

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

**UNIDADES DE GESTÃO DIFERENCIADA POR MEIO DE ÍNDICES DE
VEGETAÇÃO E MAPAS DE PRODUTIVIDADE**

VINÍCIUS HENRIQUE DIAS DE OLIVEIRA

Cascavel,
Maio de 2021

VINÍCIUS HENRIQUE DIAS DE OLIVEIRA

**UNIDADES DE GESTÃO DIFERENCIADA POR MEIO DE ÍNDICES DE
VEGETAÇÃO E MAPAS DE PRODUTIVIDADE**

Dissertação apresentada à Universidade Estadual do Oeste do Paraná, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de Mestre em Engenharia Agrícola.

Área de concentração: Sistemas Biológicos e Agroindustriais

Orientador: Erivelto Mercante

Cascavel,

Maio de 2021

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Oliveira, Vinícius Henrique Dias de
Unidades de Gestão Diferenciada por meio de índices de
vegetação e mapas de produtividade / Vinícius Henrique Dias
de Oliveira; orientador(a), Erivelto Mercante, 2021.
67 f.

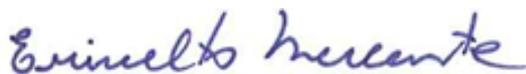
Dissertação (mestrado), Universidade Estadual do Oeste
do Paraná, Campus de Cascavel, Centro de Ciências Exatas e
Tecnológicas, Programa de Pós-Graduação em Engenharia
Agrícola, 2021.

1. Agricultura de precisão. 2. Sensoriamento remoto. 3.
Dados de colheita. 4. Agrupamento de dados. I. Mercante,
Erivelto. II. Título.

VINÍCIUS HENRIQUE DIAS DE OLIVEIRA

Unidades de Gestão Diferenciada por meio de índices de vegetação e mapas de produtividade

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



Orientador(a) - Erivelto Mercante

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



Rafael Cesar Tieppo

Universidade do Estado de Mato Grosso (UNEMAT)



Marcio Antonio Vilas Boas

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

Cascavel, 23 de fevereiro de 2021.

BIOGRAFIA

Vinícius Henrique Dias de Oliveira, filho mais velho de Henrique Dias de Oliveira e Adiles Pazzini de Oliveira, nasceu em Cascavel (PR), aos 20 dias do mês de setembro de 1995.

Cursou o Ensino Médio integrado ao Curso Técnico em meio ambiente no Centro Estadual de Educação Profissional Pedro Boaretto Neto em Cascavel. Em 2014 iniciou o ensino superior no curso de Agronomia na Universidade Estadual do Oeste do Paraná, no município de Marechal Cândido Rondon onde, cumpriu as exigências e recebeu o título de Eng.º Agrônomo em fevereiro de 2019. Atualmente é discente em nível de Mestrado no Programa de Pós-Graduação em Engenharia Agrícola da Unioeste/Campus de Cascavel.

Nos anos de 2019 e 2020 atuou como analista de agricultura de precisão na C.Vale - Cooperativa Agroindustrial, localizada no município de Palotina-PR.

“Para cada escolha, há um eco. A cada ato, mudamos o mundo.”

Sofia Lamb - Bioshock II

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela imensa dádiva da vida e pelas oportunidades nela recebidas.

Em especial aos meus pais, Henrique Dias de Oliveira e Adiles Pazzini de Oliveira, pelos ensinamentos, pela educação e por todo apoio necessário para que me tornasse a pessoa que sou e onde cheguei.

Ao orientador Prof. Dr. Erivelto Mercante, pela dedicação e contribuições no desenvolvimento deste trabalho.

Aos meus professores, pelo desafio de sua profissão, por transmitirem de forma eficaz seus conhecimentos e pela contribuição essencial ao desenvolvimento de seus alunos como pessoas e profissionais.

À Universidade Estadual do Oeste do Paraná - UNIOESTE e ao Programa de Pós-Graduação em Engenharia Agrícola - PGEAGRI, pela oportunidade do curso de mestrado.

