

1 **FERNANDO SARAGOSA ROSSI**

2

3

4

5

6

7

8

9 **BALANÇO DE CARBONO E SALDO DE**
10 **RADIAÇÃO EM DIFERENTES SISTEMAS DE**
11 **PLANTIO DE SOJA POR MEIO DE VARIÁVEIS**
12 **ESPECTRO-TEMPORAIS**

13

14

15

16

Dissertação de Mestrado

17

18

19

20

ALTA FLORESTA-MT

21

2020

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20

	2 cm
FERNANDO SARAGOSA ROSSI	15 cm
Diss. MESTRADO	7 cm
PPGBioAgro 2020	5 cm



UNIVERSIDADE DO ESTADO DE MATO GROSSO

2
3
4

FACULDADE DE CIÊNCIAS BIOLÓGICAS E
AGRÁRIAS

PROGRAMA DE PÓS-GRADUAÇÃO EM
BIODIVERSIDADE E AGROECOSSISTEMAS
AMAZÔNICOS



5

6

FERNANDO SARAGOSA ROSSI

7

8

9

10

11

**BALANÇO DE CARBONO E SALDO DE
RADIÇÃO EM DIFERENTES SISTEMAS DE
PLANTIO DE SOJA POR MEIO DE VARIÁVEIS
ESPECTRO-TEMPORAIS**

12

13

14

15

16

17

18

19

Dissertação apresentada à Universidade do Estado de Mato Grosso, como parte das exigências do Programa de Pós-Graduação em Biodiversidade e Agroecossistemas Amazônicos, para a obtenção do título de Mestre em Biodiversidade e Agroecossistemas Amazônicos.

20

21

22

Orientador: Prof. Dr. Carlos Antonio da Silva Junior
Coorientador: Prof. Dr. José Francisco de Oliveira Júnior

23

24

25

ALTA FLORESTA-MT

26

2020

1 AUTORIZO A DIVULGAÇÃO TOTAL OU PARCIAL DESTE
2 TRABALHO, POR QUALQUER MEIO, CONVENCIONAL OU
3 ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE
4 QUE CITADA A FONTE.

5

6

7

8

9

10

11

12

Catálogo na publicação

13

Faculdade de Ciências Biológicas e Agrárias

- R831b ROSSI, Fernando Saragosa.
Balanço de Carbono e Saldo de Radiação em Diferentes Sistemas de Plantio de Soja por Meio de Variáveis EspectroTemporais / Fernando Saragosa Rossi – Alta Floresta, 2020.
96 f.; 30 cm. (ilustrações) Il. color. (sim)
- Trabalho de Conclusão de Curso (Dissertação/Mestrado) – Curso de Pós-graduação Stricto Sensu (Mestrado Acadêmico) Biodiversidade e Agroecossistemas Amazônicos, Faculdade de Ciências Biológicas e Agrárias, Câmpus de Alta Floresta, Universidade do Estado de Mato Grosso, 2020.
Orientador: Carlos Antonio da Silva Junior
Coorientador: José Francisco de Oliveira Júnior
1. Cultura Agrícola. 2. Imagens Multiespectrais. 3. Produtos Orbitais. 4. Mineração de Dados. I. Fernando Saragosa Rossi. II. Balanço de Carbono e Saldo de Radiação em Diferentes Sistemas de Plantio de Soja por Meio de Variáveis EspectroTemporais:.

CDU 528.835.041.5:633.34

DEDICATÓRIA

1

2

3 Aos meus pais, Ana Aparecida Bandini Rossi e Osvaldo Saragosa
4 Rossi, por serem exemplos na vida.

5

6

AGRADECIMENTOS

1

2

3

À Deus por sempre dar força para seguir em frente;

4

5

6

7

À toda minha família, especialmente a minha mãe (Ana Aparecida Bandini Rossi), meu pai (Osvaldo Saragosa Rossi) e a minha irmã (Fernanda Saragosa Rossi) pelo apoio, amor, amizade, confiança e incentivo para o fechamento de mais esta etapa;

8

À minha namora Auana Vicente Tiago pelo apoio e compreensão.

9

10

11

12

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

13

14

Aos professores do PPGBioAgro – UNEMAT e professores de outras instituições pelas sugestões e apoio nesta caminhada;

15

Aos amigos pelo ótimo convívio e aprendizagem.

16

17

SUMÁRIO

1		
2		
3	LISTA DE TABELAS	vi
4	LISTA DE FIGURAS	vii
5	LISTA DE SIGLAS (ou de ABREVIATURAS).....	ix
6	RESUMO.....	xi
7	ABSTRACT	xii
8	1. INTRODUÇÃO GERAL.....	1
9	2. REFERÊNCIAS BIBLIOGRÁFICAS	5
10	3. CAPÍTULOS	9
11	3.1. IDENTIFICAÇÃO DO PREPARO DO SOLO PARA CULTIVO DE SOJA	
12	POR MEIO DE VARIÁVEIS ESPECTRO-TEMPORAIS, GEOBIA E ÁRVORE	
13	DE DECISÃO ¹	9
14	Resumo.....	9
15	Abstract.....	10
16	INTRODUÇÃO	11
17	MATERIAL E MÉTODOS	14
18	Área de Estudo	14
19	Aquisição de Dados Espectrais	15
20	Detecção das Áreas de Soja no Mato Grosso	16
21	Índices de Vegetação.....	17
22	Comportamento das Bandas Espectrais no Preparo do Solo	19
23	Método de seleção do tipo de preparo do solo por meio dos índices	21
24	GEOBIA e Mineração de Dados	22
25	Pré-Processamento da Imagem Multiespectral	31
26	RESULTADOS E DISCUSSÃO.....	33
27	Identificação de soja no estado de Mato Grosso	33
28	Índices espectrais	34
29	GEOBIA	39
30	Resultados de Classificação e Acurácia dos Resultados.....	42
31	CONCLUSÃO.....	45
32	REFERÊNCIAS BIBLIOGRÁFICAS	47
33	4. CAPÍTULOS	55

1	3.2. BALANÇO DE CARBONO E SALDO DE RADIAÇÃO EM ÁREAS DE	
2	PLANTIO DIRETO DE SOJA POR MEIO DE VARIÁVEIS ESPECTRO-	
3	TEMPORAIS ¹	55
4	Resumo	55
5	Abstract	56
6	INTRODUÇÃO	57
7	MATERIAL E MÉTODOS	59
8	Área de Estudo	59
9	Detecção das Áreas de Soja.....	60
10	Índices de Vegetação.....	61
11	Distinção do tipo de preparo de solo por meio de índices espectrais, GEOBIA	
12	e mineração de dados.....	63
13	Temperatura da superfície da terra (LST).....	65
14	Fluxo de CO ₂	66
15	GPP (<i>Gross Primary Productivity</i>).....	68
16	Albedo e Balanço de Radiação.....	69
17	ARIMA - Modelagem do Futuro e Passado.....	72
18	RESULTADOS E DISCUSSÃO.....	74
19	Identificação da soja nas áreas de estudo via MODIS.....	74
20	Índices de Vegetação.....	75
21	GEOBIA e Classificação do Manejo do Solo	77
22	Variáveis Ambientais e Modelagem ARIMA.....	82
23	CONCLUSÃO.....	88
24	REFERÊNCIAS BIBLIOGRÁFICAS	89
25		
26		

LISTA DE TABELAS

1		
2		
3	CAPÍTULO 1	
4	Tabela 1: Valores considerados para seleção dos segmentos das classes (PC,	
5	PD_A e PD_B).	22
6	Tabela 2: Descrição das características espectrais e texturais na composição	
7	da GEOBIA.....	26
8	Tabela 3: Resumo das variáveis e parâmetros utilizados na segmentação.	27
9	Tabela 4: Atributos extraídos do eCognition® para selecionar as classes PC,	
10	PD_A e PD_B.....	29
11		
12	CAPÍTULO 2	
13	Tabela 1: Índices de vegetação utilizados no estudo para estimar tipo de	
14	manejo de solo, no ano safra 2000/2018.	62
15	Tabela 2: Coeficientes dos pesos (ω_n) para o cálculo do albedo planetário	
16	através do uso de imagens LANDSAT-8.....	70
17	Tabela 3: Total de área preparada para o plantio convencional e plantio direto A	
18	e B em hectares (ha) nos anos safra 2000/2001 e 2017/2018 nos municípios de	
19	Passo Fundo, RS e Sinop, MT.	80
20		

LISTA DE FIGURAS

1	
2	CAPÍTULO 1
3	FIGURA 1: Local da área de estudo, compreendido na região centro-oeste do
4	Brasil, estado do Mato Grosso baseado no NDVI. 15
5	FIGURA 2: Mapa temático das curvas de resposta espectral do Plantio
6	Convencional (PC), Plantio Direto A (PD_A), Plantio Direto B (PD_B), Milho
7	Seco, Soja Seca, Folha Verde da Soja e Solo. 21
8	FIGURA 3: Fluxograma ilustrando as principais etapas que fazem parte do
9	GEOBIA e mineração de dados e a abordagem proposta para classificar as
10	áreas de plantio direto e convencional a partir de imagens de séries temporais
11	dos satélites Landsat 5 e 8. 23
12	FIGURA 4: Fluxograma representativo do processo de mineração de dados.. 31
13	FIGURA 5: Imagem originais e modificadas pelo ENVI. A: Bandas e B: Índices
14	de Vegetação. 32
15	FIGURA 6: Mapeamento da soja no ano safra 2000/2001 e 2017/2018 no
16	estado do Mato Grosso por mesorregiões (Sudeste, Centro Sul, Sudoeste,
17	Nordeste e Norte) pelo sensor MODIS. 33
18	FIGURA 7: Boxplot das mesorregiões do estado do Mato Grosso em hectares
19	(ha) da detecção de soja no ano safra 2000/2001 e 2017/2018. 34
20	FIGURA 8: PC, PD_A, PD_B, Dry Corn Straw, Dry Soy Straw, Soil and Green
21	Soy Leaf behavior at the Landsat 8 wavelength. 35
22	FIGURA 9: Recorte do município de Sinop-MT, destaque para variabilidade dos
23	índices (EVI2, NDSVI, NDTI, NDVI, SATVI e STI) para ano safra de 2017/2018.
24 37
25	FIGURA 10: Segmentação hierárquica de multiresolução para o ano safra
26	2017/2018 no estado do Mato Grosso. 39
27	FIGURA 11: Seleção das características PC, PD_A e PD_B nos objetos. 40
28	FIGURA 12: Modelo de árvore de decisão concebido por meio de C4.5 / J48. 41
29	FIGURA 13: Mapa temático do ano/safra 2000/2001 e 2017/2018 da árvore de
30	decisão. 43
31	FIGURA 14: Quantificação de objetos/polígonos em cada mesorregião do
32	estado de Mato Grosso nos anos/safras de 2000/2001 e 2017/2018 de soja.. 43
33	FIGURA 15: Taxa de precisão da árvore de decisão C4.5/J48 retirado do
34	software Weka®. 44
35	CAPÍTULO 2
36	FIGURA 1: Localização geográfica dos municípios de Sinop – MT (A) e Passo
37	Fundo – RS (B) e variabilidade espacial do NDVI, respectivamente. 60

1	FIGURA 2: Fluxograma das principais etapas do estudo, com destaque para o	
2	GEOBIA e a mineração de dados nos ambientes computacionais.	64
3	FIGURA 3: Mapeamento da soja nos anos safras 2000/2001 e 2017/2018 nos	
4	municípios de Sinop - MT e Passo Fundo - RS pelo sensor MODIS.	74
5	FIGURA 4: Índices de vegetação para o ano safra 2017/2018 para os	
6	municípios de Passo Fundo, RS (A) e Sinop, MT (B).	76
7	FIGURA 5: Segmentação e aplicação da árvore de decisão nos municípios de	
8	Passo Fundo - RS (A1/B1) e Sinop - MT (A2/B2) no ano safra 2000/2018.....	78
9	FIGURA 6: Discriminação das áreas estudadas quanto ao tipo de manejo solo	
10	nos anos safra 2000/2001 e 2017/2018, A - Passo Fundo e B - Sinop.....	80
11	FIGURA 7: Valores anuais de Albedo, CO ₂ Flux, GPP e Temperatura para série	
12	temporal 2000 a 2018 nos dois municípios estudados.....	82
13	FIGURA 8: Dados de Albedo, CO ₂ Flux, GPP e Temperatura observados e	
14	simulados de janeiro de 2000 a dezembro de 2018.....	85
15	FIGURA 9: Coeficiente de determinação (R ²) dos melhores GPP de 2011 a	
16	2018, PD_A e PD_B de Sinop (A e B respectivamente) e PD_A e PD_B de	
17	Passo Fundo (C e D respectivamente).	85
18	FIGURA 10: Histograma de cada variável na diagonal, na esquerda a dispersão	
19	pela curva de LOESS e a direita a correlação dos valores (A - PD_A observado	
20	Passo Fundo; B - PD_A previsto de Passo Fundo; C - PD_B observado Passo	
21	Fundo; D - PD_B previsto de Passo Fundo; E - PD_A observado Sinop; F -	
22	PD_A previsto de Sinop; G - PD_B observado Sinop; H - PD_B previsto de	
23	Sinp).	86
24	FIGURA 11: Modelo ARIMA aplicado as variáveis ambientais: albedo, CO ₂ Flux,	
25	GPP e temperatura para os municípios de Sinop - MT e Passo Fundo – RS,	
26	com nível de confiabilidade de 95%.	88

27

LISTA DE SIGLAS (ou de ABREVIATURAS)

- 1
- 2
- 3 **AD** Árvore de Decisão
- 4 **Am** Clima de Monção
- 5 **ARIMA** *Autoregressive Integrated Moving Average Model*
- 6 **Aw/As** Clima Tropical com Estação Seca
- 7 **C** Carbono
- 8 **CEI** *Crop Enhancement Index*
- 9 **CO₂** Dióxido de Carbono
- 10 **CO₂Flux** Fluxo de Dióxido de Carbono
- 11 **EPE** Erro Padrão de Estimativa
- 12 **ETM+** *Enhanced Thematic Mapper Plus*
- 13 **EVI2** *Enhanced Vegetation Index 2*
- 14 **GEE** Google Earth Engine
- 15 **GEOBIA** *Geographic Object-Based Image Analysis*
- 16 **GLCM** Matriz de Coocorrência de Nível de Cinza
- 17 **GPP** *Gross Primary Production*
- 18 **IA** Inteligência Artificial
- 19 **IV** Índice de Vegetação
- 20 **LST** Temperatura da Superfície da Terra
- 21 **MD** Mineração de Dados
- 22 **MDE** Modelo Digital de Elevação
- 23 **MODIS** *Moderate-Resolution Imaging Spectroradiometer*
- 24 **MODTRAN** *Moderate resolution atmospheric Transmission*
- 25 **MT** Mato Grosso
- 26 **NDSVI** *Normalized Difference Senescence Index*
- 27 **NDTI** *Normalized Difference Tillage Index*
- 28 **NDVI** *Normalized Difference Vegetation Index*
- 29 **NIR** Infravermelho Próximo

- 1 **NPV** *Vegetação Não Fotossintética*
- 2 **OLI** *Operational Land Imager*
- 3 **PC** *Plantio Convencional*
- 4 **PCEI** *Perpendicular Crop Enhancement Index*
- 5 **PD** *Plantio Direto*
- 6 **PVI** *Perpendicular Vegetation Index*
- 7 **RGB** *Vermelho, Verde e Azul*
- 8 **RS** *Rio Grande do Sul*
- 9 **SATVI** *Soil Adjusted Total Vegetation Index*
- 10 **SAVI** *Soil-adjusted Vegetation Index*
- 11 **SR** *Sensoriamento Remoto*
- 12 **SRTM** *Shuttle Radar Topography Mission*
- 13 **STI** *Soil Tillage Index*
- 14 **SWIR** *Infravermelho de Ondas Curtas*
- 15 **TIGR** *Thermodynamic Initial Guess Retrieval*
- 16 **TIRS** *Thermal Infrared Sensor*
- 17 **TM** *Thematic Mapper*
- 18 **WEKA** *Waikato Environment for Knowledge Analysis*
- 19

RESUMO

Rossi, Fernando Saragosa. M.Sc. Universidade do Estado de Mato Grosso, Dezembro de 2020. **BALANÇO DE CARBONO E SALDO DE RADIAÇÃO EM DIFERENTES SISTEMAS DE PLANTIO DE SOJA POR MEIO DE VARIÁVEIS ESPECTRO-TEMPORAIS**. Orientador: Dr. Carlos Antonio da Silva Junior. Coorientador: Dr. José Francisco de Oliveira Júnior.

O objetivo desta pesquisa foi identificar áreas cultivadas com soja (*Glycine max* L. Merr.) no estado de Mato Grosso (MT) por meio de imagens multiespectrais do sensor MODIS (*Moderate-Resolution Imaging Spectroradiometer*) e desenvolver uma metodologia aplicada para detecção de Plantios Convencional e Direto, com base na GEOBIA (*Geographic Object-Based Image Analysis*) e MD (Mineração de Dados) no processamento das bandas espectrais e os índices de vegetação em uma série temporal do satélite Landsat para as áreas do cultivo. Para a identificação das áreas cultivadas com a cultura da soja foi utilizado o PCEI (*Perpendicular Crop Enhancement*) e na distinção do tipo de preparo do solo foram utilizadas duas técnicas combinadas: i) GEOBIA e ii) MD. As bandas espectrais e os índices de vegetação foram devidamente tratados e aplicados uma segmentação em multiresolução para definição dos objetos, com a seleção pré-definida dos alvos, sendo então gerada uma árvore de decisão (AD) pelo algoritmo C4.5/J48. Neste algoritmo foram utilizados 468 objetos amostrais para obtenção de uma análise matricial de erro e estatística Kappa. As estatísticas indicaram que a classificação alcançou uma precisão geral de 95.29% e um coeficiente Kappa de 0.92. Os resultados revelaram que a combinação das técnicas GEOBIA e MD são eficientes e promissoras para o processo de classificação do tipo de tratamento de solo.

Palavras-chave: cultura agrícola, imagens multiespectrais, produtos orbitais, mineração de dados.

1 **ABSTRACT**

2 Rossi, Fernando Saragosa. M.Sc. State University of Mato Grosso, December
3 de 2020. **CARBON BALANCE AND RADIATION BALANCE IN DIFFERENT**
4 **SOY PLANTING SYSTEMS BY SPECTRUM-TIME VARIABLES.** Advisor: Dr.
5 Carlos Antonio da Silva Junior. Coorientator: Dr. José Francisco de Oliveira
6 Júnior.

7
8 The objective of this research was to identify areas cultivated with soybean
9 (*Glycine max* L. Merr.) in the state of Mato Grosso (MT) through multispectral
10 images of MODIS (Moderate-Resolution Imaging Spectroradiometer) sensor
11 and to develop an applied methodology for Plantation detection. Conventional
12 and Direct, based on GEOBIA (Geographic Object-Based Image Analysis) and
13 MD (Data Mining) in the processing of spectral bands and vegetation indices in
14 a Landsat satellite time series for crop areas. For the identification of the
15 cultivated areas with soybean cultivation, the PCEI (Perpendicular Crop
16 Enhancement) was used and in the distinction of the type of tillage two
17 combined techniques were used: i) GEOBIA and ii) MD. The spectral bands and
18 vegetation indices were properly treated and a multiresolution segmentation
19 was applied to define the objects, with the predefined selection of the targets,
20 and a decision tree (AD) was generated by the C4.5 / J4 algorithm. In this
21 algorithm, 468 sample objects were used to obtain a matrix error analysis and
22 Kappa statistics. Statistics indicated that the rating achieved an overall accuracy
23 of 95.29% and a Kappa coefficient of 0.92. The results revealed that the
24 combination of GEOBIA and MD techniques are efficient and promising for the
25 soil treatment type classification process.

26 Key-words: Agricultural culture, multispectral imaging, orbital products, data
27 mining.

1. INTRODUÇÃO GERAL

No Brasil, a modernização da agricultura possibilitou diferenças estruturais no espaço rural, principalmente de produção, como no caso de produtos para de exportação, processo de modernização no país (BALSAN, 2006). A cada ano, novas tecnologias estão sendo incorporadas aos sistemas produtivos, o que tem assegurado contínuo aumento na produtividade das culturas (EMBRAPA, 2018).

A expansão e modernização da agricultura em geral originaram impactos de ordem socioambiental, como, por exemplo, das diferentes áreas ocupadas pelo cultivo de soja e assim, as áreas de florestas foram substituídas pela agricultura, promovendo intensificação do processo de fragmentação das florestas (ITAQUI, 2002, SILVA JUNIOR & LIMA, 2018). Entretanto, os fatores edafoclimáticos favoráveis à sojicultura e o apoio do Governo Federal foram fundamentais para sua rápida expansão no país (MUELLER, 1992; SOARES, 2016; ESTEVES & PEREIRA, 2016; FARIAS, 2018).

Algumas práticas podem minimizar os impactos causados pela sojicultura no ambiente, como o sistema plantio direto (PD) e a rotação de culturas (HERNANI, 2002). Nas antigas práticas, o solo não era cultivado após a colheita da soja, sendo deteriorado sob o ponto de vista físico em virtude da intensa mobilização por meio da utilização de “grades”, como no caso do plantio convencional (PC). Atualmente esse cenário tem se modificado, pois após a colheita da soja, há o cultivo de segunda safra (chamada de “safrinha”) utilizando outras culturas, como o milho, o algodão, as forrageiras e as plantas de cobertura (CAMPOS et al. 2009; MATIAS et al., 2015; EMBRAPA, 2018). O modo de sistema PD desempenha um papel importante no controle da erosão do solo e com isso aumenta a produtividade e melhora a fertilidade do solo (LI et al., 2016). O manejo do solo por meio de PD e PC para o plantio de culturas como a soja, milho e cana-de-açúcar são uns dos impulsionadores de estudos voltados para produtividade primária bruta (GPP - *Gross Primary Production*) e fluxo de dióxido de carbono (CO₂) no Brasil (AL-KAISI & YIN, 2005; WAGLE et al., 2015; VELOSO, 2018). A remoção do CO₂ da atmosfera pela vegetação é baseada no método que sequestra e armazena carbono do aumento da

1 produtividade primária bruta. O GPP é a taxa na qual o CO₂ presente na
2 atmosfera é convertido pela atividade fotossintética em substância orgânica e
3 pode ser medido por unidade de massa por área e tempo (ARAGÃO, 2004;
4 SILVA, 2013).

5 O fluxo de CO₂ no preparo convencional tende a aumentar nos
6 primeiros dias após o plantio, no entanto a longo prazo as emissões são
7 menores e podem até ser reduzidas em relação ao plantio direto (OORTS et al.
8 2007; REGINA & ALAKUKKU, 2010; CARBONELL-BOJOLLO et al., 2015). A
9 resposta das emissões de CO₂ perante ao manejo do preparo do solo depende
10 de vários fatores, tais como temperatura e umidade do solo e/ou uma interação
11 entre eles e a disponibilidade de substratos (LU et al., 2003; OORTS et al.
12 2007). Entretanto, vários estudos mostram resultados favoráveis, negativos e
13 neutros em relação à emissão de CO₂ (ASLAM et al., 2000; FUENTES et al.,
14 2012; PLAZA-BONILLA et al., 2014; SHAHIDI et al., 2014). Portanto, a busca
15 de métodos rápidos, precisos e confiáveis, é necessária para o entendimento
16 deste fenômeno nos dias atuais, tal como a utilização de imagens
17 espectralmente digitais via sensoriamento remoto (SILVA JUNIOR et al., 2019).
18 Diversas pesquisas utilizam o sensoriamento remoto (SR) como uma
19 ferramenta tecnológica primordial nos estudos de estimativa de carbono e o
20 fluxo de CO₂ (BROWN, 1996; BAPTISTA, 2004; WATZLAWICK et al., 2009;
21 SILVA & BAPTISTA, 2015; MATA, 2015), usando imagens multitemporais de
22 sensores orbitais, como o MODIS/Terra-Aqua (Moderate-Resolution Imaging
23 Spectroradiometer), o OLI/Landsat-8 (Operational Land Imager), o Hyperion e o
24 AVIRIS.

25 Os sensores OLI e TIRS (Thermal Infrared *Sensor*), acoplados no
26 satélite Landsat-8 e o sensor MODIS acoplado nos satélites Terra e Aqua
27 (NASA, 2018), disponibilizam imagens para análises de índices de vegetação
28 (IV) para ressaltar o comportamento espectral da biomassa em relação ao solo
29 e a outros alvos da superfície terrestre, com o intuito de avaliar os recursos
30 naturais e monitorar a cobertura vegetal. Geralmente são obtidos a partir da
31 combinação de duas ou mais bandas espectrais com o intuito de fornecer

1 informações estáveis sobre a superfície em comparação com as medidas de
2 reflectância (SILVA et al., 2018).

3 Para determinação das estimativas de absorção de carbono e emissão
4 de CO₂, várias pesquisas e estudos se baseiam na utilização do SR para
5 monitoramento de forma sistemática das áreas cultivadas e da produtividade
6 das culturas agrícolas (PONZONI et al., 2007; JOHANN, 2012; SILVA JUNIOR
7 et al., 2017; SOJAMAPS, 2018; SILVA JUNIOR et al., 2019), porém não
8 mensuram a atividade de balanço de carbono nessas áreas.

9 O estado de Mato Grosso por exemplo, apresentou uma produção de
10 32.454,5 milhões de toneladas na safra 2018/19, sendo o maior produtor de
11 soja do país (SOJAMAPS, 2018; CONAB, 2019), contribuindo
12 significativamente com o agronegócio nacional. Os grãos além de serem muito
13 utilizados por agroindústrias, indústrias química e de alimentos, recentemente
14 destaca-se também como fonte alternativa de biocombustível (KAPUSTOVÁ et
15 al., 2018; ISLAM et al., 2019). A cultura da soja apresenta alta
16 representatividade no comércio exterior, com quase 90 mil toneladas de grãos
17 exportados na safra de 2017/18 (CONAB, 2018). Ao longo das últimas
18 décadas, a produção de soja apresentou um grande avanço, sendo
19 impulsionada não somente pelo aumento de área semeada, mas também pela
20 aplicação de técnicas de manejo avançadas que permitem o aumento na
21 produtividade (LAZZAROTTO & HIRAKURI, 2010; FREITAS, 2011; GAVIOLI &
22 NUNES, 2015; DALL'AGNOL, 2016).

23 No Brasil, o monitoramento de áreas agrícolas por meio de imagens
24 orbitais é muito útil, dada sua extensão territorial e enorme diversidade de
25 culturas. Estudos sobre o cultivo da soja podem ser confirmados em todo o
26 mundo, abordando temas como discriminação e quantificação de áreas,
27 identificação do estágio fenológico, estimativa da produtividade pelo teor de
28 clorofila, entre outros (SILVA JUNIOR et al., 2014).

29 Assim, o uso de dados de sensoriamento remoto para o monitoramento
30 da dinâmica agrícola requer fundamentalmente a geração contínua de imagens
31 da vegetação (BROWN et al., 2017). Além disso, a cultura da soja possui

1 algumas características que favorecem seu reconhecimento por sensores
2 remotos (SILVA JUNIOR et al., 2017). Portanto o uso do SR possibilita não só
3 a previsão de safra da cultura de soja, área de cultivares ou estádios
4 fenológicos e mapeamento de atributos de solo, mas também fatores bióticos,
5 abióticos, ações antrópicas e sua influência atmosférica, com otimização dos
6 recursos, pessoal e matéria-prima, principalmente no estado Mato Grosso pela
7 sua extensão territorial.

8 Este trabalho está dividido em dois capítulos, em que são
9 apresentados dois objetivos: i) o primeiro é fornecer uma metodologia que
10 distingue o tipo de preparo do solo (PC e PD) para a semeadura da cultura de
11 soja pelo processamento de imagens multiespectrais no estado do Mato
12 Grosso (objeto de defesa da qualificação); ii) o segundo capítulo será realizado
13 uma comparação entre os municípios situados em diferentes latitudes em
14 função das áreas com PD e sua influência no fluxo de CO₂ e Produção Primária
15 Bruta (GPP) para verificar a diferença entre os fatores ambientais e apontar
16 tendências destas variáveis para futuro.

2. REFERÊNCIAS BIBLIOGRÁFICAS

AL-KAISI, M. M.; YIN, X. Tillage and crop residue effects on soil carbon and carbon dioxide emission in corn–soybean rotations. **Journal of Environmental Quality**, v. 34, n. 2, p. 437-445, 2005.

ARAGÃO, L. E. O. C. **Modelagem dos Padrões Temporal e Espacial da produtividade Primária Bruta Na Região do Tapajós: Uma Análise Multi-Escala**. Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 2004.

ASLAM, T.; CHOUDHARY, M. A.; SAGGAR, S. Influence of land-use management on CO₂ emissions from a silt loam soil in New Zealand. **Agriculture, ecosystems & environment**, v. 77, n. 3, p. 257-262, 2000.

BALSAN, R. IMPACTOS DECORRENTES DA MODERNIZAÇÃO DA AGRICULTURA BRASILEIRA1. **CAMPO-TERRITÓRIO: revista de geografia agrária**, v. 1, n. 2, 2006.

BAPTISTA, G. M. M. Mapeamento do Seqüestro de Carbono e de Domos Urbanos de CO₂ em Ambientes Tropicais, por meio de Sensoriamento Remoto Hiperespectral. **Geografia**, v. 29, n. 2, p. 189-202, 2004.

BROWN, L. A.; DASH, J.; OGUTU, B. O.; RICHARDSON, A. D. “On the relationship between continuous measures of canopy greenness derived using near-surface remote sensing and satellite-derived vegetation products”, **Agricultural and Forest Meteorology**, v.247, n.1, p.280-292, 2017.

CAMPOS, M.F.; ONO, E.O.; RODRIGUES, J.D. Desenvolvimento da parte aérea de plantas de soja em função de reguladores vegetais. **Revista Ceres**, v.56, n.1, p. 74-79, 2009.

CARBONELL-BOJOLLO, R.; GONZÁLEZ-SÁNCHEZ, E. J.; DE TORRES, M. R. R.; ORDÓÑEZ-FERNÁNDEZ, R.; DOMÍNGUEZ-GIMENEZ, J.; BASCH, G. Soil organic carbon fractions under conventional and no-till management in a long-term study in southern Spain. **Soil Research**, v. 53, n. 2, p. 113-124, 2015.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira de grãos**. V. 7 - SAFRA 2019/20- N. 1 - Primeiro levantamento | OUTUBRO 2019, p. 1-114. Disponível em <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/29039_f309ac254b698224266e20403d4aca29> Acesso em 01 nov. 2019.

DALL'AGNOL, A. DALL'AGNOL, Amélio. **A Embrapa Soja no contexto do desenvolvimento da soja no Brasil: histórico e contribuições**. Embrapa Soja- Livro técnico (INFOTECA-E), 2016.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Artigo: Os desafios da agricultura moderna**. 2018. Disponível em: <<https://www.embrapa.br/agropecuaria-oeste/busca-de-noticias/>>

- 1 /noticia/32676228/artigo-os-desafios-da-agricultura-moderna>. Acesso em: 08
2 out. 2018.
- 3 ESTEVES, R. A., & PEREIRA, R. G. Análise sobre a evolução do biodiesel no
4 Brasil. **Revista ESPACIOS**, Vol. 37 (Nº 02) Año 2016, 2016.
- 5 FARIAS, A. B. Contexto sócio-histórico e econômico no Norte de Mato Grosso
6 (caso de Sinop): a expansão da fronteira agrícola. **Em tempo de histórias**, n.
7 31, p. 84-100. 2018.
- 8 FREITAS, M. D. C. M. D. A cultura da soja no Brasil: o crescimento da
9 produção brasileira e o surgimento de uma nova fronteira agrícola.
10 **Enciclopédia Biosfera–Centro Científico Conhecer**, Goiânia-GO, v. 7, n. 12,
11 p. 1-12, 2011.
- 12 FUENTES, M.; HIDALGO, C.; ETCHEVERS, J.; DE LEÓN, F.; GUERRERO,
13 A.; DENDOOVEN, L.; VERHULST N.; GOVAERTS, B. Conservation
14 agriculture, increased organic carbon in the top-soil macro-aggregates and
15 reduced soil CO₂ emissions. **Plant and Soil**, v. 355, n. 1-2, p. 183-197, 2012.
- 16 GAVIOLI, A. P. R.; NUNES, J. D. S. SOJA TRANSGÊNICA NO BRASIL E
17 SUAS INFLUÊNCIAS À SAÚDE E AO MEIO AMBIENTE. **Revista Científica**
18 **da Faculdade de Educação e Meio Ambiente**, 6(2): 1-16, jul-dez, 2015.
- 19 HERNANI, L. C. Uma resposta conservacionista–O impacto do Sistema Plantio
20 Direto. MANZATTO, CV, FREITAS JÚNIOR, E. & PERES, JRR (eds.) Uso
21 agrícola dos solos brasileiros. Rio de Janeiro: **Embrapa Solos**, p. 151-161,
22 2002.
- 23 ISLAM, I.; ADAM, Z.; ISLAM, S. Soja (Glycine Max): fontes alternativas de
24 nutrição humana e bioenergia para o século XXI. **American Journal of Food**
25 **Science and Technology**, v. 7, n. 1, p. 1-6, 2019.
- 26 ITAQUI, J. Quarta Colônia: inventários técnicos. **Santa Maria: Condesus**
27 Quarta Colônia, 2002.
- 28 JOHANNN, J. A. **Calibração de dados agrometeorológicos e estimativa de**
29 **área e produtividade de culturas de verão no estado do Paraná**. 2012, 201
30 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de
31 Campinas – UNICAMP, Campinas, 2012.
- 32 KAPUSTOVÁ, Z.; KAPUSTA, J.; BIELIK, P. Food-Biofuels Interactions: The
33 Case of the US Biofuels Market. **AGRIS on-line Papers in Economics and**
34 **Informatics**, v. 10, n. 665-2019-277, p. 27-38, 2018.
- 35 LAZZAROTTO, J. J.; HIRAKURI, M. H. Marcelo Hiroshi. Evolução e
36 perspectivas de desempenho econômico associadas com a produção de soja
37 nos contextos mundial e brasileiro. Londrina: **Embrapa Soja**, p. 46, 2010.
- 38 LI, Y.; HOU, C.; WANG, Q.; CHEN, Y.; MA, J.; MOHAMMAD, Z. Effect of No-Till
39 Farming and Straw Mulch on Spatial Variability of Soil Respiration in Sloping
40 Cropland. **Polish Journal of Environmental Studies**, v. 25, n. 6, 2016.

