00 |
| Perobal | 49,96 | 168,63 | 555,86 | 12,49 | 56,21 | 0,00 |
| Pérola | 662,04 | 11267,09 | 2729,33 | 630,81 | 243,58 | 518,39 |
| Pérola d'Oeste | 31,23 | 149,89 | 0,00 | 0,00 | 6,25 | 0,00 |
| Piên | 855,65 | 2941,68 | 2879,23 | 1486,46 | 886,88 | 480,91 |

| | | | | | | |
|---------------------------|----------|----------|-----------|----------|----------|----------|
| Pinhais | 31,23 | 143,65 | 181,12 | 6,25 | 31,23 | 0,00 |
| Pinhal de São Bento | 26368,98 | 92154,03 | 155621,96 | 44506,24 | 24882,53 | 30703,44 |
| Pinhalão | 13671,65 | 47210,60 | 57709,47 | 22921,40 | 11922,88 | 14708,42 |
| Pinhão | 143,65 | 1074,25 | 2629,40 | 18,74 | 37,47 | 0,00 |
| Piraí do Sul | 5246,32 | 33501,47 | 96288,63 | 14802,10 | 4346,95 | 4603,02 |
| Piraquara | 3747,37 | 7413,54 | 10742,46 | 5508,63 | 3478,81 | 4840,35 |
| Pitanga | 349,75 | 1842,46 | 1280,35 | 524,63 | 237,33 | 343,51 |
| Pitangueiras | 0,00 | 43,72 | 68,70 | 0,00 | 0,00 | 0,00 |
| Planaltina do Paraná | 25731,93 | 82879,30 | 110878,38 | 39578,46 | 21909,61 | 27143,44 |
| Planalto | 287,30 | 174,88 | 0,00 | 68,70 | 24,98 | 0,00 |
| Ponta Grossa | 306,04 | 1798,74 | 4453,12 | 512,14 | 231,09 | 224,84 |
| Pontal do Paraná | 1567,65 | 8206,74 | 8138,03 | 2654,39 | 1230,39 | 1374,04 |
| Porecatu | 356,00 | 4746,67 | 12791,02 | 543,37 | 287,30 | 380,98 |
| Porto Amazonas | 181,12 | 687,02 | 599,58 | 106,18 | 124,91 | 0,00 |
| Porto Barreiro | 62,46 | 549,61 | 0,00 | 18,74 | 31,23 | 0,00 |
| Porto Rico | 3497,54 | 6813,96 | 10423,93 | 4390,67 | 3004,14 | 3609,96 |
| Porto Vitória | 612,07 | 2073,54 | 12191,44 | 212,35 | 293,54 | 0,00 |
| Prado Ferreira | 106,18 | 693,26 | 1561,40 | 31,23 | 49,96 | 0,00 |
| Pranchita | 5689,75 | 14227,51 | 25563,30 | 6189,40 | 4159,58 | 10661,26 |
| Presidente Castelo Branco | 4184,56 | 36030,95 | 50764,35 | 4915,30 | 3179,02 | 2954,18 |
| Primeiro de Maio | 11404,49 | 19017,89 | 3360,14 | 18874,25 | 10111,65 | 13428,07 |

| | | | | | | |
|-----------------------|----------|----------|----------|----------|----------|----------|
| Prudentópolis | 0,00 | 468,42 | 31,23 | 0,00 | 0,00 | 0,00 |
| Quarto Centenário | 37,47 | 224,84 | 5458,67 | 0,00 | 0,00 | 0,00 |
| Quatiguá | 1923,65 | 4147,09 | 0,00 | 5427,44 | 1923,65 | 3597,47 |
| Quatro Barras | 618,32 | 3403,86 | 12353,82 | 730,74 | 224,84 | 318,53 |
| Quatro Pontes | 2079,79 | 8456,56 | 6782,74 | 2773,05 | 1648,84 | 549,61 |
| Quedas do Iguaçu | 4296,98 | 10623,79 | 9106,11 | 4215,79 | 2529,47 | 4109,61 |
| Querência do Norte | 1386,53 | 26056,70 | 2585,68 | 1730,04 | 224,84 | 1192,91 |
| Quinta do Sol | 106,18 | 580,84 | 424,70 | 112,42 | 49,96 | 0,00 |
| Quitandinha | 4877,82 | 10398,95 | 14371,16 | 6158,18 | 3716,14 | 8406,60 |
| Ramilândia | 5995,79 | 12260,14 | 5596,07 | 10136,63 | 4578,03 | 8450,32 |
| Rancho Alegre | 262,32 | 1742,53 | 11004,77 | 162,39 | 137,40 | 0,00 |
| Rancho Alegre d'Oeste | 4503,09 | 23252,42 | 28648,63 | 5833,40 | 3522,53 | 6526,67 |
| Realeza | 1386,53 | 5696,00 | 19811,09 | 1736,28 | 943,09 | 555,86 |
| Rebouças | 1386,53 | 18543,23 | 24120,56 | 1780,00 | 1030,53 | 499,65 |
| Renascença | 11342,03 | 34407,09 | 65553,96 | 17843,72 | 10817,40 | 11897,89 |
| Reserva | 49,96 | 2641,89 | 905,61 | 37,47 | 31,23 | 0,00 |
| Reserva do Iguaçu | 699,51 | 5552,35 | 11685,54 | 1392,77 | 605,82 | 687,02 |
| Ribeirão Claro | 1711,30 | 21934,60 | 24738,88 | 2192,21 | 961,82 | 2204,70 |
| Ribeirão do Pinhal | 18,74 | 799,44 | 5065,19 | 149,89 | 24,98 | 0,00 |
| Rio Azul | 368,49 | 3816,07 | 14939,51 | 212,35 | 224,84 | 0,00 |
| Rio Bom | 680,77 | 7038,81 | 15926,32 | 1748,77 | 549,61 | 374,74 |

| | | | | | | |
|-----------------------------|----------|----------|----------|----------|---------|----------|
| Rio Bonito do Iguaçu | 12,49 | 5252,56 | 3172,77 | 24,98 | 0,00 | 0,00 |
| Rio Branco do Ivaí | 1767,51 | 15045,68 | 4247,02 | 755,72 | 405,96 | 405,96 |
| Rio Branco do Sul | 10055,44 | 24470,32 | 41533,33 | 16251,09 | 8462,81 | 14021,40 |
| Rio Negro | 4665,47 | 14277,47 | 40509,05 | 5627,30 | 3147,79 | 3672,42 |
| Rolândia | 81,19 | 1061,75 | 162,39 | 81,19 | 49,96 | 0,00 |
| Roncador | 62,46 | 1236,63 | 3516,28 | 74,95 | 37,47 | 0,00 |
| Rondon | 2810,53 | 7226,18 | 13122,03 | 3959,72 | 2254,67 | 5789,68 |
| Rosário do Ivaí | 0,00 | 212,35 | 1111,72 | 0,00 | 0,00 | 0,00 |
| Sabáudia | 131,16 | 999,30 | 961,82 | 143,65 | 93,68 | 0,00 |
| Salgado Filho | 131,16 | 843,16 | 3747,37 | 106,18 | 87,44 | 0,00 |
| Salto do Itararé | 187,37 | 1617,61 | 4409,40 | 137,40 | 118,67 | 0,00 |
| Salto do Lontra | 256,07 | 4128,35 | 9243,51 | 1267,86 | 156,14 | 0,00 |
| Santa Amélia | 1686,32 | 5240,07 | 4015,93 | 1786,25 | 1336,56 | 380,98 |
| Santa Cecília do Pavão | 3047,86 | 6258,11 | 10498,88 | 3934,74 | 2910,46 | 2579,44 |
| Santa Cruz de Monte Castelo | 7856,98 | 19273,96 | 2398,32 | 13015,86 | 5483,65 | 7625,89 |
| Santa Fé | 131,16 | 530,88 | 936,84 | 93,68 | 99,93 | 0,00 |
| Santa Helena | 1511,44 | 3191,51 | 1904,91 | 1823,72 | 1274,11 | 1536,42 |
| Santa Inês | 62,46 | 999,30 | 10142,88 | 56,21 | 37,47 | 0,00 |
| Santa Isabel do Ivaí | 805,68 | 3204,00 | 0,00 | 2223,44 | 568,35 | 299,79 |
| Santa Izabel do Oeste | 749,47 | 5502,39 | 16413,47 | 580,84 | 568,35 | 187,37 |
| Santa Lúcia | 7950,67 | 20042,17 | 30647,23 | 9755,65 | 6264,35 | 12035,30 |

| | | | | | | |
|---------------------------|----------|----------|----------|----------|---------|----------|
| Santa Maria do Oeste | 1424,00 | 4528,07 | 4571,79 | 1942,39 | 1261,61 | 843,16 |
| Santa Mariana | 1436,49 | 5327,51 | 10042,95 | 1923,65 | 1155,44 | 0,00 |
| Santa Mônica | 3378,88 | 10111,65 | 12097,75 | 5277,54 | 2798,04 | 1692,56 |
| Santa Tereza do Oeste | 2985,40 | 7020,07 | 1848,70 | 2748,07 | 1361,54 | 3035,37 |
| Santa Terezinha de Itaipu | 549,61 | 5883,37 | 10729,96 | 437,19 | 306,04 | 74,95 |
| Santana do Itararé | 824,42 | 2273,40 | 3853,54 | 493,40 | 505,89 | 0,00 |
| Santo Antônio da Platina | 312,28 | 4290,74 | 11379,51 | 1086,74 | 212,35 | 399,72 |
| Santo Antônio do Caiuá | 24,98 | 493,40 | 5333,75 | 62,46 | 12,49 | 0,00 |
| Santo Antônio do Paraíso | 187,37 | 1130,46 | 1548,91 | 149,89 | 149,89 | 0,00 |
| Santo Antônio do Sudoeste | 624,56 | 2604,42 | 1929,89 | 424,70 | 387,23 | 56,21 |
| Santo Inácio | 2167,23 | 12410,03 | 21328,77 | 3247,72 | 1511,44 | 1523,93 |
| São Carlos do Ivaí | 131,16 | 1030,53 | 12247,65 | 118,67 | 56,21 | 0,00 |
| São Jerônimo da Serra | 206,11 | 993,05 | 1124,21 | 118,67 | 156,14 | 0,00 |
| São João | 1155,44 | 6670,32 | 15332,98 | 1111,72 | 755,72 | 724,49 |
| São João do Caiuá | 3478,81 | 30497,33 | 37948,35 | 3572,49 | 1630,11 | 2460,77 |
| São João do Ivaí | 62,46 | 1111,72 | 6682,81 | 0,00 | 12,49 | 0,00 |
| São João do Triunfo | 10636,28 | 21516,14 | 27530,67 | 13921,47 | 8138,03 | 21341,26 |
| São Jorge d'Oeste | 68,70 | 468,42 | 1592,63 | 31,23 | 43,72 | 0,00 |
| São Jorge do Ivaí | 2379,58 | 10904,84 | 22940,14 | 4809,12 | 2260,91 | 943,09 |
| São Jorge do Patrocínio | 156,14 | 774,46 | 505,89 | 262,32 | 87,44 | 0,00 |
| São José da Boa Vista | 1061,75 | 16063,72 | 2729,33 | 443,44 | 399,72 | 493,40 |