À CAPES, pelo apoio financeiro.

Aos colegas do Laboratório de Topografia e Geoprocessamento.

A toda minha família e amigos que, de alguma forma, contribuíram para realização deste trabalho.

Muito obrigado!

UNIDADES DE GESTÃO DIFERENCIADA POR MEIO DE ÍNDICES DE VEGETAÇÃO E MAPAS DE PRODUTIVIDADE

RESUMO

Muitos estudos indicam que a população no mundo pode ter um grande aumento em poucos anos e, junto a isso, a demanda por alimentos também tende a aumentar. Ademais, o espaço destinado à produção de alimentos se encontra perto de um limite, sendo que muitas áreas já encontram um desgaste e não podem mais suprir essa necessidade. Portanto, é necessária uma alternativa aos métodos tradicionais de produção, como a agricultura de precisão que visa aumentar a produtividade, por meio da otimização do uso de recursos e do espaço disponível. No entanto, é necessário coletar dados sobre todos os parâmetros que possam interferir na produtividade e, ainda mais importante, a melhor forma de interpretar esses dados para se tomar decisões. O presente trabalho tem como objetivo avaliar diversos índices de vegetação, por meio de mapas de colheita, para delineamento de unidades de gestão diferenciada (UGDs), visto que os dados de produtividade, geralmente, são de difícil acesso entre a maioria de pequenos e médios produtores. Para isso, foram selecionados dez índices de vegetação para quatro diferentes datas, referentes a duas safras de soja e duas safras de milho. Tais safras possuem registro de colheita, que foram convertidos em mapas e utilizados para comparação e validação dos mapas gerados por índices de vegetação. As unidades de gestão diferenciada foram geradas por meio do algoritmo *Fuzzy C-means*, que realiza um agrupamento dados semelhantes, de acordo com um número pré-determinado de classes. Para determinação do melhor agrupamento, os dados foram submetidos a análises de variância e índices de validação fuzzy. Para determinação da melhor delimitação entre as UGDs dos índices de vegetação, foi utilizado o índice Kappa. Os resultados indicaram um melhor agrupamento dos dados em quatro classes, gerando quatro UGDs. A comparação entre as UGDs geradas pela produtividade e as UGDs geradas por índice de vegetação indicou boa concordância para quatro classes ($K = 0,64$ a $0,70$). Espera-se, com este trabalho, uma contribuição no processo de transformação da agricultura em relação à facilidade no acesso de informação e antecipação nas tomadas de decisão.

Palavras-chave: agricultura de precisão, sensoriamento remoto, dados de colheita, agrupamento de dados.

MANAGEMENT ZONES USING VEGETATION INDICES AND PRODUCTIVITY MAPS

ABSTRACT

Many studies indicate that the population in the world may have a large increase in a few years and, in addition, the demand for food also tends to increase. Moreover, the space for food production is close to a limit, with many areas already in degradation and no longer being able to supply this need. Therefore, an alternative to traditional production methods is necessary, such as precision agriculture, which aims to increase productivity by optimizing the use of resources and available space. However, it is necessary to collect data on all parameters that may interfere with productivity and, even more importantly, the best way to interpret this data to make decisions. The present work aims to evaluate several vegetation indexes, through harvest maps, for the delineation of management zones (ZMs), since productivity data is generally difficult to access among most small and medium producers. For this, ten vegetation indexes were selected for four different dates, referring to two soybean crops and two corn crops. Such crops have harvest records, which were converted into maps and used for comparison and validation of maps generated by vegetation indexes. The management zones were generated using the Fuzzy C-means algorithm, which performs similar data grouping according to a predetermined number of classes. For determination of the best procedure, the data were submitted to analysis of variance and fuzzy validation indexes. To determine the best delimitation between the ZMs of the vegetation indexes, the Kappa index was used. The results indicated a better grouping of the data in four classes, generating four ZMs. The comparison between the ZMs generated by productivity and the ZMs generated by vegetation index indicated good agreement for four classes ($K = 0.64$ to 0.70). It is expected, with this work, a contribution in the transformation process of agriculture in regards to making information easier to access and increasing anticipation in decision making.