- 1 LU, D.; MORAN, E.; BATISTELLA, M. Linear mixture model applied to
2 Amazonian vegetation classification. **Remote sensing of environment**, v. 87,
3 n. 4, p. 456-469, 2003.
- 4 MATA, M. D. V. M. D. **Estimativa das emissões de dióxido de carbono**
5 **associadas às mudanças no uso e cobertura da terra do bioma caatinga**
6 **no Estado do Rio Grande do Norte**. 2015. f. 120. Tese (Doutorado) -
7 Universidade Federal do Rio Grande do Norte, Programa de Pós-Graduação
8 em Ciências Climáticas, Natal-RN, 2015.
- 9 MATIAS, S. S. R.; NÓBREGA, J. C. A.; NÓBREGA, R. S. A.; ANDRADE, F. R.;
10 BAPTISTEL, A. C. Variabilidade espacial de atributos químicos em Latossolo
11 cultivado de modo convencional com soja no cerrado piauiense. **Revista**
12 **Agro@ambiente On-line**, v. 9, n. 1, p. 17-26, 2015.
- 13 MUELLER, C. C. Dinâmica, condicionantes e impactos socioambientais da
14 evolução da fronteira agrícola no Brasil. **Revista de Administração Pública**, v.
15 26, n. 3, p. 64-87, 1992.
- 16 NASA - NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (EUA).
17 **Landsat 8**. 2018. Disponível em: <[https://landsat.gsfc.nasa.gov/landsat-data-](https://landsat.gsfc.nasa.gov/landsat-data-continuity-mission/)
18 [continuity-mission/](https://landsat.gsfc.nasa.gov/landsat-data-continuity-mission/)>. Acesso em: 15 jul. 2018.
- 19 OORTS, K.; MERCKX, R.; GRÉHAN, E.; LABREUCHE, J.; NICOLARDOT, B.
20 Determinants of annual fluxes of CO₂ and N₂O in long-term no-tillage and
21 conventional tillage systems in northern France. **Soil and Tillage Research**, v.
22 95, n. 1-2, p. 133-148, 2007.
- 23 PLAZA-BONILLA, D.; CANTERO-MARTÍNEZ, C.; BARECHE, J.; ARRÚE, J. L.;
24 ÁLVARO-FUENTES, J. Soil carbon dioxide and methane fluxes as affected by
25 tillage and N fertilization in dryland conditions. **Plant and Soil**, v. 381, n. 1-2, p.
26 111-130, 2014.
- 27 PONZONI, R. W.; NGUYEN, N. H.; KHAW, H. L. Investment appraisal of
28 genetic improvement programs in Nile tilapia (*Oreochromis niloticus*).
29 **Aquaculture**. p.187- 199, 2007.
- 30 REGINA, K.; ALAKUKKU, L. Greenhouse gas fluxes in varying soils types
31 under conventional and no-tillage practices. **Soil and Tillage Research**, v. 109,
32 n. 2, p. 144-152, 2010.
- 33 SHAHIDI, B. M. R.; DYCK, M.; MALHI, S. S. Carbon dioxide emissions from
34 tillage of two long-term no-till Canadian prairie soils. **Soil and Tillage**
35 **Research**, v. 144, p. 72-82, 2014.
- 36 SILVA JUNIOR, C. A., NANNI, M. R., TEODORO, P. E., & SILVA, G. F. C.
37 Vegetation Indices for Discrimination of Soybean Areas: A New Approach.
38 **Agronomy Journal**, v. 109, p. 1331-1343, 2017.
- 39 SILVA JUNIOR, C. A.; LIMA, M. Soy Moratorium in Mato Grosso: deforestation
40 undermines the agreement. **Land Use Policy**, v. 71, p. 540-542, 2018.

- 1 SILVA JUNIOR, C. A.; MOREIRA, E. P.; FRANK, T.; MOREIRA, M. A.;
2 BARCELLOS, D. Comparação de áreas de soja (*Glycine max* (L) Merr.) obtidas
3 por meio da interpretação de imagens TM/Landsat e MODIS/Terra no município
4 de Maracaju (MS), **Bioscience Journal**, v.30, n.5, p.707-716, 2014.
- 5 SILVA, D. V. R.; SEBEM, E.; PEDRALI, L. D.; SANTOS, M. A. G. Variabilidade
6 espacial de NDVI E EVI no estágio vegetativo da soja. **Revista de Gestão do**
7 **Agronegócio**, v. 2, n. 2, 2018.
- 8 SILVA, F. B. **Modelagem da Produtividade Primária Bruta na Amazônia.**
9 Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto.
10 Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos,
11 2013.
- 12 SILVA, S. C. P.; BAPTISTA, G. M. D. M. ANÁLISES ESPECTRAIS DA
13 VEGETAÇÃO COM DADOS HYPERION E SUA RELAÇÃO COM A
14 CONCENTRAÇÃO E O FLUXO DE CO₂ EM DIFERENTES AMBIENTES NA
15 AMAZÔNIA BRASILEIRA. **Boletim de Ciências Geodésicas**, v. 21, n. 2, p.
16 354-370, 2015.
- 17 SOARES, P. **Determinantes de eficiência técnica da agricultura: um**
18 **estudo para as culturas de milho e soja no Brasil.** 2016. 96 p. Dissertação
19 (Mestrado em Ciências) - USP, Escola Superior de Agricultura "Luiz de
20 Queiroz", Piracicaba, 2016.
- 21 SOJAMAPS – **Monitoramento de áreas de soja por meio de imagens de**
22 **satélite.** 2018. Disponível em:
23 <<http://pesquisa.unemat.br/gaaf/uploads/publicacoes/sojamaps-89.pdf>> Acesso
24 em 10 de jul. 2018.
- 25 VELOSO, G. A. **PRODUTIVIDADE PRIMÁRIA BRUTA E BIOMASSA EM**
26 **PASTAGEM NO BIOMA CERRADO: UMA ANÁLISE A PARTIR DOS**
27 **MODELOS SEBAL/CASA E MOD17 NO ESTADO DE GOIÁS.** 2018. 149 f.
28 Tese (Doutorado)- Universidade Federal de Goiás, Instituto de Estudos
29 Socioambientais (Iesa), Programa de Pós-Graduação em Geografia, Goiânia,
30 2018.
- 31 WAGLE, P.; XIAO, X.; SUYKER, A. E. Estimation and analysis of gross primary
32 production of soybean under various management practices and drought
33 conditions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 99,
34 p. 70-83, 2015.
- 35 WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de
36 biomassa e carbono em floresta com araucária utilizando imagens do satélite
37 Ikonos II. **Ciência Florestal**, v. 19, n. 2, p. 169-181, 2009.
- 38

1 **3. CAPÍTULOS**

2 **3.1. IDENTIFICAÇÃO DO PREPARO DO SOLO PARA CULTIVO DE SOJA**
3 **POR MEIO DE VARIÁVEIS ESPECTRO-TEMPORAIS, GEOBIA E ÁRVORE**
4 **DE DECISÃO ¹**

5

6

7

8

9

10

11

12

13

14

15

16 ¹ Artigo submetido no periódico “PLOS ONE”.

17 **Resumo** – (IDENTIFICAÇÃO DO PREPARO DO SOLO PARA CULTIVO DE
18 SOJA POR MEIO DE VARIÁVEIS ESPECTRO-TEMPORAIS, GEOBIA E
19 ÁRVORE DE DECISÃO). O objetivo desta pesquisa foi identificar áreas
20 cultivadas com soja (*Glycine max* L. Merr.) no estado de Mato Grosso (MT) por
21 meio de imagens multiespectrais do sensor MODIS (*Moderate-Resolution*
22 *Imaging Spectroradiometer*) e desenvolver uma metodologia aplicada para
23 detecção de Plantios Convencional e Direto, com base na GEOBIA
24 (*Geographic Object-Based Image Analysis*) e MD (Mineração de Dados) no
25 processamento das bandas espectrais e os índices de vegetação em uma série
26 temporal do satélite Landsat para as áreas do cultivo. Para a identificação das
27 áreas cultivadas com a cultura da soja foi utilizado o PCEI (*Perpendicular Crop*
28 *Enhancement*) e na distinção do tipo de preparo do solo foram utilizadas duas
29 técnicas combinadas: i) GEOBIA e ii) MD. As bandas espectrais e os índices de
30 vegetação foram devidamente tratados e aplicados uma segmentação em
31 multiresolução para definição dos objetos, com a seleção pré-definida dos
32 alvos, sendo então gerada uma árvore de decisão (AD) pelo algoritmo

1 C4.5/J48. Neste algoritmo foram utilizados 468 objetos amostrais para
2 obtenção de uma análise matricial de erro e estatística Kappa. As estatísticas
3 indicaram que a classificação alcançou uma precisão geral de 95.29% e um
4 coeficiente Kappa de 0.92. Os resultados revelaram que a combinação das
5 técnicas GEOBIA e MD são eficientes e promissoras para o processo de
6 classificação do tipo de tratamento de solo.

7 Palavras-chave: Cultura agrícola, imagens multiespectrais, produtos orbitais,
8 mineração de dados.

9

10 **Abstract** - (IDENTIFICATION OF TILLAGE FOR SOY CROP BY SPECTRUM-
11 TEMPORAL VARIABLES, GEOBIA AND DECISION TREE). The objective of
12 this research was to identify areas cultivated with soybean (*Glycine max* L.
13 Merr.) in the state of Mato Grosso (MT) through multispectral images of MODIS
14 (Moderate-Resolution Imaging Spectroradiometer) sensor and to develop an
15 applied methodology for Plantation detection. Conventional and Direct, based
16 on GEOBIA (Geographic Object-Based Image Analysis) and MD (Data Mining)
17 in the processing of spectral bands and vegetation indices in a Landsat satellite
18 time series for crop areas. For the identification of the cultivated areas with
19 soybean cultivation, the PCEI (Perpendicular Crop Enhancement) was used
20 and in the distinction of the type of tillage two combined techniques were used:
21 i) GEOBIA and ii) MD. The spectral bands and vegetation indices were properly
22 treated and a multiresolution segmentation was applied to define the objects,
23 with the predefined selection of the targets, and a decision tree (AD) was
24 generated by the C4.5 / J4 algorithm. In this algorithm, 468 sample objects were
25 used to obtain a matrix error analysis and Kappa statistics. Statistics indicated
26 that the rating achieved an overall accuracy of 95.29% and a Kappa coefficient
27 of 0.92. The results revealed that the combination of GEOBIA and MD
28 techniques are efficient and promising for the soil treatment type classification
29 process.

30 Key-words: Agricultural culture, multispectral imaging, orbital products, data
31 mining.

32

33

34

35

36

37

1 INTRODUÇÃO

2 A soja (*Glycine max* L. Merrill) está entre as leguminosas mais
3 importantes do mundo, sendo que dois terços de toda a sua proteína é
4 destinada para a alimentação mundial, e 25% de todo óleo consumido
5 globalmente advém da mesma (AGARWAL et al., 2013). O seu farelo está
6 presente em quase todas as fórmulas de ração animal e é amplamente
7 utilizado para produzir diversos produtos alimentares (RAVI et al., 2019). Dada
8 a sua importância socioeconômica, a produção de soja apresentou um grande
9 avanço nas últimas décadas, impulsionada não apenas pelo aumento da área
10 semeada, mas também pela aplicação de técnicas de melhoramento genético e
11 de manejo que permitiram o aumento da produtividade (DALL'AGNOL, 2016;
12 GAVIOLI & NUNES, 2015; FREITAS, 2011; LAZZAROTTO & HIRAKURI,
13 2010). Práticas aprimoradas de gerenciamento de culturas, expansão e
14 intensificação de terras cultivadas tornaram o Brasil um grande exportador de
15 soja (FAO, 2015), com isso alcançou 35% das exportações mundiais, ao se
16 considerar grãos e produtos derivados (WESTCOTT & CONTACT, 2016).

17 O estado do Mato Grosso (MT) tornou-se um centro de produção
18 agrícola de importância global (SPERA et al., 2016; COHN et al., 2016), sendo
19 beneficiado pelas condições geográficas e institucionais que aumentaram a
20 capacidade do setor agrícola. As mudanças no uso da terra para a cultura da
21 soja entre 2001 a 2011 foram de quase 8,7 milhões de ha no estado de MT,
22 dos quais quase 3,5 milhões de ha pertenciam ao bioma Amazônia brasileira
23 (ARVOR et al., 2014). O principal objetivo da mudança do uso da terra foi
24 modificar a arquitetura do solo, com isso alterou a distribuição agregada de
25 tamanho, a densidade e a porosidade do solo e, assim criou condições ideais
26 para as atividades de lavoura (KAINIEMI et al., 2013). O preparo do solo pode
27 aumentar a mineralização da matéria orgânica devido à melhor aeração em
28 condições úmidas e ao aumento da exposição da matéria orgânica fisicamente
29 protegida aos decompositores causados pela ruptura de grandes agregados
30 (MEIJER et al., 2013).

31 Quando comparamos os métodos de preparo do solo Plantio
32 Convencional (PC) e Direto (PD), a resposta do solo varia entre os dois.
33 Estudos apontam que no PD há uma contribuição para o sequestro de carbono

1 (C) do solo e leva a melhorias nas propriedades físicas do solo, capacidade de
2 retenção de água no solo e taxa de infiltração de água (LAL et al., 2015;
3 PITTELKOW et al., 2015), porém outros estudos revelaram que quando
4 camadas de solo mais profundas (> 20 cm) são incluídas na comparação, tais
5 diferenças geralmente são menores ou mesmo revertidas com a utilização do
6 PC (BALESDENT et al., 2000; GOVAERTS et al., 2009). As práticas de manejo
7 do solo são consideradas necessárias para sustentar a produtividade das
8 culturas para conservar ou melhorar a qualidade do solo (AZIZ et al., 2009).
9 Dadas essas percepções, a aplicação de metodologias baseada na inteligência
10 artificial (IA) e análise geoespacial tornaram-se necessárias para a
11 implementação de uma sinergia entre práticas agrícolas sustentáveis e a
12 diminuição dos impactos ambientais.

13 O uso combinado de diferentes métodos de análise, como índices de
14 vegetação e aprendizado de máquina, traz uma nova perspectiva para essas
15 investigações. Na última década, diversas pesquisas sobre o mapeamento da
16 distribuição de terras cultivadas no Brasil foi realizada (EPIPHANIO et al., 2010;
17 ARVOR et al., 2011; ARVOR et al., 2012; BROWN et al., 2013; GUSSO et al.,
18 2014; ZHU et al., 2016). As imagens de satélites multiespectrais como Landsat
19 e TERRA/AQUA foram utilizadas em estudos para análises das propriedades
20 do solo e os resíduos das culturas sob vários tratamentos de lavoura, usando
21 certos tipos de índices (GAUSMAN et al., 1977; NAGLER et al., 2000; CHANG
22 et al., 2001). Além disso, a identificação de resíduos de culturas de solos por
23 refletância no infravermelho também foi estudada (Daughtry, 2001). No
24 entanto, identificar os dados e gerar informações a partir deles pode consumir
25 tempo e esforço com algoritmos de classificação convencionais com índices
26 multiespectrais.

27 Portanto, ainda é necessário desenvolver um modelo que possa
28 distinguir com precisão e rapidez os tratamentos de lavoura e as práticas de
29 gerenciamento de resíduos diretamente usando refletâncias multiespectrais. Os
30 métodos da árvore de decisão tornaram-se alternativas úteis para classificar os
31 dados multiespectrais, tendo em vista a necessidade de obter informações
32 sobre as áreas ocupadas com o cultivo da soja no estado do MT e qual o tipo
33 de preparo do solo para este cultivo. Ao considerar os avanços

1 computacionais, o objetivo deste trabalho é desenvolver uma metodologia
2 aplicada por meio de técnicas avançadas de processamento de imagens
3 multiespectrais do satélite Landsat, em uma série temporal de áreas com
4 cultivo de soja baseada nas técnicas de GEOBIA e MD para detectar o tipo de
5 preparo do solo (PC e PD).

6

7

8

9

10

11

1 MATERIAL E MÉTODOS

2 Área de Estudo

3 A área de estudo compreende o estado de Mato Grosso, na região
4 Centro-Oeste do Brasil, localizado entre as coordenadas geográficas 09°00' a
5 18°00'S e 49°00' a 61°00'W (Figura 1), com uma área aproximada de
6 903.206,997 km² e constituído por 141 municípios (IBGE, 2019). A altitude da
7 área varia de 442 a 301 m conforme os dados do modelo digital de elevação
8 (MDE) - SRTM (*Shuttle Radar Topography Mission*) pelo produto
9 USGS/SRTMGL1_003 (SRTM, SEE FARR et al., 2007). O clima predominante
10 é o tropical super-úmido de monção, com elevada temperatura média anual,
11 superior a 24°C e uma alta taxa pluviométrica (2.000 mm. anuais⁻¹) e o
12 tropical, com chuvas na estação verão e o inverno seco, sendo caracterizado
13 por médias de 23°C, que segundo a classificação de Köppen-Geiger são: “Am”
14 (clima de monção) e “Aw/As” (clima tropical com estação seca) (ALVARES et
15 al., 2013).

16

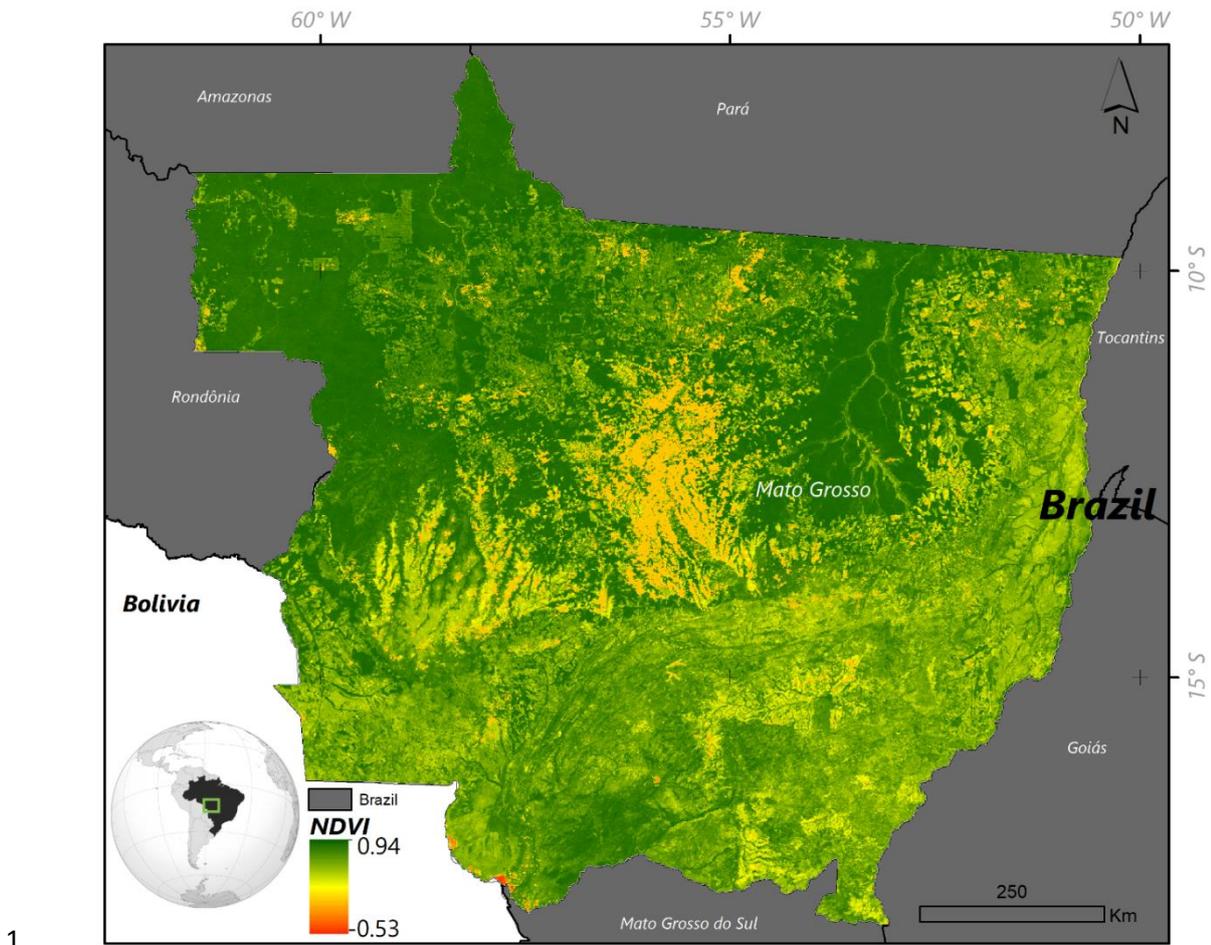


FIGURA 1: Local da área de estudo, compreendido na região centro-oeste do Brasil, estado do Mato Grosso baseado no NDVI.

Aquisição de Dados Espectrais

As imagens utilizadas neste estudo foram adquiridas pelos satélites Landsat 5 e 8 derivadas dos produtos LANDSAT/LT05/C01/T1_TOA e LANDSAT/LC08/C01/T1_RT_TOA já corrigidos a reflectância atmosférica (CHANDER et al., 2009) na série temporal de 25 de julho a 15 de setembro de 2000 para o Landsat 5 e de 25 de julho a dia 15 de setembro de 2017 para o Landsat 8 com uma tolerância de 20% de nuvem para ambos. As bandas utilizadas no Landsat 5 foram a banda 1 - Azul (0.45 - 0.52 μm), banda 2 - Verde (0.52 - 0.60 μm), banda 3 - Vermelho (0.63 - 0.69 μm), banda 4 - Próximo ao infravermelho (NIR) (0.76 - 0.90 μm), banda 5 - Infravermelho de ondas curtas (SWIR1) (1.55 - 1.75 μm) e banda 7 - Infravermelho médio (SWIR2) (2.08 - 2.35 μm) e para o Landsat 8 foram a banda 2 - Azul (0,45 - 0,51 μm), banda 3 - Verde (0,53 - 0,59 μm), banda 4 - Vermelho (0,64 - 0,67

1 μm), banda 5 – Próximo ao infravermelho (NIR) (0,85 - 0,88 μm), banda 6 –
2 Infravermelho de ondas curtas 1 (SWIR1) (1,57 - 1,65 μm) e banda 7 –
3 Infravermelho de ondas curtas 2 (SWIR2) (2,11 - 2,29 μm) com uma resolução
4 espacial de 30 m na resolução temporal de 16 dias para ambos os satélites.

5 O download de todas as imagens foi realizado pela plataforma
6 Google Earth Engine (GEE) por meio de programação JavaScript, sendo
7 aplicado a máscara de soja para as bandas e os índices de vegetação na série
8 temporal e, assim facilitar o tempo de processamento localmente das imagens.

9 **Detecção das Áreas de Soja no Mato Grosso**

10 O mapeamento da cultura da soja foi realizado por meio do uso da
11 máscara de soja do ano/safra 2000/2001 e 2017/2018, baseado na geração de
12 imagem dos satélites Landsat 5 (*Thematic Mapper* - TM) e Landsat 8
13 (*Operational Land Imager* – OLI e *Thermal Infrared Sensor* - TIRS) e
14 TERRA/AQUA (*Moderate-Resolution Imaging Spectroradiometer* – MODIS),
15 por meio do uso de bandas espectrais conforme metodologia proposta por
16 Silva Junior et al. (2017).

17 Com base no calendário da cultura de soja no Mato Grosso, pode-se
18 obter o *Perpendicular Crop Enhancement Index* (PCEI) desenvolvido por SILVA
19 JUNIOR et al. (2017). No estágio inicial da cultura de soja as reflectâncias
20 registradas pelo sensor podem interferir nos valores de PCEI, pois o solo
21 estará sem cultivo. Para evitar essa interferência é aplicado o *Perpendicular*
22 *Vegetation Index* (PVI) (Eq. 1) e usando as bandas espectrais de vermelho e
23 infravermelho para regressão em linha da terra, como descrito por NANNI e
24 DEMATTÊ (2006).

$$25 \quad PVI = \frac{P_{IVP} - aP_V - b}{\sqrt{1+a^2}} \quad [\text{Eq. 1}]$$

26

27 em que: a e b são, respectivamente, a inclinação e o intercepto da linha da
28 terra, sendo P_{IVP} uma variável independente.

29 Por meio da série-temporal do índice PVI, foi calculado o índice
30 PCEI (*Perpendicular Crop Enhancement Index*), que é representado pela Eq.
31 (2) e, sintetizada na Eq. (3), conforme descrito por Silva Junior et al. (2017):

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

$$PCEI = \frac{(MaxPVI+S)-(MinPVI+S)}{(MaxPVI+S)+(MinPVI+S)} \quad [\text{Eq. 3}]$$

O valor de *MaxPVI* é o valor máximo de *PVI* observado no período de máximo desenvolvimento da cultura da soja, *MinPVI* é o valor mínimo observado no período de pré-semeadura e/ou emergência, *S* é o coeficiente de melhoria (10^2) e *g* é o fator de ganho (10^2).

Índices de Vegetação

Neste estudo consideramos necessário implementar vários índices de vegetação (IVs) para estabelecer um monitoramento e correlacionar a saúde, abundância e vigor da vegetação, bem como às medidas físicas de radiância ou reflectância. Portanto, seis índices diferentes foram calculados, o *Enhanced Vegetation Index 2* (EVI2) proposto por Jiang et al. (2008) na Eq. (4), que não utiliza a banda espectral na faixa do azul e, assim proporciona menor distorção ocasionado pela variação na atmosfera.

$$EVI2 = 2.5 * \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + (2.4 * \rho_{RED}) + 1} \quad [\text{Eq. 4}]$$

em que: ρ_{NIR} = Reflectância no infravermelho próximo e ρ_{RED} = Reflectância no visível vermelho.

Um dos produtos utilizados no estudo foi MOD13Q1 obtido do sensor MODIS que se encontra a bordo das plataformas orbitais TERRA e AQUA - (https://lpdaac.usgs.gov/dataset_discovery/modis/modis_products_table/mod13q1_v006), em que fornece o índice NDVI (*Normalized Difference Vegetation Index*; ROUSE et al., 1974). (Eq. 5). O NDVI faz separação da vegetação verde do brilho do solo que está presente na mistura espectral na imagem.

1
$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad [\text{Eq. 5}]$$

2 em que: NDVI = Índice de vegetação por diferença normalizada; ρ_{NIR} =
3 Reflectância no infravermelho próximo e ρ_{RED} = Reflectância no visível
4 vermelho.

5 Na identificação de vegetação em senescência e menor grau de
6 densidade de vegetação verde, foi utilizado o *Normalized Difference*
7 *Senescence Index* (NDSVI) (QI et al., 2002) (Eq. 6).

8
$$NDSVI = \frac{\rho_{SWIR1} - \rho_{RED}}{\rho_{SWIR1} + \rho_{RED}} \quad [\text{Eq. 6}]$$

9 em que: ρ_{SWIR1} = Reflectância no infravermelho de ondas curtas e ρ_{RED} =
10 Reflectância no visível vermelho.

11 O *Soil Tillage Index* (STI) (VAN DEVENTER et al., 1997) busca
12 fornecer a estimativa da massa da vegetação seca e da fração de cobertura em
13 áreas secas (Eq. 7).

14
$$STI = \frac{\rho_{SWIR1}}{\rho_{SWIR2}} \quad [\text{Eq. 7}]$$

15 em que: ρ_{SWIR1} = Reflectância no infravermelho de ondas curtas e ρ_{SWIR2} =
16 Reflectância no infravermelho médio.

17 Os valores do *Normalized Difference Tillage Index* (NDTI) (VAN
18 DEVENTER et al., 1997) está diretamente relacionado aos sistemas de manejo
19 e preparo do solo que variam periodicamente aos anos (Eq. 8).

20
$$NDTI = \frac{\rho_{SWIR1} - \rho_{SWIR2}}{\rho_{SWIR1} + \rho_{SWIR2}} \quad [\text{Eq. 8}]$$

21 em que: ρ_{SWIR1} = Reflectância no infravermelho de ondas curtas e ρ_{SWIR2} =
22 Reflectância no infravermelho médio.

23 O *Soil-adjusted Vegetation Index* (SAVI) (HUETE, 1988) é um índice
24 definido pela equação 9, que leva em consideração os efeitos do solo exposto
25 nas imagens analisadas, para ajustar o NDVI quando a superfície não está
26 completamente coberta pela vegetação.

$$1 \quad SAVI = \frac{(1+L_s)(\rho_{NIR}-\rho_{RED})}{(L_s+\rho_{NIR}+\rho_{RED})} \quad [Eq. 9]$$

2 em que: L_s é uma constante chamada fator de ajuste do índice SAVI e pode
 3 assumir valores de 0,25 a 1, dependendo da cobertura do solo. Segundo Huete
 4 (1988), um valor para L_s de 0,25 é indicado para vegetação densa e de 0,5
 5 para vegetação com densidade intermediária, quando o valor de L_s é 1 para
 6 vegetação com baixa densidade. Se o valor SAVI for igual a 0, seus valores se
 7 tornarão iguais aos valores do NDVI. Portanto, o valor mais usado de L_s é 0,5.

8 Para o cálculo de correlação entre a vegetação verde e senescente
 9 presente no solo, foi utilizado o *Soil Adjusted Total Vegetation Index* (SATVI)
 10 (MARSETT et al., 2006) (Eq. 10) que combina o NDSVI e o SAVI.

$$11 \quad SATVI = \frac{\rho_{SWIR1} - \rho_{RED}}{\rho_{SWIR1} + \rho_{RED} + L} (1 + L) - \left(\frac{\rho_{SWIR2}}{2}\right) \quad [Eq. 10]$$

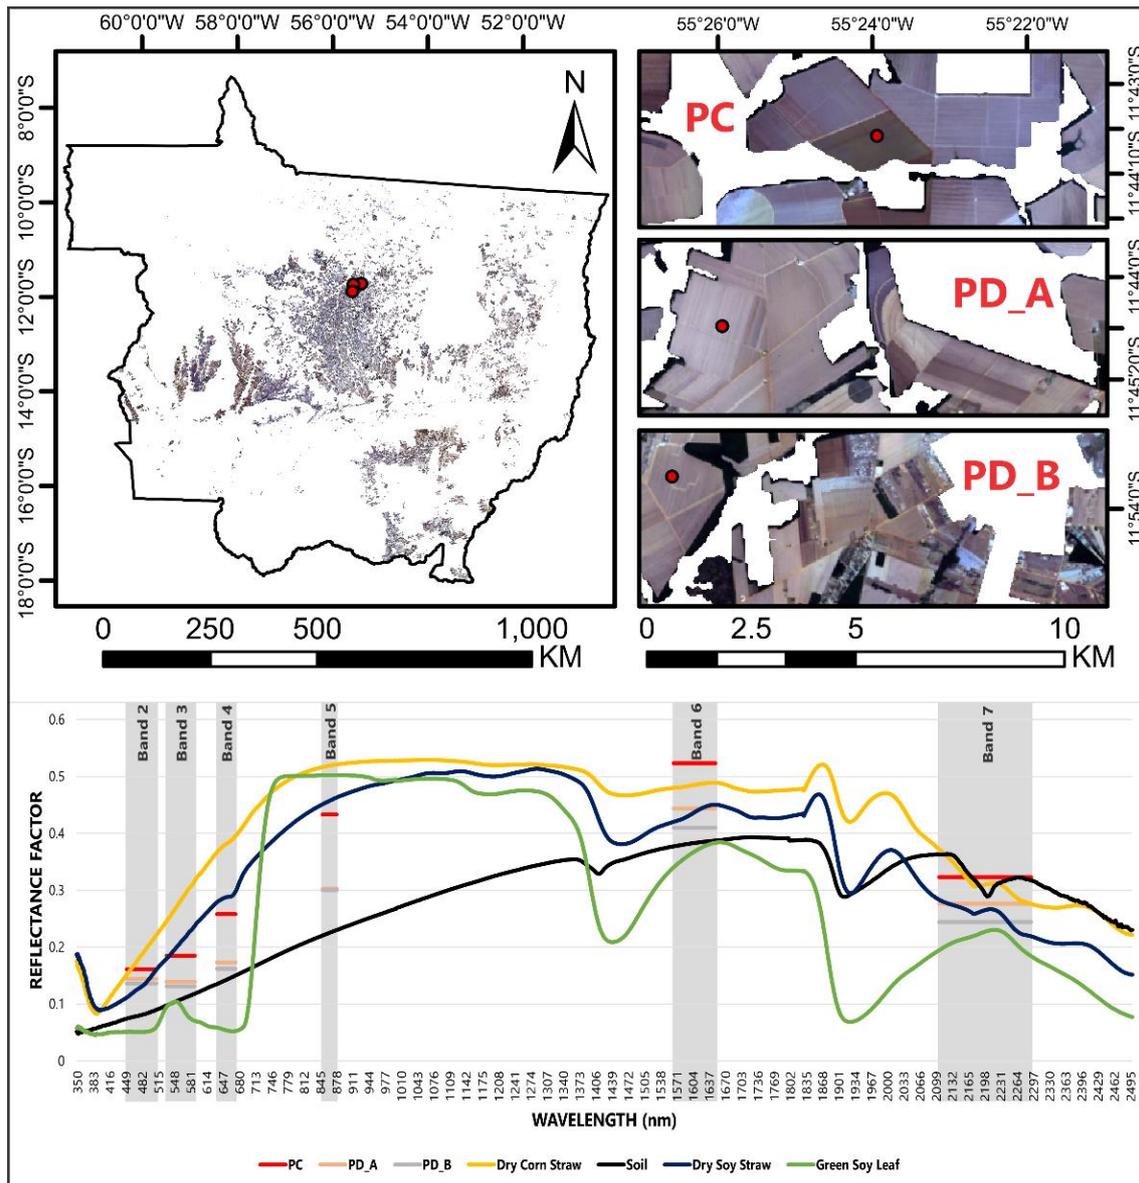
12

13 em que: ρ_{SWIR1} = Reflectância no infravermelho de ondas curtas, ρ_{RED} =
 14 Reflectância no visível vermelho, L é constante (relacionada à inclinação da
 15 linha do solo em um gráfico de espaço de característica) que geralmente é
 16 definido como 0,5 e ρ_{SWIR2} = Reflectância no infravermelho médio.

17 **Comportamento das Bandas Espectrais no Preparo do Solo**

18 Assinatura espectral de compostos de matéria seca proveniente de
 19 alguma cultura ou qualquer vegetação não fotossintética (NPV) no solo é mais
 20 sensível no infravermelho de ondas curtas (SWIR, 1100–2500 nm), com isso
 21 permite a criação de vários índices de vegetação seca usando essa faixa. Na
 22 faixa do espectro visível (Vis, 400-700 nm) a reflectância da vegetação não
 23 fotossintética é maior do que no infravermelho próximo (NIR, 700-1200 nm),
 24 sendo correspondente à falta de absorção de pigmentos da clorofila e alteração
 25 da estrutura foliar (CAO et al., 2010). Devido a presença de água, carbono
 26 orgânico no solo e a mineralogia do solo têm a maior dificuldade de separação
 27 da NPV do solo via sensoriamento remoto (NAGLER et al., 2000; LI & GUO,
 28 2016).

1 Nesse contexto, os dados de sensoriamento óptico passivo têm o
2 potencial de estimar a vegetação não fotossintética, principalmente porque o
3 NPV tem um conteúdo de clorofila e água menor que a vegetação verde
4 (SERBIN et al., 2013) e o alto conteúdo de celulose e lignina na vegetação não
5 fotossintética está ausente no solo descoberto (NAGLER et al., 2003; SERBIN
6 et al., 2009). Essas diferenças causam variações em seus espectros (Figura 2),
7 que pode ser usado para separar a vegetação não fotossintética da vegetação
8 fotossintética e do solo descoberto. As curvas de resposta espectral (Figura 2)
9 foram retiradas do satélite Landsat 8 no dia 20 de setembro de 2017, para os
10 pontos amostrais considerados como PC, PD_A, PD_B em comparação com a
11 curva hiperespectral adquirida pelo espectrorradiômetro FieldSpec 3 da
12 palhada de milho e soja seca, a folha da soja verde e a curva do solo adquirida
13 na Biblioteca Espectral de Solos do Brasil (BESB, 2019).



1

2 FIGURA 2: Mapa temático das curvas de resposta espectral do Plantio
 3 Convencional (PC), Plantio Direto A (PD_A), Plantio Direto B (PD_B), Milho
 4 Seco, Soja Seca, Folha Verde da Soja e Solo.