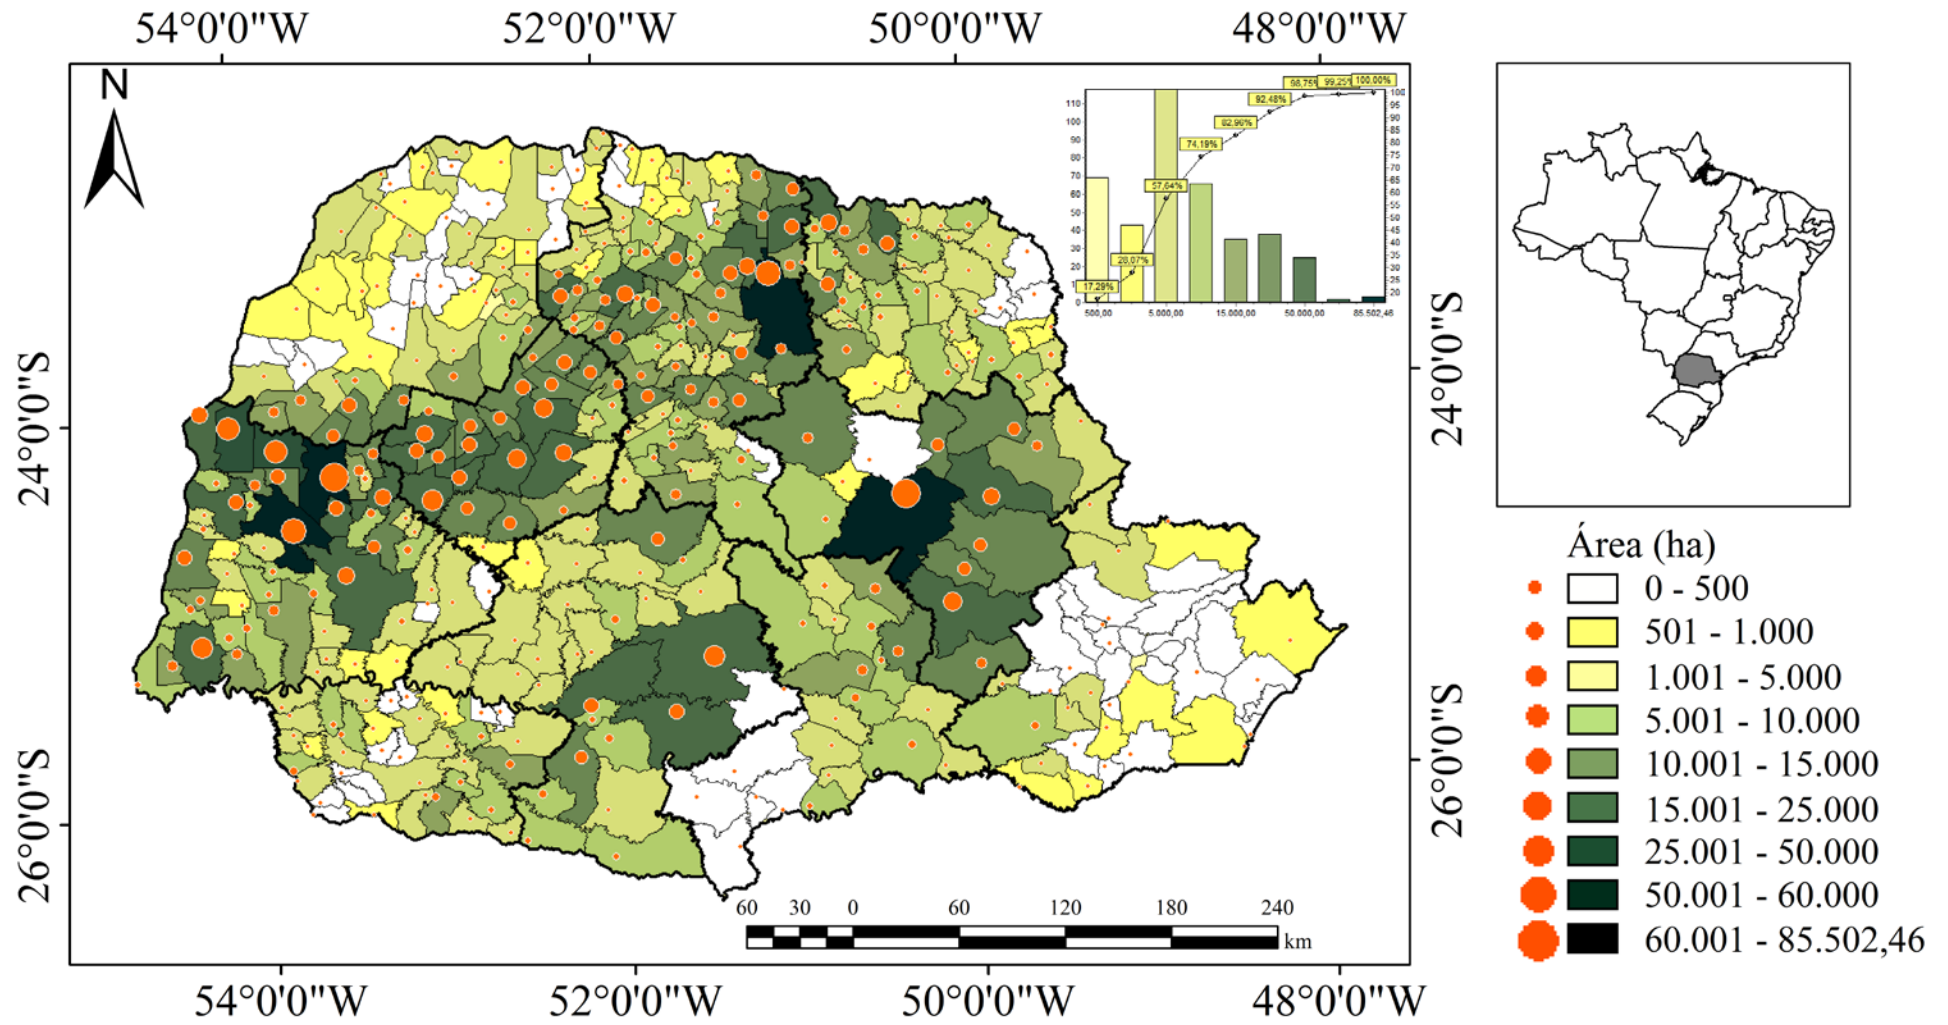
| | | | | | | |
|---------------------------|----------|----------|----------|----------|----------|----------|
| São José das Palmeiras | 93,68 | 405,96 | 518,39 | 6,25 | 62,46 | 0,00 |
| São José dos Pinhais | 14015,16 | 53843,44 | 44381,33 | 10948,56 | 9630,74 | 13415,58 |
| São Manoel do Paraná | 11523,16 | 26731,23 | 10792,42 | 17962,39 | 8031,86 | 23595,93 |
| São Mateus do Sul | 1117,96 | 3803,58 | 5614,81 | 2054,81 | 768,21 | 18,74 |
| São Miguel do Iguaçu | 293,54 | 1305,33 | 1442,74 | 81,19 | 149,89 | 199,86 |
| São Pedro do Iguaçu | 162,39 | 724,49 | 993,05 | 112,42 | 124,91 | 0,00 |
| São Pedro do Ivaí | 1305,33 | 7838,25 | 17063,02 | 3172,77 | 1024,28 | 1611,37 |
| São Pedro do Paraná | 518,39 | 2335,86 | 3135,30 | 199,86 | 268,56 | 774,46 |
| São Sebastião da Amoreira | 249,82 | 10761,19 | 8462,81 | 449,68 | 62,46 | 0,00 |
| São Tomé | 655,79 | 2560,70 | 4284,49 | 755,72 | 505,89 | 1511,44 |
| Sapopema | 12,49 | 1030,53 | 4977,75 | 37,47 | 6,25 | 0,00 |
| Sarandi | 1130,46 | 7101,26 | 17200,42 | 2404,56 | 899,37 | 0,00 |
| Saudade do Iguaçu | 3485,05 | 9187,30 | 17094,25 | 5383,72 | 2916,70 | 4977,75 |
| Sengés | 8387,86 | 20341,96 | 31046,95 | 10948,56 | 6339,30 | 16182,39 |
| Serranópolis do Iguaçu | 13409,33 | 27599,37 | 43307,09 | 19305,19 | 11804,21 | 16232,35 |
| Sertaneja | 168,63 | 980,56 | 1555,16 | 124,91 | 124,91 | 0,00 |
| Sertanópolis | 18,74 | 231,09 | 3672,42 | 0,00 | 0,00 | 0,00 |
| Siqueira Campos | 1261,61 | 11017,26 | 23870,74 | 4209,54 | 861,89 | 630,81 |
| Sulina | 62,46 | 830,67 | 574,60 | 0,00 | 18,74 | 0,00 |
| Tamarana | 87,44 | 1149,19 | 943,09 | 12,49 | 43,72 | 0,00 |
| Tamboara | 224,84 | 1473,96 | 537,12 | 249,82 | 137,40 | 143,65 |