Keywords: precision agriculture, remote sensing, harvest data, data grouping.

SUMÁRIO

LISTA DE TABELAS.....	ix
LISTA DE FIGURAS	x
1 INTRODUÇÃO	12
2 OBJETIVOS.....	14
2.1 Objetivo geral	14
2.2 Objetivos específicos.....	14
3 REVISÃO BIBLIOGRÁFICA	15
3.1 Cenário da agricultura no Brasil e no mundo	15
3.2 Agricultura de precisão	16
3.3 Unidades de gestão diferenciada	17
3.4 Mapeamento da produtividade	18
3.5 Sensoriamento remoto	18
3.6 Índices de vegetação.....	19
4 MATERIAL E MÉTODOS.....	23
4.1 Caracterização da área de estudo.....	23
4.2 Processamento de dados de colheita e geração de mapas de produtividade.....	27
4.3 Processamento de imagens orbitais	30
4.4 Geração de unidades de gestão diferenciada.....	31
4.5 Análises de validação de agrupamento	32
4.5.1 Análise de variância (Kruskal-Wallis).....	32
4.5.2 Redução da variância (VR).....	33
4.5.3 Índice de desempenho Fuzzy (FPI)	33
4.5.4 Índice da partição da entropia modificada (MPE)	33
4.5.5 Índice aprimorado de validação de Cluster (ICVI).....	34
4.5.6 Validação por concordância Kappa	34
5 RESULTADOS E DISCUSSÃO	36
5.1 Filtragem dos dados de produtividade	37
5.2 Índices de vegetação.....	40
5.3 Agrupamento de dados	47
5.4 Coeficiente de concordância Kappa	50

6	CONCLUSÕES	54
7	CONSIDERAÇÕES FINAIS	55
	REFERÊNCIAS	56
	ANEXO I - TESTE DUNN ENTRE CLASSES.....	66

LISTA DE TABELAS

Tabela 1	Datas de semeadura e colheita para as safras de soja 2017/2018, milho 2018, soja 2018/2019 e milho 2019	25
Tabela 2	Descrição das bandas do satélite <i>Sentinel-2</i> utilizadas para o cálculo dos índices de vegetação.....	30
Tabela 3	Índices de vegetação.....	31
Tabela 4	Qualidade de concordância associada aos valores do índice Kappa.....	35
Tabela 5	Análise estatística descritiva dos dados originais.	36
Tabela 6	Quantidades de pontos removidos dos dados de colheita após o processo de filtragem.....	37
Tabela 7	Análise estatística descritiva dos dados filtrados	37
Tabela 8	Comparação entre os dados de colheita com altitude e declividade, pelo coeficiente de correlação de Spearman.....	40
Tabela 9	Datas de aquisição de imagens de satélite.....	41
Tabela 10	Estatística descritiva dos índices de vegetação	43
Tabela 11	Correlação entre os índices de vegetação e produtividade de soja 2017/2018..	44
Tabela 12	Correlação entre os índices de vegetação e produtividade de milho 2018.....	44
Tabela 13	Correlação entre os índices de vegetação e produtividade de soja 2018/2019..	45
Tabela 14	Correlação entre os índices de vegetação e produtividade de milho 2019.....	45
Tabela 15	Correlação entre os índices de vegetação e produtividade média	47
Tabela 16	Teste de variância Kruskal-Wallis e índices de validação Fuzzy para os agrupamentos.....	49
Tabela 17	Coeficientes de concordância Kappa entre as UGDs geradas por índices de vegetação e UGDs geradas por dados de produtividade	53