5 Método de seleção do tipo de preparo do solo por meio dos índices

6 Como mencionado no tópico anterior, foram utilizadas diversas
 7 metodologias conhecidas e consolidadas na literatura. Após, o pré-
 8 processamento das imagens multiespectrais e a segmentação das mesmas, foi
 9 feito uma correlação entre os valores dos índices para coleta supervisionada
 10 dos segmentos das classes (PC, Plantio Direto A - PD_A e Plantio Direto B -
 11 PD_B) (Tabela 1). Na coleta supervisionada dos segmentos das classes foi
 12 considerada a densidade de fitomassa foliar fotossinteticamente ativa (EVI2 e

1 NDVI), que quanto maior os valores, mais densa e vigorosa a vegetação, a
 2 cobertura da vegetação senescente (NDSVI), presença de resíduos de culturas
 3 (NDTI e STI) e a quantificação da cobertura da vegetação herbácea ajustada
 4 ao solo (SATVI).

5 *Tabela 1: Valores considerados para seleção dos segmentos das classes (PC,*
 6 *PD_A e PD_B).*

	Tillage	No-till A	No-till B
EVI2	<= 70	> 70 <= 135	> 135
NDSVI	< 172	> 172 <= 180	>180
NDTI	<= 70	> 70 <= 131	> 131
NDVI	<= 100	> 100 <= 160	> 160
SATVI	< 150	> 150 <= 180	>180
STI	<= 42	> 42 <= 130	> 130

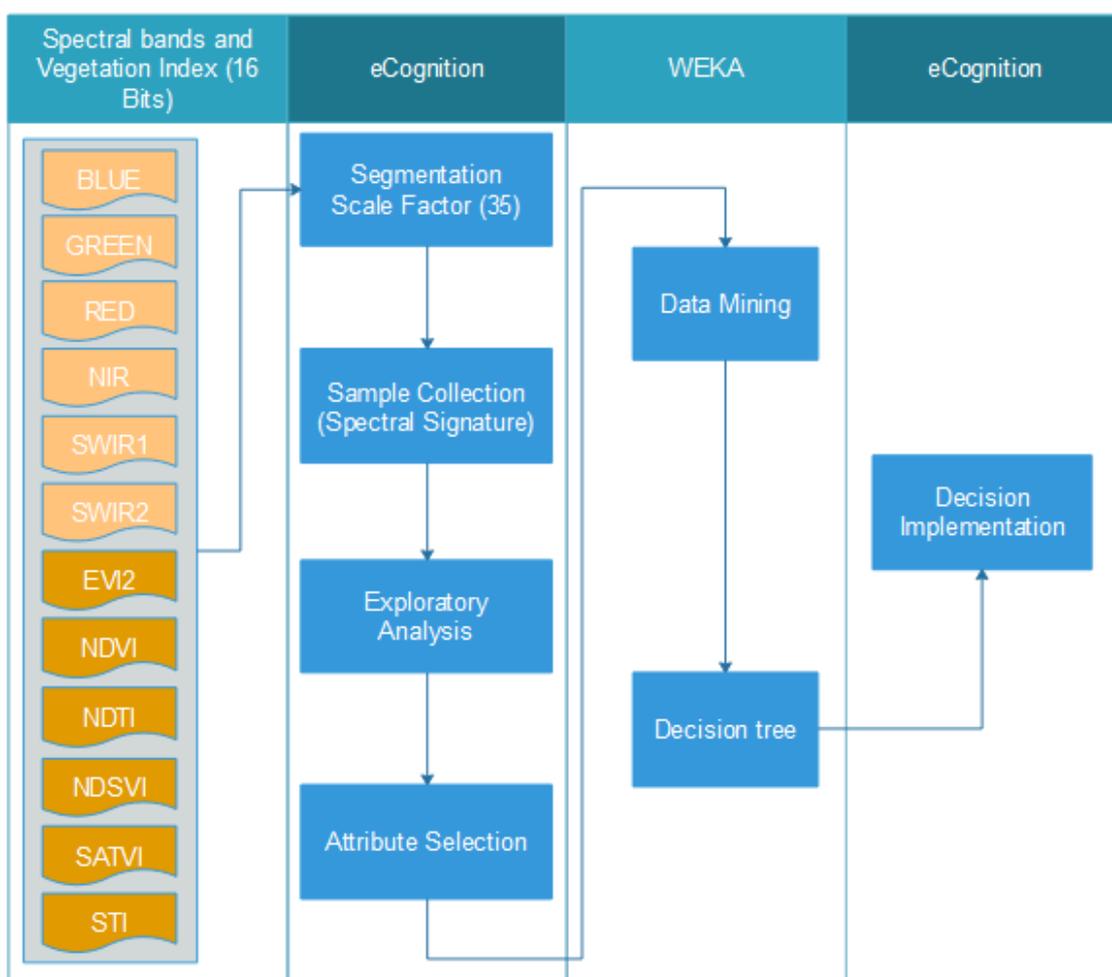
7

8 **GEOBIA e Mineração de Dados**

9 Todos os passos para classificar as áreas de PD e PC estão
 10 representados na Figura 4. Essa análise utilizou o GEOBIA (*Geographic*
 11 *Object-Based Image Analysis*) e a mineração de dados (MD) aplicadas nas
 12 imagens dos satélites Landsat 5 e 8, que busca aprimorar e auxiliar no
 13 processamento de classificação das imagens. Assim, permitiu explorar as
 14 relações espaciais, formas e semânticas entre regiões, juntamente com suas
 15 características espectrais (GARCIA-PEDRERO et al., 2015). O processamento
 16 das imagens por algoritmo de segmentação multiresolução, define segmentos
 17 como regiões geradas por um ou mais critérios de homogeneidade em uma ou
 18 mais dimensões do espaço de atributos (BLASCHKE, 2010).

19 A Figura 3 demonstra os ambientes computacionais (eCognition
 20 Developer® e a plataforma WEKA® (*Waikato Environment for Knowledge*
 21 *Analysis*) para cada etapa da análise geográfica de imagem baseada em
 22 objetos (GEOBIA) somado a abordagem de MD. O software eCognition®

1 desenvolvido pela empresa Trimble GeoSpatial utiliza o método de
 2 classificação orientado a objetos para interpretar as imagens (GAO et al.,
 3 2019), enquanto que o WEKA® é um conjunto equipado com algoritmos de
 4 aprendizagem para tarefas de mineração de dados, avaliação estatística dos
 5 esquemas de aprendizado e a visualização dos dados de entrada e do
 6 resultado do aprendizado desenvolvido pela Universidade de Waikato, na Nova
 7 Zelândia (KALMEGH, 2015).



8

9 FIGURA 3: Fluxograma ilustrando as principais etapas que fazem parte do
 10 GEOBIA e mineração de dados e a abordagem proposta para classificar as
 11 áreas de plantio direto e convencional a partir de imagens de séries temporais
 12 dos satélites Landsat 5 e 8.

13 As etapas propostas no fluxograma foram a junção das imagens
 14 com modificação da resolução radiométrica, configuração dos fatores da
 15 segmentação, segmentação das imagens, seleção dos objetos para geração
 16 do conjunto de treinamento, mineração dos dados, interpretação e avaliação da

1 árvore de decisão, classificação dos dados multitemporais por meio de
2 implantação da decisão e validação da classificação.

3 A segmentação multirresolução foi realizada no eCognition®, no qual
4 os objetos desenvolvidos (polígonos) foram expostos à decisão de
5 heterogeneidade, que pode ser ajustada selecionando o parâmetro de escala,
6 os pesos das bandas espectrais, os fatores de forma e compactação. O ajuste
7 de um parâmetro de escala pode influenciar o tamanho dos segmentos
8 desenvolvidos.

9 Na segmentação multiresolução, a regra de similaridade foi
10 estabelecida a partir da heterogeneidade do conceito de regiões internas. A
11 heterogeneidade foi estabelecida a partir da diferença entre o atributo de uma
12 região provável e a soma dos valores entre esse atributo nas regiões que os
13 compõem. Além disso, a heterogeneidade dos atributos de cor e forma, que
14 foram ajustados de acordo com o tamanho dos objetos, foi calculada durante a
15 segmentação. A soma ponderada dessas duas heterogeneidades formou o
16 critério de similaridade f , conforme expresso pela Eq. 11.

$$17 \quad f = w \cdot h_{color} + (1 - w) \cdot h_{form} \quad [Eq. 11]$$

18 em que: w é o peso do atributo de cor no processo de segmentação (0.1), h_{color}
19 é a heterogeneidade da cor e h_{form} é a heterogeneidade da forma.

20 A cor é criada a partir de uma soma estimada dos desvios padrão de cada
21 banda em uma região específica. Cada peso da banda é definido pelo analista
22 (0,1) Eq. 12 representa a cor.

$$23 \quad color = \sum_c w_c \cdot \sigma_c \quad [Eq. 12]$$

24 em que: w_c é o peso atribuído de cada banda multiespectral, σ é o desvio
25 padrão e c é a nomenclatura de cada banda.

26 A seguinte Eq. 13 representa a heterogeneidade da cor.

$$27 \quad h_{color} = \sum_c w_c \left(n_{union} \cdot \sigma_c^{union} - (n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2}) \right) \quad [Eq.13]$$

28

1 em que: n_{union} é o número possível de pixels do objeto a ser formado, σ_c^{union} é o
 2 desvio padrão para o possível objeto a ser formado em cada banda c , n_{obj1} é o
 3 número de pixels do primeiro objeto, σ_c^{obj1} é o desvio padrão do primeiro objeto
 4 em cada banda c , n_{obj2} é o número de pixels do segundo objeto e σ_c^{obj2} é o
 5 desvio padrão do segundo objeto em cada banda c .

6 Forma é um atributo composto; portanto, é necessário incorporar
 7 compacidade, como mostrado nas equações 14 e 15. A suavidade, descrita
 8 pela segunda equação abaixo, é a razão entre o perímetro do objeto e a caixa
 9 delimitadora (isto é, o retângulo circundante que é paralelo às bordas da
 10 imagem e tem o menor comprimento possível).

$$11 \quad cp = \frac{l}{\sqrt{n}} \quad [\text{Eq. 14}]$$

$$12 \quad st = \frac{l}{b} \quad [\text{Eq. 15}]$$

13 Nas equações acima, l é o perímetro do objeto, n é o tamanho do
 14 objeto descrito como o número de pixels e b é o perímetro da caixa
 15 delimitadora.

16 A heterogeneidade da forma é a soma ponderada das
 17 heterogeneidades de compacidade e suavidade, em que o peso é definido pelo
 18 analista (Eq. 16). A Eq. 17 expressa a heterogeneidade da compactação
 19 enquanto a Eq. 18 mostra a heterogeneidade da suavidade.

$$20 \quad h_{form} = w_{cp} \cdot h_{cp} + (1 - w_{cp})h_{st} \quad [\text{Eq. 16}]$$

$$21 \quad h_{cp} = n_{union} \cdot cp_{union} - (n_{obj1} \cdot cp_{obj1} + n_{obj2} \cdot cp_{obj2}) \quad [\text{Eq. 17}]$$

$$22 \quad h_{st} = n_{union} \cdot st_{union} - (n_{obj1} \cdot st_{obj1} + n_{obj2} \cdot st_{obj2}) \quad [\text{Eq. 18}]$$

23 Nas equações acima, w_{cp} é o peso atribuído à compactação (0,1),
 24 h_{cp} e h_{st} são as heterogeneidades de compactação e suavidade,
 25 respectivamente, cp_{union} é a compactação do possível objeto a ser formado em
 26 cada banda c , cp_{obj1} e cp_{obj2} são a compactação do primeiro e do segundo em
 27 cada banda c , atordoamento é a compactação do possível objeto a ser formado

1 em cada banda c , e st_{obj1} e st_{obj2} são a compactação do primeiro e segundo
 2 objetos em cada banda c .

3 Em comparação com os métodos baseados em pixel, a abordagem
 4 baseada em objetos ofereceu a possibilidade de avaliar áreas por
 5 características espectrais, texturais, contextuais e hierárquicas. As categorias
 6 de objetos podem ser caracterizadas nos dois grupos a seguir (Tabela 2): 1 -
 7 informações espectrais dos objetos com base em valores médios e desvio
 8 padrão; e 2 - informações espectrais texturais baseadas na matriz de
 9 coocorrência de nível de cinza (GLCM) proposta por Haralick et al. (1973) e
 10 implementado por Definiens (2006).

11 *Tabela 2: Descrição das características espectrais e texturais na composição*
 12 *da GEOBIA.*

Category/Name	Equations
Object spectral	
Mean	$\frac{1}{\#P_{Obj}} \sum_{(x,y) \in P_{Obj}} C_k(x,y)$
Standard deviation	$\sqrt{\frac{1}{\#P_{Obj}} \sum_{(x,y) \in P_{Obj}} \left(c_k(x,y) - \frac{1}{\#P_{Obj}} \sum_{(x,y) \in P_{Obj}} c_k(x,y) \right)^2}$
Object texture	
GLCM homogeneity	$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$
GLCM dissimilarity	$\sum_{i,j=0}^{N-1} P_{ij} i - j $
GLCM entropy	$\sum_{i,j=0}^{N-1} P_{ij} (-\ln P_{ij})$

13

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

- 1 $\#P_{Obj}$ = número total de pixels contidos em P_{Obj} ;
- 2 $c_k(x, y)$ = valor da camada de imagem em pixel (x, y) , em que (x, y) são
- 3 coordenadas de pixel;
- 4 i = o número da linha da matriz de coocorrência;
- 5 j = o número da coluna da matriz de coocorrência;

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}}$$

- 6 $P_{i,j}$ = o valor normalizado na célula i,j ;
- 7 $V_{i,j}$ = o valor na célula i, j da matriz de coocorrência;
- 8 N = o número de linhas ou colunas da matriz de coocorrência.

9 Todas as bandas espectrais e os índices utilizados foram
 10 processados ao mesmo tempo durante a segmentação, com isso garantiu a
 11 homogeneidade dos objetos. Na tabela 3 está representado o resumo das
 12 variáveis e parâmetros utilizados na segmentação.

13 *Tabela 3: Resumo das variáveis e parâmetros utilizados na segmentação.*

Segmentation Variables

Image	Weight
BLUE	0.5
GREEN	0.5
RED	0.5
NIR	0.5
SWIR1	0.5
SWIR2	0.5
EVI2	1

NDVI	1
NDTI	1
NDSVI	1
SATVI	1
STI	1

Scale Parameter

Scale	35
-------	----

Homogeneity of Composition Criterion

Form	0.1
Compactness	0.5

1

2 As classes de objetos da amostra (Plantio Convencional - PC,
3 Plantio Direto A - PD_A e Plantio Direto B - PD_B) foram selecionadas
4 conforme os pontos de amostra em campo e com auxílio de alguns artigos que
5 utilizaram os índices. No treinamento foi selecionado um total de 468 objetos,
6 dos quais 77 pertenciam à classe de plantio convencional (PC), 176 a classe
7 plantio direto A (PD_A) e 215 a classe plantio direto B (PD_B).

8 Depois de construído o conjunto de treino, a plataforma eCognition®
9 foi utilizada para extrair os atributos (Tabela 4), consideradas como as mais
10 representativas das classes de interesse. Os atributos selecionados foram
11 espectral, espacial e textural, conforme BLASCHKE (2010).

12 Na classificação foram inseridos todos os processos filhos, sendo
13 utilizado o algoritmo classification, em que as regras são inseridas nas próprias
14 classes (Plantio Convencional - PC, Plantio Direto A - PD_A e Plantio Direto B -
15 PD_B). Após a etapa de classificação foi inserido um processo com o algoritmo
16 merge region. Assim, os objetos de cada classe são agrupados em objetos
17 maiores.

1 A fase de mineração de dados envolve a seleção e aplicação de
2 técnicas inteligentes, a fim de extrair padrões de interesse e desenvolvimento
3 de conhecimento. O termo conhecimento é sinônimo de padrões de
4 comportamento de cada classe. O algoritmo utilizado para a árvore de decisão
5 foi o J48 para executar a tarefa de mineração de dados, operado no programa
6 computacional WEKA® do famoso algoritmo de treinamento em árvore C4.5
7 (WITTEN e FRANK, 2005; QUINLAN, 2014).

8 O algoritmo J48 é uma implementação do C4.5 que escolhe um
9 atributo para dividir os dados em dois subconjuntos, com base no maior ganho
10 de informação normalizada (diferença de entropia). O algoritmo repete este
11 procedimento em cada subconjunto até que todos os casos passem a
12 pertencer à mesma classe. Assim, um nó de folha é criado na árvore de
13 decisão. As vantagens do modelo de classificação em árvore de decisão são
14 fáceis de entender e identificadas com precisão comparável a outros modelos
15 de classificação (CRUZ e TUMIBAY, 2019).

16 Em seguida, após o treinamento e avaliação da árvore de decisão,
17 os atributos extraídos das bandas espectrais e dos índices de vegetação foram
18 classificados para mapear áreas de plantio convencional, plantio direto A e
19 direto B para os anos-safras estudados.

20 O conjunto de regras definidas pelos atributos e seus respectivos
21 limites identificados pelo algoritmo J48, durante as fases de mineração de
22 dados, constituem a árvore de decisão. A estrutura entre os atributos e os
23 limiares foi implementado manualmente no eCognition® (DEFINIENS, 2006).
24 Neste programa computacional da classificação hierárquica é então realizada
25 uma programação de classificação de acordo com o conjunto de regras da
26 árvore de decisão, gerando um mapa temático com as três classes de
27 interesse (PC, PD_A e PD_B). Todo o processo pode ser visualizado e
28 sintetizado pela figura 4, conforme adaptado de Hsu et al., 2002.

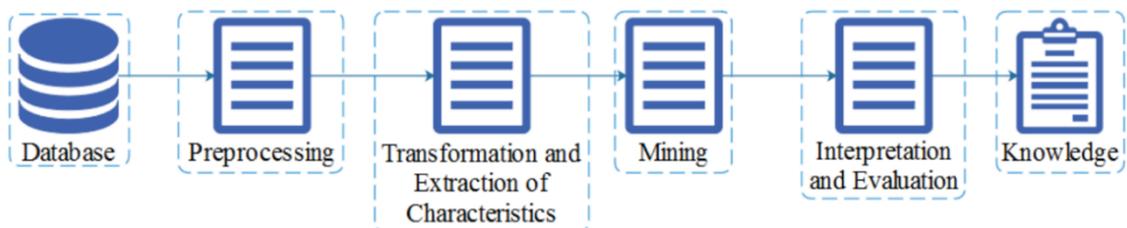
29 *Tabela 4: Atributos extraídos do eCognition® para selecionar as classes PC,*
30 *PD_A e PD_B.*

Type	Name	Value Range	Characteristics
------	------	-------------	-----------------

Spectral	Mean	$[C_k^{min}, C_k^{max}]$
	Standard deviation	$[0, \frac{1}{2} C_k^{range}]$
		C_k^{min} : darkest possible intensity value
		C_k^{max} : brightest possible intensity value
Geometry	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
Texture	GLCM homogeneity	[0, 90]
	GLCM contrast	[0, 90]
	GLCM dissimilarity	[0, 90]
	GLCM entropy	[0, 90]
Custom	BLUE	[0,1000]
	GREEN	[0,1000]

RED	[0,1000]
NIR	[0,1000]
SWIR1	[0,1000]
SWIR2	[0,1000]
EVI2	[0,200]
NDVI	[0,200]
NDTI	[0,200]
NDSVI	[0,200]
SATVI	[0,200]
STI	[0,200]

1



2

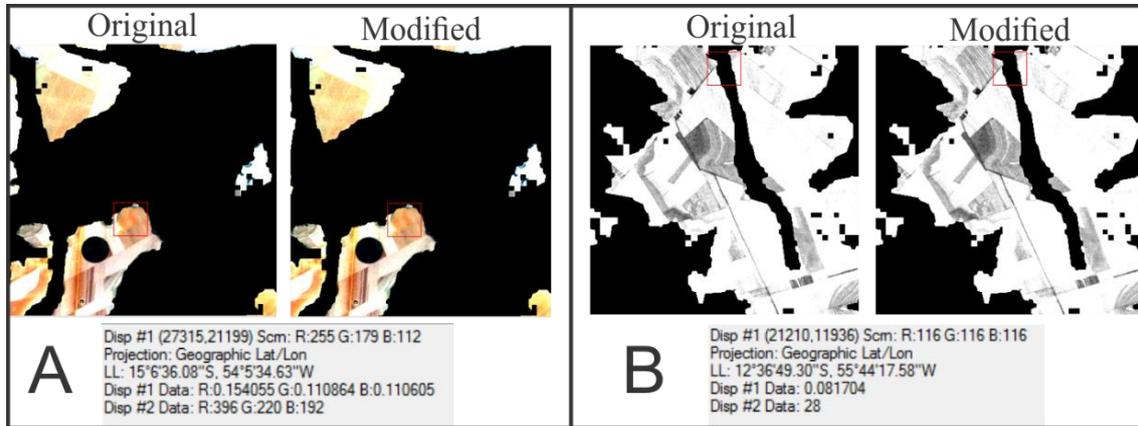
3 FIGURA 4: Fluxograma representativo do processo de mineração de dados.

4 **Pré-Processamento da Imagem Multiespectral**

5 O pré-processamento das imagens multiespectrais dos satélites
 6 Landsat 5 e 8 foi realizada por meio do software Arcgis® com a finalidade de
 7 analisar previamente as bandas espectrais e os índices de vegetação,
 8 verificando se os valores estão corretos. As imagens GeoTIFF adquiridas
 9 encontram-se com uma resolução radiométrica de 32 bits e para as imagens
 10 serem processadas pelo software eCognition Developer®, as mesmas foram
 11 redimensionadas pelo software ENVI®.

12 Utilizando a função STRETCH no ENVI® os valores das bandas
 13 espectrais foram originalmente redimensionados para os valores de mínimo 0 e

1 máximo 1000 e os valores dos índices de vegetações para mínimo 0 e máximo
2 200, conseguindo assim uma resolução radiométrica de 16 bits para ambas
3 (Figura 5).



4
5 FIGURA 5: Imagem originais e modificadas pelo ENVI. A: Bandas e B: Índices
6 de Vegetação.

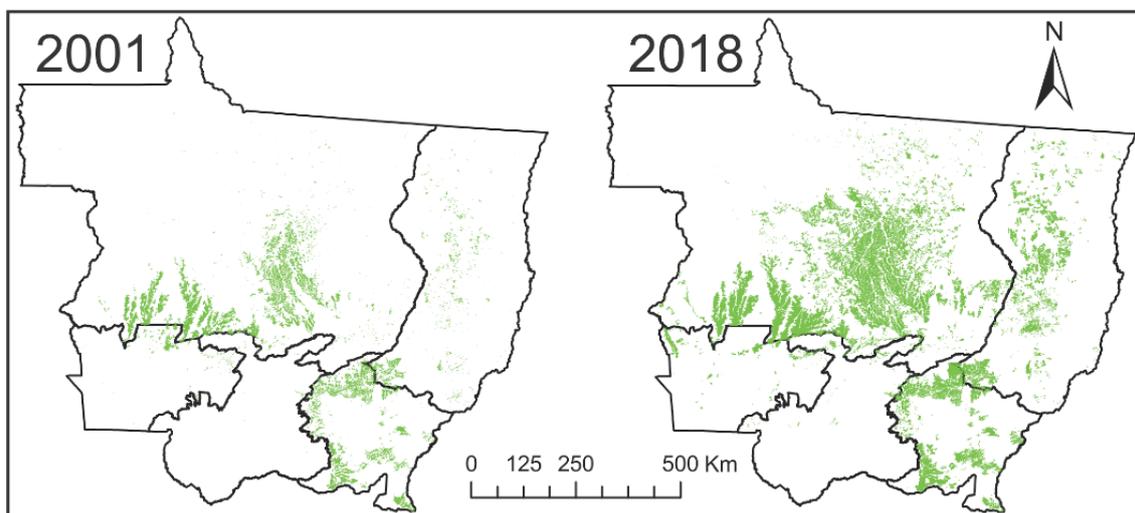
7

8

1 RESULTADOS E DISCUSSÃO

2 Identificação de soja no estado de Mato Grosso

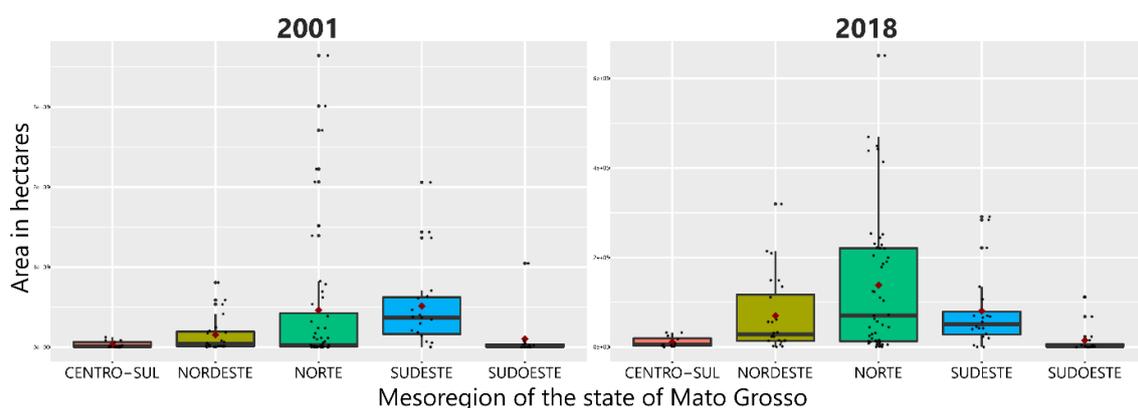
3 A detecção de soja no estado de MT para os anos safra de
4 2000/2001 e 2017/2018 por meio do sensor MODIS, conforme Silva Junior et
5 al., (2017), foi realizado com sucesso na criação da máscara de soja (Figura 6).
6 Vale ressaltar que outros trabalhos já aplicaram metodologias oriundas do
7 sensoriamento remoto para o monitoramento de soja, sua correlação com o
8 desmatamento e políticas públicas (GUSSO et al., 2013; SPERA et al., 2013;
9 KASTENS et al., 2017; SILVA JUNIOR e LIMA, 2018; SILVA JUNIOR et al.,
10 2019).



11
12 FIGURA 6: Mapeamento da soja no ano safra 2000/2001 e 2017/2018 no
13 estado do Mato Grosso por mesorregiões (Sudeste, Centro Sul, Sudoeste,
14 Nordeste e Norte) pelo sensor MODIS.

15 Destaque para a expansão nas áreas de cultura da soja do ano safra
16 de 2000/2001 para o ano safra de 2017/2018 no estado do MT (Figura 7). É
17 possível observa na Figura 7 que os valores mapeados da cultura de soja nas
18 mesorregiões estão distribuídos no terceiro quartil. Essa concentração se dá ao
19 fato de que a soja no estado do Mato Grosso está presente em grandes áreas
20 planas. Assim, a concentração das áreas em média de tamanho dos polígonos
21 variam entre 3.254,431 a 51.378,636 hectares, em que na mesorregião Centro
22 Sul e Sudeste estão entre 11.524,003 a 80.941,568 hectares para nos anos
23 safras de 2000/2001 e 2017/2018, respectivamente.

1 A mesorregião Norte para o ano safra de 2017/2018 apresentou uma
 2 discrepância no limite superior, com área de 469.377,379 hectares e sua
 3 mediana de 70.384,307 hectares, o que demonstra que essa mesorregião
 4 estão presentes as maiores áreas de cultivo. No ano safra 2000/2001 a
 5 mesorregião Norte apresentou maior registro de áreas como *outliers*,
 6 mostrando que a explosão do avanço da soja na região logo no início foi
 7 intenso, devido a topografia, fertilidade e clima para o cultivo da soja.



8

9 FIGURA 7: Boxplot das mesorregiões do estado do Mato Grosso em hectares
 10 (ha) da detecção de soja no ano safra 2000/2001 e 2017/2018.

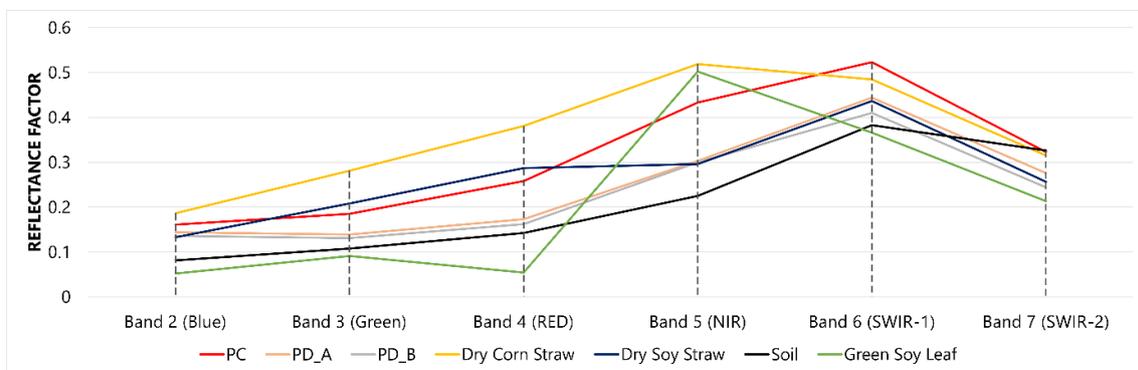
11 Este aumento na proporção do plantio de soja nos anos avaliados no
 12 estado do MT mostrou que a soja teve uma valorização no preço e melhor
 13 acessibilidade ao mercado em relação as outras commodities no Brasil e no
 14 mundo ao passar destes 18 anos (RICHARDS et al., 2012), houve também a
 15 inversão de pastagem para o plantio de soja (PARENTE et al., 2019) e a
 16 abertura de novas áreas com o avanço da fronteira agrícola (GIBBS et al.,
 17 2010) no decorrer desta série temporal. Outro ponto que merece destaque é o
 18 avanço das tecnologias, que por sua vez proporciona uma série de técnicas
 19 (isto é, cultivares de soja, herbicidas, melhoramento no plantio
 20 direto/convencional e semeadura) que tornaram a cultura da soja
 21 proporcionalmente competitiva em relação a outros manejos, sendo agregado
 22 produtividade e lucratividade maior (DIAS et al., 2016).

23 Índices espectrais

24 A interação da energia eletromagnética com solo pode variar devida
 25 à presença de umidade, conteúdo de matéria orgânica presente, a presença de

1 óxido de ferro, pela proporção de argila, silte, areia e a rugosidade do solo. As
2 assinaturas espectrais usadas no trabalho foram de áreas de cultivo de soja
3 determinada pela máscara de soja extraída pelos algoritmos implementados no
4 Google Earth Engine. Os pontos amostrais extraídos foram selecionados no
5 período de seca no estado do Mato Grosso, julho à setembro, para que as
6 bandas espectrais não sofressem extrema interferência com a umidade e o
7 mais próximo possível do preparo do solo para a semeadura da soja (CONAB,
8 2019; YUE et al., 2019). Pontos amostrais selecionados no mapa sempre
9 apresentavam no solo resíduos da palhada da cultura de milho e soja ou
10 palhada de pastagem seca ou em estado de decomposição.

11 Resíduos contidos no solo afetam diretamente na leitura das bandas
12 espectrais por variarem em quantidade ou até mesmo em qual estágio de
13 decomposição que se encontra (SHABOU et al., 2015; QUEMADA et al., 2018).
14 Na figura 8, a leitura espectral de PC, PD_A e PD_B são diferentes durante o
15 comprimento afetadas diretamente por esses fatores assim já descritos. O
16 PD_A e PD_B apresentam maiores quantidades de matéria orgânica, e como
17 consequência maior será a absorção de energia incidente e menor a
18 reflectância espectral. No PC tendo o uso de grade ou niveladora no preparo
19 do solo, os resíduos não são totalmente incorporados ao solo, logo não temos
20 um solo totalmente descoberto. A utilização da grade ou niveladora podem
21 mudar a rugosidade do solo, faz com que o comportamento de onda varie na
22 mesma área de semeadura (PAUL OBADE et al., 2014; ESKANDARI et al.,
23 2016; NAJAFI et al., 2018).



24

25 FIGURA 8: PC, PD_A, PD_B, Dry Corn Straw, Dry Soy Straw, Soil and Green
26 Soy Leaf behavior at the Landsat 8 wavelength.

1 Outro fator que foi observado na análise do comprimento de onda
2 das bandas espectrais foi à textura do solo, analisando o comportamento da
3 onda espectral do solo adquirido da Biblioteca Espectral de Solos do Brasil do
4 município de Querência no estado do MT (BESB, 2019) que tem em sua
5 análise física 14% de areia, 36% de silte e 50% de argila. Este solo tendo a
6 maior presença de argila o comprimento de onda será baixo devido à maior
7 presença de água, quanto maior a umidade do solo, maior será a absorção de
8 energia radiante incidente e, portanto, menor será a quantidade de radiação
9 refletida.

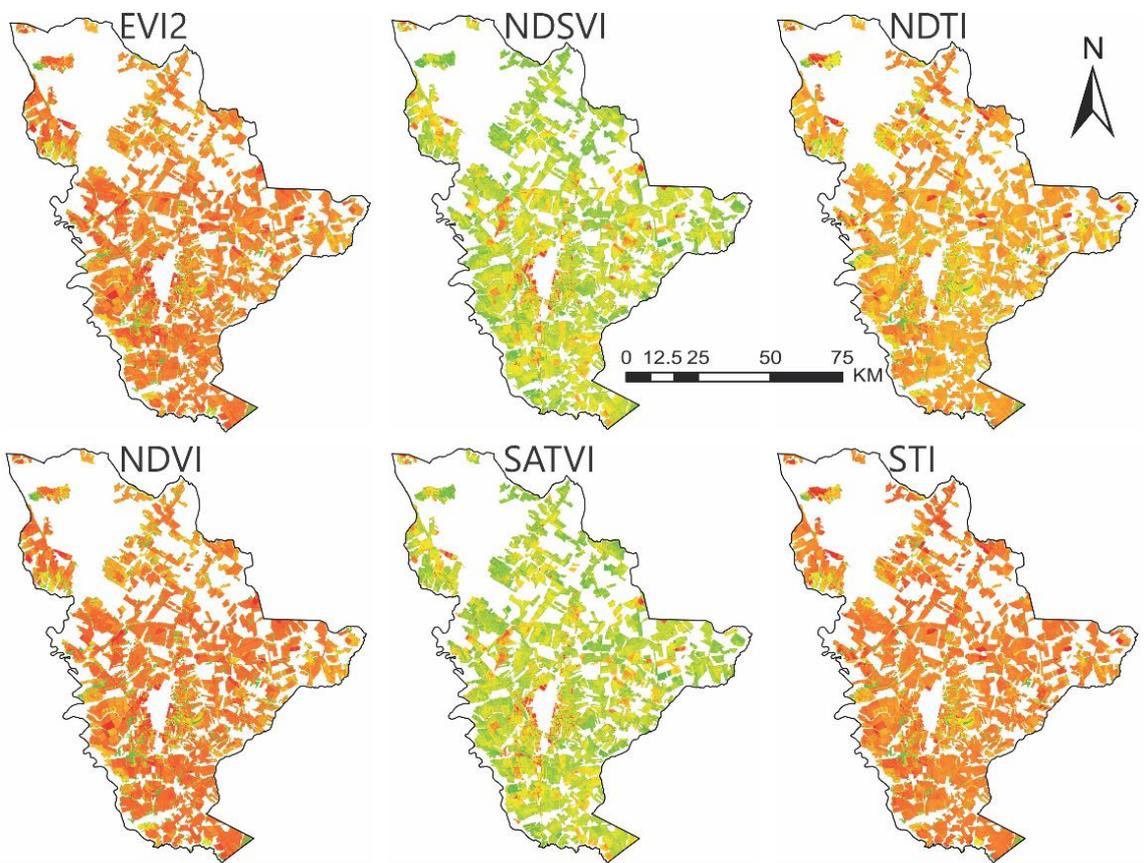
10 Observa-se na região do visível (0.38 - 0.76 μ m) a folha da soja
11 verde em comparação com os outros (PC, PD_A, PD_B, Palhada de Milho
12 Seco, Folha de Soja Seca e solo) tem uma absorção maior e assim uma
13 Reflectância espectral menor, pois nesta região a clorofila contida nas folhas
14 absorve a energia incidente entre 0.43 - 0.45 μ m e 0.65 - 0.66 μ m. O
15 comportamento da onda espectral na região do infravermelho próximo (NIR) na
16 vegetação verde é de uma absorção menor da radiação eletromagnética (REM)
17 tendo um pico considerado alto da região do visível (MOTOHKA et al., 2010).