| | | | | | | |
|-----------------------|----------|-----------|-----------|----------|----------|----------|
| Tapejara | 12285,12 | 42351,51 | 44225,19 | 16544,63 | 9893,05 | 13940,21 |
| Tapira | 181,12 | 5096,42 | 4215,79 | 56,21 | 6,25 | 124,91 |
| Teixeira Soares | 3916,00 | 8775,09 | 15301,75 | 3035,37 | 2598,18 | 6426,74 |
| Telêmaco Borba | 206,11 | 1542,67 | 1161,68 | 131,16 | 93,68 | 0,00 |
| Terra Boa | 27861,68 | 42976,07 | 1661,33 | 46448,63 | 29073,33 | 31627,79 |
| Terra Rica | 27468,21 | 103240,00 | 152024,49 | 48384,77 | 23908,21 | 21809,68 |
| Terra Roxa | 1142,95 | 11922,88 | 8581,47 | 680,77 | 493,40 | 0,00 |
| Tibagi | 16669,54 | 39141,26 | 15183,09 | 34863,02 | 13490,53 | 28186,46 |
| Tijucas do Sul | 930,60 | 7438,53 | 7975,65 | 1792,49 | 668,28 | 1311,58 |
| Toledo | 387,23 | 3684,91 | 1111,72 | 886,88 | 256,07 | 0,00 |
| Tomazina | 18,74 | 3447,58 | 2748,07 | 0,00 | 0,00 | 0,00 |
| Três Barras do Paraná | 2292,14 | 11192,14 | 12990,88 | 4640,49 | 1892,42 | 2092,28 |
| Tunas do Paraná | 14695,93 | 22896,42 | 8337,89 | 22221,89 | 12410,03 | 14564,77 |
| Tuneiras do Oeste | 1167,93 | 9087,37 | 28317,61 | 1205,40 | 774,46 | 206,11 |
| Tupãssi | 21459,93 | 37479,93 | 4047,16 | 35749,89 | 15745,19 | 37030,24 |
| Turvo | 206,11 | 2160,98 | 2866,74 | 62,46 | 62,46 | 0,00 |
| Ubiratã | 911,86 | 9505,82 | 15320,49 | 505,89 | 318,53 | 761,96 |
| Umuarama | 574,60 | 1180,42 | 1555,16 | 580,84 | 437,19 | 99,93 |
| União da Vitória | 855,65 | 4971,51 | 12341,33 | 668,28 | 455,93 | 936,84 |
| Uniflor | 1811,23 | 10848,63 | 18168,49 | 4197,05 | 1673,82 | 768,21 |
| Uraí | 5146,39 | 20379,44 | 22771,51 | 8106,81 | 4440,63 | 5146,39 |

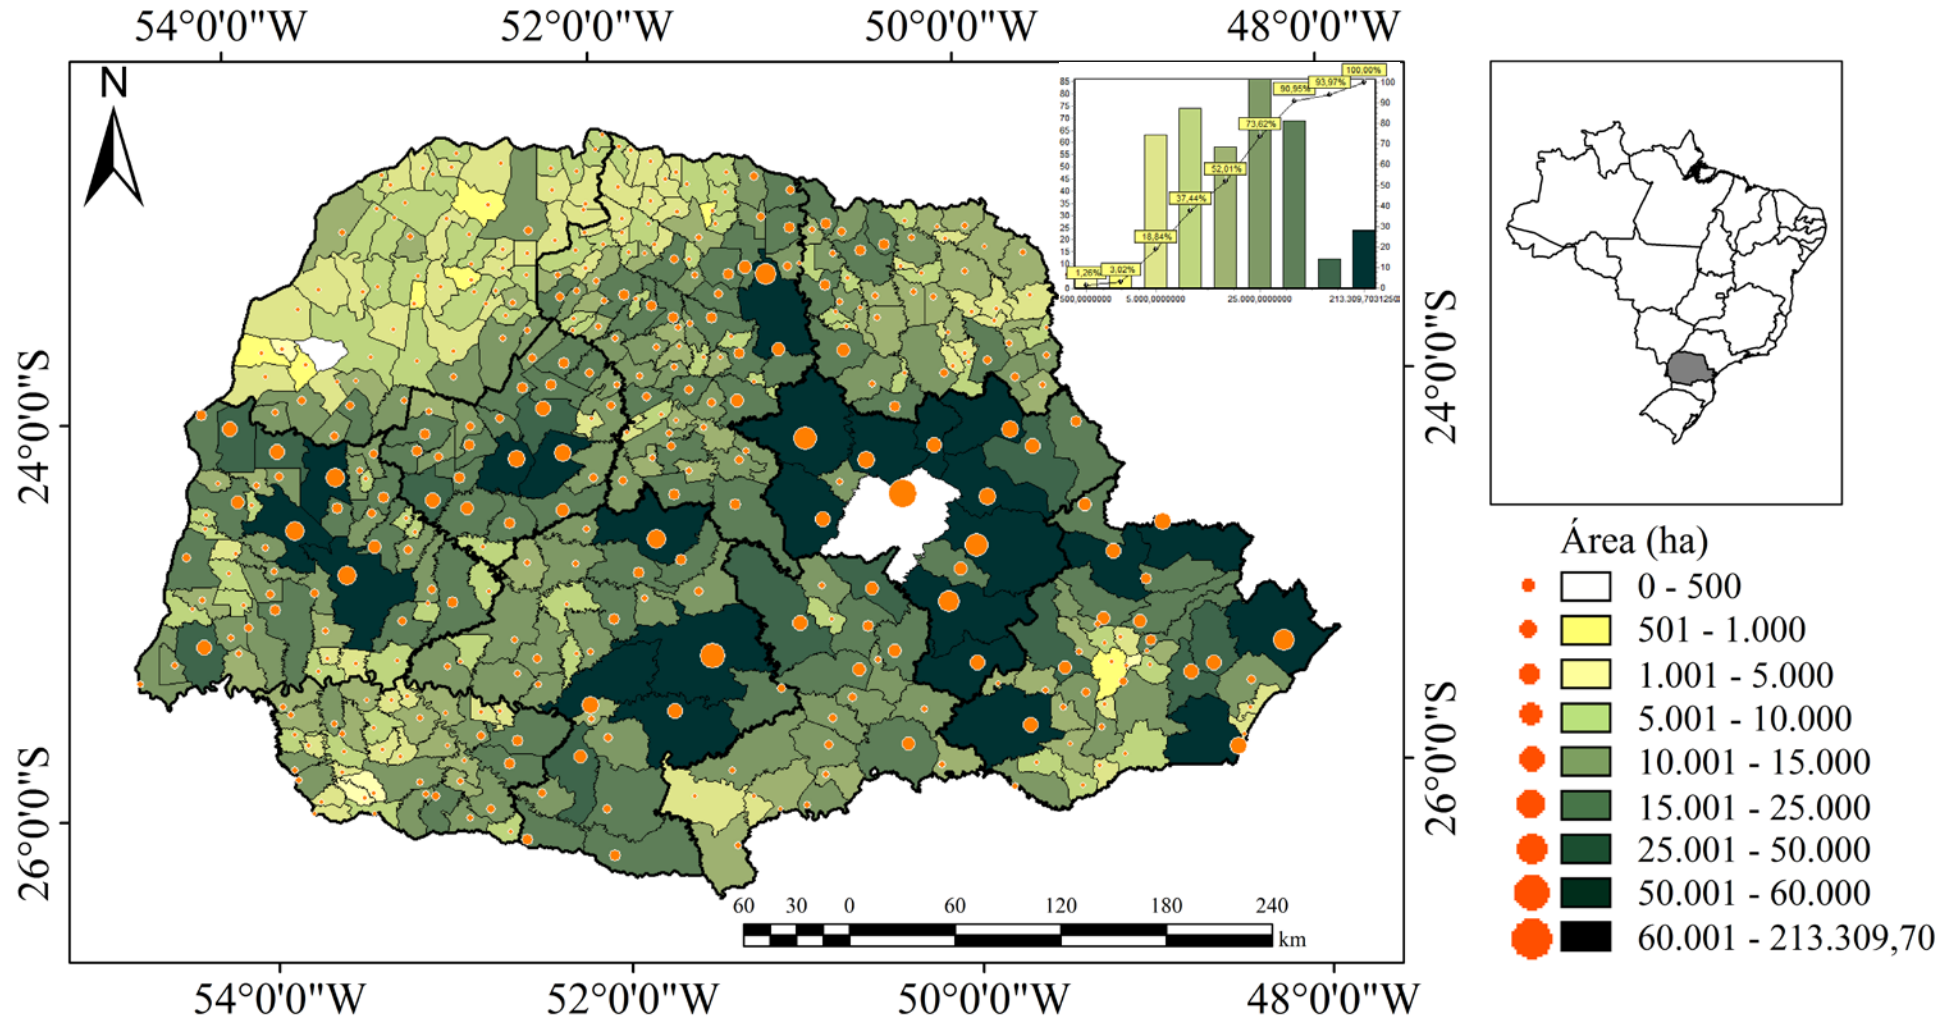
| | | | | | | |
|--------------------|--------|---------|----------|--------|--------|--------|
| Ventania | 418,46 | 2691,86 | 9487,09 | 443,44 | 274,81 | 0,00 |
| Vera Cruz do Oeste | 455,93 | 2242,18 | 6682,81 | 318,53 | 318,53 | 0,00 |
| Verê | 387,23 | 1854,95 | 5908,35 | 343,51 | 299,79 | 0,00 |
| Virmond | 99,93 | 4415,65 | 1349,05 | 187,37 | 31,23 | 312,28 |
| Vitorino | 124,91 | 3335,16 | 10680,00 | 112,42 | 43,72 | 0,00 |
| Wenceslau Braz | 911,86 | 3247,72 | 8337,89 | 861,89 | 693,26 | 249,82 |
| Xambê | 62,46 | 549,61 | 156,14 | 18,74 | 49,96 | 0,00 |