LISTA DE FIGURAS

Figura 1	Espectro eletromagnético.	20
Figura 2	Curva espectral de vegetação sadia.	21
Figura 3	Localização da área de estudo.	23
Figura 4	Alturas mensais de precipitação (mm) registradas no município de Campina da Lagoa – PR, entre set/2017 e ago./2019.	24
Figura 5	Altitude (a esquerda) e declividade (a direita) da área de estudo.	24
Figura 6	Precipitação e graus-dia, durante o período de 12/10/2017 a 06/02/2018, em Campina da Lagoa - PR.	25
Figura 7	Precipitação e graus-dia, durante o período de 22/02/2018 a 05/07/2018, em Campina da Lagoa - PR.	26
Figura 8	Precipitação e graus-dia, durante o período de 24/09/2018 a 14/01/2019, em Campina da Lagoa - PR.	26
Figura 9	Precipitação e graus-dia, durante o período de 24/09/2018 a 14/01/2019, em Campina da Lagoa - PR.	27
Figura 10	Dados referentes às safras de milho 2018, milho 2019, soja 2017/2018 e soja 2018/2019 (Na ordem da esquerda para direita).	28
Figura 11	Ponto de colheita registrado fora das delimitações do talhão.	28
Figura 12	Identificação de pontos discrepantes locais.	29
Figura 13	Histogramas da produtividade de soja da safra 2017/2018. a) Dados originais; b) Dados filtrados.	39
Figura 14	Histogramas da produtividade de milho da safra 2018. a) Dados originais; b) Dados filtrados.	39
Figura 15	Histogramas da produtividade de soja da safra 2018/2019. a) Dados originais; b) Dados filtrados.	39
Figura 16	Histogramas da produtividade de milho da safra 2019. a) Dados originais; b) Dados filtrados.	40
Figura 17	Gráfico NDVI da área de estudo e datas de imagens do <i>Sentinel-2</i> . disponíveis no período de 12/12/2017 a 06/02/2018.	41
Figura 18	Gráfico NDVI da área de estudo e datas de imagens do <i>Sentinel-2</i> , disponíveis no período de 22/02/2018 a 05/07/2018.	42
Figura 19	Gráfico NDVI da área de estudo e datas de imagens do <i>Sentinel-2</i> , disponíveis no período de 24/09/2018 a 14/01/2019.	42
Figura 20	Gráfico NDVI da área de estudo e datas de imagens do <i>Sentinel-2</i> , disponíveis no período de 23/01/2019 a 07/06/2019.	43

Figura 21	Histogramas dos conjuntos de dados. a) Média de colheita; b) Altitude; c) Declividade; d) ARVI; e) EVI; f) GCVI; g) GNDVI; h) MPRI; i) MSR; j) NDVI; k) RDVI; l) SAVI; m) TNDVI.	46
Figura 22	Seleção de dados para agrupamento. a) Média de colheita; b) Índice ARVI.....	47
Figura 23	Unidades de gestão diferenciada geradas para duas classes. a) Média de colheita; b) ARVI; c) EVI; d) GCVI; e) GNDVI; f) MPRI; g) MSR; h) NDVI; i) RDVI; j) SAVI; k) TNDVI.....	50
Figura 24	Unidades de gestão diferenciada geradas para três classes. a) Média de colheita; b) ARVI; c) EVI; d) GCVI; e) GNDVI; f) MPRI; g) MSR; h) NDVI; i) RDVI; j) SAVI; k) TNDVI.....	51
Figura 25	Unidades de gestão diferenciada geradas para quatro classes. a) Média de colheita; b) ARVI; c) EVI; d) GCVI; e) GNDVI; f) MPRI; g) MSR; h) NDVI; i) RDVI; j) SAVI; k) TNDVI.....	52

1 INTRODUÇÃO

O agronegócio, tanto o brasileiro quanto o internacional, a cada dia precisam modernizar e agilizar os métodos de produção de forma a acompanhar a crescente demanda por alimentos que aumenta à medida que crescem os números da população. Para atender a esse crescimento, torna-se necessária a tomada de decisões assertivas de modo rápido e eficiente.