18 No PC tendo quase a total ausência do processo fotossintético, o
19 solo mais seco em função da utilização de grade aradora e niveladora (mesmo
20 em solos com maior presença física de areia ou argila) e com a menor
21 presença de resíduos provenientes de pastagens ou de resíduos da agricultura
22 a reflectância permanece maior do que PD_A e PD_B. No entanto as curvas
23 espectrais de PD_A e PD_B apresentam pouca diferenciação, mas essa
24 diferenciação é principalmente devido a presença de resíduos orgânicos e ao
25 estágio que se encontra a decomposição da matéria orgânica sobre o solo
26 (NAGLER et al., 2000; SMITH et al., 2015).

27 O PD_A apresenta maior quantidade de resíduos vegetais com
28 pouca decomposição, tendo solo com pouca presença de plantas e pouca
29 umidade em comparação ao PD_B, que apresenta resíduos em maior
30 decomposição e o solo com maior presença de plantas e umidade. Os resíduos
31 vegetais em estágio menor de decomposição têm menor absorção da radiação
32 eletromagnética e baixos teores de clorofila na planta e também a umidade que

1 absorvem a REM, o comprimento de onda de PD_A permanece maior do que
 2 PD_B (HILL et al., 2017).

3 As curvas espectrais obtidas em cada ponto amostral denotaram
 4 diferenciações. Observou-se também neste estudo não somente o
 5 comportamento das bandas espectrais para discriminação das áreas de plantio
 6 convencional, plantio direto A e plantio direto B, mas também os índices de
 7 vegetação. Com base nos valores de reflectância dos canais espectrais do
 8 sensor Operational Land Imager (OLI), os índices espectrais foram calculados,
 9 recortou-se o município de Sinop para demonstrar o comportamento dos
 10 índices nas áreas identificadas como plantio de soja (Figura 9).



	EVI2	NDSVI	NDTI	NDVI	SATVI	STI
High	0.682479	0.60731	0.516148	0.831719	0.322102	3.13349
Low	-0.150162	-0.732943	-0.0117356	-0.458682	-0.276152	0.976801

11

12 FIGURA 9: Recorte do município de Sinop-MT, destaque para variabilidade dos
 13 índices (EVI2, NDSVI, NDTI, NDVI, SATVI e STI) para ano safra de 2017/2018.

14 Na figura 9, a resposta espectral dos índices EVI2 e NDVI no
 15 município de Sinop tem uma variação significativa nos pixels de 0.682 a -0.150

1 e 0.831 a -0.458 respectivamente, onde isso indicou a presença de pixels com
2 cobertura vegetal fotossinteticamente ativa realçadas na cor verde. As áreas
3 demonstradas pelo EVI2 e NDVI identificaram a presença de vegetação verde
4 que pode ser justificada pelo manejo da terra para o plantio direto, pois neste
5 tipo de plantio há sempre a presença de ervas daninhas e germinação de
6 sementes da cultura anterior (LÓPEZ-GRANADOS, 2011; KERGOAT et al.,
7 2015; HIVELY et al., 2018; LAMBERT et al., 2018). Os índices EVI2 e NDVI
8 são bem consolidados no meio científico na análise do vigor vegetativo da
9 planta, na definição automática de linhas de cultivo (PEÑA-BARRAGÁN et al.,
10 2012).

11 Na identificação da vegetação verde em senescência, o índice
12 NDSVI demonstrou uma variação de 0.607 a -0.732 e o índice SATVI que
13 utilizou a correlação do solo variaram de 0.322 a -0.276, sendo observado que
14 os dois índices apontam uma quantidade significativa de vegetação presente
15 no estágio de senescência destacado na cor verde para o vermelho. As plantas
16 presentes nesta área estão certamente com stress hídrico, pois a série
17 temporal analisada é na época da seca no estado do MT, mesmo contendo
18 resíduos sobre o solo.

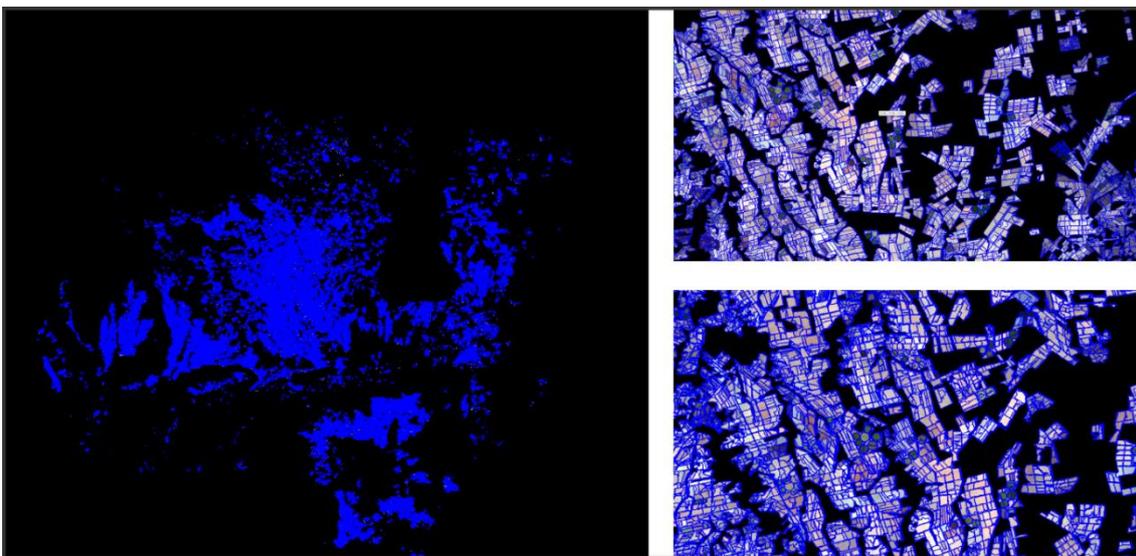
19 Os resíduos de vegetação seca contidos no solo foram observados
20 pelo índice STI, este variou de 3.13 a 0.97, onde quanto maior tonalidade verde
21 maior é a concentração da massa seca no solo. Nas áreas de cultivo de soja
22 sempre há vestígios de resíduos da própria soja deixada pelos maquinários
23 durante a colheita, resíduos do milho plantado ou de pastagem utilizada após o
24 plantio da soja nas áreas consideradas como PC, PD_A e PD_B (NAJAFI et al.,
25 2019; YUE et al., 2019). Mesmo em áreas que se utilizam o PC encontram-se
26 resíduos, pois os mesmos não são totalmente incorporados ao solo. Foi
27 observado que nos pontos amostrais in situ, onde a sucessão do plantio de
28 algodão para o de soja é feito o destocamento dos restos da cultura do algodão
29 pelo maquinário agrícola, sendo assim considerado como PC.

30 A identificação de manejo da terra o índice NDTI demonstrou uma
31 variação de 0.516 a -0.011 no quais as regiões com menos manejo foram
32 destacadas em verdes e inversamente pela cor vermelha. Foi possível

1 visualizar que na região demonstrada na figura 9 o índice NDTI mostrou alta
2 variação de manejo da terra para fins de plantio da soja.

3 **GEOBIA**

4 A segmentação das seis bandas espectrais e seis índices de
5 vegetação foram devidamente divididas em áreas de objetos segmentados
6 através do princípio da homogeneidade em uma ou mais dimensões de um
7 espaço de feição (BLASCHKE, 2010). Para um melhor estudo de dados dos
8 objetos adquiridos na segmentação das 12 imagens foi utilizado uma escala
9 (DRĂGUȚ et al., 2010) que não criasse objetos menores, e se os objetos são
10 bem pequenos, os parâmetros de textura também são frequentemente
11 expostos a um alto nível de variabilidade (Figura 10).



12

13 FIGURA 10: Segmentação hierárquica de multiresolução para o ano safra
14 2017/2018 no estado do Mato Grosso.

15 A segmentação das imagens apresentaram uma variação de objetos
16 aceitável para a coleta de dados com base no método heurístico, outros
17 trabalhos utilizaram metodologia similar de segmentação para analisar as
18 alterações da cobertura e uso da terra (SOUZA-FILHO et al., 2018; XI et al.,
19 2019), detecção de áreas irrigadas por pivô central (VOGELS et al., 2019),
20 discriminação de ervas daninhas (LÓPEZ-GRANADOS, 2011; DE CASTRO, et
21 al., 2013; CASTILLEJO-GONZÁLEZ, et al., 2014).

1 Com base nas informações das imagens segmentação a seleção
2 dos objetos, foi feita através da seleção de 468 objetos definidos entre PC,
3 PD_A e PD_B levando em consideração as diretrizes definidas na tabela 1
4 como pode ser observado na figura 11. Autores como Piper (1987) e MATHER
5 e KOCH (2011), consideram uma coleta de amostra satisfatório em um
6 treinamento de 10 a 30 vezes o número de características. VAN NIEL et al.
7 (2005) considera que uma coleta de amostra satisfatória é necessária somente
8 2 a 4 vezes o número de características para obter uma precisão. No entanto,
9 BO e DING (2010) demonstram que a coleta de amostra de 2 a 3 vezes do
10 número de características em um treinamento para uma classificação baseada
11 em objetos está muito abaixo do exigido. Nenhum trabalho aponta
12 concretamente qual a quantidade necessária de amostras em um treinamento
13 com base na classificação por objetos.

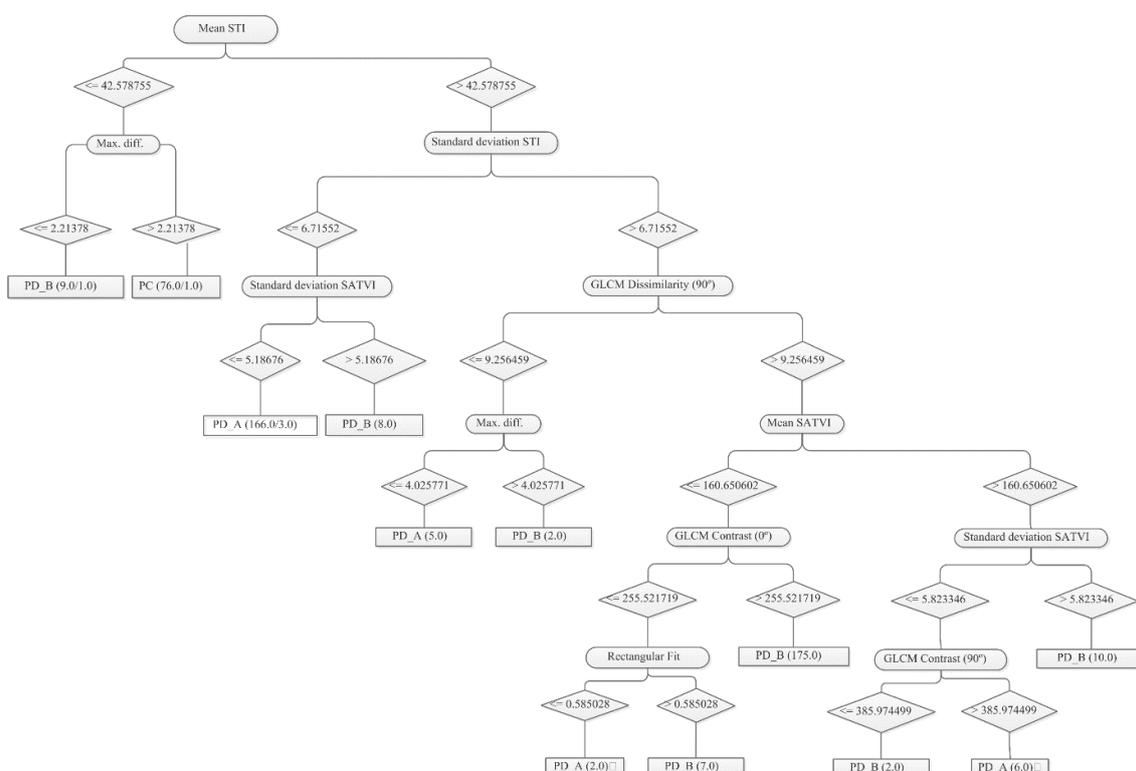


14

15 FIGURA 11: Seleção das características PC, PD_A e PD_B nos objetos.

16 Objetos amostrais selecionados foram exportados com os atributos
17 definidos pela tabela 4 no software eCognition®, uma planilha contendo 45
18 colunas e 940 linhas foi gerado para implementação do treinamento e criação

1 de uma árvore de lógica pelo software WEKA® utilizando o algoritmo não-
 2 paramétrico C4.5/J48. O processo de criação da lógica da árvore identificou a
 3 definição de um limiar no índice STI no primeiro ramo da árvore (Figura 12),
 4 onde os valores variaram de 0 a 200 e um valor de corte nesta ramificação foi
 5 de 42,57. Silva Junior et al. (2019) utilizaram o software WEKA® e geraram
 6 uma árvore de decisão pelo algoritmo C4.5/J48, sendo definido pelos valores
 7 dos índices de vegetação um limiar de corte no *crop enhancement index* (CEI)
 8 de ≤ 0.3734 onde era soja e não soja.



9

10 FIGURA 12: Modelo de árvore de decisão concebido por meio de C4.5 / J48.

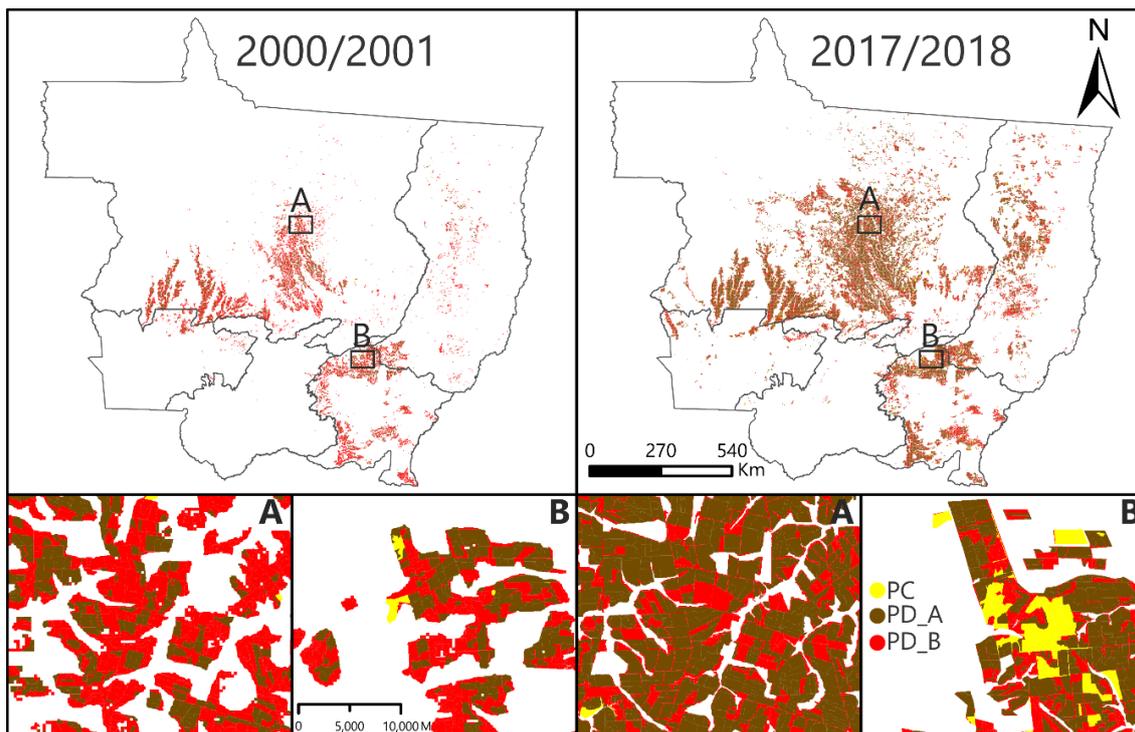
11 A árvore tem um total de 23 ramificações com 12 pontas (folhas) das
 12 características definidas nos pontos amostrais, em suas ramificações foi
 13 identificada somente uma que faz referência ao PC. Onde tem um limiar de
 14 corte na média do *Soil Tillage Index* (STI) no valor menor e igual a 42,57 e a
 15 máxima diferença maior que 2,21 ao qual esse limiar foi baseado nas bandas
 16 espectrais e índices de vegetação da coleta de amostras sobrepostas, nesta
 17 mesma ramificação os valores de máxima diferença maiores que 2,21 foi
 18 definido como plantio direto B (PD_B).

1 Ao derivar o primeiro limiar de corte da árvore o atributo desvio
2 padrão do índice STI que indicou a dispersão dos dados dentro de uma
3 amostra com relação à média. Essa variação dentro dos dados amostrais
4 variou de 0,85 a 42,74 com um limiar de corte 6,71 na árvore, no limiar menor e
5 igual encontra-se 237 objetos amostrais. Trabalhos que apresentaram
6 resultados bem-sucedidos atribuem o índice STI na estimativa fracionária
7 vegetação fotossintética, não fotossintética e solo nu (VAN DEVENTER et al.,
8 1997; JACQUES et al., 2014; WANG et al., 2019).

9 Outro índice utilizado pela árvore foi o SATVI com um limiar de corte
10 na sua ramificação de 160,650602 para diferenciar o plantio direto A e B (PD_A
11 e PD_B). O SATVI é índice de infravermelho de ondas médias e curtas que
12 corresponde a verificar a cobertura vegetal e senescente, prevê a cobertura
13 vegetal mais eficaz do que outros índices de vegetação (MARSETT et al.,
14 2006; VILLARREAL et al., 2016). Goirán et al. (2012) apontam que
15 conseguiram observar as alterações da vegetação associadas ao uso da terra
16 com o índice espectral de vegetação SATVI, que não foram detectados por
17 outros índices.

18 **Resultados de Classificação e Acurácia dos Resultados**

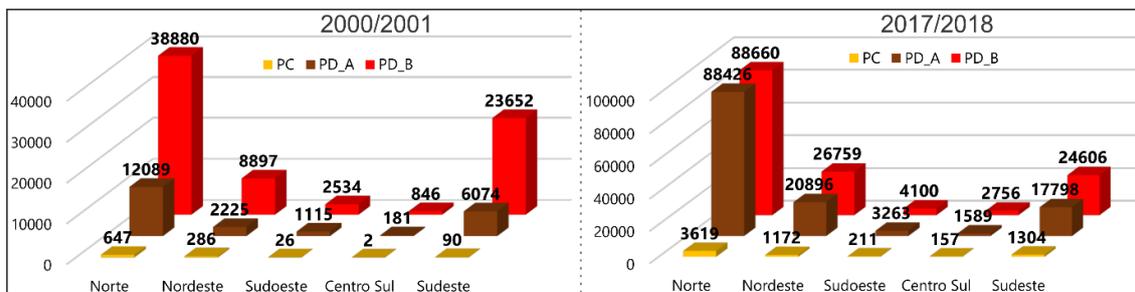
19 Com base nos resultados da árvore de decisão a partir do algoritmo
20 C4.5/J48 e nos dados de treinamento, o mapa temático final que representou
21 as áreas dos tipos de plantios foram demonstrados na Figura 13. Os objetos
22 cujas cores em amarelo, marrom e vermelho representam respectivamente
23 áreas de PC, PD_A e PD_B dos anos/safras de 2000/2001 e 2017/2018. Cada
24 objeto classificado pela GEOBIA e a MD foi designado pela árvore de decisão
25 com cada característica. No resultado gerado pela classificação automatizada
26 feita pela árvore de decisão, encontrou-se nos anos/safras 2000/2001 e
27 2017/2018 respectivamente um total de 97544 e 285316 objetos/polígonos
28 classificados entre as classes de PC, PD_A e PD_B.



1

2 FIGURA 13: Mapa temático do ano/safra 2000/2001 e 2017/2018 da árvore de
 3 decisão.

4 Os objetos/polígonos contidos nos dois mapas temáticos foram
 5 divididos em mesorregiões e quantificados para cada classe (figura 14), no
 6 ano/safra de 2017/2018 tivemos um aumento de 292.5% de objetos/polígonos
 7 classificados em comparação a 2000/2001. Nas mesorregiões Centro Sul
 8 (437.51%), Nordeste (428.01%) e Norte (350.01%) houve um aumento
 9 significativo pela classificação, mas nas regiões Sudoeste e Sudeste tiveram
 10 um aumento de 206.09% e 146.59% respectivamente. O resultado gerado pela
 11 árvore de decisão são formas de representar o conhecimento que são gerados
 12 de maneira supervisionada a partir de algoritmos como o C4.5/J48.



13

14 FIGURA 14: Quantificação de objetos/polígonos em cada mesorregião do
 15 estado de Mato Grosso nos anos/safras de 2000/2001 e 2017/2018 de soja.

1 A matriz de confusão (figura 15) retirada do processamento do
 2 algoritmo C4.5/J48, foi gerada após o cruzamento de 468 pontos amostrais de
 3 referência com o mapa obtido pela segmentação. A caracterização das áreas
 4 com os tipos de plantios com base na metodologia GEOBIA e MD obteve um
 5 mapa temático cujos coeficientes de precisão global (95.29%) e Kappa (K) -
 6 (0.92), respectivamente. Segundo os autores Landis e Koch (1977), para
 7 valores de Kappa entre 0.80 e 1 há uma concordância quase perfeita na
 8 interpretação para a medição do grau de concordância entre proporções
 9 derivadas de amostras dependentes. Em relação a precisão global atingida na
 10 classificação do algoritmo para geração do mapa temático indicam uma boa
 11 qualidade, pois segundo Foody (2002) é desejável que uma classificação atinja
 12 um percentual de acerto superior a 85%.

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

Correctly Classified Instances	446	95.2991%
Incorrectly Classified Instances	22	4.7009%
Kappa statistic	0.9241	
Mean absolute error	0.0379	
Root mean squared error	0.1737	
Relative absolute error	9.1668%	
Root relative squared error	38.1897%	
Total Number of Instances	468	

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
	0,955	0,024	0,960	0,955	0,957	0,932	0,969	0,934	PD_A
	0,958	0,047	0,945	0,958	0,952	0,910	0,959	0,931	PD_B
	0,935	0,008	0,960	0,935	0,947	0,937	0,951	0,910	PC
Weighted Avg.	0,953	0,032	0,953	0,953	0,953	0,923	0,962	0,929	

=== Confusion Matrix ===

a	b	c		<-- classified as		
168	8	0		a	=	PD_A
6	206	3		b	=	PD_B
1	4	72		c	=	PC

14 FIGURA 15: Taxa de precisão da árvore de decisão C4.5/J48 retirado do
 15 software Weka®.

16

17

1 **CONCLUSÃO**

2 O trabalho mostra de forma clara a viabilidade da integração de
3 técnicas de análise de imagem baseada em objetos (GEOBIA) e mineração de
4 dados para mapear os tipos de preparo de solo para o plantio de soja a partir
5 de uma série temporal de imagens dos satélites Landsat 5 e 8 com resolução
6 espacial de 30 m, quantização de 16 bits e com resolução espectral moderada.
7 A classificação das imagens segmentadas apresenta um nível de exatidão
8 aceitável, conforme os coeficientes de precisão global e Kappa,
9 respectivamente. Essa elevada exatidão é obtida por um conjunto de amostra
10 de 468 objetos, com base na validação cruzada (10 vezes), onde esses pontos
11 amostrais são divididos de forma sucessiva em amostras de treinamento e
12 validação pelo algoritmo C4.5/J48.

13 Vale ressaltar que uso da metodologia desenvolvida é vital para
14 distinção do tipo de preparo do solo para o plantio de soja ou até mesmo para
15 outro tipo de lavoura. Destaque para possibilidade de integrar o GEOBIA e a
16 mineração de dados para simular o conhecimento de uma pessoa, já que a
17 árvore de decisão obtida de forma automatizada é capaz de distinguir na época
18 de preparo do solo qual o tipo ali presente, usando atributos espectrais e de
19 textura. A Árvore de Decisão permite a exploração de uma série temporal de
20 imagens e, ainda considera as características da dinâmica temporal obtidas
21 pelo sensoriamento remoto.

22 Diferentes atributos extraídos dos objetos gerados pela
23 segmentação são decisivos para garantir o desempenho satisfatório da
24 metodologia aplicada, os atributos de textura são relevantes quando os objetos
25 se encontram em áreas com diferente rugosidade (variação espectral na banda
26 4). Atributos dos objetos em relação ao índice STI apresenta variação
27 susceptível ao manejo do solo. Algoritmos que se baseiam apenas em atributos
28 estatísticos de pixels individuais provavelmente não são capazes de realizar a
29 separação da mudança nos atributos como Rectangular Fit e GLCM Contrast
30 (90°) que são diferenciados neste estudo.

31 A metodologia proposta elimina a subjetividade e, ainda diminui
32 possíveis erros humanos de interpretação. Ao considerar o número de atributos

1 com os quais o algoritmo de mineração de dados (C4.5/J48) funciona, este
2 trabalho traz uma contribuição significativa na busca de automação de
3 processos de classificação de imagens multiespectrais via sensoriamento
4 remoto, já que potencializa a mineração de dados e o GEOBIA. Apesar disso, é
5 entendido que para o desenvolvimento de um sistema totalmente automatizado
6 necessita de mais pesquisas. Portanto, se deve focar mais em equipamentos in
7 situ para validação dos dados espectrais obtidos, porém a robustez do
8 algoritmo em detectar a variação do tipo de manejo do solo é válida.

9

10

11

1 REFERÊNCIAS BIBLIOGRÁFICAS

- 2 AGARWAL, D. K.; BILLORE, S. D.; SHARMA, A. N.; DUPARE, B. U.;
3 SRIVASTAVA, S. K. Soybean: introduction, improvement, and utilization in
4 India—problems and prospects. **Agricultural Research**, v. 2, n. 4, p. 293-300,
5 2013.
- 6 ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.;
7 SPAROVEK, G. Köppen's climate classification map for Brazil.
8 **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728. 2013.
- 9 ARVOR, D.; JONATHAN, M.; MEIRELLES, M. S. P.; DUBREUIL, V.;
10 DURIEUX, L. Classification of MODIS EVI time series for crop mapping in the
11 state of Mato Grosso, Brazil. **International Journal of Remote Sensing**. 32,
12 7847–7871. 2011.
- 13 ARVOR, D.; MARGARETH, M.; DUBREUIL, V.; BÉGUÉ, A.; SHIMABUKURO,
14 Y. E. Analyzing the agricultural transition in Mato Grosso, Brazil, using satellite-
15 derived indices. **Applied Geography**, v. 32, n. 2, p. 702-713, 2012.
- 16 AZIZ, I.; MAHMOOD, T.; RAUT, Y.; LEWIS, W.; ISLAM, R.; WEIL, R. R. Active
17 organic matter as a simple measure of field soil quality. In: **ASA Internation**
18 **Meetings**, Pittsburg, PA. 2009.
- 19 BALESSENT, J.; CHENU, C.; BALABANE, M. Relationship of soil organic
20 matter dynamics to physical protection and tillage. *Soil and tillage research*, v.
21 53, n. 3-4, p. 215-230, 2000.
- 22 BESB - Biblioteca Espectral de Solos do Brasil. **Escola Superior de**
23 **Agricultura "Luiz de Queiroz" - Universidade de São Paulo**. Departamento
24 de Ciência do Solo - Laboratório de Sensoriamento Remoto Aplicado a Solos.
25 Planilha Modelo Novo – 2015/2016. Disponível em:
26 <<https://bibliotecaespectral.wixsite.com/esalq/protocolo>>. Acesso em: 05 de
27 nov. de 2019.
- 28 BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS*
29 *Journal of Photogrammetry and Remote Sensing*, v.65, n.1, p.2-16, 2010.
- 30 BO, S.; DING, L. The Effect of the Size of Training Sample on Classification
31 Accuracy in Object-Oriented Image Analysis. **Journal of Image and Graphics**.
32 15: 1106–1111. 2010.
- 33 BROWN, J. C.; KASTENS, J. H.; COUTINHO, A. C.; VICTORIA, D. D. C.;
34 BISHOP, C. R. Classifying multiyear agricultural land use data from Mato
35 Grosso using time-series MODIS vegetation index data. **Remote Sensing of**
36 **Environment**. 130, 39–50. 2013.
- 37 CAO, X.; CHEN, J.; MATSUSHITA, B.; IMURA, H. Developing a MODIS-based
38 index to discriminate dead fuel from photosynthetic vegetation and soil
39 background in the Asian steppe area. **International Journal of Remote**
40 **Sensing**, v. 31, n. 6, p. 1589-1604, 2010.

- 1 CASTILLEJO-GONZÁLEZ, I. L.; PENA-BARRAGÁN, J. M.; JURADO-
2 EXPÓSITO, M.; MESAS-CARRASCOSA, F. J.; LÓPEZ-GRANADOS, F.
3 Evaluation of pixel-and object-based approaches for mapping wild oat (*Avena*
4 *sterilis*) weed patches in wheat fields using QuickBird imagery for site-specific
5 management. **European Journal of Agronomy**, v. 59, p. 57-66, 2014.
- 6 CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current
7 radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI
8 sensors. **Remote sensing of environment**, v. 113, n. 5, p. 893-903, 2009.
- 9 COHN, A. S.; GIL, J.; BERGER, T.; PELLEGRINA, H.; TOLEDO, C. Patterns
10 and processes of pasture to crop conversion in Brazil: Evidence from Mato
11 Grosso State. **Land Use Policy**, v. 55, p. 108-120, 2016.
- 12 CONAB - Companhia Nacional de Abastecimento. **Calendário de Plantio e**
13 **Colheita de Grãos no Brasil 2019**. Disponível em:
14 <<https://www.ibge.gov.br/cidades-e-estados/mt.html>>. Acesso em: 05 de nov.
15 de 2019.
- 16 CRUZ, A. P. D.; TUMIBAY, G. M. Predicting Tuberculosis Treatment Relapse:
17 A Decision Tree Analysis of J48 for Data Mining. **Journal of Computer and**
18 **Communications**, v. 7, n. 7, p. 243-251, 2019.
- 19 DALL'AGNOL, A. DALL'AGNOL, Amélio. A Embrapa Soja no contexto do
20 desenvolvimento da soja no Brasil: histórico e contribuições. Embrapa Soja-
21 Livro técnico (INFOTECA-E), 2016.
- 22 DE CASTRO, A. I.; LÓPEZ-GRANADOS, F.; JURADO-EXPÓSITO, M.
23 Montserrat. Broad-scale cruciferous weed patch classification in winter wheat
24 using QuickBird imagery for in-season site-specific control. **Precision**
25 **Agriculture**, v. 14, n. 4, p. 392-413, 2013.
- 26 DEFINIENS. **Definiens professional 5**: Reference book. Munich, Germany:
27 The Imaging Intelligence Company, p.122. 2006.
- 28 DIAS, L. C.; PIMENTA, F. M.; SANTOS, A. B.; COSTA, M. H.; LADLE, R. J.
29 Patterns of land use, extensification, and intensification of Brazilian agriculture.
30 **Global change biology**, v. 22, n. 8, p. 2887-2903, 2016.
- 31 DRĂGUȚ, L.; TIEDE, D.; LEVICK, S. R. ESP: a tool to estimate scale
32 parameter for multiresolution image segmentation of remotely sensed data.
33 **International Journal of Geographical Information Science**, v. 24, n. 6, p.
34 859-871, 2010.
- 35 EPIPHANIO, R. D. V.; FORMAGGIO, A. R.; RUDORFF, B. F. T.; MAEDA, E.
36 E.; LUIZ, A. J. B. Estimating soybean crop areas using spectral-temporal
37 surfaces derived from MODIS images in Mato Grosso, Brazil. **Pesquisa**
38 **Agropecuária Brasileira**. 45, 72–80. 2010.
- 39 ESKANDARI, I.; NAVID, H.; RANGZAN, K. Evaluating spectral indices for
40 determining conservation and conventional tillage systems in a vetch-wheat
41 rotation. **International Soil and Water Conservation Research**, v. 4, n. 2, p.
42 93-98, 2016.

- 1 FAO - Food and Agriculture Organization of the United Nations. FAOSTAT
2 Statistical Database. **Food and Agriculture Organization of the United**
3 **Nations**, Rome. 2015.
- 4 FARR, T.G.; ROSEN, P.A.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY,
5 S.; KOBRICK, M.; PALLER, M.; RODRIGUEZ, E.; ROTH, L.; SEAL, D.;
6 SHAFFER, S.; SHIMADA, J.; UMLAND, J.; WERNER, M.; OSKIN, M.;
7 BURBANK, D.; ALSDORF, D. E. The shuttle radar topography mission.
8 **Reviews of geophysics**, v. 45, n. 2, 2007.
- 9 FOODY, G. M. Status of land cover classification accuracy assessment.
10 **Remote sensing of environment**, v. 80, n. 1, p. 185-201, 2002.
- 11 FREITAS, M. D. C. M. D. **A cultura da soja no Brasil: o crescimento da**
12 **produção brasileira e o surgimento de uma nova fronteira agrícola.**
13 **Enciclopédia Biosfera–Centro Científico Conhecer, Goiânia-GO, v. 7, n. 12, p.**
14 **1-12, 2011.**
- 15 GAO, J.; YU, Z., WANG, L.; VEJRE, H. Suitability of regional development
16 based on ecosystem service benefits and losses: A case study of the Yangtze
17 River Delta urban agglomeration, China. **Ecological Indicators**, v. 107, p.
18 105579, 2019.
- 19 GARCIA-PEDRERO, A.; GONZALO-MARTIN, C.; FONSECA-LUENGO, D.;
20 LILLO-SAAVEDRA, M. A GEOBIA methodology for fragmented agricultural
21 landscapes. **Remote Sensing**, v. 7, n. 1, p. 767-787, 2015.
- 22 GAVIOLI, A. P. R.; NUNES, J. D. S. SOJA TRANSGÊNICA NO BRASIL E
23 SUAS INFLUÊNCIAS À SAÚDE E AO MEIO AMBIENTE. **Revista Científica**
24 **da Faculdade de Educação e Meio Ambiente**, 6(2): 1-16, jul-dez, 2015
- 25 GIBBS, H. K.; RUESCH, A. S.; ACHARD, F.; CLAYTON, M. K.; HOLMGREN,
26 P.; RAMANKUTTY, N.; FOLEY, J. A. Tropical forests were the primary sources
27 of new agricultural land in the 1980s and 1990s. **Proceedings of the National**
28 **Academy of Sciences**, v. 107, n. 38, p. 16732-16737, 2010.
- 29 GOIRÁN, S. B.; ARANIBAR, J. N.; GOMEZ, M. L. Heterogeneous spatial
30 distribution of traditional livestock settlements and their effects on vegetation
31 cover in arid groundwater coupled ecosystems in the Monte desert (Argentina).
32 **Journal of Arid Environments**, v. 87, p. 188-197, 2012.
- 33 GOVAERTS, B.; VERHULST, N.; CASTELLANOS-NAVARRETE, A.; SAYRE,
34 K. D.; DIXON, J.; DENDOOVEN, L. Conservation agriculture and soil carbon
35 sequestration: between myth and farmer reality. **Critical Reviews in Plant**
36 **Science**, v. 28, n. 3, p. 97-122, 2009.
- 37 GUSSO, A.; ARVOR, D.; RICARDO DUCATI, J.; VERONEZ, M. R.; DA
38 SILVEIRA, L. G. Assessing the MODIS crop detection algorithm for soybean
39 crop area mapping and expansion in the Mato Grosso state, Brazil. **The**
40 **Scientific World Journal**. 2014.
- 41 GUSSO, A.; DUCATI, J. R.; VERONEZ, M. R.; ARVOR, D.; SILVEIRA JUNIOR,
42 L. G. D. Spectral model for soybean yield estimate using MODIS/EVI data.