APÊNDICE E

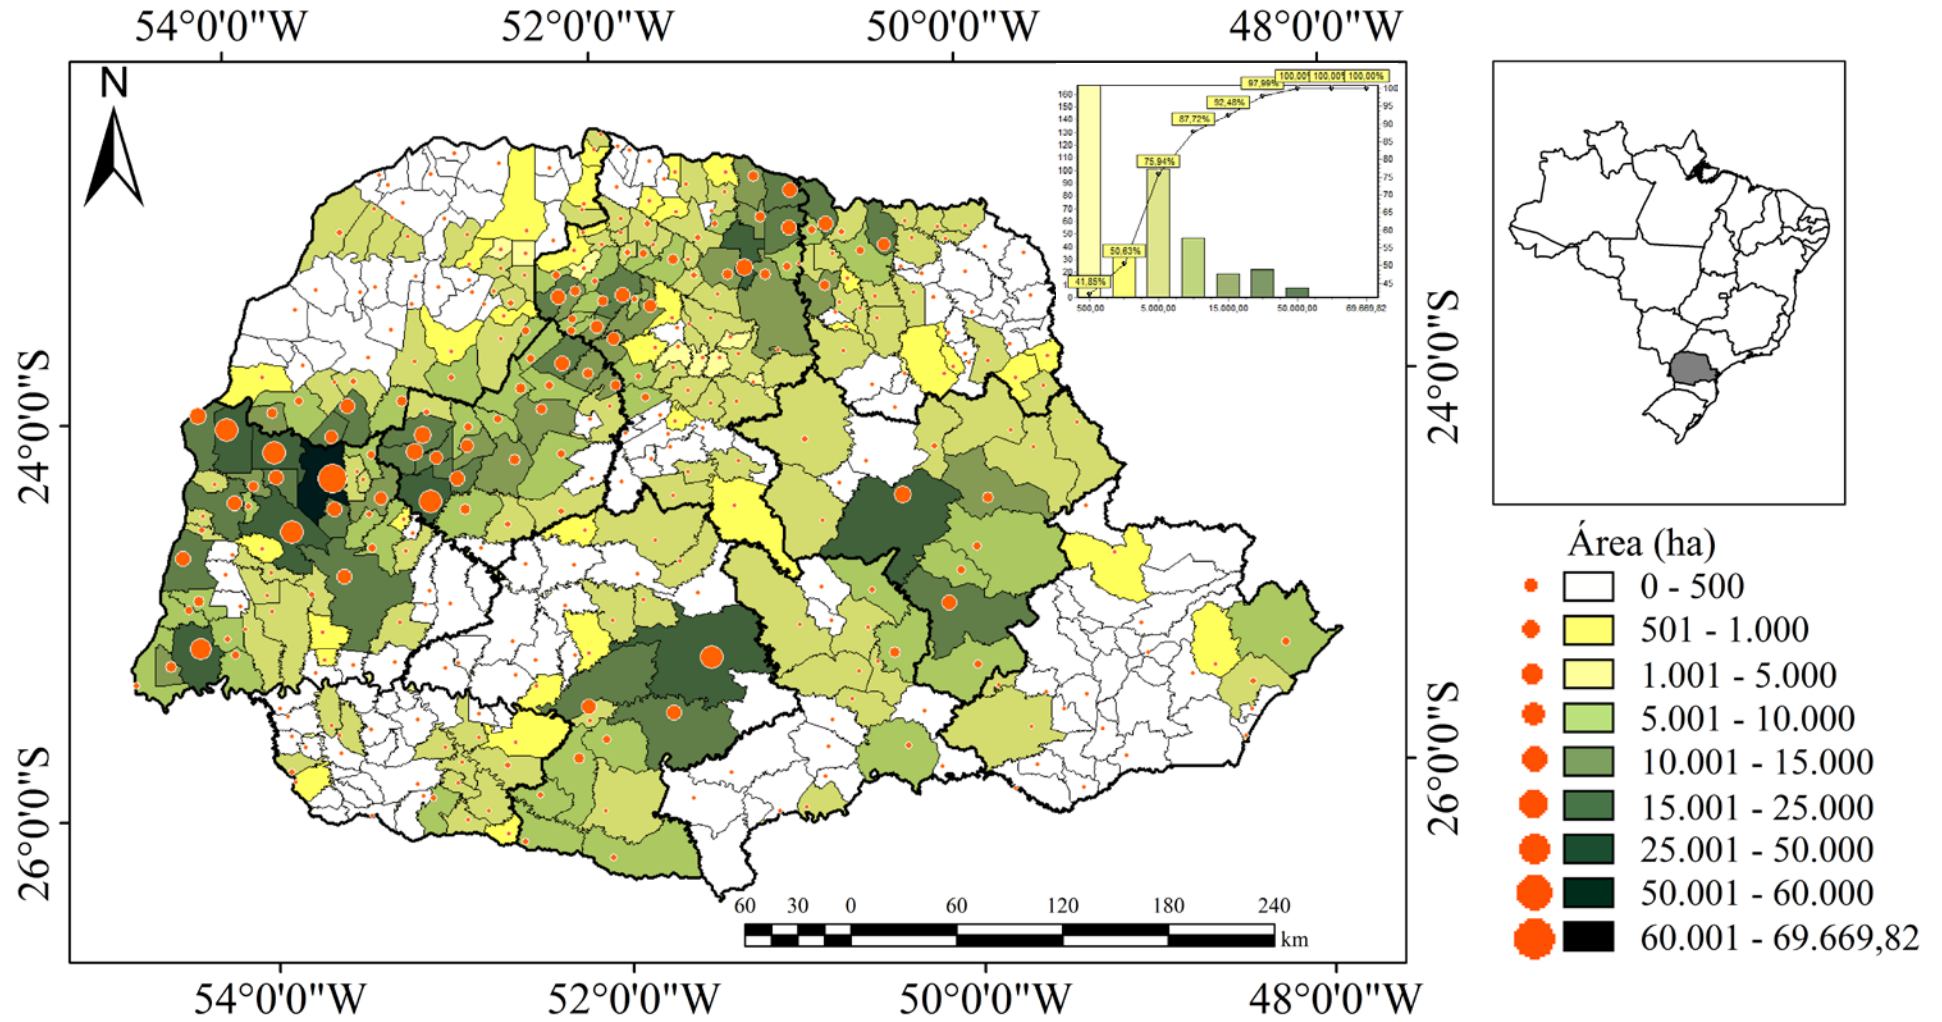
COMPONENTES PRINCIPAIS – 2010/2011



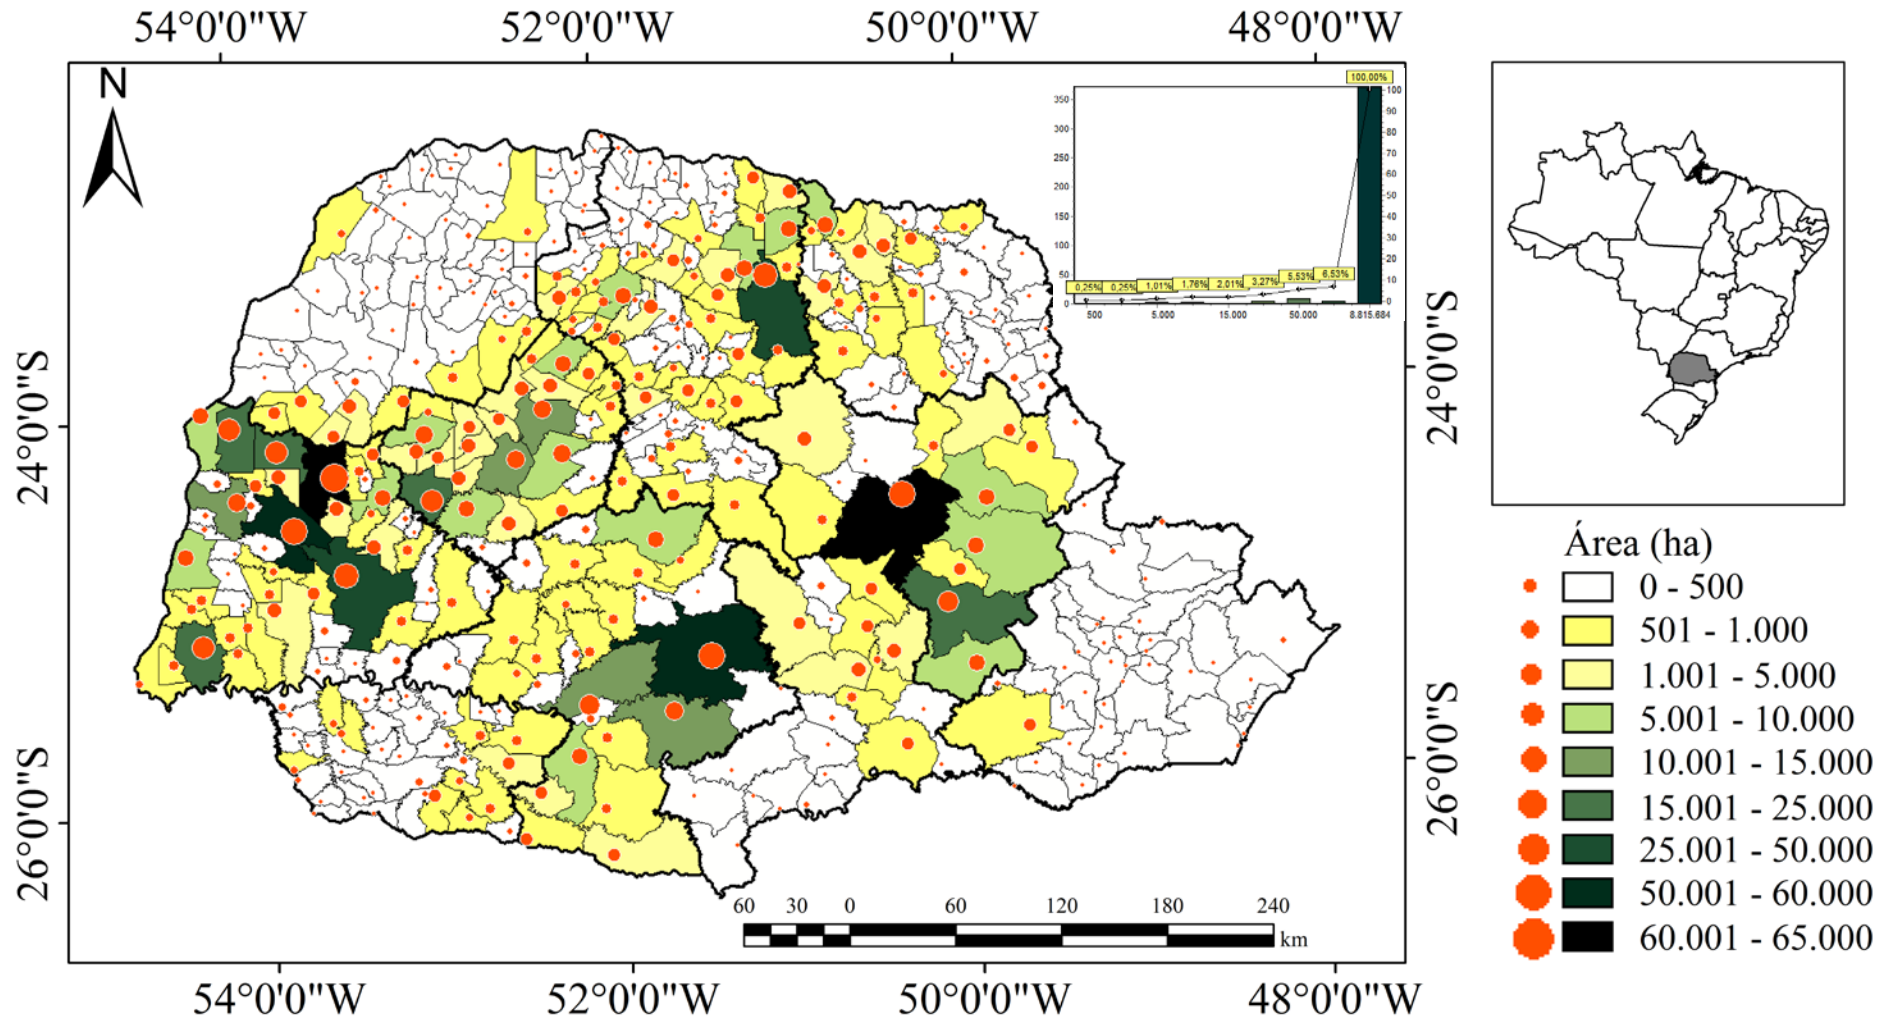