A variabilidade da produtividade dentro das propriedades agrícolas é um dos problemas que requerem muitos dados para sua detecção, dentre eles, dados de produção. Muitos produtores (e a assistência técnica) não possuem a tecnologia necessária para acompanhar a produtividade de forma visual em mapas de colheita e agir de forma mais fácil no sentido de reduzir a variabilidade no plantio seguinte. Técnicas como a agricultura de precisão podem fornecer métodos simples e eficazes para contornar este problema, como as unidades de gestão diferenciada (UGDs).

Identificar subáreas com diferentes padrões e adaptar os tratos culturais a elas, pode ser caracterizada como uma atividade de manejo específico da lavoura. Na agricultura de precisão, as UGDs podem ser delimitadas a partir de estudos sobre as variáveis quantitativas de vários atributos como: a produtividade da lavoura, os índices de vegetação, a declividade, os parâmetros físicos e químicos do solo, a classificação do solo e, até mesmo, a combinação de todos os fatores disponíveis. É preferível que, entre todas as variáveis presentes, opte-se por aquelas que estejam correlacionadas ao rendimento, pois, assim, podem ser espacialmente projetadas.

A adoção de práticas agrícolas em UGDs representa uma forma mais viável para os produtores aderirem à agricultura de precisão, pois os equipamentos convencionais podem ser utilizados quando regulados para cada área específica. Quanto à fertilidade do solo, as UGDs permitem a definição de grades amostrais de solo, facilitando a interpretação de mapas temáticos, comuns na agricultura de precisão. Tais práticas podem otimizar a utilização de recursos e insumos, resultando em vantagens econômicas e ambientais.

Nesse cenário, a pesquisa tem um papel importante e o sensoriamento remoto surge como um método capaz de suprir a demanda por dados de forma rápida, podendo indicar a variabilidade dos índices dentro das áreas agrícola. Atualmente milhares de satélites orbitam o planeta e, muitos deles, fornecem informações diárias muito úteis à agricultura. Dentre essas informações, a interação com a luz (principalmente a solar), chamada de radiação eletromagnética, pode ser captada pelos sensores e transformada em índices de vigor de plantas.

Os índices de vegetação (IVs) são um indicativo de vigor, de biomassa e até mesmo de rendimento de culturas. Índices, como o NDVI, são muito utilizados em diversos estudos agrícolas como, por exemplo, detectar manchas na lavoura por meio de avaliações periódicas. Atualmente, na agricultura de precisão diversos autores procuram associar os IVs ao rendimento das culturas (DAMIAN et al., 2017; HUFKENS et al., 2019; LI et al., 2016; ROSSI et al., 2018; VELOSO et al., 2017), muitos deles para a avaliação de delimitação de UGDs em comparação aos mapas de produtividade ou para operações localizadas (GEORGI et al., 2018; JIN et al., 2017; LEE; EHSANI, 2015; WACHOWIAK et al., 2017; ZANELLA et al., 2019).

Ainda são necessários mais estudos, em diferentes cenários, no sentido de avaliar se os índices de vegetação podem ser eficazes ao substituir dados de produtividade.

2 OBJETIVOS

2.1 Objetivo geral

Avaliar a viabilidade em delimitações de unidades de gestão diferenciada utilizando índices de vegetação e dados de produtividade, referentes a dois anos safras para as culturas de soja e milho.

2.2 Objetivos específicos

- Filtrar dados de colheita de forma a evitar discrepâncias;
- Delimitar UGDs por meio de mapas de produtividade e mapas de índice de vegetação provenientes do satélite *Sentinel-2*, utilizando algoritmo *Fuzzy C-means*;
- Determinar o número ideal de UGDs por meio dos índices de validação de cluster;
- Comparar as UGDs geradas, por meio do coeficiente de concordância Kappa, tendo mapas de produtividade como referência;
- Avaliar a viabilidade de delimitação de UGDs por meio dos índices de vegetação.