- 1 **International journal of geosciences**. Irvine, CA. Vol. 4, n. 9 (Nov. 2013), p.
2 1233-1241, 2013.
- 3 HARALICK, R. M.; SHANMUGAM, K.; DINSTEIN, I. H. Textural features for
4 image classification. **IEEE Transactions on systems, man, and cybernetics**,
5 n. 6, p. 610-621, 1973.
- 6 HILL, M. J.; ZHOU, Q.; SUN, Q.; SCHAAF, C. B.; PALACE, M. Relationships
7 between vegetation indices, fractional cover retrievals and the structure and
8 composition of Brazilian Cerrado natural vegetation. **International journal of
9 remote sensing**, v. 38, n. 3, p. 874-905, 2017.
- 10 HIVELY, W.; LAMB, B.; DAUGHTRY, C.; SHERMEYER, J.; MCCARTY, G.;
11 QUEMADA, M. Mapping crop residue and tillage intensity using WorldView-3
12 satellite shortwave infrared residue indices. **Remote Sensing**, v. 10, n. 10, p.
13 1657, 2018.
- 14 HSU, W.; LEE, M.; ZHANG, J. Image Mining: Trends and Developments.
15 **Journal of Intelligent Information Systems**, v.19, n.1, p.7–23, 2002.
- 16 HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of
17 environment**, v. 25, n. 3, p. 295-309, 1988.
- 18 HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA,
19 L. G. Overview of the radiometric and biophysical performance of the MODIS
20 vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195-
21 213, 2002.
- 22 HUETE, A.R.; WARRICK, A.R. Assessment of vegetation and soil water
23 regimes in partial canopies with optical remotely sensed data. **Remote Sensing
24 of Environment**, New York, v.32, p.155-167, 1990.
- 25 IBGE - Instituto Brasileiro de Geografia e Estatística. **Cidades e Estados**.
26 Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/mt.html>>. Acesso
27 em: 05 de nov. de 2019.
- 28 JACQUES, D. C.; KERGOAT, L.; HIERNAUX, P.; MOUGIN, E.; DEFOURNY,
29 P. Monitoring dry vegetation masses in semi-arid areas with MODIS SWIR
30 bands. **Remote sensing of environment**, v. 153, p. 40-49, 2014.
- 31 JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band
32 enhanced vegetation index without a blue band. **Remote sensing of
33 Environment**, v. 112, p. 3833-3845, 2008.
- 34 KAINIEMI, V.; ARVIDSSON, J.; KÄTTERER, T. Short-term organic matter
35 mineralisation following different types of tillage on a Swedish clay soil. **Biology
36 and fertility of soils**, v. 49, n. 5, p. 495-504, 2013.
- 37 KALMEGH, S. Analysis of weka data mining algorithm reptree, simple cart and
38 randomtree for classification of indian news. **International Journal of
39 Innovative Science, Engineering & Technology**, v. 2, n. 2, p. 438-446, 2015.

- 1 KASTENS, J. H.; BROWN, J. C.; COUTINHO, A. C.; BISHOP, C. R.;
2 ESQUERDO, J. C. D. Soy moratorium impacts on soybean and deforestation
3 dynamics in Mato Grosso, Brazil. **PloS one**, v. 12, n. 4, p. e0176168, 2017.
- 4 KERGOAT, L.; HIERNAUX, P.; DARDEL, C.; PIERRE, C.; GUICHARD, F.;
5 KALILOU, A. Dry-season vegetation mass and cover fraction from SWIR1. 6
6 and SWIR2. 1 band ratio: Ground-radiometer and MODIS data in the Sahel.
7 **International journal of applied earth observation and geoinformation**, v.
8 39, p. 56-64, 2015.
- 9 LAL, R.; NEGASSA, W.; LORENZ, K. Carbon sequestration in soil. **Current**
10 **Opinion in Environmental Sustainability**, v. 15, p. 79-86, 2015.
- 11 LAMBERT, M. J.; TRAORÉ, P. C. S.; BLAES, X.; BARET, P.; DEFOURNY, P.
12 Estimating smallholder crops production at village level from Sentinel-2 time
13 series in Mali's cotton belt. **Remote Sensing of Environment**, v. 216, p. 647-
14 657, 2018.
- 15 LANDIS, J. R. & KOCH, G. G. The measurement of observer agreement for
16 categorical data. **Biometrics**, p. 159-174, 1977.
- 17 LAZZAROTTO, J. J.; HIRAKURI, M. H. Marcelo Hiroshi. Evolução e
18 perspectivas de desempenho econômico associadas com a produção de soja
19 nos contextos mundial e brasileiro. Londrina: **Embrapa Soja**, p. 46, 2010.
- 20 LI, Z.; GUO, X. Remote sensing of terrestrial non-photosynthetic vegetation
21 using hyperspectral, multispectral, SAR, and LiDAR data. **Progress in**
22 **Physical Geography**, v. 40, n. 2, p. 276-304, 2016.
- 23 LÓPEZ-GRANADOS, F. Weed detection for site-specific weed management:
24 mapping and real-time approaches. **Weed Research**, v. 51, n. 1, p. 1-11, 2011.
- 25 MARSETT, R.C.; QI, J.; HEILMAN, P.; BIEDENBENDER, S.H.; WATSON,
26 M.C.; AMER, S.; WELTZ, M.; GOODRICH, D.; MARSETT, R. Remote sensing
27 for grassland management in the arid southwest. **Rangeland Ecology &**
28 **Management**, v. 59, n. 5, p. 530-540, 2006.
- 29 MATHER, P. M. & KOCH, M. **Computer processing of remotely-sensed**
30 **images**: an introduction. John Wiley & Sons, 2011.
- 31 MEIJER, A. D.; HEITMAN, J. L.; WHITE, J. G.; AUSTIN, R. E. Measuring
32 erosion in long-term tillage plots using ground-based lidar. *Soil and Tillage*
33 *Research*, v. 126, p. 1-10, 2013.
- 34 MOTOHKA, T.; NASAHARA, K. N.; OGUMA, H.; TSUCHIDA, S. Applicability of
35 green-red vegetation index for remote sensing of vegetation phenology.
36 **Remote Sensing**, v. 2, n. 10, p. 2369-2387, 2010.
- 37 NAGLER, P. L.; DAUGHTRY, C. S. T.; GOWARD, S. N. Plant litter and soil
38 reflectance. **Remote Sensing of Environment**, v. 71, n. 2, p. 207-215, 2000.

- 1 NAGLER, P. L.; INOUE, Y.; GLENN, E. P.; RUSS, A. L.; DAUGHTRY, C. S. T.
2 Cellulose absorption index (CAI) to quantify mixed soil-plant litter scenes.
3 **Remote sensing of environment**, v. 87, n. 2-3, p. 310-325, 2003.
- 4 NAJAFI, P.; NAVID, H.; FEIZIZADEH, B.; ESKANDARI, I. Remote sensing for
5 crop residue cover recognition: a review. **Agricultural Engineering**
6 **International: CIGR Journal**, v. 20, n. 1, 2018.
- 7 NAJAFI, P.; NAVID, H.; FEIZIZADEH, B.; ESKANDARI, I.; BLASCHKE, T.
8 Fuzzy Object-Based Image Analysis Methods Using Sentinel-2A and Landsat-8
9 Data to Map and Characterize Soil Surface Residue. **Remote Sensing**, v. 11,
10 n. 21, p. 2583, 2019.
- 11 NANNI, M. R.; DEMATTÊ, J. A. M. Comportamento da linha do solo obtida por
12 espectrorradiometria laboratorial para diferentes classes de solo. **Revista**
13 **Brasileira de Ciência do Solo**, v. 30, n. 6, p. 1031-1038, 2006.
- 14 PARENTE, L.; MESQUITA, V.; MIZIARA, F.; BAUMANN, L.; FERREIRA, L.
15 Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to
16 2017: A novel approach based on high spatial resolution imagery and Google
17 Earth Engine cloud computing. **Remote Sensing of Environment**, v. 232, p.
18 111301, 2019.
- 19 PAUL OBADE, V.; LAL, R.; MOORE, R. Assessing the accuracy of soil and
20 water quality characterization using remote sensing. **Water resources**
21 **management**, v. 28, n. 14, p. 5091-5109, 2014.
- 22 PEÑA-BARRAGÁN, J. M.; KELLY, M.; CASTRO, A. I. D.; LÓPEZ GRANADOS,
23 F. **Object-based approach for crop row characterization in UAV images for**
24 **site-specific weed management**. 2012.
- 25 PIPER, J. The effect of zero feature correlation assumption on maximum
26 likelihood based classification of chromosomes. **Signal processing**, v. 12, n. 1,
27 p. 49-57, 1987.
- 28 PITTELKOW, C. M.; LINQUIST, B. A.; LUNDY, M. E.; LIANG, X.; VAN
29 GROENIGEN, K. J.; LEE, J.; GESTEL, N. V.; SIX, J.; VENTERA, R. T.; VAN
30 KESSEL, C. When does no-till yield more? A global meta-analysis. **Field Crops**
31 **Research**, v. 183, p. 156-168, 2015.
- 32 QI, J.; MARSETT, R.; HEILMAN, P.; BIEDEN-BENDER, S.; MORAN, S.;
33 GOODRICH, D.; WELTZ, M. RANGES improves satellite-based information and
34 land cover assessments in southwest United States. *Eos*, **Transactions**
35 **American Geophysical Union**, v. 83, n. 51, p. 601-606, 2002.
- 36 QUEMADA, M.; HIVELY, W. D.; DAUGHTRY, C. S. T.; LAMB, B. T.;
37 SHERMEYER, J. Improved crop residue cover estimates obtained by coupling
38 spectral indices for residue and moisture. **Remote sensing of environment**, v.
39 206, p. 33-44, 2018.
- 40 QUINLAN, J. R. **C4. 5: programs for machine learning**. Elsevier, 2014.

- 1 RAVI, R.; TAHERI, A.; KHANDEKAR, D.; MILLAS, R. Rapid Profiling of
2 Soybean Aromatic Compounds Using Electronic Nose. **Biosensors**, v. 9, n. 2,
3 p. 66, 2019.
- 4 RICHARDS, P. D.; MYERS, R. J.; SWINTON, S. M.; WALKER, R. T. Exchange
5 rates, soybean supply response, and deforestation in South America. **Global
6 environmental change**, v. 22, n. 2, p. 454-462, 2012.
- 7 ROUSE, J.W.; HASS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring
8 vegetation systems in the Great Plains with ERTS. In: EARTH RESOURCES
9 TECHNOLOGY SATELLITE SYMPOSIUM, 3., Washington. **Proceedings**.
10 Washington: NASA, 1974. p.309-317. 1974.
- 11 SERBIN, G.; DAUGHTRY, C. S.; HUNT JR, E. R.; REEVES III, J. B.; BROWN,
12 D. J. Effects of soil composition and mineralogy on remote sensing of crop
13 residue cover. **Remote Sensing of Environment**, v. 113, n. 1, p. 224-238,
14 2009.
- 15 SERBIN, G.; HUNT JR, E. R.; DAUGHTRY, C. S.; MCCARTY, G. W.
16 Assessment of spectral indices for cover estimation of senescent vegetation.
17 **Remote sensing letters**, v. 4, n. 6, p. 552-560, 2013.
- 18 SHABOU, M.; MOUGENOT, B.; CHABAANE, Z.; WALTER, C.; BOULET, G.;
19 AISSA, N.; ZRIBI, M. Soil clay content mapping using a time series of Landsat
20 TM data in semi-arid lands. **Remote sensing**, v. 7, n. 5, p. 6059-6078, 2015.
- 21 SILVA JUNIOR, C. A. D.; NANNI, M. R.; OLIVEIRA-JÚNIOR, J. F. D.; CEZAR,
22 E.; TEODORO, P. E.; DELGADO, R. C.; SHIRATSUCHI L. S.; SHAKIR M.;
23 CHICATI, M. L. Object-based image analysis supported by data mining to
24 discriminate large areas of soybean. **International Journal of Digital Earth**, v.
25 12, n. 3, p. 270-292, 2019.
- 26 SILVA JUNIOR, C. A.; LIMA, MENDELSON. Soy Moratorium in Mato Grosso:
27 Deforestation undermines the agreement. **Land Use Policy**, v. 71, p. 540-542,
28 2018.
- 29 SILVA JUNIOR, C. A.; NANNI, M. R.; TEODORO, P. E.; SILVA, G. F. C.
30 Vegetation indices for discrimination of soybean areas: A new approach.
31 **Agronomy Journal**, Vol. 109 No. 4, p. 1331-1343, 2017.
- 32 SMITH, A. M.; HILL, M. J.; ZHANG, Y. Estimating ground cover in the mixed
33 prairie grassland of southern Alberta using vegetation indices related to
34 physiological function. **Canadian Journal of Remote Sensing**, v. 41, n. 1, p.
35 51-66, 2015.
- 36 SOUZA-FILHO, P.; NASCIMENTO, W.; SANTOS, D.; WEBER, E., SILVA, R.;
37 SIQUEIRA, J. A GEOBIA approach for multitemporal land-cover and land-use
38 change analysis in a tropical watershed in the southeastern Amazon. **Remote
39 Sensing**, v. 10, n. 11, p. 1683, 2018.
- 40 SPERA, S. A.; GALFORD, G. L.; COE, M. T.; MACEDO, M. N.; MUSTARD, J.
41 F. Land-use change affects water recycling in Brazil's last agricultural frontier.
42 **Global change biology**, v. 22, n. 10, p. 3405-3413, 2016.

- 1 VAN DEVENTER, A. P.; WARD, A. D.; GOWDA, P. H.; LYON, J. G. Using
2 Thematic Mapper data to identify contrasting soil plains and tillage practices.
3 **Photogrammetric Engineering and Remote Sensing**, v. 63, p. 87-93, 1997.
- 4 VAN LEEUWEN, W. J.D.; HUETE, A. R.; LAING, T. W. MODIS vegetation
5 index compositing approach: A prototypewith AVHRR data. **RemoteSensing of**
6 **Environment**, v. 69, n. 3, p. 264-280, 1999.
- 7 VAN NIEL, T. G.; MCVICAR, T. R.; DATT, B. On the relationship between
8 training sample size and data dimensionality: Monte Carlo analysis of
9 broadband multi-temporal classification. **Remote Sensing of Environment**, v.
10 98, n. 4, p. 468-480, 2005.
- 11 VILLARREAL, M. L.; NORMAN, L. M.; BUCKLEY, S.; WALLACE, C. S.; COE,
12 M. A. Multi-index time series monitoring of drought and fire effects on desert
13 grasslands. **Remote sensing of environment**, v. 183, p. 186-197, 2016.
- 14 VOGELS, M. F.; DE JONG, S. M.; STERK, G.; DOUMA, H.; ADDINK, E. A.
15 Spatio-temporal patterns of smallholder irrigated agriculture in the horn of Africa
16 using GEOBIA and Sentinel-2 imagery. **Remote Sensing**, v. 11, n. 2, p. 143,
17 2019.
- 18 WANG, G.; WANG, J.; ZOU, X.; CHAI, G.; WU, M.; WANG, Z. Estimating the
19 fractional cover of photosynthetic vegetation, non-photosynthetic vegetation and
20 bare soil from MODIS data: Assessing the applicability of the NDVI-DFI model
21 in the typical Xilingol grasslands. **International Journal of Applied Earth**
22 **Observation and Geoinformation**, v. 76, p. 154-166, 2019.
- 23 WESTCOTT, P.; CONTACT, E. USDA Agricultural Projections to 2025
24 Interagency Agricultural Projections Committee; USDA Long-term Projections;
25 **US Department of Agriculture: Washington, DC, USA, 2016.**
- 26 XI, W.; DU, S.; WANG, Y. C.; ZHANG, X. A spatiotemporal cube model for
27 analyzing satellite image time series: Application to land-cover mapping and
28 change detection. **Remote Sensing of Environment**, v. 231, p. 111212, 2019.
- 29 YUE, J.; TIAN, Q.; DONG, X.; XU, K.; ZHOU, C. Using Hyperspectral Crop
30 Residue Angle Index to Estimate Maize and Winter-Wheat Residue Cover: A
31 Laboratory Study. **Remote Sensing**, v. 11, n. 7, p. 807, 2019.
- 32 ZHU, C.; LU, D.; VICTORIA, D.; DUTRA, L. Mapping fractional cropland
33 distribution in Mato Grosso, Brazil using time series MODIS enhanced
34 vegetation index and Landsat Thematic Mapper data. **Remote Sensing**. 8, 22.
35 2016.
- 36

1 **4. CAPÍTULOS**

2 **3.2. BALANÇO DE CARBONO E SALDO DE RADIAÇÃO EM ÁREAS DE**
3 **PLANTIO DIRETO DE SOJA POR MEIO DE VARIÁVEIS ESPECTRO-**
4 **TEMPORAIS ¹**

5

6

7

8

9

10

11

12

13

14

15

16 ¹ Artigo submetido no periódico “Journal of Environmental Management”.

17 **Resumo** – (BALANÇO DE CARBONO E SALDO DE RADIAÇÃO EM ÁREAS
18 DE PLANTIO DIRETO DE SOJA POR MEIO DE VARIÁVEIS ESPECTRO-
19 TEMPORAIS). O processo de modernização e expansão agrícola aumentou a
20 produtividade das lavouras, porém as alterações de uso e manejo do solo têm-
21 se tornado alvo de discussão sobre alterações do clima, sido apontada como
22 uma das causas dessas mudanças. Apesar dos avanços científicos, ainda não
23 está claro o impacto da expansão agrícola em larga escala sobre a vegetação
24 nativa altera o balanço de carbono na biosfera. Sendo assim, os objetivos com
25 esse estudo consistiram em: i) comparar área de plantio direto em dois
26 municípios situados em diferentes regiões do Brasil, sua influência no fluxo de
27 CO₂ e na Produção Primária Bruta (GPP) e ii) verificar a diferença entre os
28 fatores ambientais, seguido das tendências destas variáveis para futuro. O
29 estudo foi realizado em duas áreas com latitudes distintas nos municípios de
30 Sinop - MT e Passo Fundo - RS. Foi executada uma série temporal de 19 anos
31 com dados adquiridos via sensoriamento remoto dos satélites Landsat
32 (*Operational Land Imager* - OLI e *Thermal Infrared Sensor* - TIRS) e

1 TERRA/AQUA (*Moderate-Resolution Imaging Spectroradiometer* - MODIS). Os
2 resultados apresentam que as variáveis são diretamente influenciadas pelo
3 manejo do solo e a prática da agricultura durante a série temporal analisada,
4 com uma correlação satisfatória nas previsões futuras das variáveis para os
5 próximos 10 anos.

6 Palavras-chave: ARIMA, sensoriamento remoto, produtos orbitais, modelagem
7 de dados.

8

9 **Abstract** - (CARBON BALANCE AND RADIATION BALANCE IN SOYBEAN
10 PLANTING AREAS THROUGH SPECTRUM-TEMPORARY VARIABLES). The
11 process of modernization of agriculture and their territorial expansion has
12 increased the crop's yield, but the land-use change and soil management have
13 become the subject of discussion on climate change, which has been identified
14 as one of the causes of these changes. Although the scientific advances, it's
15 still not clear how the impact of large-scale agricultural expansion on native
16 vegetation alters the carbon balance in the biosphere. Therefore, the objectives
17 of this study was: i) to compare the area of no-tillage in two municipalities
18 located in different regions of Brazil, their influence on the CO₂ flux and on the
19 Gross Primary Productivity (GPP) and ii) to verify the difference between
20 environmental factors, followed by trends in these variables for the future. The
21 study was carried out in two areas with different latitudes in the municipalities of
22 Sinop - MT and Passo Fundo - RS. The time series of 19-years was performed
23 with data acquired via remote sensing of the Landsat satellites (Operational
24 ground sensor - OLI and Thermal infrared sensor - TIRS) and TERRA/AQUA
25 (*Moderate-resolution image spectroradiometer* - MODIS). The results presented
26 as variables are directly influenced by soil management and the practice of
27 agriculture during an analyzed time series, with a satisfactory correlation in the
28 future statistics of the variables for the next 10 years.

29 Key-words: ARIMA, remote sensing, orbital products, data modeling.

30

31

32

33

34

35

1 INTRODUÇÃO

2 A soja [*Glycine max* (L.) Merrill] é uma das culturas de maior potencial
3 econômico, com crescimento expressivo no agronegócio brasileiro nas últimas
4 décadas. Sua produtividade é definida por meio da interação da planta com o
5 ambiente e manejo do solo (GUIMARÃES et al., 2008; PEREIRA et al., 2011),
6 e, portanto, o sojicultor se utiliza de métodos que ocasionem menos danos aos
7 solos e ao ambiente (ORMOND, 2013).

8 As atividades agrícolas contribuem para as emissões de gases do efeito
9 estufa (GEE), sendo o preparo convencional do solo uma das atividades
10 agrícolas com maior influência neste cenário (HANSEL et al., 2013; ZANELA et
11 al., 2016). Isso ocorre, porque o revolvimento do solo, ocasiona a redução do
12 carbono (C) estocado no solo, que por sua vez, é perdido na forma de dióxido
13 de carbono (CO₂) acarretando no aumento da concentração deste gás na
14 atmosfera (CARVALHO et al., 2009). Ao contrário do modelo convencional, o
15 preparo do solo no sistema de plantio direto pode reduzir as emissões de CO₂,
16 com capacidade de elevar os estoques de C do solo (MOSIER et al., 2004; DE
17 ARAÚJO SANTOS et al., 2019).

18 Quando se modifica os métodos de uso da terra, os locais de
19 armazenamento do C na vegetação (raízes), na palhada (madeira morta) e no
20 solo podem ser alterados. Logo, um longo tempo se faz necessário até que
21 uma nova condição de equilíbrio seja estabelecida (CHERUBINI, 2010;
22 RADICETTI et al., 2019; SINGH et al., 2020).

23 As mudanças climáticas causadas pelo aumento da concentração de
24 GEE podem acarretar em alterações na biodiversidade marinha e terrestre, nos
25 recursos hídricos e na diminuição dos serviços ecossistêmicos. Além disso,
26 estudos têm mostrado que o aumento da temperatura do ar por exemplo, irá
27 refletir diretamente no desenvolvimento, crescimento e rendimento das culturas
28 agrícolas (FAGUNDES et al., 2010; KUMAR & BABALAD, 2018; SALOMÃO et
29 al., 2020).

30 O aumento da emissão de GEE e o conseqüente aquecimento global
31 tem ocasionado a busca por estratégias que proporcionem a redução das

1 fontes desses gases (CARVALHO et al., 2010). As contribuições da tecnologia
2 de sensoriamento remoto via uso de sensores MODIS (*Moderate-Resolution*
3 *Imaging Spectroradiometer*) e satélites LANDSAT podem proporcionar avanços
4 em estudos que visem caracterizar a dinâmica da cobertura vegetal e do
5 carbono na superfície terrestre, sendo possível estimar a perda de CO₂ para a
6 atmosfera (RICHEY et al., 2002; NOVO et al., 2005), quanto a absorção de
7 carbono por meio da produtividade primária bruta – GPP (*Gross Primary*
8 *Production*) (SILVA JUNIOR et al., 2019a; ROSSI et al., 2020). Variáveis como
9 albedo e temperatura também podem ajudar a compreender essa dinâmica.

10 Há muitos trabalhos na literatura que se destinam à quantificação do C
11 estocado na vegetação, com base nas projeções futuras sobre o sistema
12 climático (SILVA et al., 2005; BRAGA, 2013; WU et al., 2016; OUYANG et al.,
13 2020). O conhecimento das alterações dessas variáveis para atmosfera é
14 fundamental em estudos que visem acompanhar, comparar e avaliar o impacto
15 em relação às modificações da relação solo-planta-atmosfera, pois as
16 informações obtidas poderão ser aplicadas em estratégias para redução de
17 emissão de CO₂ para atmosfera.

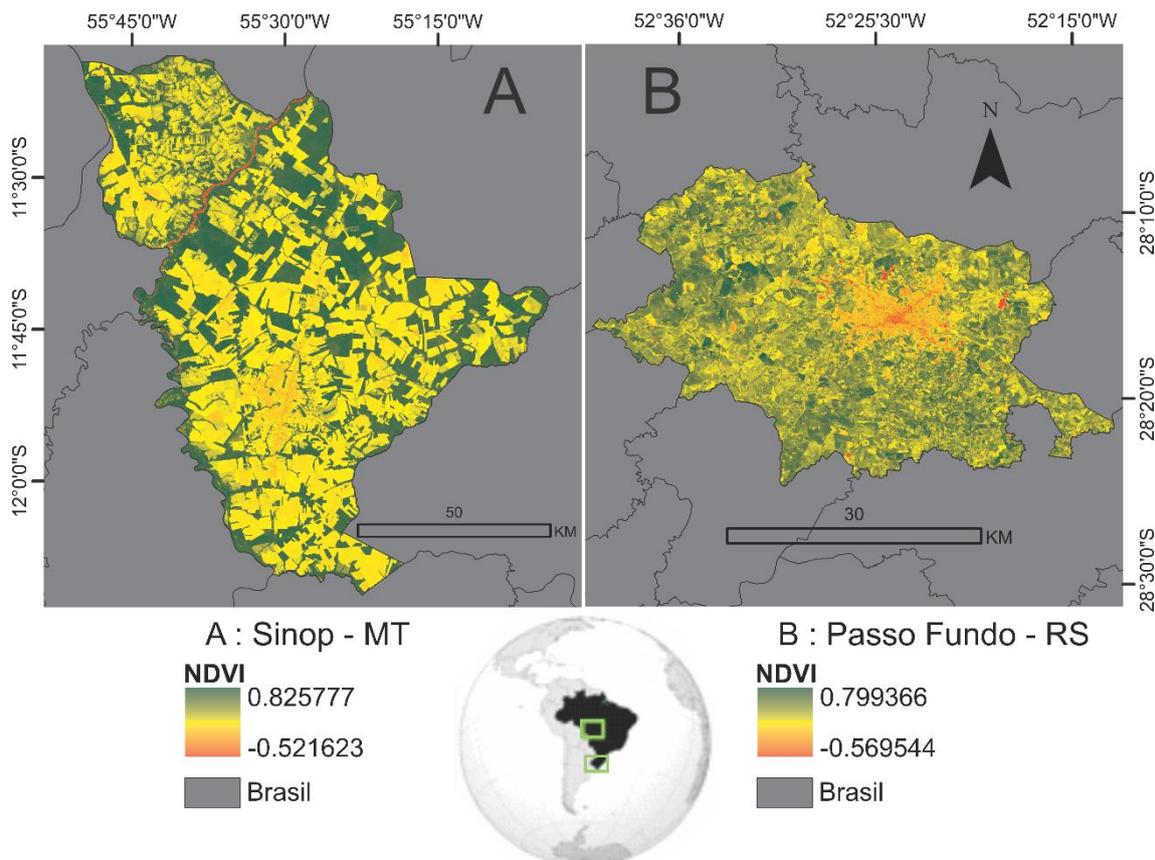
18 Portanto, os objetivos neste estudo consistem em: i) comparar área de
19 plantio direto em dois municípios situados em diferentes regiões do Brasil, sua
20 influência no fluxo de CO₂ e na Produção Primária Bruta (GPP) e ii) verificar a
21 diferença entre os fatores ambientais, seguido das tendências destas variáveis
22 para futuro.

23

1 MATERIAL E MÉTODOS

2 Área de Estudo

3 Foram selecionadas duas áreas de estudos: a primeira localiza-se no
4 município de Sinop com aproximadamente 3.941,958 km² (IBGE, 2020),
5 situado no estado do Mato Grosso, região Centro Oeste do Brasil. O município
6 de Sinop fica localizado entre as coordenadas geográficas 11°20' a 12°10'S e
7 55°50' a 55°10'W com uma altitude de 371 m. Segundo a classificação de
8 Köppen, o clima da região é "Aw" (tropical quente e úmido), com duas estações
9 bem definidas: chuvosa (outubro a abril) e seca (maio a setembro), com chuva
10 média anual de 1974,77 mm, respectivamente, e temperaturas médias mensais
11 entre 23,2 e 25,8°C (SOUZA et al., 2013) (Figura 1A). A segunda área de
12 estudo localiza-se no município de Passo Fundo com aproximadamente
13 783,603 km² (IBGE, 2020), localizado no estado do Rio Grande do Sul, região
14 Sul do Brasil. O município de Passo Fundo encontra-se entre as coordenadas
15 geográficas 28°6' a 28°24'S e 52°40' a 52°12'W com uma altitude de 687 m. De
16 acordo com a classificação Köppen o clima é descrito como subtropical-úmido
17 ("Cfa") com temperatura anual média de 17,5°C e no verão superior a 30°C,
18 com chuva anual de 1787,8 mm (Figura 1B).



1

2 FIGURA 1: Localização geográfica dos municípios de Sinop – MT (A) e Passo
 3 Fundo – RS (B) e variabilidade espacial do NDVI, respectivamente.

4 **Deteccção das Áreas de Soja**

5 O mapeamento da cultura da soja foi realizado com imagem dos
 6 satélites Landsat 5 (*Thematic Mapper - TM*), Lansat 7 (*Enhanced Thematic*
 7 *Mapper Plus - ETM+*), Landsat 8 (*Operational Land Imager - OLI e Thermal*
 8 *Infrared Sensor - TIRS*) e TERRA/AQUA (*Moderate-Resolution Imaging*
 9 *Spectroradiometer - MODIS*), por meio do uso de bandas espectrais conforme
 10 metodologia anteriormente proposta por Silva Junior et al. (2017).

11 Com base no calendário da cultura de soja no Mato Grosso e do Rio
 12 Grande do Sul, foi obtido o *Perpendicular Crop Enhancement Index (PCEI)*
 13 desenvolvido por Silva Junior et al. (2017). No estágio inicial da cultura de soja
 14 as reflectâncias registradas pelo sensor podem interferir nos valores de PCEI,
 15 pois o solo estará sem cultivo. Para evitar essa interferência foi aplicado o
 16 *Perpendicular Vegetation Index (PVI)* (Equação 1) e usado as bandas
 17 espectrais de vermelho e infravermelho para regressão em linha da terra, como
 18 descrito por Nanni e Demattê (2006).

$$PVI = \frac{P_{IVP} - ap_V - b}{\sqrt{1 + a^2}} \quad (1)$$

1 em que: a e b são, respectivamente, a inclinação e o intercepto da linha da
2 terra, sendo PIVP uma variável independente.

3 Por meio da série-temporal do índice PVI, foi calculado o índice PCEI
4 (*Perpendicular Crop Enhancement Index*), que é representado pela Equação
5 (2) e, sintetizada na Equação (3), conforme descrito por Silva Junior et al.
6 (2017):

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

$$PCEI = \frac{(MaxPVI + S) - (MinPVI + S)}{(MaxPVI + S) + (MinPVI + S)} \quad (3)$$

7 O valor de MaxPVI é o valor máximo de PVI observado no período de
8 máximo desenvolvimento da cultura da soja; MinPVI é o valor mínimo
9 observado no período de pré-semeadura e/ou emergência; S é o coeficiente de
10 melhoria (10^2) e g é o fator de ganho (10^2).

11 Índices de Vegetação

12 Para este estudo, foram utilizados seis índices de vegetação: o
13 *Normalized Difference Vegetation Index* (NDVI), o *Enhanced Vegetation Index*
14 2 (EVI2), o *Normalized Difference Senescence Index* (NDSVI), o *Soil Adjusted*
15 *Total Vegetation Index* (SATVI), o *Soil Tillage Index* (STI) e o *Normalized*
16 *Difference Tillage Index* (NDTI) (Tabela 1). Os índices NDVI e EVI2 quantificam
17 a presença de pigmentos fotossintéticos da vegetação. Para identificação de
18 vegetação em senescência e o grau de densidade de vegetação verde foram
19 utilizados os índices NDSVI e SATVI. Na identificação da fração de cobertura
20 seca e o sistema de manejo do solo ao decorrer dos anos trabalhou-se com os
21 índices STI e NDTI.

22

1 Tabela 1: Índices de vegetação utilizados no estudo para estimar tipo de
 2 manejo de solo, no ano safra 2000/2018.

Índices de Vegetação	Equações	Referências
<i>Normalized Difference Vegetation (NDVI)</i>	$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}$	Rouse et al. (1974)
<i>Enhanced Vegetation Index 2 (EVI2)</i>	$EVI2 = 2.5 * \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + (2.4 * \rho_{RED}) + 1}$	Jiang et al. (2008)
<i>Normalized Difference Senescence Index (NDSVI)</i>	$NDSVI = \frac{\rho_{SWIR1} - \rho_{RED}}{\rho_{SWIR1} + \rho_{RED}}$	Qi et al. (2002)
<i>Soil Adjusted Total Vegetation Index (SATVI)</i>	$SATVI = \frac{\rho_{SWIR1} - \rho_{RED}}{\rho_{SWIR1} + \rho_{RED} + L} (1 + L) - \left(\frac{\rho_{SWIR2}}{2}\right)$	Marslett et al. (2006)
<i>Soil Tillage Index (STI)</i>	$STI = \frac{\rho_{SWIR1}}{\rho_{SWIR2}}$	Van Deventer et al. (1997)
<i>Normalized Difference Tillage Index (NDTI)</i>	$NDTI = \frac{\rho_{SWIR1} - \rho_{SWIR2}}{\rho_{SWIR1} + \rho_{SWIR2}}$	Van Deventer et al. (1997)

3
 4 Refletância no comprimento de onda do infravermelho próximo (ρ_{NIR});
 5 Refletância no comprimento de onda do vermelho (ρ_{RED}); Refletância no
 6 comprimento de onda do infravermelho curto (ρ_{SWIR1} e ρ_{SWIR2}); Constante
 7 (relacionada à inclinação da linha do solo em um gráfico de espaço de
 8 característica) que geralmente é definido como 0,5. (L).