K-MÉDIA – 2010/2011



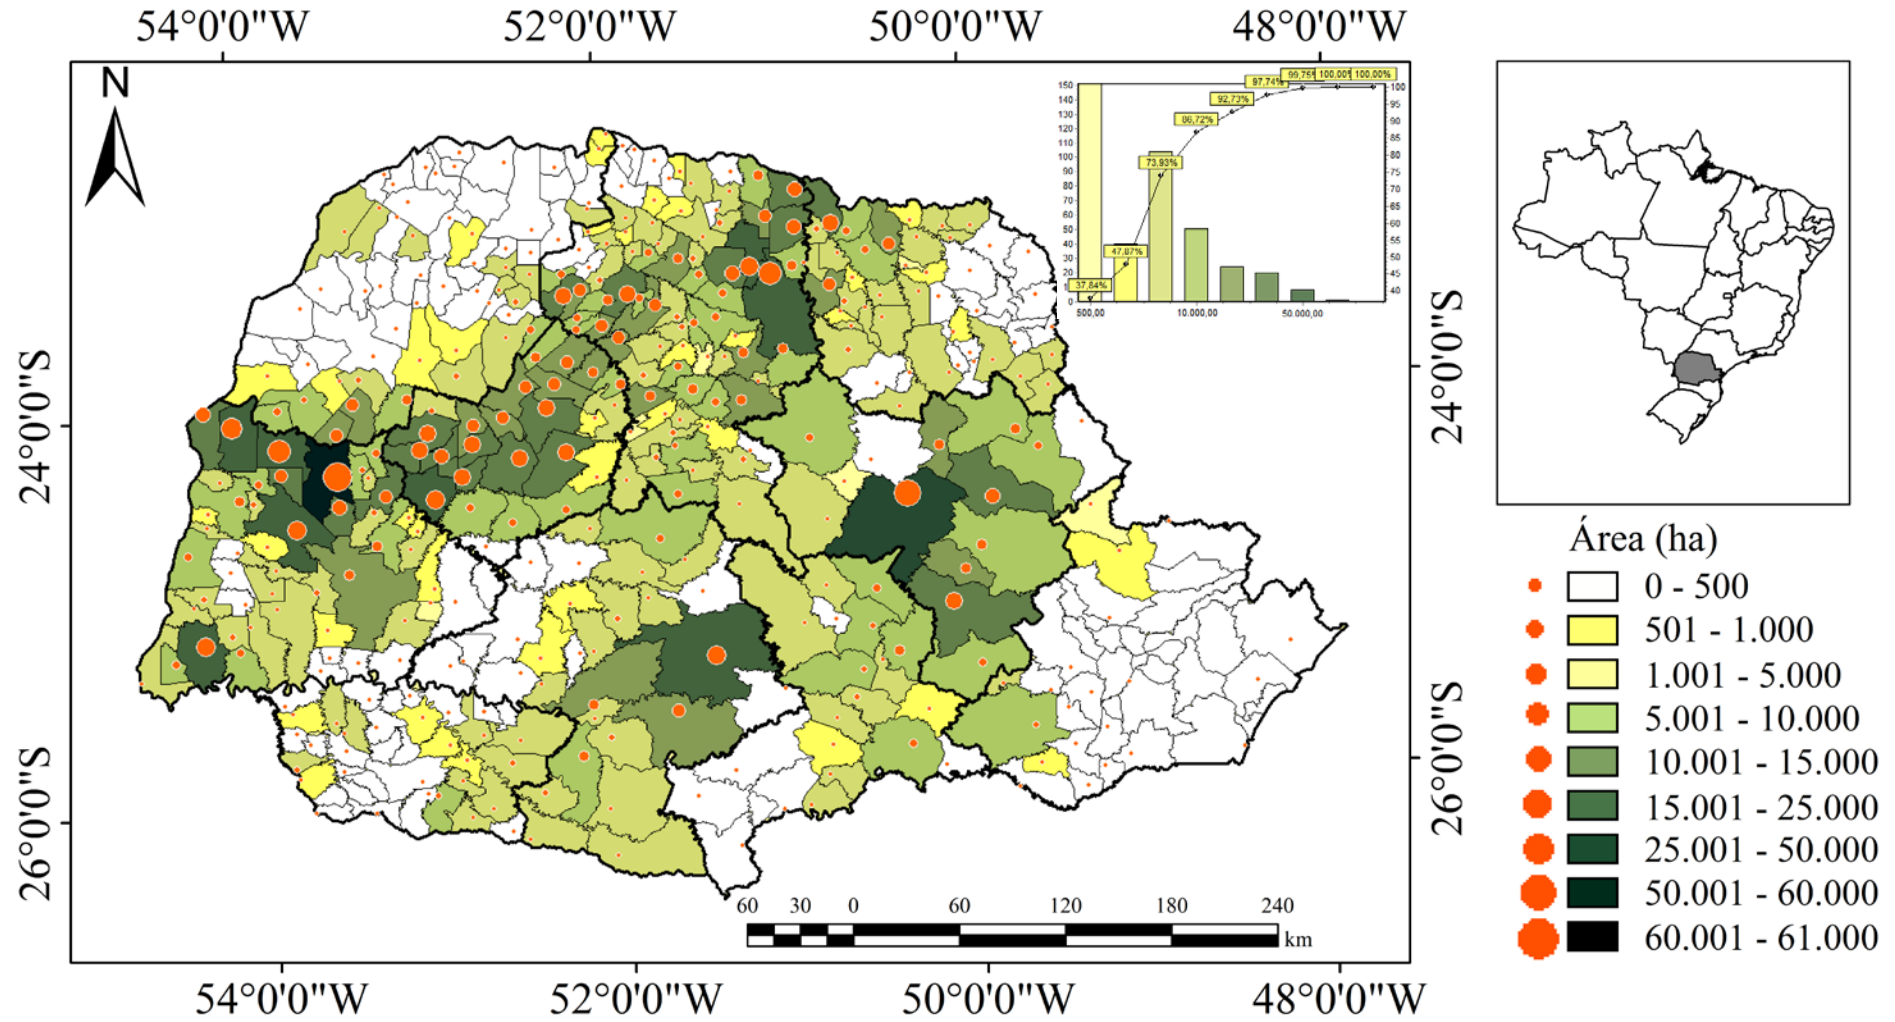
CEI - 2010/2011



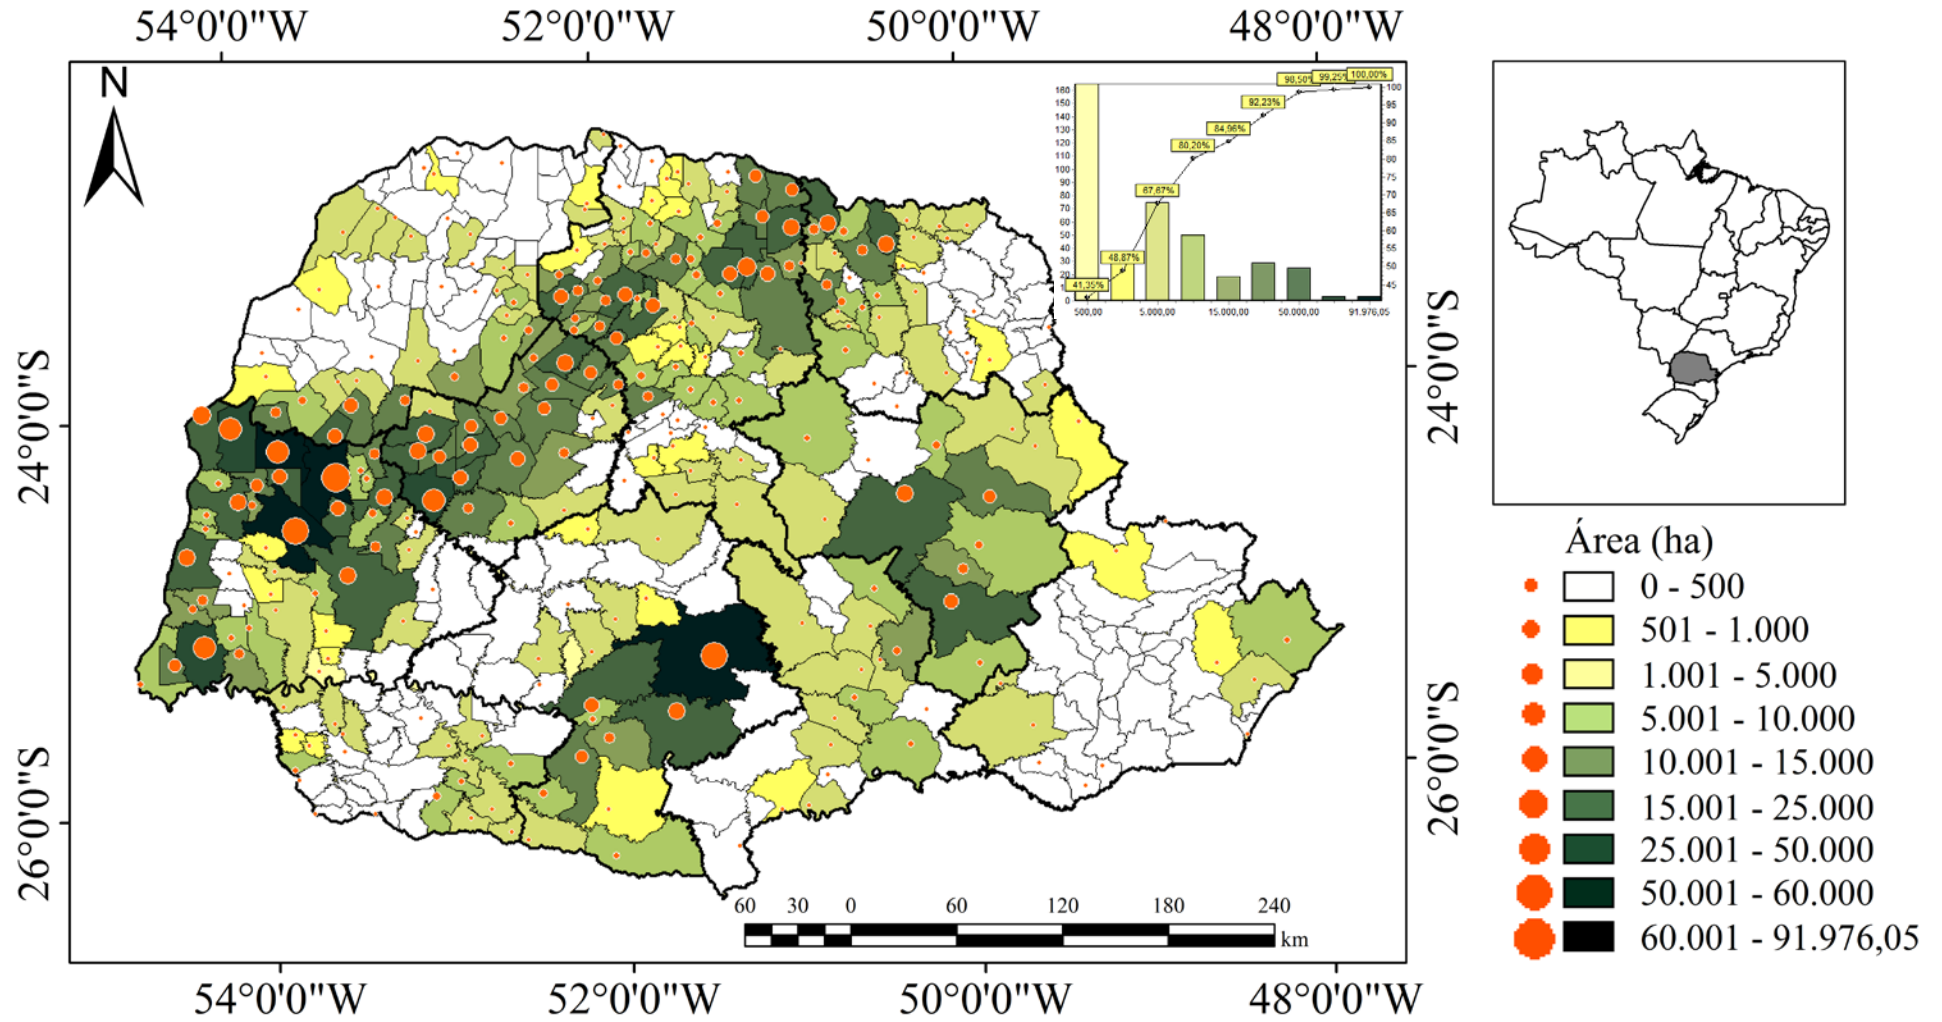