3 REVISÃO BIBLIOGRÁFICA

3.1 Cenário da agricultura no Brasil e no mundo

De acordo com as estimativas a *Food and Agriculture Organization* (FAO), a população no mundo em 2050 será 29% maior do que em 2017, sendo que a maioria, cerca de 70%, se encontrará em meio urbano. Além disso, diversos fatores podem contribuir para que o aumento da escassez e a má distribuição de alimentos acompanhe esse crescimento populacional. A alta demanda de alimentos em países emergentes, as mudanças climáticas, a falta de água, a degradação dos solos e a instabilidade no custo dos alimentos podem ser alguns desses fatores, que atualmente contribuem para que cerca de 800 milhões de pessoas já estejam em condições de subnutrição em todo o mundo, principalmente em regiões em desenvolvimento (FAO, 2019).

Conjuntamente aos problemas de abastecimento no mundo, pôde-se estimar que cerca de 25% de todo o solo no mundo encontra-se em estado de degradação (IASS, 2015). É necessário que a agricultura possa continuar se aprimorando no espaço que já ocupa, procurando meios de limitar também a quantidade de insumos utilizados, mantendo os níveis de produção seguros para a humanidade (SPRINGMANN et al., 2018).

No cenário da agricultura no Brasil, há destaque para a produção de grãos, principalmente a soja e o milho. Muitos autores afirmam que, a cada ano, a produção destes grãos deve aumentar, visando acompanhar a crescente demanda por alimentos, tanto dentro do país quanto no mundo (BATTISTI et al., 2018; CATTELAN; DALL'AGNOL, 2018; FIEUZAL et al., 2017). A Companhia Nacional de Abastecimento (CONAB) estima que a produção total nacional de milho, no ano de 2019, possa ter chegado em 101,9 milhões de toneladas, levando em consideração todas as safras durante o período, volume próximo ao total do ano de 2018 (CONAB, 2020). Por outro lado, é estimado que a produção de soja possa ter alcançado um total de 122,1 milhões de toneladas, tornando-se um recorde em todo o histórico de produção do grão, o que se deve, principalmente, às condições climáticas favoráveis na maior parte dos principais estados produtores (CONAB, 2020).

Tanto os problemas apresentados quanto os números da produção confirmam a necessidade e a importância de que alternativas sustentáveis e tecnológicas sejam adaptadas e disponibilizadas para diversas realidades no mundo, tendo em vista o aumento da quantidade e da qualidade dos alimentos, bem como a necessidade de proporcionar um desenvolvimento inclusivo (FAO, 2019).

A quantidade de dados disponíveis é grande e muito diversificada como, por exemplo, informações disponíveis pela amostragem e análise de tecido vegetal ou de solo, registros meteorológicos, sensores de umidade no campo, mapeamento do solo, análise do histórico de colheita e sensoriamento remoto (WOLFERT et al., 2017).

3.2 Agricultura de precisão

Uma das formas para se trabalhar com os dados referentes ao campo é a utilização da agricultura de precisão (AP). A AP pode ser conceituada como uma forma de gerenciamento da lavoura por meio da observação, do registro e do manejo realizado sobre a variabilidade presente no solo e nas culturas (LI et al., 2019; LINDBLOM et al., 2017). Alguns autores afirmam que há um processo de reconstrução da ideia de agricultura de precisão, pois com as novas tecnologias e ferramentas disponíveis, aprimora-se a compreensão da relação entre o solo, planta e atmosfera (LEE; EHSANI, 2015; SRBINOVSKA et al., 2015).

Desde o início do século XX, com o desenvolvimento dos microcomputadores e sensores, a agricultura pode utilizar novas ferramentas para aprimorar as técnicas de manejo das lavouras, dessa forma surgem os primeiros fundamentos da agricultura de precisão atual (LAMPARELLI, 2013). Nos últimos anos, estudos envolvendo novos equipamentos e técnicas de medição por sensoriamento remoto, aliados à automação de coletas, fez com que aumentasse de forma significativa o número de dados relativos ao solo, às culturas agrícolas e também ambientais (RAJ et al., 2018).

Grande parte dos dados obtidos vão, gradualmente, sendo assimilados ao funcionamento da AP, assim, o trabalho com as informações disponíveis e a tomada de decisões se tornam cada vez mais ágeis (BENDRE; THOOL; THOOL, 2016; WOLFERT et al., 2017).