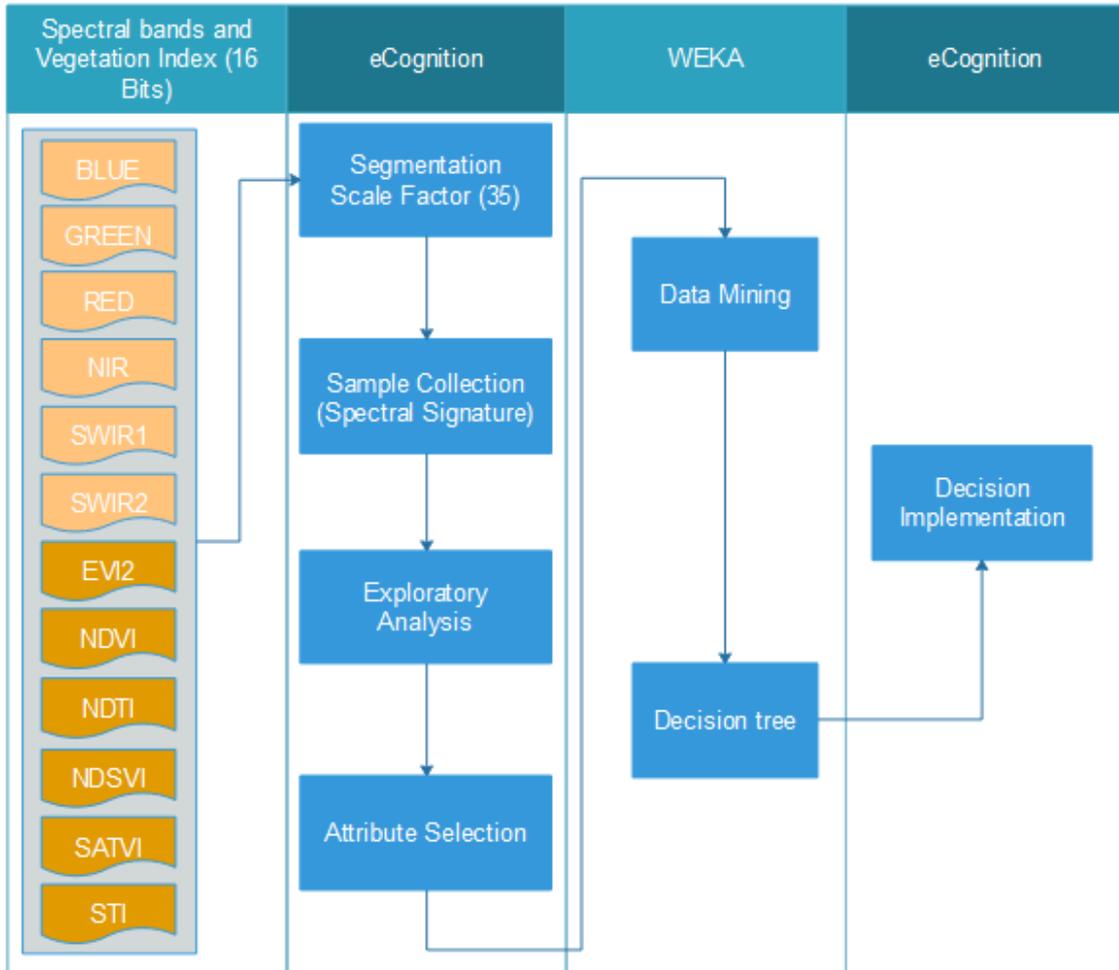
1 **Distinção do tipo de preparo de solo por meio de índices espectrais,** 2 **GEOBIA e mineração de dados**

3 Os passos para identificação do tipo de preparo do solo antes da
4 semeadura da soja para as duas áreas de estudo seguiram a metodologia
5 assim descritos no Capítulo 1. Neste estudo a metodologia aplicada nos
6 satélites do Landsat 5, 7 e 8 utilizou o GEOBIA (*Geographic Object-Based*
7 *Image Analysis*) e a mineração de dados (MD), para aprimorar o
8 processamento das imagens.

9 O processamento das imagens por meio da segmentação
10 multiresolução, busca explorar as relações espaciais, juntamente com suas
11 características espectrais ou mais critérios de homogeneidade em uma ou mais
12 dimensões do espaço de atributos (BLASCHKE, 2010; GARCIA-PEDRERO et
13 al., 2015).

14 Para análise das imagens foram utilizados ambiente computacional do
15 software eCognition® para interpretar as imagens, através do método da
16 classificação de orientação a objetos (GAO et al., 2019), juntamente com o
17 software WEKA®, que é um conjunto equipado com algoritmos de
18 aprendizagem para tarefas de mineração de dados e avaliação estatística
19 (KALMEGH, 2015).

20 As etapas propostas no fluxograma (Figura 2) foram a junção das
21 imagens com modificação da resolução radiométrica, configuração dos fatores
22 da segmentação, segmentação das imagens, seleção dos objetos para
23 geração do conjunto de treinamento, mineração dos dados, interpretação e
24 avaliação da árvore de decisão, classificação dos dados multitemporais por
25 meio de implantação da decisão e validação da classificação.



1

2 FIGURA 2: Fluxograma das principais etapas do estudo, com destaque para o
 3 GEOBIA e a mineração de dados nos ambientes computacionais.

4

5 A segmentação multirresolução realizada no eCognition®, no qual os
 6 objetos desenvolvidos (polígonos) foram expostos à decisão de
 7 heterogeneidade, sendo ajustada conforme o parâmetro de escala, os pesos
 8 das bandas espectrais, os fatores de forma e compactação. O ajuste de um
 9 parâmetro de escala pode influenciar o tamanho dos segmentos desenvolvidos.

10

11 Na segmentação multiresolução, a regra de similaridade foi estabelecida
 12 a partir da heterogeneidade a partir da diferença entre o atributo de uma região
 13 provável e a soma dos valores entre esse atributo nas regiões que os
 14 compõem. Além disso, a heterogeneidade dos atributos de cor é criada a partir
 15 de uma soma estimada dos desvios padrão de cada banda em uma região
 16 específica e forma, que foram ajustados de acordo com o tamanho dos objetos,
 sendo calculada durante a segmentação, gerando objetos distintos.

1 A abordagem baseada em objetos ofereceu a possibilidade de avaliar
2 áreas por características espectrais, texturais, contextuais e hierárquicas. Os
3 objetos podem ser caracterizados nas informações espectrais dos objetos com
4 base em valores médios e desvio padrão e em informações espectrais texturais
5 baseadas na matriz de co-ocorrência de nível de cinza (GLCM) proposta por
6 Haralick et al. (1973) e implementado por Definiens (2006).

7 Todas as bandas espectrais e os índices utilizados receberam
8 respectivamente o peso de 0.5 e 1 com escala 35 nas duas áreas de estudo,
9 para o processamento ao mesmo tempo durante a segmentação, com isso
10 garantiu a homogeneidade dos objetos. Após a segmentação foi levado em
11 consideração as classes atribuídas no Capítulo 1 na definição de cada objeto
12 como Plantio Convencional - PC, Plantio Direto A - PD_A e Plantio Direto B -
13 PD_B.

14 Para classificação dos objetos como PC, PD_A e PD_B nas áreas de
15 semeadura de soja, a árvore de decisão discriminada no Capítulo 1 foi
16 implementada nos atributos extraídos das bandas espectrais e dos índices de
17 vegetação das duas áreas de estudo. Tendo em vista que essa árvore de
18 decisão foi adquirida usando o algoritmo J48 é uma implementação do C4.5
19 que escolhe um atributo para dividir os dados em dois subconjuntos, com base
20 no maior ganho de informação normalizada (diferença de entropia).

21 As vantagens do modelo de classificação em árvore de decisão são fáceis de
22 entender e identifica-las com precisão comparável a outros modelos de
23 classificação (CRUZ e TUMIBAY, 2019).

24 **Temperatura da superfície da terra (LST)**

25 Neste estudo, um algoritmo baseado na série do satélite Landsat foi
26 usado para aquisição da temperatura da superfície das áreas de estudo,
27 conforme descrito por Du et al. (2015). O método baseia-se no estudo da
28 inversão do vapor de água atmosférico com base nos dados de infravermelho
29 térmico do satélite Landsat para obter os parâmetros do vapor de água
30 atmosférico (REN et al., 2015).

31 O algoritmo fundamenta-se nos dados dos dois canais infravermelho
32 térmicos do sensor do Landsat, a Equação (4) de janela dividida não linear de
33 dois canais.

1

$$T_s = B_0 + \left(B_2 \frac{1 - \varepsilon}{\varepsilon} + B_3 \frac{\Delta \varepsilon}{\varepsilon^2} \right) \frac{T_i + T_j}{2} + \left(B_4 + B_5 \frac{1 - \varepsilon}{\varepsilon} + B_6 \frac{\Delta \varepsilon}{\varepsilon^2} \right) \frac{T_i + T_j}{2} + B_7 (T_i + T_j)^2 \quad (4)$$

2

3 em que, ε e $\Delta \varepsilon$ são a média e a diferença na emissividade dos dois canais,
4 respectivamente, dependendo do tipo de cobertura da terra e densidade de
5 cobertura; T_i e T_j o brilho observado da radiação dos dois canais; B_i é o
6 coeficiente e seu valor pode ser obtido a partir de dados experimentais, dados
7 de parâmetros atmosféricos ou da equação de transferência radiativa
8 atmosférica simulada, que depende do conteúdo de vapor de água da
9 atmosfera para melhorar a precisão.

10 Para reduzir o acoplamento dos parâmetros atmosféricos, o algoritmo
11 estima o vapor de água atmosférico com base em dados de infravermelho
12 térmico.

13 Uma relação empírica é estabelecida entre a taxa de transmitância
14 atmosférica $\frac{T_i}{T_j}$ e o conteúdo de vapor de água atmosférico (wv) dos dois canais
15 usando os perfis atmosféricos de *Moderate resolution atmospheric*
16 *Transmission* (MODTRAN) e *Thermodynamic Initial Guess Retrieval* (TIGR)
17 primeiro e depois usando a taxa de covariância e covariância entre as
18 temperaturas de brilho dos dois canais em uma janela móvel de um certo
19 tamanho para estimar a taxa de transmitância atmosférica (Equações 5 e 6).

$$wv = a + b \left(\frac{T_i}{T_j} \right) + c \left(\frac{T_i}{T_j} \right)^2 \quad (5)$$

$$\frac{T_i}{T_j} \approx R_{ji} = \frac{\sum_{k=1}^N (T_{i,k} - \bar{T}_j)(T_{i,k} - \bar{T}_j)}{(T_{i,k} - \bar{T}_j)^2} \quad (6)$$

20 Na Equação (7) os resultados do cálculo da temperatura da superfície
21 sem unidade foram divididos por 100 para obtenção em graus Kelvin (K) e em
22 seguida foi convertido em Celsius (°C).

$$LST = T_s - 273.15 \quad (7)$$

23 Fluxo de CO₂

24 Entre os usos do solo atuais descritos foi aplicado via sistema-sensor
25 TM, RTM+ e OLI dos satélites Landsat 5, 7 e 8 respectivamente, o

1 monitoramento do quão eficiente foram os usos do solo e suas perdas no
2 sequestro de carbono da região de estudo. Para isso, foram utilizadas as
3 imagens orbitais corrigidas para fator de reflectância e o mosaico de
4 composição de melhores tiles via plataforma Google Earth Engine entre 01-01-
5 2000 a 31-12-2018.

6 Foi utilizado o índice CO₂Flux (RAHMAN et al., 2001), que tem a
7 finalidade de medir a eficiência do processo de sequestro de carbono pela
8 vegetação, ou seja, a taxa de fotossíntese no processo de fotossíntese. Para
9 tanto, foi calculado o Índice de Vegetação Fotossintético – PRI (Equação 8)
10 (GAMON et al., 1997). Para a elaboração deste índice, foram utilizadas as
11 bandas espectrais do verde e azul. O PRI estima os pigmentos de carotenóides
12 da folhagem. Estes pigmentos, por sua vez, indicam a taxa de armazenagem
13 de CO₂ nas folhagens (RAHMAN et al., 2001; BARNES et al., 2017).

$$PRI = \frac{A - V_e}{A + V_e} \quad (8)$$

14 A= Reflectância na banda espectral azul;

15 Ve= Reflectância na banda espectral verde.

16 Contudo, os resultados do PRI precisam ser reescalados, resultando
17 em valores positivos. Para isso é necessário gerar o sPRI (Equação 9)
18 (MARTINS & BAPTISTA, 2013).

$$sPRI = \frac{(PRI + 1)}{2} \quad (9)$$

19

20 Desta forma o índice CO₂Flux ($\mu\text{mol m}^{-2} \text{s}^{-1}$) foi o resultado da
21 multiplicação entre o NDVI e o sPRI, em que há uma relação entre o índice
22 PRI, que indica a eficiência do uso da luz na fotossíntese, com o NDVI que
23 demonstra o vigor da vegetação fotossinteticamente ativa, em que este pode
24 ser capaz de captar absorções oriundas do sequestro de carbono (RAHMAN et
25 al., 2001).

26 Para uma melhor correlação dos valores observados via sensoriamento
27 remoto com os valores medidos por torres micrometeorológicas. As medidas de
28 fluxos de CO₂ das torres são determinadas por meio do método de Covariância
29 de Vórtices Turbulentos (Eddy Covariance), que de acordo com Aguiar et al.,
30 (2006), é um sistema que emprega sensores de resposta rápida, medindo três

1 componentes da velocidade do vento: velocidade horizontal do vento a leste,
2 velocidade horizontal do vento a norte, e velocidade vertical do vento. O
3 sistema fornece médias a cada 30 minutos.

4 Segundo Boas dos Santos, (2017) a melhor correlação foi por meio da
5 Equação (10).

$$CO2FLUX = 13.63 - (66.207 * (NDVI * sPRI)) \quad (10)$$

6 **GPP (Gross Primary Productivity)**

7 O produto MOD17A2 relacionado à produção primária bruta é um
8 composto cumulativo dos valores de GPP baseado no conceito da eficiência de
9 utilização da radiação solar pela vegetação (ϵ). Nesta lógica, a produção
10 primária é linearmente relacionada à radiação fotossinteticamente ativa
11 absorvida (APAR), de acordo com a Equação (11). O APAR pode ser calculado
12 como o produto da radiação fotossinteticamente ativa incidente (PAR), na faixa
13 espectral visível de 0,4 μm – 0,7 μm , assumida como 45% da radiação solar
14 incidente total e a fração de radiação fotossinteticamente ativa absorvida pela
15 cobertura vegetal (FPAR) (HEINSCH et al., 2003; DELGADO et al., 2018).

$$GPP = \epsilon * PAR * FPAR \quad (11)$$

16 Um dos maiores desafios no uso de tais modelos é obter a eficiência do
17 uso da luz " ϵ " em uma grande área, devido à sua dependência de fatores
18 ambientais e da própria vegetação. Uma das soluções consiste em relacionar
19 " ϵ " de acordo com seu valor máximo (ϵ_{max}), mais as contribuições ambientais
20 sintetizadas pela temperatura mínima do ar ($T_{minscalar}$) e o estado da água na
21 vegetação (VPD_{scalar} - déficit de pressão do vapor d'água) (FIELD et al.,
22 1995), de acordo com a Equação (12).

$$\epsilon = \epsilon_{max} * T_{minscalar} * VPD_{scalar} \quad (12)$$

23

24 Neste estudo, utilizou-se o MODIS GPP (Gross Primary Productivity),
25 versão 5.0 com composição na plataforma Google Earth Engine entre as datas
26 01-06-2017 a 31-05-2018. Os valores dos pixels referentes aos números
27 digitais das imagens MODIS foram convertidos em valores biofísicos (Kg C
28 m^{-2}) através da multiplicação pelo fator de escala (0,0001) (HEINSCH et al.,

1 2003) (Equação 13). Os valores de GPP também foram transformados do valor
 2 acumulado a cada 8 dias para valores médios a cada 8 dias e convertidos de
 3 Kg C m⁻² dia⁻¹ para g C m⁻² dia⁻¹.

$$GPP_{1Km} = \frac{\text{Biophysical Pixel (Kg C m}^{-2}\text{)}}{8} \quad (13)$$

4

5 **Albedo e Balanço de Radiação**

6 Segundo Allen et al. (2002), o albedo baseia-se na integração linear da
 7 reflectância dos comprimentos de onda variando do visível ao infravermelho
 8 próximo e médio com mensurações de fator de reflectância no topo da
 9 atmosfera. Para Tasumi et al. (2008), a estimativa do albedo foi criada para
 10 melhorar a precisão sobre diversas condições da superfície no balanço de
 11 energia, tal como uso e conversão da superfície do solo por ações antrópicas
 12 principalmente. O albedo é calculado pela integração da reflectância da
 13 superfície das bandas espectrais de ondas curtas. O fator de reflectância da
 14 superfície é derivado das imagens orbitais usando funções de transmitância
 15 atmosférica em cada banda espectral, em que se utilizam dados de pressão
 16 atmosférica, ângulo zenital solar, ângulo de visada de aquisição da imagem e
 17 coeficientes calibrados para diferentes sensores (HE et al., 2018; WANG et al.,
 18 2016).

19 O albedo da superfície foi calculado no domínio da radiação de onda
 20 curta (0,3 – 3,0 μm), porém sem correção atmosférica, em que será obtido por
 21 meio de combinação linear das refletâncias espectrais ρ_{λ,b}, com pesos ω_{λ,b}
 22 estabelecido para cada banda, sendo a Equação (14):

23

$$\alpha_{toa} = (\omega_2 * \rho_{\lambda,2}) + (\omega_3 * \rho_{\lambda,3}) + (\omega_4 * \rho_{\lambda,4}) + (\omega_5 * \rho_{\lambda,5}) + (\omega_6 * \rho_{\lambda,6}) + (\omega_7 * \rho_{\lambda,7}) \quad (14)$$

24 assim, cada peso será obtido pela razão entre a constante solar específica da
 25 banda b e a somatória de todas as constantes ESUN_{λ,b}, qual seja (Equação
 26 15):

$$\omega_{\lambda,b} = \frac{ENSU_{\lambda,b}}{\sum ENSU_{\lambda,b}} \quad (15)$$

27 em que para o OLI/LANDSAT-8 os valores são apresentados na Tabela 2.

1

2 Tabela 2: Coeficientes dos pesos (ω_n) para o cálculo do albedo planetário
3 através do uso de imagens LANDSAT-8.

Bandas	Banda 2	Banda 3	Banda 4	Banda 5	Banda 6	Banda 7
ω_n	0,300	0,277	0,233	0,143	0,036	0,012
ESUN λ ,b	2011,3	1853	1532,8	956,4	237,8	80,2

4 Fonte: Silva et al. (2016), adaptado pelo autor.

5

6 Posteriormente, foi realizado a correção do albedo, sendo calculado de
7 acordo com a Equação (16) a seguir, proposto por Tasumi et al. (2008):

$$\alpha_{SUP} = \frac{\alpha_{TOA} - \alpha_{atm}}{\tau_{SW}^2} \quad (16)$$

8

9 em que: α_{atm} é a porção da radiação solar refletida pela atmosfera, adotado
10 0,03 de acordo com Bastiaanssen et al. (2000), em que τ_{SW} é a transmitância
11 atmosférica para dias de céu claro na Equação (17) proposta por Allen et al.
12 (2002):

$$\tau_{SW} = 0,75 + 2 * 10^{-5} * MED, \quad (17)$$

13

14 em que: MED é o modelo de elevação digital, representado pela altitude (m) de
15 cada pixel, o qual será utilizado pela missão com o radar *Shuttle Radar*
16 *Topography Mission*.

17 Após obtido os valores de IAF será calculada a Emissividade de Superfície (ϵ_0)
18 por meio da equação de Plank invertida, proposta para um corpo negro. O
19 cálculo de ϵ_0 é feito em função do IAF, como apresentado na seguinte Equação
20 (18):

$$\epsilon_0 = 0,95 + 0,01 * IAF \quad (18)$$

21

22 Para realizar o cálculo da temperatura da Superfície, antes deverá ser
23 computado a radiância monocromática utilizando a banda 10 do sensor
24 *Thermal Infrared Sensor* (TIRS) LANDSAT-8. Empregando os fatores de
25 reescalamento da radiância fornecidos nos metadados (USGS, 2019)
26 (Equação 19):

$$L_{\lambda} = M_L Q_{cal} + A_L \quad (19)$$

1

2 em que: L_{λ} é a radiância monocromática, M_L é o fator de reescalonamento
 3 multiplicativo específico ($3,342 \times 10^{-4}$), A_L é o fator de reescalonamento aditivo
 4 específico (0,1), e Q_{cal} é o valor pixel a pixel da imagem orbital, utilizando a
 5 Equação (20):

$$T_s = \frac{K_2}{\ln\left(\frac{K_1}{K_2} + 1\right)} \quad (20)$$

6

7 em que: K_2 e K_1 são constantes de calibração da banda termal 10.

8 Em seguida será calculado a radiação de onda longa emitida ($W m^{-2}$) por
 9 cada pixel, mediante a Equação (21) de Stefan-Boltzmann, em função da
 10 temperatura T_s e da emissividade da superfície ε_0 :

$$R_{ol,emi} = \varepsilon_0 \cdot \sigma \cdot T_s^4 \quad (21)$$

11

12 em que σ é a constante de Boltzmann ($5,67 \times 10^{-8} W m^{-2} K^{-4}$).

13 A radiação de onda longa incidente ($W m^{-2}$) também será calculada
 14 segunda a Equação (22) de Stefan-Boltzmann, em função da emissividade do
 15 ar – ε_a e da temperatura do ar – T_a (obtido pela estação em superfície), dada
 16 por:

$$R_{ol,atm} = \varepsilon_a \cdot \sigma \cdot T_a^4 \quad (22)$$

17 em que:

$$\varepsilon_a = 0,85 \cdot (-\ln \tau_{sw})^{0,09} \quad (22)$$

18

19 A radiação de onda curta incidente ($W m^{-2}$) será considerada constante
 20 para a área de estudo e na carência de dados piranométricos será obtida
 21 segundo o modelo (ALLEN et al., 2002; GOMES et al., 2009) (Equação 23):

$$R_s = Q \cdot \cos \theta \cdot dr \cdot \tau_{sw} \quad (23)$$

22

1 Em que Q é a constante solar (1367 W m^{-2}); θ é o ângulo de incidência
2 solar; dr é a distância Terra-Sol e τ_{sw} é a transmissividade atmosférica
3 (calculada segundo a Equação 24).

4 O saldo de radiação (W m^{-2}) será obtido segundo a Equação 33 a seguir:

$$Rn = (1 - \alpha) \cdot R_s + R_{ol,atm} - R_{ol,emi} - (1 - \varepsilon_0) \cdot R_{ol,atm} \quad (24)$$

5
6 em que: α é o albedo de superfície; R_s é a radiação de onda curta incidente;
7 $R_{ol,atm}$ é a radiação de onda longa incidente; $R_{ol,emi}$ é a radiação de onda longa
8 emitida e ε_0 é a emissividade da superfície ($4 - 100 \mu\text{m}$).

9 **ARIMA - Modelagem do Futuro e Passado**

10 O *Autoregressive Integrated Moving Average Model* (ARIMA) foi utilizado
11 para prever mudanças prováveis das variáveis CO_2Flux , Albedo, GPP e
12 Temperatura a partir da série de dados do período estudado, representando as
13 duas áreas estudadas sobre a máscara de soja. Os modelos ARIMA têm duas
14 formas gerais (p, d e q) e (P, D, Q), não sazonais e sazonais, respectivamente,
15 como mostrado na Equação (25). O modelo sazonal foi usado neste estudo em
16 que, AR (p) refere-se ao número de observações de atraso incluídas no
17 modelo, também chamado de ordem de atraso na equação de regressão para
18 a série Y . I (d) refere-se ao número de vezes que as observações brutas são
19 diferenciadas, também chamadas de grau de diferenciação, e MA (q) é o termo
20 da média móvel, leva à observação de erros anteriores. Os dados das variáveis
21 analisadas foram parametrizados seguindo seus valores de variação de mínimo
22 e máximo de cada autor.

$$Y_t = c + \phi_1 y_{dt-1} + \phi_p y_{dt-p} + \dots + \phi_1 e_{t-1} + \phi_q e_{t-q} + e_t \quad (25)$$

23
24 onde y (d) é Y diferenciado vezes d , e c são constantes, p é a ordem
25 autorregressiva, d é a ordem de diferenciação (1 ou 2 normalmente) e q é a
26 ordem da média móvel.

27 A validação ocorreu com a geração das séries de dados de 8 anos, ou
28 seja, a partir do modelo, as séries anteriores de 132 amostras foram geradas

1 para prever o próximo ano. Todos os anos considerados foram validados a
2 partir de indicadores estatísticos, como Erro Padrão de Estimativa (EPE),
3 coeficiente de determinação (R^2) e índice de concordância de Willmott (d). A
4 simulação futura das variáveis CO₂Flux, Albedo, GPP e Temperatura foi
5 realizada para o período de 10 anos, de janeiro de 2019 a dezembro de 2028,
6 usando dados mensais da série temporal de 19 anos (2000 a 2018). Esses
7 modelos dependem diretamente de valores passados e, portanto, funcionam
8 bem em séries longas e estáveis (VALIPOUR, 2015).

9 Todo o processamento foi realizado em software ambiente R versão
10 3.5.1 por meio das bibliotecas (MASS, tseries, forecast, readxl, raster, rgdal,
11 maptools, RSAGA e ggplot2) (R CORE TEAM, 2015).

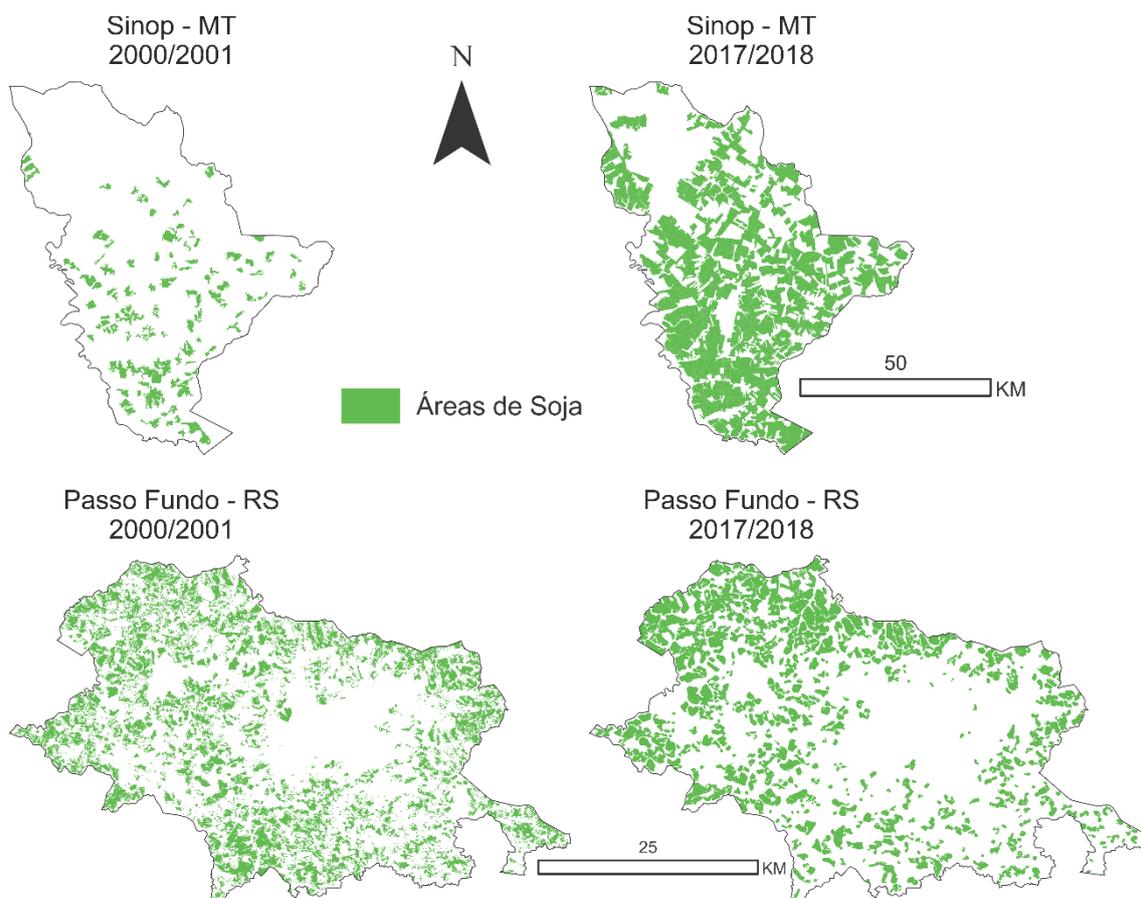
12

1 RESULTADOS E DISCUSSÃO

2 Identificação da soja nas áreas de estudo via MODIS

3 A detecção de soja nos municípios de Sinop - MT e Passo Fundo - RS,
4 para os anos safra de 2000/2001 e 2017/2018 por meio do sensor MODIS, é
5 apresentada na Figura 3. No ano safra de 2000/2001 foram mapeados
6 34.875,95 hectares (Sinop, MT) e 22.461,58 hectares (Passo Fundo, RS),
7 respectivamente. Já na safra de 2017/2018, a área mapeada foi de 199.519,97
8 hectares (Sinop, MT) e 21.886,41 hectares (Passo Fundo, RS), revelando um
9 aumento de 472% e um decréscimo de 2,56% respectivamente comparando os
10 dois anos safra analisados. Este aumento da área cultivada entre os anos
11 safras se deve ao acréscimo da demanda internacional e dos preços atrativos
12 da soja e, assim contribuíram para aumento significativo das áreas cultiváveis
13 em ambos os municípios (CONAB, 2019).

14



15

16 FIGURA 3: Mapeamento da soja nos anos safras 2000/2001 e 2017/2018 nos
17 municípios de Sinop - MT e Passo Fundo - RS pelo sensor MODIS.

1

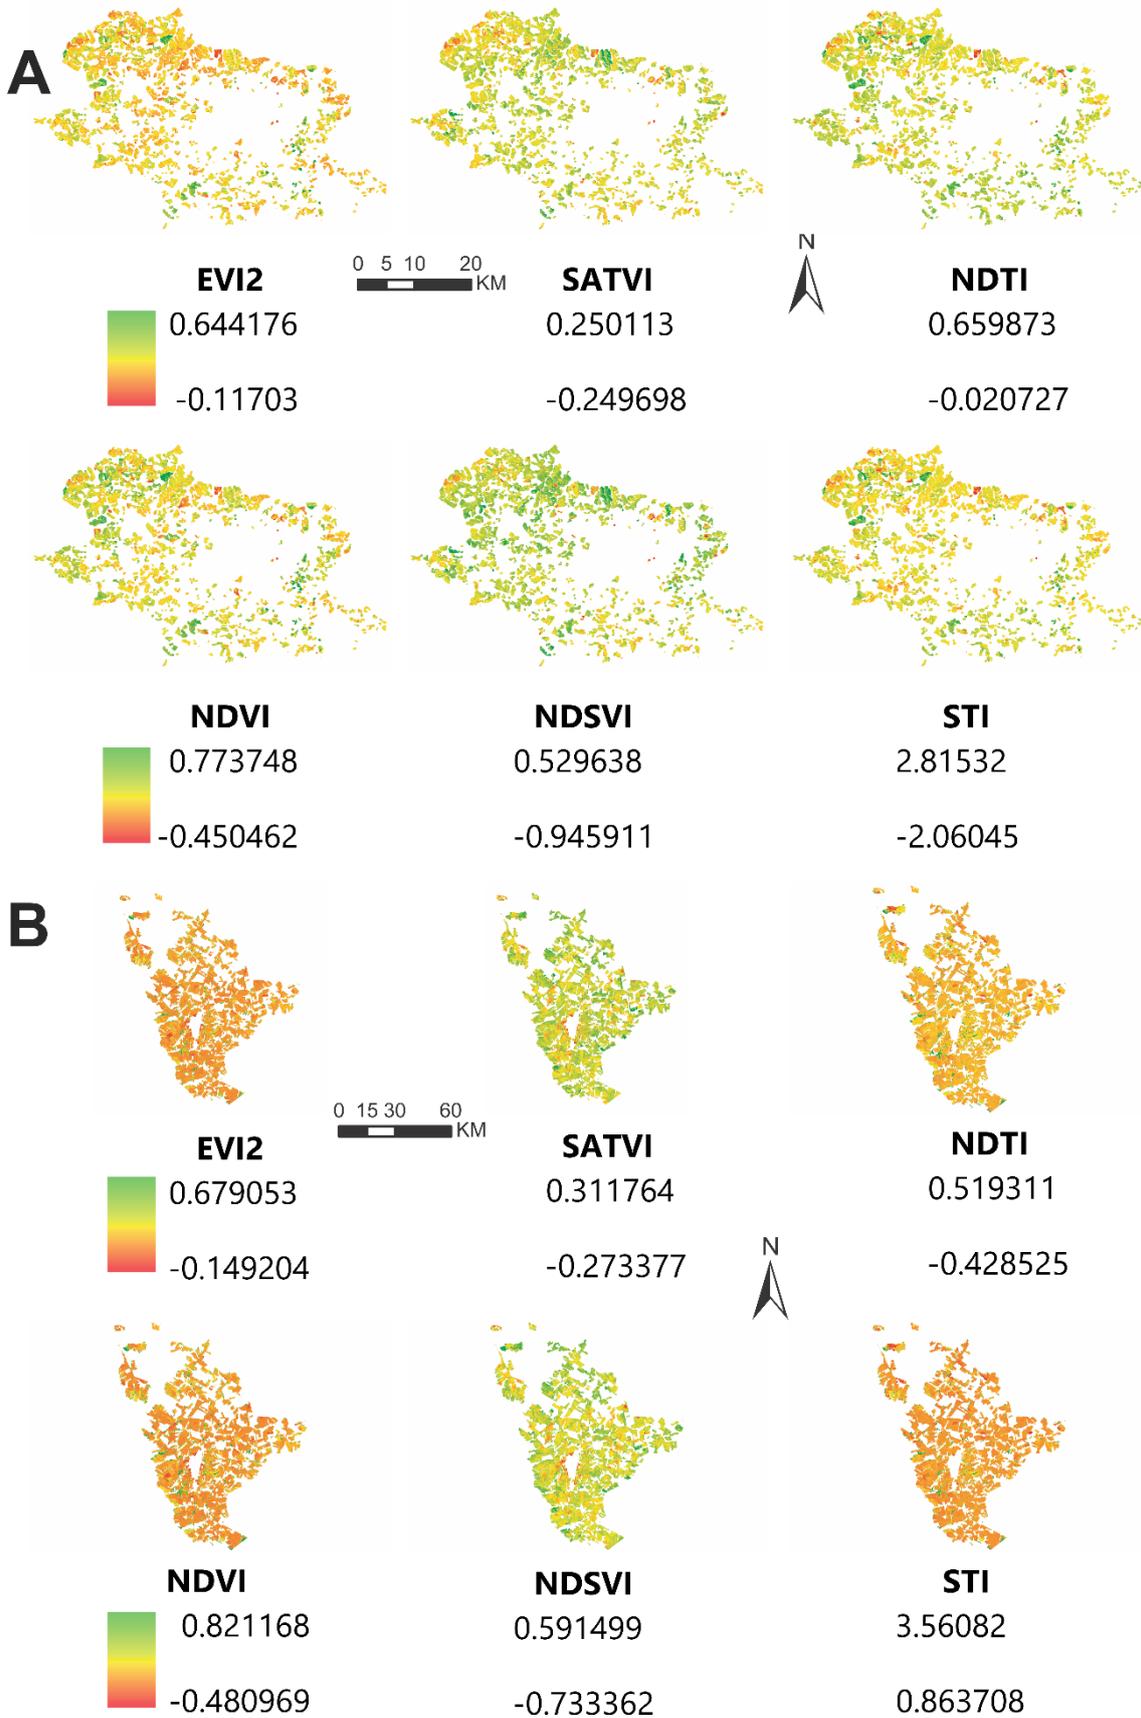
2 Os resultados obtidos pelo mapeamento apresentam de modo geral
3 satisfatório na discriminação das áreas de cultivo de soja, outros trabalhos
4 como descrito por Gusso et al., (2013); Spera et al. (2016); Kastens et al.
5 (2017); Silva Junior e Lima, (2018); Silva Junior et al., (2019b), também
6 afirmam a eficiência da metodologia utilizada assim como neste trabalho.