PCEI – 2010/2011



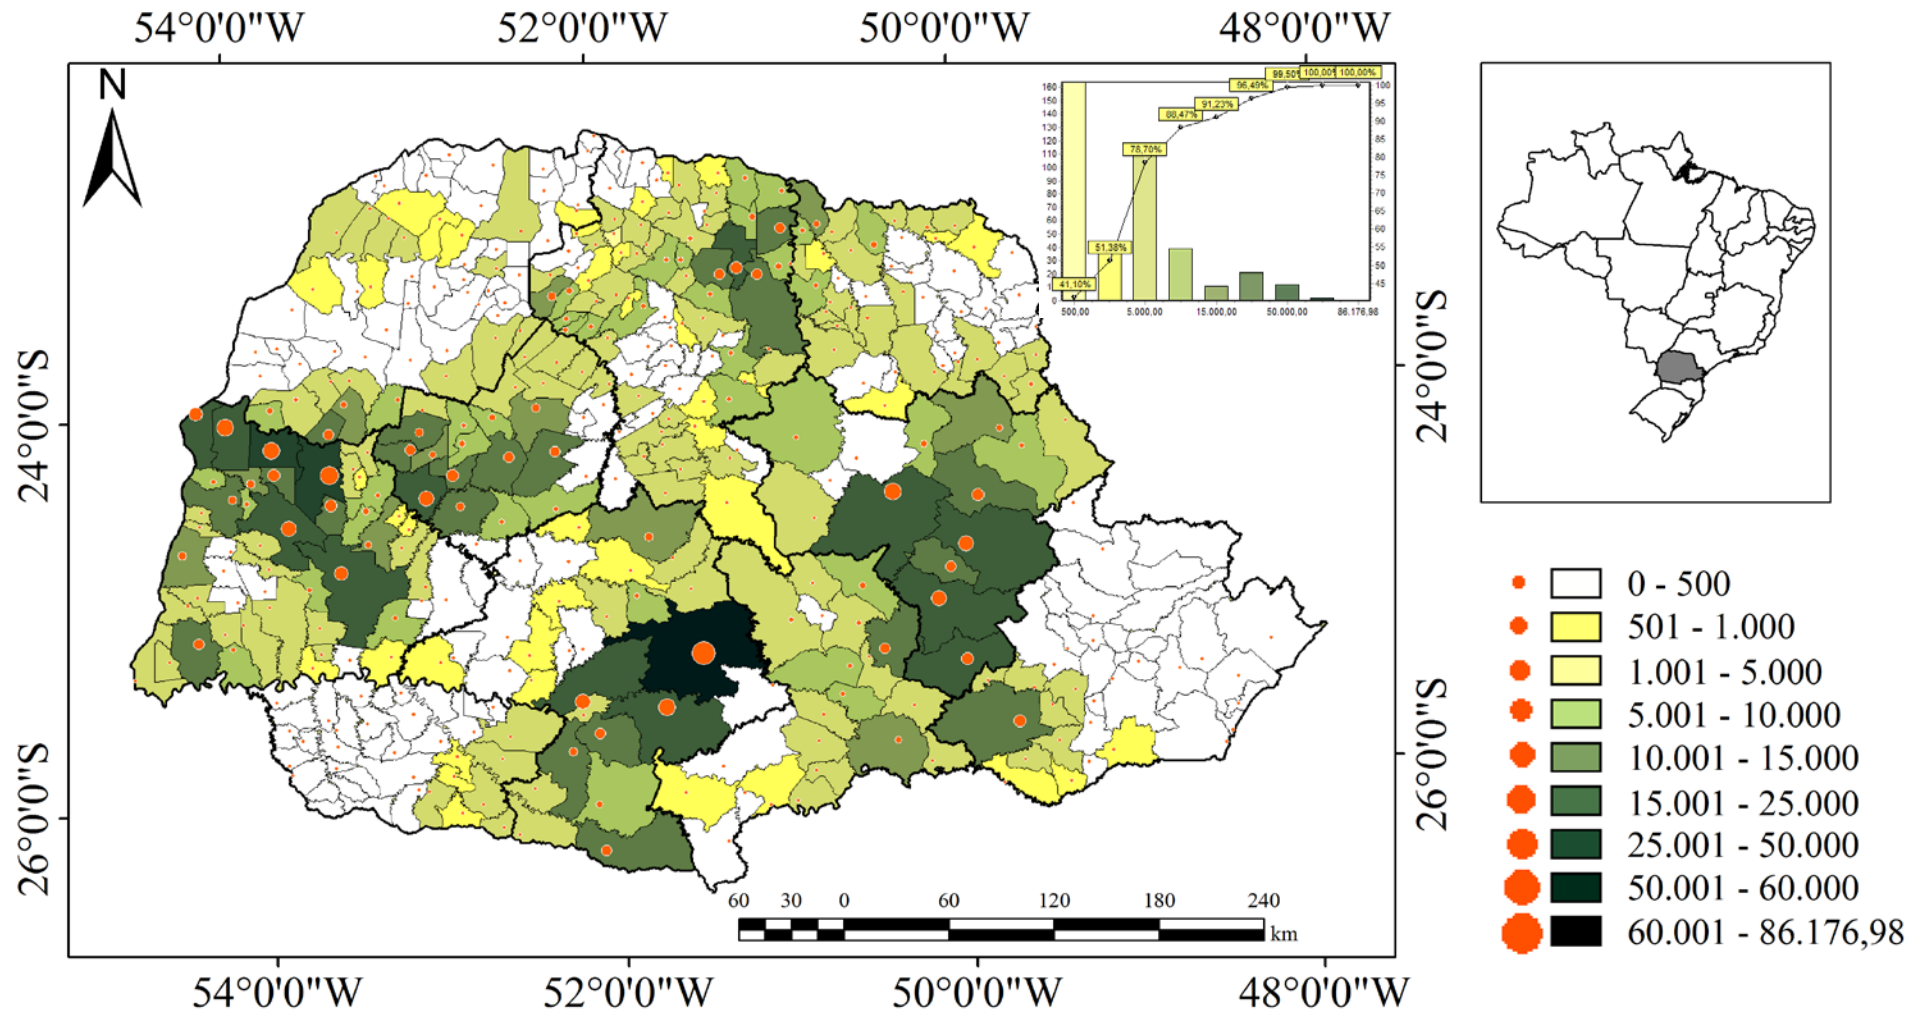
REDES NEURAIIS ARTIFICIAIS – 2010/2011