7 **Índices de Vegetação**

8 A Figura 4 mostra os índices de vegetação nos municípios de Sinop -
9 MT e Passo Fundo – RS. Os índices de vegetação usados no estudo
10 apresentaram alta variabilidade espacial entre os municípios analisados,
11 conforme mostrado no ano safra de 2017/2018 (Figura 4), ano safra de maior
12 produção e área de plantio de soja nos dois municípios (SOJAMAPS, 2020;
13 CONAB, 2019; IBGE, 2020). O município de Passo Fundo, RS, apresentou
14 uma maior quantidade de áreas com densidade vegetativa em comparação
15 com o município de Sinop, MT, conforme os índices EVI2 e NDVI. Áreas de
16 cultivo no estado do Rio Grande do Sul tem o comumente uso de forrageiras
17 antes da semeadura da soja e, no entanto, o estado do Mato Grosso não tem
18 esse costume entre os produtores.

19 Os índices NDTI e STI, no município de Passo Fundo, RS, mostraram
20 uma maior aglomeração de áreas com fração de cobertura seca ao sistema de
21 manejo do solo em relação ao município de Sinop, MT, como já demonstrados
22 em estudos anteriores (DAI et al., 2018; CHAI et al., 2019; WANG et al., 2019).
23 SATVI e NDSVI apresentaram uma senescência da vegetação quase
24 proporcional entre os dois municípios.

25



1

2 FIGURA 4: Índices de vegetação para o ano safra 2017/2018 para os
 3 municípios de Passo Fundo, RS (A) e Sinop, MT (B).

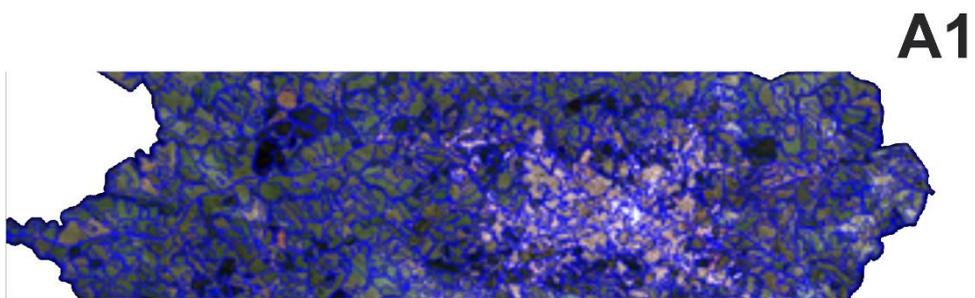
1 Vale destacar que os valores obtidos dos índices EVI2 e NDVI, em
2 relação ao comportamento espectral do solo, pode ser afetado por vários
3 fatores, por exemplo, devida à presença de umidade, conteúdo de matéria
4 orgânica, a presença de óxido de ferro, proporção de argila, silte, areia e a
5 rugosidade do solo, que por sua vez interfere na energia eletromagnética com
6 o solo (MORAES NOVO, 2010).

7 As imagens multiespectrais e os índices de vegetação foram extraídos o
8 mais próximo possível do início do preparo do solo para a semeadura da soja,
9 para que as bandas espectrais não sofressem extrema interferência com a
10 umidade (CONAB, 2019; YUE et al., 2019).

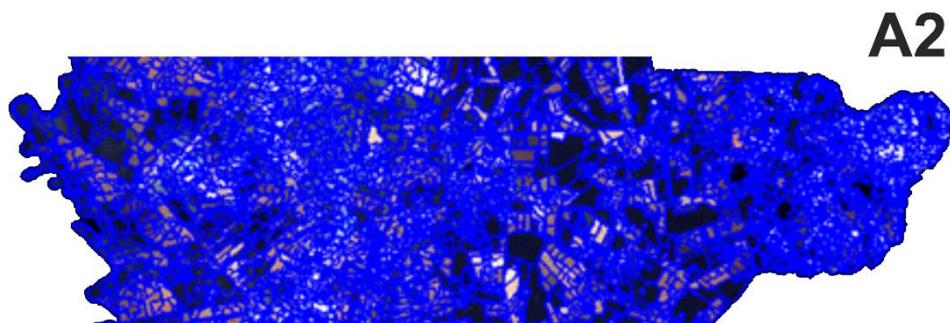
11 **GEOBIA e Classificação do Manejo do Solo**

12 Na Figura 5 A evidencia a eficiência da aplicação da segmentação
13 multirresolução nas bandas espectrais e os índices de vegetação seguindo a
14 metodologia do capítulo 1. A segmentação apresenta na Figura 5 demonstra
15 discriminação distintas dos objetos (polígonos) gerados, assim visualmente
16 percebido quando se aplica a combinação da falsa cor (RGB) na imagem,
17 outros trabalhos apontam maior precisão quando se utiliza a classificação por
18 segmentação de multirresolução (BLASCHKE, 2010; KAVZOGLU & TONBUL,
19 2017; YIN et al., 2017; WANG et al., 2020). Essa segmentação utilizada
20 juntamente com o método classificação automatizado, por meio de árvore de
21 decisão, proposto no capítulo 1 foi gerado a Figura 5 B exibindo os tipos de
22 manejo do solo (PC, PD_A e PD_B).

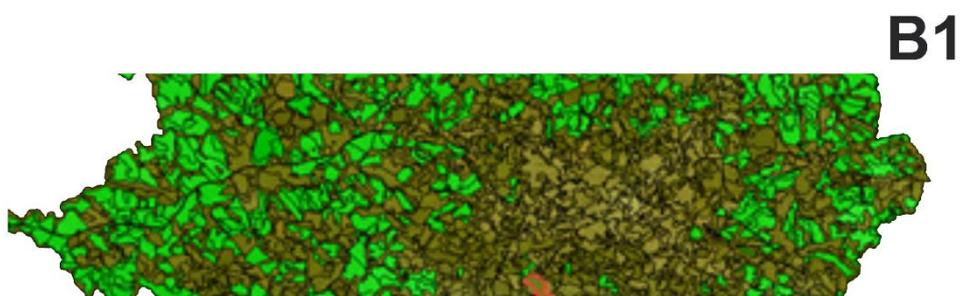
23



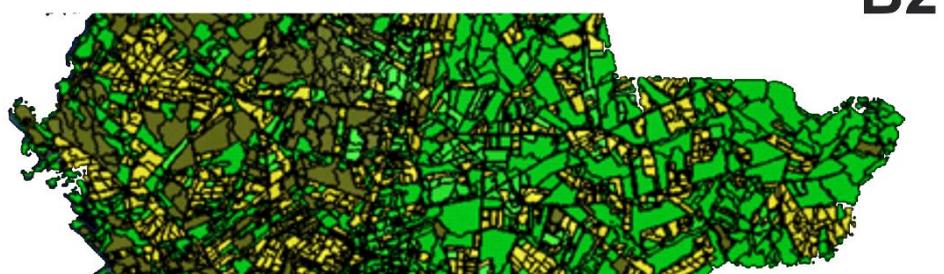
A1



A2



B1



B2

1

2 FIGURA 5: Segmentação e aplicação da árvore de decisão nos municípios de
3 Passo Fundo - RS (A1/B1) e Sinop - MT (A2/B2) no ano safra 2000/2018.

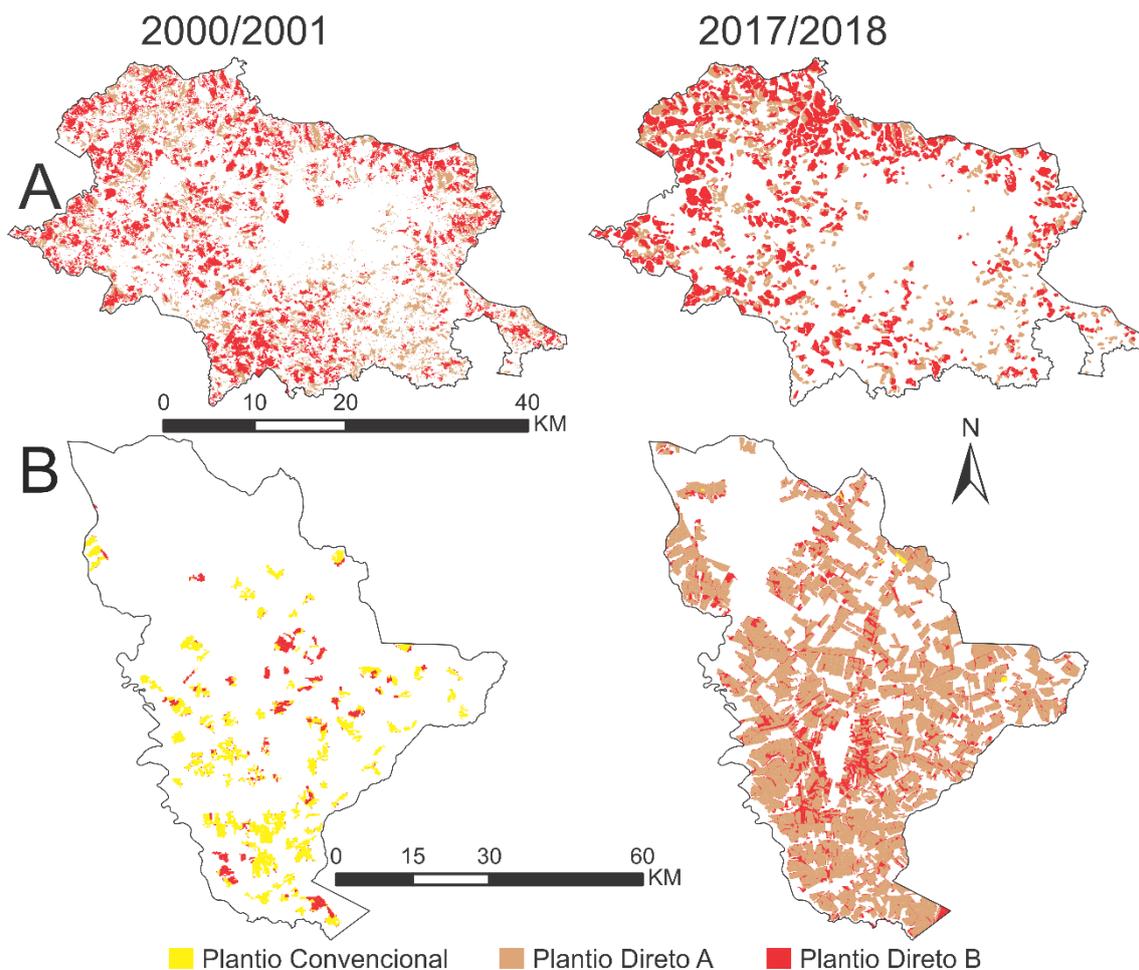
4 A técnica de segmentação das imagens apresentou uma variação de
5 objetos aceitável para aplicação do algoritmo árvore de decisão. Vale ressaltar
6 que outros trabalhos realizados anteriormente utilizaram metodologia similar de
7 segmentação para analisar as alterações da cobertura e uso da terra (SOUZA-
8 FILHO et al., 2018; XI et al., 2019), detecção de áreas irrigadas por pivô central

1 (VOGELS et al., 2019) e discriminação de ervas daninhas (LÓPEZ-
2 GRANADOS, 2011; DE CASTRO, et al., 2013; CASTILLEJO-GONZÁLEZ, et
3 al., 2014).

4 A Figura 6 representa a discriminação do mapa temático das áreas
5 estudadas em relação os tipos de plantios da soja, após a aplicação do
6 algoritmo da árvore de decisão. Os resultados obtidos apontam uma maior
7 intensidade de manejo do solo para o plantio direto B no município de Passo
8 Fundo, RS, em todos os anos safras analisadas. Ao contrário, do município de
9 Sinop, MT, onde foi observada uma variação no método de manejo do solo,
10 uma vez que, nos anos anteriores 2000/2001, o domínio maior foi pelo plantio
11 convencional e posteriormente, nos anos safras de 2017/2018, houve maior
12 utilização do preparo do solo pelo plantio direto B, com aumento significativo
13 para o plantio direto A se comparado ao ano safra anterior. Tal fato se deve ao
14 tempo de chegada da cultura da soja em cada município e sua produção em
15 grande escala, por exemplo, em Passo Fundo a implementação da lavoura de
16 soja ocorreu antes de 2000 tendo a intensificação na produção a partir de
17 2005, ao contrário, de Sinop que suas áreas planta de soja eram mínimas em
18 2000 e sua intensificação na produção teve início em 2010 (IBGE, 2020).

19 O município de Passo Fundo, RS, no ano safra 2000/2001 em
20 comparação ao município de Sinop, MT, apresentou maior porcentagem
21 (86,14%) de área preparada com o Plantio Direto A (PD_A) – (Tabela 3). Isso
22 se justifica pela quantidade de área plantada em cada município, conforme
23 descrito no item 3.1. No entanto, no ano safra 2017/2018 o município de Sinop
24 superou o município de Passo Fundo em 91,43% de área identificada como
25 PD_A. No Plantio Direto B (PD_B), verifica-se a mesma ocorrência do PD_A,
26 sendo que no ano safra 2000/2001 no município de Passo Fundo, RS, obteve
27 40,74% maior que no município de Sinop, MT, e, assim ocorreu uma mudança
28 significativa no ano safra 2017/2018 de 77,69% maior para o município de
29 Sinop (Tabela 3).

30



1 ■ Plantio Convencional ■ Plantio Direto A ■ Plantio Direto B
 2 FIGURA 6: Discriminação das áreas estudadas quanto ao tipo de manejo solo
 3 nos anos safra 2000/2001 e 2017/2018, A - Passo Fundo e B - Sinop.

4
 5 Tabela 3: Total de área preparada para o plantio convencional e plantio direto A
 6 e B em hectares (ha) nos anos safra 2000/2001 e 2017/2018 nos municípios de
 7 Passo Fundo, RS e Sinop, MT.

Município	Ano Safra	PC (ha)	PD_A (ha)	PD_B (ha)
Passo Fundo	2000/2001	0	853,65	13921,93
	2017/2018	0	14063,01	7823,39
Sinop	2000/2001	26507,55	118,31	8250,07
	2017/2018	383,70	164066,52	35069,74

8
 9 A análise exploratória via boxplot representada pela série temporal em
 10 19 anos de estudo das variáveis albedo, CO₂FLUX, GPP e temperatura (°C) é

1 apresentada na (Figura 7). O albedo calculado para o município de Passo
2 Fundo, RS, para o PD_A foi de 0,15. Destaque para o mês de setembro de
3 2010 (0,283) com a maior média de albedo e agosto de 2016 (0,061), com
4 menor valor, respectivamente. Em relação ao PD_B, a média do albedo foi de
5 0,19, sendo o mês de maior emissão agosto de 2017 (0,462) e a menor em
6 agosto de 2015 (0,058). Comparativamente os métodos de PD_A com PD_B,
7 mostraram que no PD_B houve maior albedo registrado. Porém, os dois
8 métodos coincidiram com a menor produção do albedo, registrada nos meses
9 de agosto em anos subsequentes.

10 No município de Sinop a média do albedo emitido durante os anos
11 analisados para o PD_A (0,18) e PD_B (0,21). Os meses registrados com
12 maiores valores de albedo foram outubro de 2010 (0,36) e janeiro de 2001
13 (0,516) para PD_A e PD_B, respectivamente. Os valores mínimos foram
14 obtidos em agosto de 2015 (0,07) e junho de 2013 (0,10) (PD_A e PD_B). Os
15 municípios de Passo Fundo e Sinop se relacionam quanto a menor produção
16 do albedo para o método PD_A e maior para o PD_B.

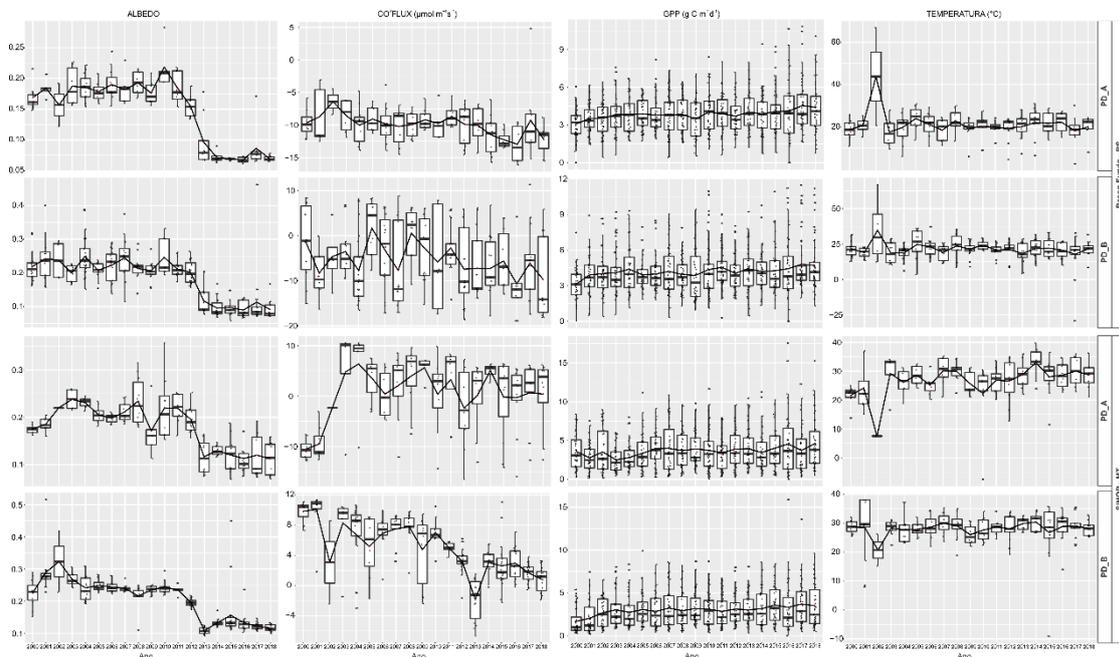
17 A quantidade de emissão (-) e absorção (+) de CO₂Flux pode ser
18 verificada na Figura 7. Os meses de maior emissão do CO₂Flux no PD_A
19 ocorreu em agosto de 2016 (Passo Fundo) e em dezembro 2012 (Sinop) -
20 (Figura 7). No PD_B os meses com maior valor de emissão de CO₂Flux foi
21 fevereiro de 2016 (Passo Fundo, RS) e março de 2013 e (Sinop, MT),
22 respectivamente. Vale ressaltar que os municípios de Passo Fundo e Sinop
23 absorveram praticamente a mesma quantidade de CO₂Flux no PD_B ao
24 decorrer de toda série temporal, no entanto, vale destacar que no ano de 2017
25 Passo Fundo absorveu menos CO₂Flux.

26 Os valores de GPP apresentaram um pico distinto em cada município
27 dos anos de 2000 até 2011, picos elevados no início de novembro ao final de
28 fevereiro para PD_A e PD_B de Passo Fundo (Figura 7). Em Sinop são picos
29 no início de fevereiro até o final de junho. No entanto, a partir de ano de 2012
30 até 2018 os picos de valores do GPP dos dois municípios se iniciam juntos no
31 mês de novembro até o final de março. A média de temperatura para o PD_A
32 variou de 20,64 °C para Passo Fundo a 26,20 °C para Sinop. No PD_B essas
33 temperaturas apresentaram-se em torno dos 21,20 °C a 27,16 °C para Passo

1 Fundo e Sinop. Portanto, as temperaturas em Sinop são maiores que Passo
2 Fundo durante toda série temporal de 19 anos.

3

4



5

6 FIGURA 7: Valores anuais de Albedo, CO₂Flux, GPP e Temperatura para série
7 temporal 2000 a 2018 nos dois municípios estudados.

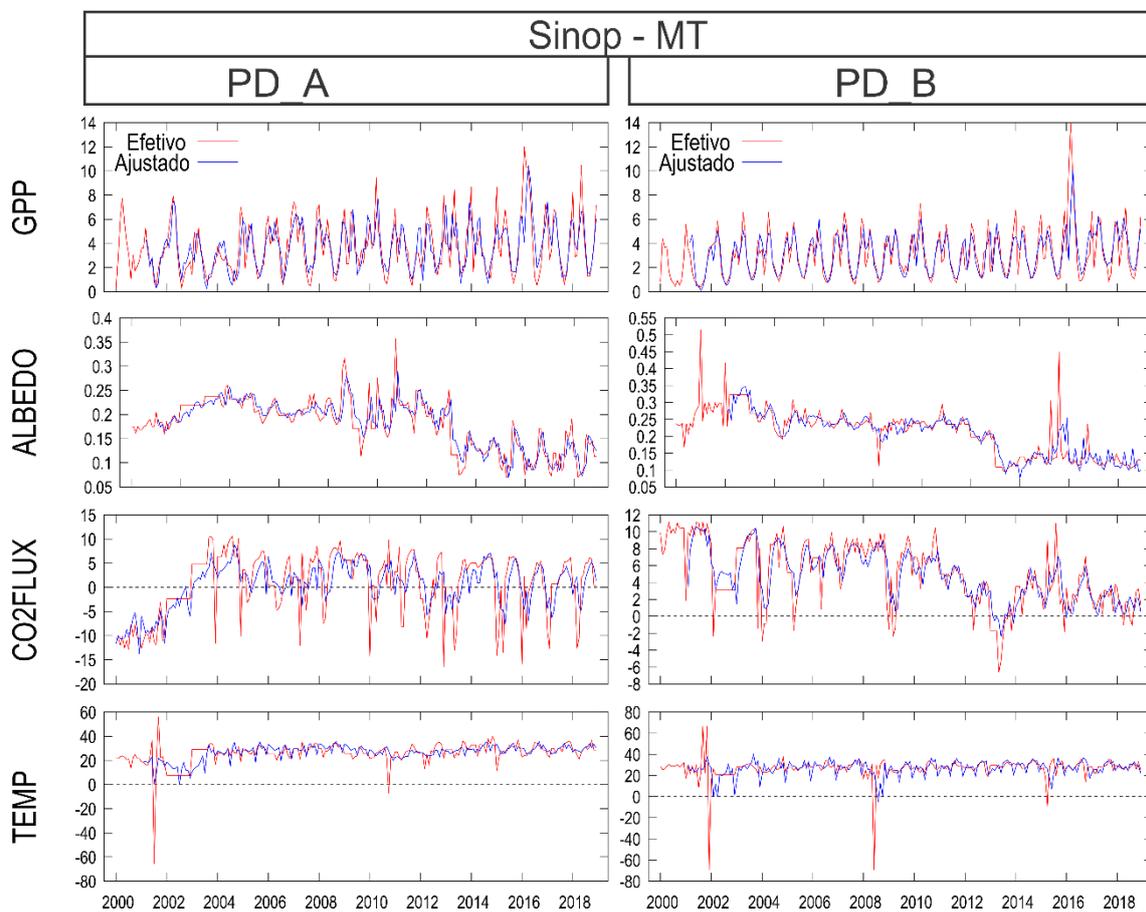
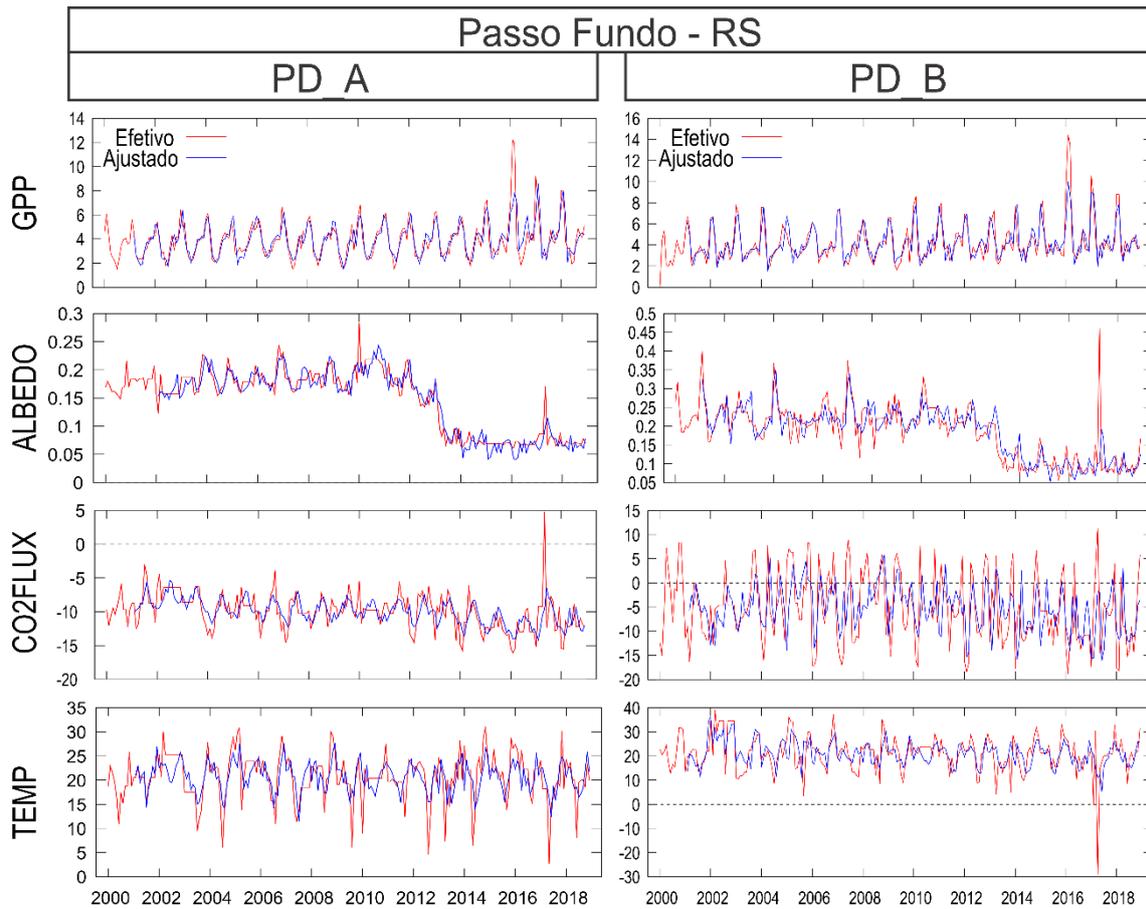
8 Variáveis Ambientais e Modelagem ARIMA

9 Com base nas análises estatísticas utilizadas para a fase de validação
10 do modelo, verifica-se que o modelo simulou de forma satisfatória a série
11 temporal para CO₂Flux, Albedo, GPP e Temperatura. A relação dos maiores
12 coeficientes de determinação (R²) encontrados no município de Passo Fundo,
13 no PD_A e PD_B, para GPP (0,94 (2008) e 0,91 (2006)) mostra uma
14 correlação forte entre o observado e a previsto com 90% da variação é
15 explicada e menos de 10% dos valores não tem uma correlação. No Albedo
16 (0,74 (2006) e 0,59 (2013)) e na Temperatura (0,72 (2004) e 0,58 (2012)) as
17 duas variáveis apresentam mais de 70% da variação do observado é explicado
18 pela variação do previsto, CO₂Flux (0,56 (2004) e 0,59 (2012)) menos de 60%
19 da variação do observado é explicado pelo previsto.

20 No município de Sinop a relação de GPP (0,82 (2017) e 0,91 (2005))
21 apresenta uma correlação forte de mais de 80% da variação do observado é
22 explicado no observado e menos de 20% não tem correlação, os valores de

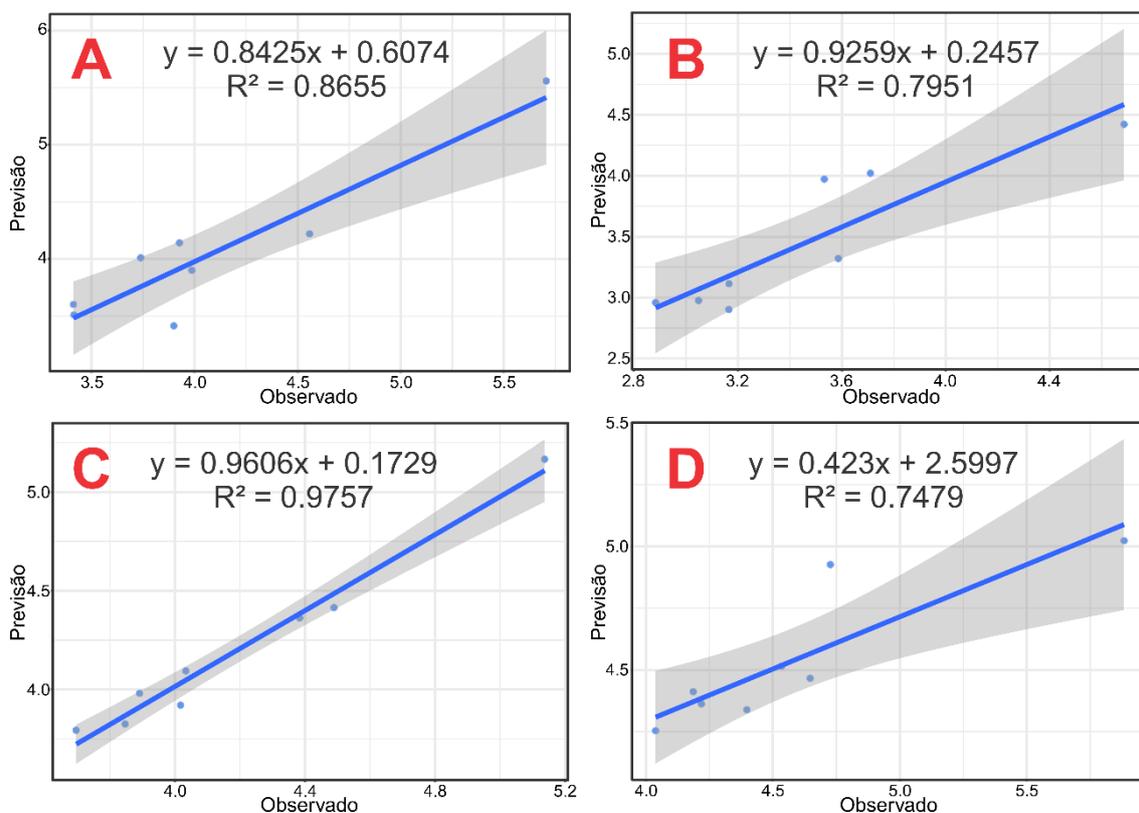
1 Albedo (0,70 (2014) e 0,64 (2004)) e o CO₂Flux (0,65 (2014) e 0,62 (2004))
2 apresentam mais de 60% da variação do observado é explicado pelo previsto e
3 Temperatura (0,54 (2011) e 0,39 (2018)) tendo uma correlação mais fraca entre
4 todas as variáveis.

5 Dos 19 anos e 16 variáveis analisadas entre os dois municípios e os dois
6 tipos de plantio, dos 304 valores de R² somente 193 apresentaram R² inferior a
7 0,50, mostrando que 36,50% da variação dos dados do previsto é explicado
8 pela variação do observado e que 63,50% dos dados do previsto podem não
9 ter uma correlação tão satisfatória com o observado. O índice de Willmott (d) foi
10 aproximadamente 0,99 para todos os anos da série temporal (Figura 8). Os
11 resultados obtidos da regressão mostraram uma correlação linear positiva para
12 todos os anos das séries de dados estudadas. Isso mostrou a capacidade do
13 modelo ARIMA de representar a condição de cada variável em cada no
14 município e os métodos de plantios de soja.



1 FIGURA 8: Dados de Albedo, CO₂Flux, GPP e Temperatura observados e
2 simulados de janeiro de 2000 a dezembro de 2018.

3 É perceptível que, para GPP nos dois municípios, os dados estão mais
4 agrupados e mais próximos da linha, esta variável apresentou o maior R2
5 (0,90) da série e coeficiente d = 1 (Figura 9). As variáveis Albedo, CO₂Flux e
6 Temperatura tiveram a pior correlação, mostrando um R2 de 0,00058, 0,0025 e
7 0,0010 respectivamente e um coeficiente d = 1. Para toda a série temporal
8 estudada nos dois municípios, o padrão o erro da estimativa (EPE) foi
9 considerado muito bom, com um valor médio de 0,82.

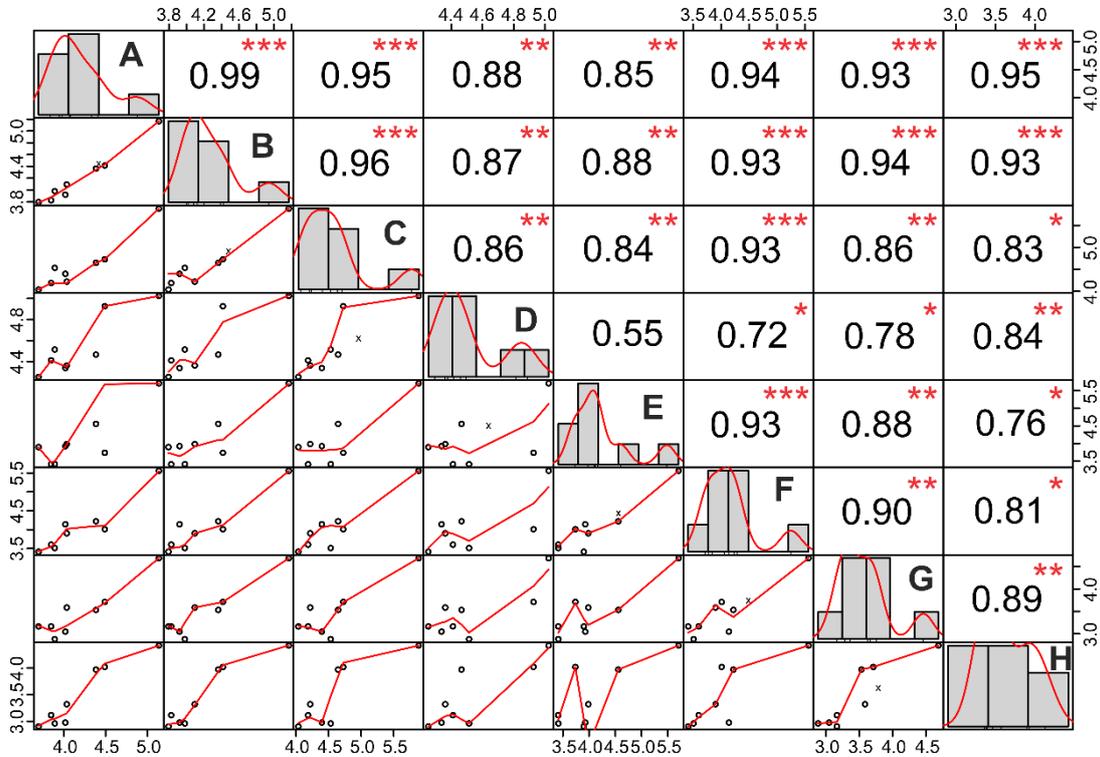


10

11 FIGURA 9: Coeficiente de determinação (R^2) dos melhores GPP de 2011 a
12 2018, PD_A e PD_B de Sinop (A e B respectivamente) e PD_A e PD_B de
13 Passo Fundo (C e D respectivamente).

14 Avaliando a distribuição de todos os dados observados e previstos do
15 GPP em um histograma nos anos de 2011 a 2018 para validação dos dados
16 futuros nas duas áreas de estudo, foi possível gerar um polígono das
17 frequências das variáveis (Figura 10). Na Figura 10, também temos a curva de
18 LOESS mostrando a dispersão de todos os dados, o PD_A observado de
19 Passo Fundo tem a melhor dispersão dos dados e uma melhor correlação com

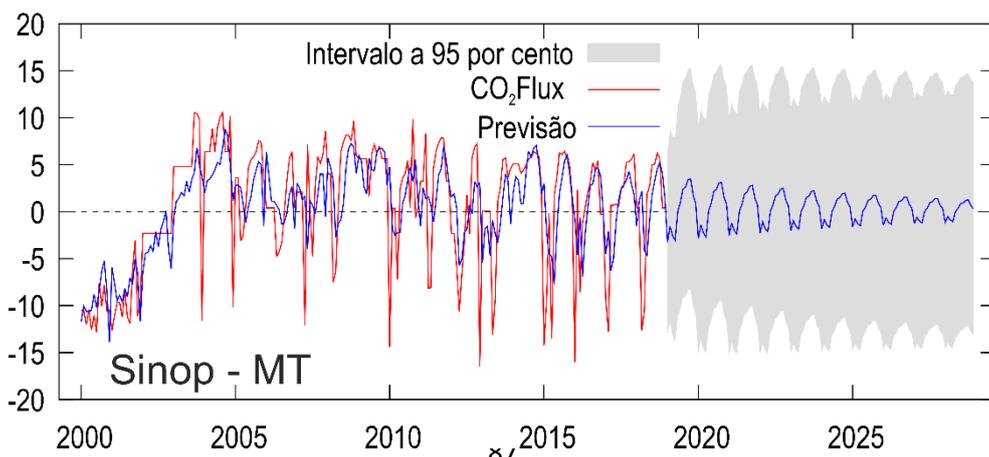
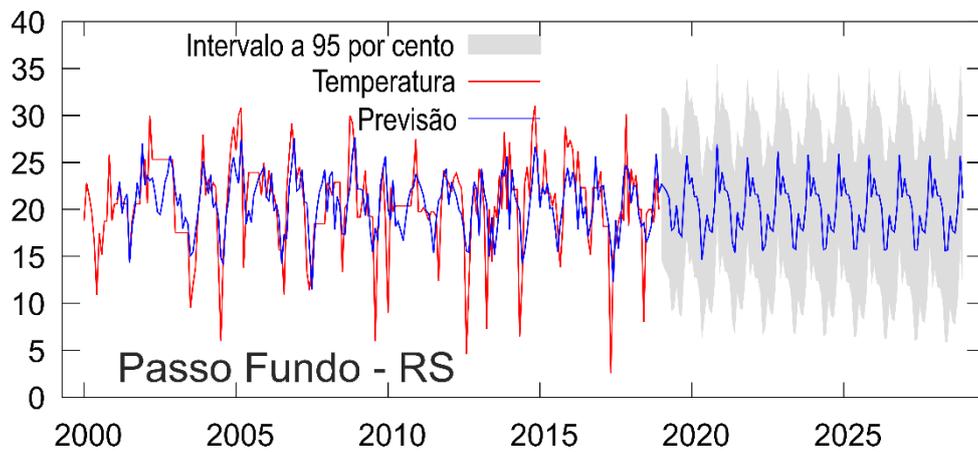
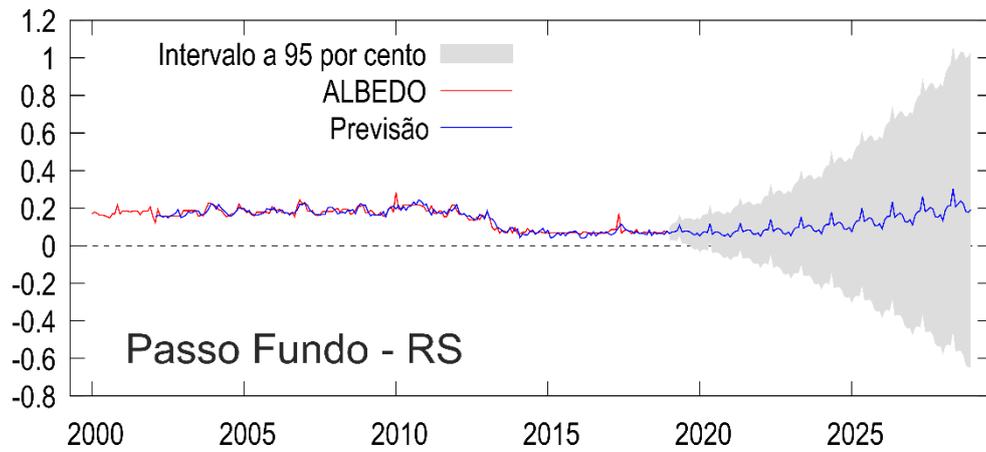
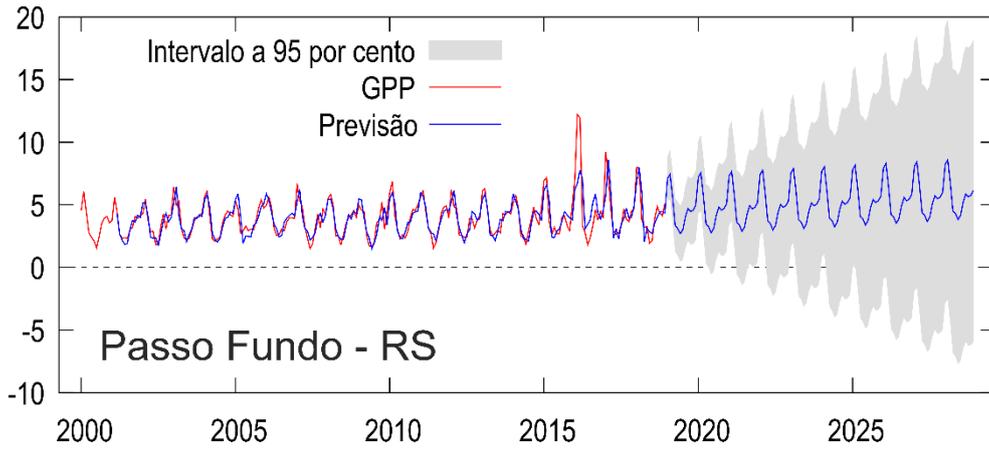
1 os outros dados. No entanto, as piores dispersões e correlações entre os
 2 dados foram o PD_A observado de Sinop e PD_B previsto de Passo Fundo.



3

4 FIGURA 10: Histograma de cada variável na diagonal, na esquerda a dispersão
 5 pela curva de LOESS e a direita a correlação dos valores (A - PD_A observado
 6 Passo Fundo; B - PD_A previsto de Passo Fundo; C - PD_B observado Passo
 7 Fundo; D - PD_B previsto de Passo Fundo; E - PD_A observado Sinop; F -
 8 PD_A previsto de Sinop; G - PD_B observado Sinop; H - PD_B previsto de
 9 Sinop).

10 Após os resultados da validação, a variabilidade do CO₂Flux, albedo,
 11 GPP e temperatura foi simulada para o cenário futuro de janeiro de 2019 a
 12 dezembro de 2028 com base no modelo ARIMA (Figura 11). O modelo ARIMA
 13 é bastante utilizado para previsão de seca (HAN et al., 2010) ou chuva (DUFFY
 14 et al., 2015; RIZEEI et al., 2018), análise de inundações nos rios e previsões de
 15 curto prazo para as séries no futuro (MACHEKPOSHTI et al., 2017) e um
 16 grande desempenho no fluxo de rios (FASHAE et al., 2019). O modelo ARIMA
 17 foi capaz de representar a sazonalidade do período futuro das variáveis
 18 ambientais de ambos os municípios avaliados.



1 FIGURA 11: Modelo ARIMA aplicado as variáveis ambientais: albedo, CO₂Flux,
2 GPP e temperatura para os municípios de Sinop - MT e Passo Fundo – RS,
3 com nível de confiabilidade de 95%.

4 **CONCLUSÃO**

5 A dinâmica ambiental dos municípios de Sinop - MT e Passo Fundo - RS
6 é ligada à cultura da soja. Das variáveis estudadas nos 19 anos da série
7 temporal, o GPP se sobressai em relação às demais, principalmente na época
8 de preparo do solo, com os menores valores em Sinop em relação a Passo
9 Fundo e no estágio de maturação da cultura. Destaque para os valores de
10 CO₂Flux com uma proporção contrária do GPP na época de preparo do solo e
11 até na colheita da soja. O albedo não apresenta valores discrepantes na série
12 temporal entre os municípios, com exceção da estação de altas temperaturas
13 em Sinop.

14 A modelagem futura com base no modelo ARIMA mostra que essas
15 tendências sazonais das variáveis ambientais analisadas são alteradas, devido
16 ao manejo do solo e a implementação das culturas. O modelo ARIMA aplicado
17 a série temporal mostra um nível de confiança para o cenário futuro da soja nas
18 áreas de estudo, visto que há uma tendência de aumento da GPP, seguido de
19 uma diminuição considerável no albedo, CO₂Flux e temperatura nos dois
20 municípios para os próximos anos.

1 REFERÊNCIAS BIBLIOGRÁFICAS

- 2 AGUIAR, R. G.; RANDOW, C. V.; FILHO, N. P.; MANZI, A. O.; AGUIAR, L. J.
3 G.; CARDOSO, F. L. Fluxos de massa e energia em uma floresta tropical no
4 sudoeste da Amazônia. **Revista Brasileira de Meteorologia**, v.21, n.3b, p.248-
5 257, 2006.
- 6 ALLEN, R.; BASTIAANSEN, W.; WATERS, R.; TASUMI, M.; TREZZA, R.
7 **Surface energy balance algorithms for land (SEBAL)**, Idaho implementation
8 - Advanced training and users manual, version 1.0, 97p. 2002.
- 9 BARNES, M. L.; BRESHEARS, D. D.; LAW, D. J.; VAN LEEUWEN, W. J.
10 MONSON, R. K.; FOJTIK, A. C.; BARRON-GAFFORD, G. A.; MOORE, D. J.
11 Beyond greenness: Detecting temporal changes in photosynthetic capacity with
12 hyperspectral reflectance data. **PloS one**, v. 12, n. 12, 2017.
- 13 BASTIAANSEN, W. G. M. SEBAL-based sensible and latent heat fluxes in the
14 irrigated Gediz Basin. Turkey. **Journal of Hydrology**. V. 229, p. 87-100. 2000.
- 15 BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS**
16 **Journal of Photogrammetry and Remote Sensing**, v.65, n.1, p.2-16, 2010.
- 17 BOAS DOS SANTOS, C. V. **MODELAGEM ESPECTRAL PARA**
18 **DETERMINAÇÃO DE FLUXO DE CO2 EM ÁREAS DE CAATINGA**
19 **PRESERVADA E EM REGENERAÇÃO**. 2017. Dissertação (mestrado) –
20 Universidade Estadual de Feira de Santana. Programa de Pós-Graduação em
21 Modelagem em Ciências da Terra e do Ambiente, 2017.
- 22 BRAGA, A. P. **Estimativa da produtividade primária bruta em áreas**
23 **agrícolas e de vegetação primária no cerrado por sensoriamento remoto**.
24 2013. Dissertação (Mestrado em Meteorologia) – Universidade Federal de
25 Campina Grande, Centro de Tecnologia e Recursos Naturais, Campina
26 Grande, 2013.
- 27 CARVALHO, J. L. N.; AVANZI, J. C.; SILVA, M. L. N.; MELLO, C. R. D.;
28 CERRI, C. E. P. Potencial de sequestro de carbono em diferentes biomas do
29 Brasil. **Revista Brasileira de Ciência do Solo**, v. 34, n. 2, p. 277-290, 2010.
- 30 CARVALHO, J. L. N.; CERRI, C. E. P.; CERRI, C. C. SPD aumenta o sequestro
31 de carbono pelo solo. **Visão agrícola**, v. 9, p. 132-135, 2009.
- 32 CASTILLEJO-GONZÁLEZ, I. L.; PENA-BARRAGÁN, J. M.; JURADO-
33 EXPÓSITO, M.; MESAS-CARRASCOSA, F. J.; LÓPEZ-GRANADOS, F.
34 Evaluation of pixel-and object-based approaches for mapping wild oat (*Avena*
35 *sterilis*) weed patches in wheat fields using QuickBird imagery for site-specific
36 management. **European Journal of Agronomy**, v. 59, p. 57-66, 2014.
- 37 CHAI, G.; WANG, J.; WANG, G.; KANG, L.; WU, M.; WANG, Z. Estimating
38 fractional cover of non-photosynthetic vegetation in a typical grassland area of
39 northern China based on Moderate Resolution Imaging Spectroradiometer
40 (MODIS) image data. **International Journal of Remote Sensing**, v. 40, n. 23,
41 p. 8793-8810, 2019.

- 1 CHERUBINI, F. GHG balances of bioenergy systems—Overview of key steps in
2 the production chain and methodological concerns. **Renewable Energy**, v. 35,
3 n. 7, p. 1565-1573, 2010.
- 4 CONAB - Companhia Nacional de Abastecimento. **Calendário de Plantio e**
5 **Colheita de Grãos no Brasil 2019**. Disponível em:
6 <<https://www.ibge.gov.br/cidades-e-estados/mt.html>>. Acesso em: 05 de nov.
7 de 2019.
- 8 CRUZ, A. P. D.; TUMIBAY, G. M. Predicting Tuberculosis Treatment Relapse:
9 A Decision Tree Analysis of J48 for Data Mining. **Journal of Computer and**
10 **Communications**, v. 7, n. 7, p. 243-251, 2019.
- 11 DAI, J.; ROBERTS, D.; DENNISON, P.; STOW, D. Spectral-radiometric
12 differentiation of non-photosynthetic vegetation and soil within Landsat and
13 Sentinel 2 wavebands. **Remote Sensing Letters**, v. 9, n. 8, p. 733-742, 2018.
- 14 DE ARAÚJO SANTOS, G. A.; MOITINHO, M. R.; DE OLIVEIRA SILVA, B.;
15 XAVIER, C. V.; TEIXEIRA, D. D. B.; CORÁ, J. E.; JÚNIOR, N. L. S. Effects of
16 long-term no-tillage systems with different succession cropping strategies on
17 the variation of soil CO₂ emission. **Science of the total environment**, v. 686,
18 p. 413-424, 2019.
- 19 DE CASTRO, A. I.; LÓPEZ-GRANADOS, F.; JURADO-EXPÓSITO, M.
20 Montserrat. Broad-scale cruciferous weed patch classification in winter wheat
21 using QuickBird imagery for in-season site-specific control. **Precision**
22 **Agriculture**, v. 14, n. 4, p. 392-413, 2013.
- 23 DEFINIENS. **Definiens professional 5**: Reference book. Munich, Germany:
24 The Imaging Intelligence Company, p.122. 2006.
- 25 DELGADO, R. C.; PEREIRA, M. G.; TEODORO, P. E.; DOS SANTOS, G. L.;
26 DE CARVALHO, D. C.; MAGISTRALI, I. C.; VILANOVA, R. S. Seasonality of
27 gross primary production in the Atlantic Forest of Brazil. **Global Ecology and**
28 **Conservation**, v. 14, p. e00392, 2018.
- 29 DU, C.; REN, H.; QIN, Q.; MENG, J.; ZHAO, S. A practical split-window
30 algorithm for estimating land surface temperature from Landsat 8 data. **Remote**
31 **Sensing**, v. 7, n. 1, p. 647-665, 2015.
- 32 DUFFY, P. B.; BRANDO, P.; ASNER, G. P.; FIELD, C. B. Projections of future
33 meteorological drought and wet periods in the Amazon. **Proceedings of the**
34 **National Academy of Sciences**, v. 112, n. 43, p. 13172-13177, 2015.
- 35 FAGUNDES, J. D.; PAULA, G. M. D.; LAGO, I.; STRECK, N. A.; BISOGNIN, D.
36 A. Aquecimento global: efeitos no crescimento, no desenvolvimento e na
37 produtividade de batata. **Ciência Rural**, v. 40, n. 6, p. 1464-1472, 2010.
- 38 FASHAE, O. A.; OLUSOLA, A. O.; NDUBUISI, I.; UDOMBOSO, C. G.
39 Comparing ANN and ARIMA model in predicting the discharge of River Opeki
40 from 2010 to 2020. **River research and applications**, v. 35, n. 2, p. 169-177,
41 2019.

- 1 FIELD, C. B.; RANDERSON, J. T.; MALMSTRÖM, C. M. Global net primary
2 production: combining ecology and remote sensing. **Remote sensing of**
3 **Environment**, v. 51, n. 1, p. 74-88, 1995.
- 4 GAMON, J.; SERRANO, L.; SURFUS, J. S. The photochemical reflectance
5 index: an optical indicator of photosynthetic radiation use efficiency across
6 species, functional types, and nutrient levels. **Oecologia**, v. 112, n. 4, p. 492-
7 501, 1997.
- 8 GAO, J.; YU, Z.; WANG, L.; VEJRE, H. Suitability of regional development
9 based on ecosystem service benefits and losses: A case study of the Yangtze
10 River Delta urban agglomeration, China. **Ecological Indicators**, v. 107, p.
11 105579, 2019.
- 12 GARCIA-PEDRERO, A.; GONZALO-MARTIN, C.; FONSECA-LUENGO, D.;
13 LILLO-SAAVEDRA, M. A GEOBIA methodology for fragmented agricultural
14 landscapes. **Remote Sensing**, v. 7, n. 1, p. 767-787, 2015.
- 15 GOMES, H. B. **Balço de radiao e energia em áreas de cultivo de cana-**
16 **de-açucar e cerrado no estado de São Paulo mediante imagens orbitais.**
17 2009. 125p. Tese (Doutorado) – Universidade Federal de Campina Grande
18 (UFCG). Campina Grande, 29 abr. 2009.
- 19 GUIMARÃES, F. D. S.; REZENDE, P. M. D.; CASTRO, E. M. D.; CARVALHO,
20 E. D. A.; ANDRADE, M. J. B. D.; CARVALHO, E. R. Cultivares de soja [Glycine
21 max (L.) Merrill] para cultivo de verão na região de Lavras-MG. **Ciência e**
22 **Agrotecnologia**, v.32, n. 4, p. 1099-1106, 2008.
- 23 GUSSO, A.; DUCATI, J. R.; VERONEZ, M. R.; ARVOR, D.; SILVEIRA JUNIOR,
24 L. G. D. Spectral model for soybean yield estimate using MODIS/EVI data.
25 **International journal of geosciences**. Irvine, CA. Vol. 4, n. 9 (Nov. 2013), p.
26 1233-1241, 2013.
- 27 HAN, P.; WANG, P. X.; ZHANG, S. Y. Drought forecasting based on the remote
28 sensing data using ARIMA models. **Mathematical and computer modelling**, v.
29 51, n. 11-12, p. 1398-1403, 2010.
- 30 HANSEL, F. D.; AMADO, T. J. C.; KELLER, C.; BORTOLOTTI, R. P.;
31 NICOLOSO, R. D. S.; NORA, D. Emissões de dióxido de carbono em sistema
32 plantio direto de longa duração. In: **Embrapa Suínos e Aves-Artigo em anais**
33 **de congresso (ALICE)**. In: CONGRESSO BRASILEIRO DE CIÊNCIA DO
34 SOLO, 34., 2013. Florianópolis. Anais... Viçosa, MG: Sociedade Brasileira de
35 Ciência do Solo, 2013., 2013.
- 36 HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for
37 image classification. **IEEE Transactions on systems, man, and cybernetics**,
38 n. 6, p. 610-621, 1973.
- 39 HE, T.; LIANG, S.; WANG, D.; CAO, Y.; GAO, F.; YU, Y.; FENG, M. Evaluating
40 land surface albedo estimation from Landsat MSS, TM, ETM+, and OLI data
41 based on the unified direct estimation approach. **Remote Sensing of**
42 **Environment**, v. 204, p. 181-196, 2018.

- 1 HEINSCH, F. A.; REEVES, M.; VOTAVA, P.; KANG, S. Y.; MILESI, C.; ZHAO,
2 M.S.; GLASSY, J.; JOLLY, W. M.; LOEHMAN, R.; BOWKER, C. F.; KIMBALL,
3 J. S.; NEMANI, R. R.; RUNNING, S. W. Gpp and npp (mod17a2/a3) products
4 nasa modis land algorithm. **MOD17 User's Guide**, p. 1-57, 2003.
- 5 IBGE - Instituto Brasileiro de Geografia e Estatística. CONHEÇA CIDADES E
6 ESTADOS DO BRASIL. Disponível em: < <https://cidades.ibge.gov.br/>>. Acesso
7 em: 22 jan. 2020.
- 8 JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band
9 enhanced vegetation index without a blue band. **Remote sensing of**
10 **Environment**, v. 112, p. 3833-3845, 2008.
- 11 KALMEGH, S. Analysis of weka data mining algorithm reptree, simple cart and
12 randomtree for classification of indian news. **International Journal of**
13 **Innovative Science, Engineering & Technology**, v. 2, n. 2, p. 438-446, 2015.
- 14 KASTENS, J. H.; BROWN, J. C.; COUTINHO, A. C.; BISHOP, C. R.;
15 ESQUERDO, J. C. D. Soy moratorium impacts on soybean and deforestation
16 dynamics in Mato Grosso, Brazil. **PloS one**, v. 12, n. 4, p. e0176168, 2017.
- 17 KAVZOGLU, T., & TONBUL, H. A comparative study of segmentation quality for
18 multi-resolution segmentation and watershed transform. In: **2017 8th**
19 **International Conference on Recent Advances in Space Technologies**
20 **(RAST)**. IEEE. p. 113-117. 2017.
- 21 KUMAR, B. N., & BABALAD, H. B. Soil organic carbon, carbon sequestration,
22 soil microbial biomass carbon and nitrogen and soil enzymatic activity as
23 influenced by conservation agriculture in pigeonpea and soybean intercropping
24 system. **Int. J. Curr. Microbiol. App. Sci**, v. 7, n. 3, p. 323-333, 2018.
- 25 LÓPEZ-GRANADOS, F. Weed detection for site-specific weed management:
26 mapping and real-time approaches. **Weed Research**, v. 51, n. 1, p. 1-11, 2011.
- 27 MACHEKPOSHTI, K. H.; SEDGHI, H.; TELVARI, A.; BABAZADEH, H. Flood
28 analysis in Karkheh River basin using stochastic model. **Civil Engineering**
29 **Journal**, v. 3, n. 9, p. 794-808, 2017.
- 30 MARSETT, R.C.; QI, J.; HEILMAN, P.; BIEDENBENDER, S.H.; WATSON,
31 M.C.; AMER, S.; WELTZ, M.; GOODRICH, D.; MARSETT, R. Remote sensing
32 for grassland management in the arid southwest. **Rangeland Ecology &**
33 **Management**, v. 59, n. 5, p. 530-540, 2006.
- 34 MARTINS, L. N., BAPTISTA, G. M. M. Análise multitemporal do sequestro
35 florestal de carbono no projeto de Assentamento Carão, Acre. **Revista**
36 **Brasileira de Geografia Física**, v. 6, n. 06, p. 1648-1657, 2013.
- 37 MORAES NOVO, E. M. L. de. Sensoriamento Remoto: Princípios e Aplicações.
38 4ª Edição-São Paulo, Blucher, 363p. 2010.
- 39 MOSIER, A.; WASSMANN, R.; VERCHOT, L.; KING, J.; PALM, C. Methane
40 and nitrogen oxide fluxes in tropical agricultural soils: sources, sinks and

- 1 mechanisms. **Environment, Development and Sustainability**, v. 6, n. 1-2, p.
2 11-49, 2004.
- 3 NANNI, M. R.; DEMATTÊ, J. A. M. Comportamento da linha do solo obtida por
4 espectrorradiometria laboratorial para diferentes classes de solo. **Revista**
5 **Brasileira de Ciência do Solo**, v. 30, n. 6, p. 1031-1038, 2006.
- 6 NOVO, E. M. L. D. M.; FERREIRA, L. G.; BARBOSA, C.; CARVALHO, C.;
7 SANO, E. E.; SHIMABUKURO, Y.; MELACK, J. J.; HUETE, A.; POTTER, C.;
8 ROBERTS, Dar.A.; HESS, L. L.; YOSHIOKA, H.; KLOOSTER, S.; KUMAR, V.;
9 MYNENI, R.; RATANA, P.; DIDAN, K.; MIURA, T. Técnicas avançadas de
10 sensoriamento remoto aplicadas ao estudo de mudanças climáticas e ao
11 funcionamento dos ecossistemas amazônicos. **Acta Amazonica**, v. 35, n. 2, p.
12 259-272, 2005.
- 13 ORMOND, A. T. S. **Sistemas de semeadura e manejo do solo no**
14 **desenvolvimento da cultura da soja**. 2013. Dissertação (Mestrado em
15 Engenharia Agrícola) - UNIVERSIDADE FEDERAL DE MATO GROSSO,
16 Rondonópolis. 71p. 2013.
- 17 OUYANG, W.; WAN, X.; XU, Y.; WANG, X.; LIN, C. Vertical difference of
18 climate change impacts on vegetation at temporal-spatial scales in the upper
19 stream of the Mekong River Basin. **Science of The Total Environment**, v. 701,
20 p. 134782, 2020.
- 21 PEREIRA, R. G.; ALBUQUERQUE, A. W. D.; SOUZA, R. D. O.; SILVA, A. D.
22 D.; SANTOS, J. P. A. D.; BARROS, E. D. S.; MEDEIROS, P. V. Q. D. Sistemas
23 de manejo do solo: soja [*Glycine max* (L.)] consorciada com *Brachiaria*
24 *decumbens* (STAPF). **Pesquisa Agropecuária Tropical**, v. 41, n. 1, p. 44-51,
25 2011.
- 26 QI, J.; MARSETT, R.; HEILMAN, P.; BIEDEN-BENDER, S.; MORAN, S.;
27 GOODRICH, D.; WELTZ, M. RANGES improves satellite-based information and
28 land cover assessments in southwest United States. *Eos*, **Transactions**
29 **American Geophysical Union**, v. 83, n. 51, p. 601-606, 2002.
- 30 R CORE TEAM. R (2015) A language and environment for statistical
31 computing. 583 Vienna, Austria. R Foundation for Statistical Computing. 2015.
- 32 RADICETTI, E.; OSIPITAN, O. A.; LANGEROODI, A. R. S.; MARINARI, S.;
33 MANCINELLI, R. CO₂ Flux and C Balance due to the Replacement of Bare Soil
34 with Agro-Ecological Service Crops in Mediterranean Environment.
35 **Agriculture**, v. 9, n. 4, p. 71, 2019.
- 36 RAHMAN, A. F.; GAMON, J. A.; FUENTES, D. A.; ROBERTS, D. A.;
37 PRENTISS, D. Modeling spatially distributed ecosystem flux of boreal forest
38 using hyperspectral indices from AVIRIS imagery. **Journal of Geophysical**
39 **Research**, v. 106, n. D24, p. 33,579-33,591, 2001.
- 40 REN, H.; DU, C.; LIU, R.; QIN, Q.; YAN, G.; LI, Z. L.; MENG, J. Atmospheric
41 water vapor retrieval from Landsat 8 thermal infrared images. **Journal of**
42 **Geophysical Research: Atmospheres**, v. 120, n. 5, p. 1723-1738, 2015.

- 1 RICHEY, J. E.; MELACK, J. M.; AUFDENKAMPE, A. K.; BALLESTER, V. M.;
2 HESS, L. L. Outgassing from Amazonian rivers and wetlands as a large tropical
3 source of atmospheric CO₂. **Nature**, v. 416, n. 6881, p. 617-620, 2002.
- 4 RIZEEI, H. M.; PRADHAN, B.; SAHARKHIZ, M. A. Surface runoff prediction
5 regarding LULC and climate dynamics using coupled LTM, optimized ARIMA,
6 and GIS-based SCS-CN models in tropical region. **Arabian Journal of
7 Geosciences**, v. 11, n. 3, p. 53, 2018.
- 8 ROSSI, F. S.; DE ARAÚJO SANTOS, G. A. Fire dynamics in Mato Grosso
9 State, Brazil: the relative roles of gross primary productivity. **Big Earth Data**, v.
10 1, p. 1-22, 2020.
- 11 ROUSE, J.W.; HASS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring
12 vegetation systems in the Great Plains with ERTS. In: EARTH RESOURCES
13 TECHNOLOGY SATELLITE SYMPOSIUM, 3., Washington. **Proceedings**.
14 Washington: NASA, 1974. p.309-317. 1974.
- 15 SALOMÃO, P. E. A.; KRIEBEL, W.; SANTOS, A. A.; MARTINS, A. C. E. The
16 Importance of Straw No-Tillage System for Soil Restructuring and Organic
17 Matter Restoration. **Research, Society and Development**, v. 9, n. 1, p.
18 154911870, 2020.
- 19 SILVA JUNIOR, C. A. D.; NANNI, M. R.; OLIVEIRA-JÚNIOR, J. F. D.; CEZAR,
20 E.; TEODORO, P. E.; DELGADO, R. C.; SHIRATSUCHI L. S.; SHAKIR M.;
21 CHICATI, M. L. Object-based image analysis supported by data mining to
22 discriminate large areas of soybean. **International Journal of Digital Earth**, v.
23 12, n. 3, p. 270-292, 2019b.
- 24 SILVA JUNIOR, C. A.; COSTA, G. M.; ROSSI, F. S.; VALE, J. C. E.; LIMA, R.
25 B.; LIMA, M. G.; OLIVEIRA-JUNIOR, J. F.; TEODORO, P. E.; SANTOS, R. C.
26 Remote Sensing for Updating the Boundaries between the Brazilian Cerrado-
27 Amazonia Biomes. **ENVIRONMENTAL SCIENCE & POLICY**, v. 1, p. 1, 2019a.
- 28 SILVA JUNIOR, C. A.; LIMA, MENDELSON. Soy Moratorium in Mato Grosso:
29 Deforestation undermines the agreement. **Land Use Policy**, v. 71, p. 540-542,
30 2018.
- 31 SILVA JUNIOR, C. A.; NANNI, M. R.; TEODORO, P. E.; SILVA, G. F. C.
32 Vegetation indices for discrimination of soybean areas: A new approach.
33 **Agronomy Journal**, Vol. 109 No. 4, p. 1331-1343, 2017.
- 34 SILVA, B. B.; LOPES, G. M.; AZEVEDO, P. V. Balanço de radiação em áreas
35 irrigadas utilizando imagens Landsat 5-TM. **Revista Brasileira de
36 Meteorologia**, v. 20, n. 2, p. 243-252, 2005.
- 37 SINGH, A. P.; SINGH, S. K.; RAI, S.; KUMAR, M. Soil Carbon Dynamics in
38 Relation to Soil Surface Management and Cropping System. In: **Carbon
39 Management in Tropical and Sub-Tropical Terrestrial Systems**. Springer,
40 Singapore, p. 159-172. 2020.

- 1 SOJAMAPS. **Geotecnologia Aplicada em Agricultura e Floresta (GAAF)**.
2 Disponível em: < <http://pesquisa.unemat.br/gaaf/sojamaps/>>. Acesso em: 05 de
3 jan. de 2020.
- 4 SOUZA, A. P.; MOTA, L. L.; ZAMADEI, T.; MARTIM, C. C.; ALMEIDA, F. T.;
5 PAULINO, J. Classificação climática e balanço hídrico climatológico no Estado
6 de Mato Grosso. **Nativa**, v.1, n.1, p.34-43, 2013.
- 7 SOUZA-FILHO, P.; NASCIMENTO, W.; SANTOS, D.; WEBER, E., SILVA, R.;
8 SIQUEIRA, J. A GEOBIA approach for multitemporal land-cover and land-use
9 change analysis in a tropical watershed in the southeastern Amazon. **Remote**
10 **Sensing**, v. 10, n. 11, p. 1683, 2018.
- 11 SPERA, S. A.; GALFORD, G. L.; COE, M. T.; MACEDO, M. N.; MUSTARD, J.
12 F. Land-use change affects water recycling in Brazil's last agricultural frontier.
13 **Global change biology**, v. 22, n. 10, p. 3405-3413, 2016.
- 14 TASUMI, M.; ALLEN, R. G.; TREZZA, R.; WRIGHT, J. L. Satellite-Based
15 Energy Balance to Assess Within-Population Variance of Crop Coefficient
16 Curves. **Journal of Irrigation and Drainage Engineering**, ASCE, 94-108 p.,
17 2008.
- 18 UNITED STATES GEOLOGICAL SURVEY (USGS). **Using the USGS Landsat**
19 **8 Product**. Disponível em: <[https://landsat.usgs.gov/using-usgs-landsat-8-](https://landsat.usgs.gov/using-usgs-landsat-8-product)
20 [product](https://landsat.usgs.gov/using-usgs-landsat-8-product)>. Acessado em: 04 out. 2019.
- 21 VALIPOUR, M. Long-term runoff study using SARIMA and ARIMA models in
22 the United States. **Meteorological Applications**, v. 22, n. 3, p. 592-598, 2015.
- 23 VAN DEVENTER, A. P.; WARD, A. D.; GOWDA, P. H.; LYON, J. G. Using
24 Thematic Mapper data to identify contrasting soil plains and tillage practices.
25 **Photogrammetric Engineering and Remote Sensing**, v. 63, p. 87-93, 1997.
- 26 VOGELS, M. F.; DE JONG, S. M.; STERK, G.; DOUMA, H.; ADDINK, E. A.
27 Spatio-temporal patterns of smallholder irrigated agriculture in the horn of Africa
28 using GEOBIA and Sentinel-2 imagery. **Remote Sensing**, v. 11, n. 2, p. 143,
29 2019.
- 30 WANG, G.; WANG, J.; ZOU, X.; CHAI, G.; WU, M.; WANG, Z. Estimating the
31 fractional cover of photosynthetic vegetation, non-photosynthetic vegetation and
32 bare soil from MODIS data: Assessing the applicability of the NDVI-DFI model
33 in the typical Xilingol grasslands. **International Journal of Applied Earth**
34 **Observation and Geoinformation**, v. 76, p. 154-166, 2019.
- 35 WANG, X.; GAO, X.; ZHANG, X.; WANG, W.; YANG, F. An Automated Method
36 for Surface Ice/Snow Mapping Based on Objects and Pixels from Landsat
37 Imagery in a Mountainous Region. **Remote Sensing**, v. 12, n. 3, p. 485, 2020.
- 38 WANG, Z.; ERB, A. M.; SCHAAF, C. B.; SUN, Q.; LIU, Y.; YANG, Y.; ROMÁN,
39 M. O. Early spring post-fire snow albedo dynamics in high latitude boreal forests
40 using Landsat-8 OLI data. **Remote sensing of environment**, v. 185, p. 71-83,
41 2016.

- 1 WU, L.; QIN, Q.; LIU, X.; REN, H.; WANG, J.; ZHENG, X.; YE, X.; SUN, Y.
2 Spatial up-scaling correction for leaf area index based on the fractal theory.
3 **Remote Sensing**, v. 8, n. 3, p. 197, 2016.
- 4 XI, W.; DU, S.; WANG, Y. C.; ZHANG, X. A spatiotemporal cube model for
5 analyzing satellite image time series: Application to land-cover mapping and
6 change detection. **Remote Sensing of Environment**, v. 231, p. 111212, 2019.
- 7 YIN, H.; KHAMZINA, A.; PFLUGMACHER, D.; MARTIUS, C. Forest cover
8 mapping in post-Soviet Central Asia using multi-resolution remote sensing
9 imagery. **Scientific reports**, v. 7, n. 1, p. 1-11, 2017.
- 10 YIN, H.; PRISHCHEPOV, A. V.; KUEMMERLE, T.; BLEYHL, B.; BUCHNER, J.;
11 RADELOFF, V. C. Mapping agricultural land abandonment from spatial and
12 temporal segmentation of Landsat time series. **Remote Sensing of**
13 **Environment**, v. 210, p. 12-24, 2018.
- 14 YUE, J.; TIAN, Q.; DONG, X.; XU, K.; ZHOU, C. Using Hyperspectral Crop
15 Residue Angle Index to Estimate Maize and Winter-Wheat Residue Cover: A
16 Laboratory Study. **Remote Sensing**, v. 11, n. 7, p. 807, 2019.
- 17 ZANELA, P. M.; SANTOS, A. P. S.; YAMAGUCHI, C. K. RELAÇÃO DAS
18 EMISSÕES DE GÁS CARBONO E A AGRICULTURA. **Seminário de Ciências**
19 **Sociais Aplicadas**, v. 5, n. 5, 2016.