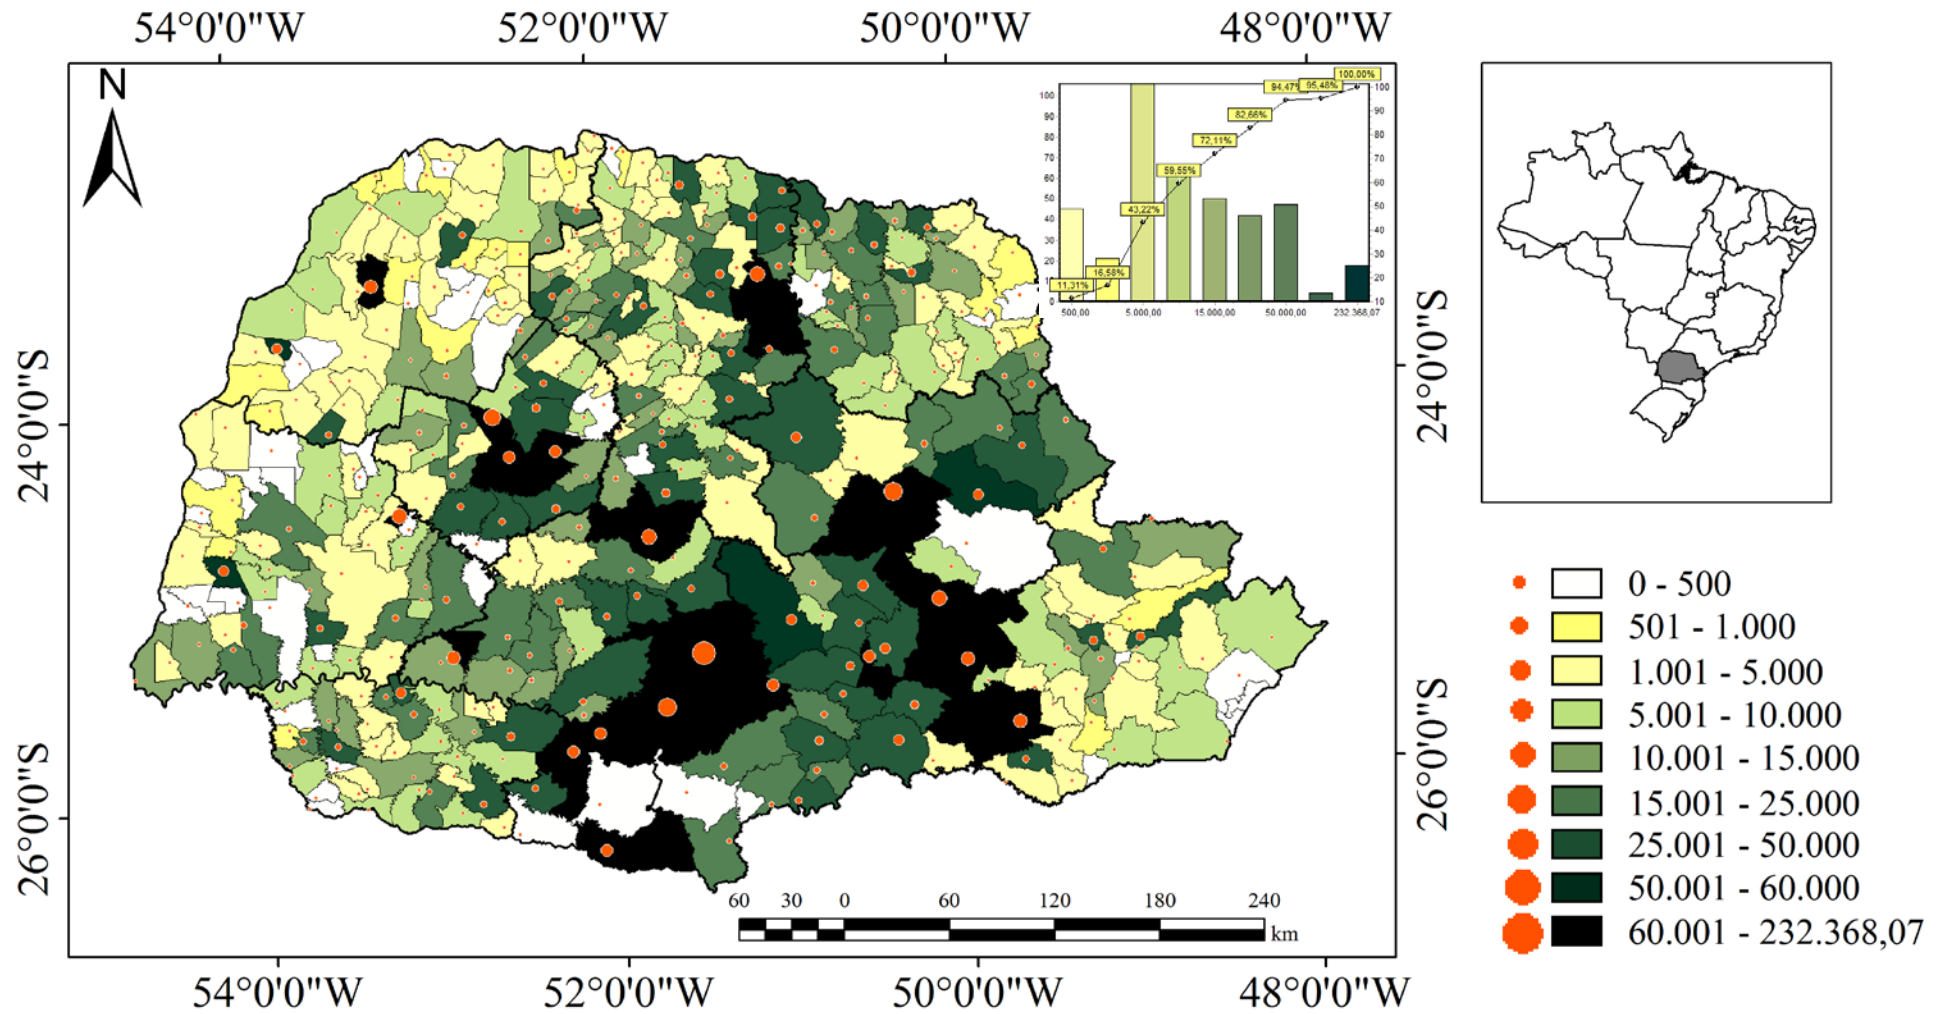
GEOBIA – 2010/2011

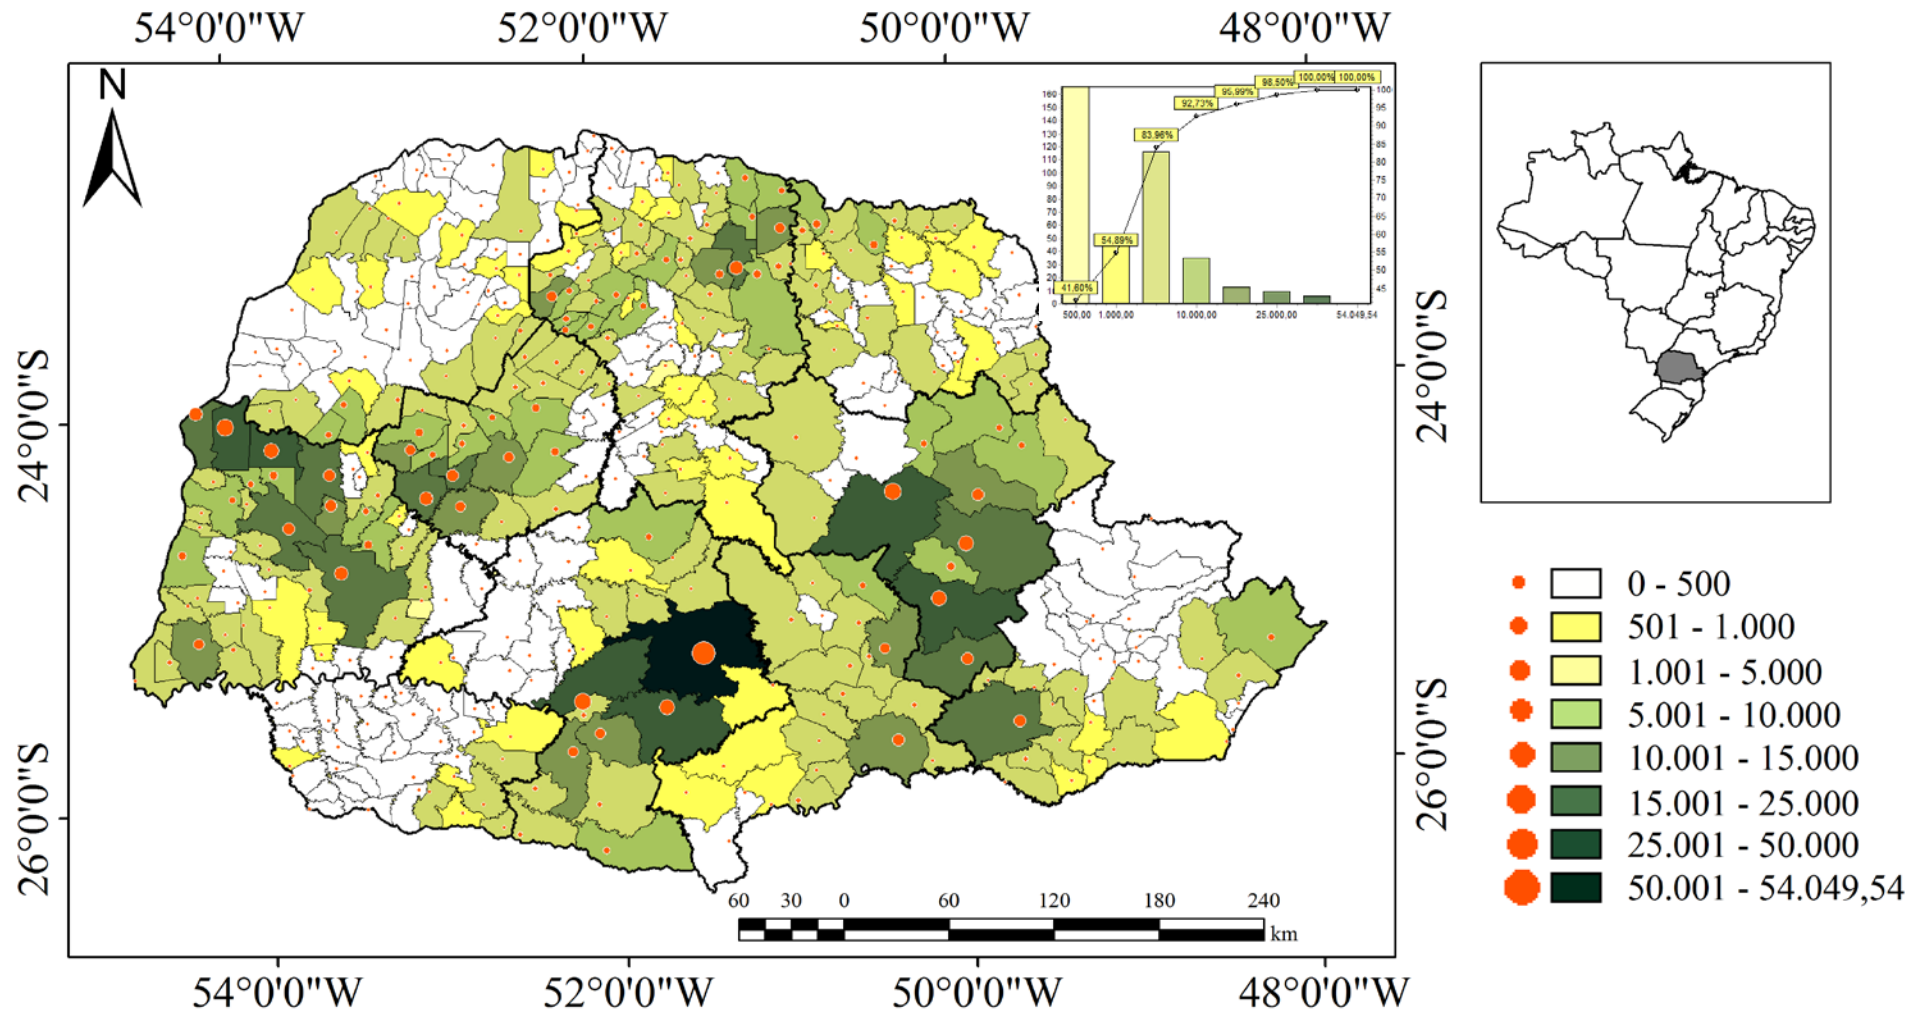


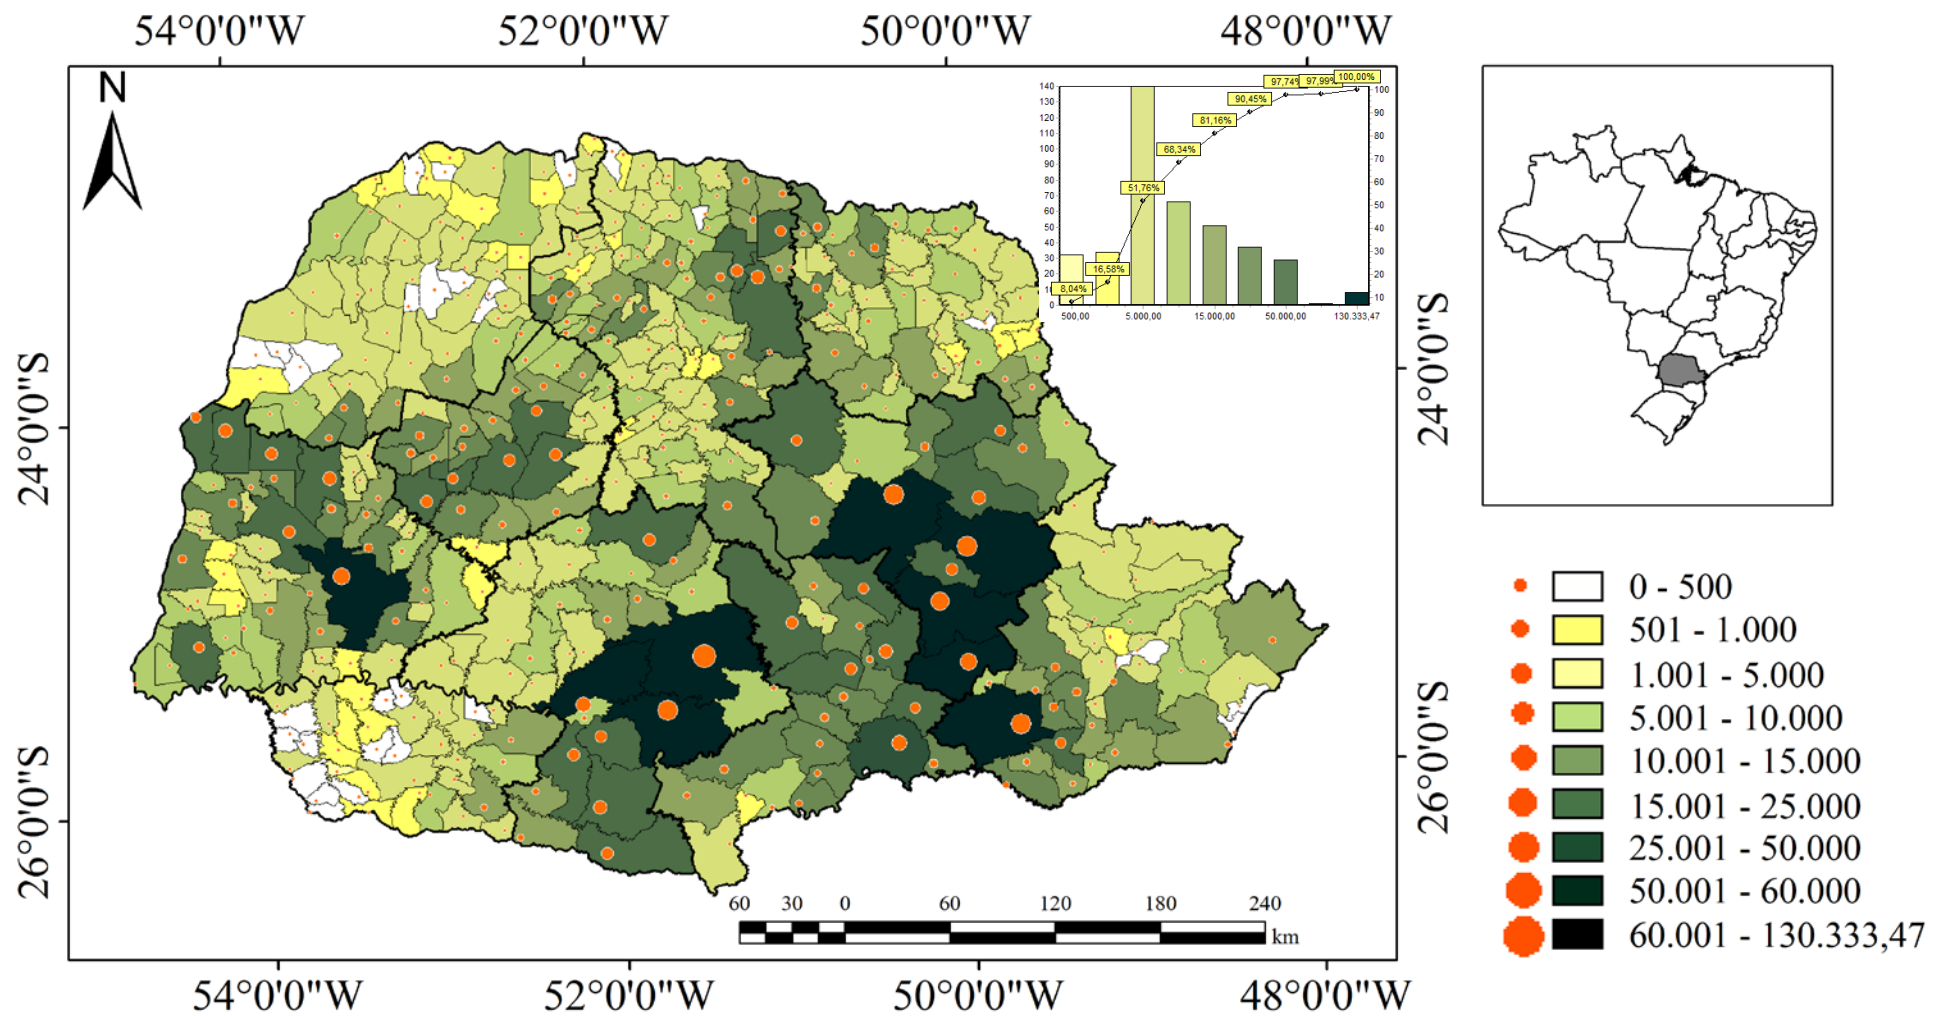
COMPONENTES PRINCIPAIS – 2011/2012



K-MÉDIA – 2011/2012







REDES NEURAIIS ARTIFICIAIS – 2011/2012