Muitos dados utilizados na AP podem ser adquiridos diretamente no campo ou com a ajuda de sensores (no solo ou em satélites), porém, basicamente, toda a informação registrada possui georreferenciamento e é ligada a áreas, geralmente de forma quadrada, chamadas de célula ou *pixel*.

A pesquisa se torna uma forma de transformar a elevada quantidade de dados em informações mais diretas e precisas. Também é possível dizer que a pesquisa contribui para criar e aprimorar novos métodos para aquisição de informação (SABARINA; PRIYA, 2015).

Ferramentas como, por exemplo, o GPS utilizado em colheita ou amostragem de solo, monitores de produtividade e veículos aéreos não-tripulados (VANT's) vêm sendo desenvolvidas para aplicação nas lavouras a mais de 30 anos, que coincide com o início da comercialização dos sistemas de posicionamento global (BALAFOUTIS et al., 2017; GUO et al., 2018; YANG et al., 2017). Diversos autores afirmam que a utilização das ferramentas de

AP está ligada a uma série de benefícios, tais como melhoria da produtividade, a utilização de insumos de forma reduzida (que também proporciona otimização nos lucros), a aplicação direcionada de defensivos e a redução no tempo de operações (EORY et al., 2015; KINDRED et al., 2015; SILVA; MORAES; MOLIN, 2011; SMITH et al., 2013).

Borghi et al. (2016), em estudo com produtores que utilizam agricultura de precisão, constataram que 100% utilizavam grid georreferenciado para amostragem de solo, 56% tomavam decisões com ajuda de mapas de produtividade e apenas 22% utilizavam imagens aéreas ou orbitais. Os mapas de produtividade são muito importantes para a agricultura de precisão e, por isso, necessitam ser processados (filtrados) e normalizados para que seja possível comparar diferentes safras e definir regiões de igual tendência. Assim, torna-se possível identificar as subáreas que requerem atenção maior. Esse é um dos princípios básicos para a compreensão do conceito de manejo específico (unidades de gestão diferenciada).

3.3 Unidades de gestão diferenciada

Unidades de gestão diferenciada (UGDs) podem ser definidas como regiões ou sub-regiões, nos quais os parâmetros físicos e/ou químicos ou o rendimento das culturas apresentam equivalência, geralmente dividindo o talhão em sítios específicos de manejo (YAO, 2014). Além desse conceito, as UGDs também são consideradas por diversos autores como uma prática básica em um sistema de agricultura de precisão visando utilizar ao máximo cada porção do talhão para o aumento da produtividade (DAMIAN et al., 2017; GEORGI et al., 2018; HUFKENS et al., 2019).

Comparado a outras ferramentas de agricultura de precisão (que na maioria das vezes são equipamentos caros de aplicação em taxa variável), o delineamento de UGDs possibilita que pequenos e médios produtores também utilizem seus recursos de forma direcionada com equipamentos mais comuns, enaltecendo o custo-benefício da prática (GAVIOLI et al., 2016).

Além de diversos fatores econômicos, como a redução no número de amostras de folhas e de solo, a adoção da prática também possibilita uma forma de manejo mais ambientalmente sustentável, pois reduz e direciona fertilizantes e defensivos, evitando que o excesso dos produtos possa acabar atingindo rios e florestas (GAVIOLI et al., 2016; VALENTE et al., 2014). Entre os benefícios citados, vale destacar que as UGDs permitem avaliar as datas para a realização de operações como o plantio e o preparo mecanizado do solo (EDREIRA et al., 2017).

Muitos pesquisadores apresentam formas diversas para delineamento das UGDs. Dentre elas é possível destacar as unidades geradas por mapas de produtividade (DAMIAN et al., 2017; SANTI et al., 2013), parâmetros químicos do solo (GILI et al., 2017; PERALTA et

al., 2015; ROSSI et al., 2018; TRIPATHI et al., 2015) e produtos de sensoriamento remoto (GEORGI et al., 2018; JIN et al., 2017). Gavioli et al. (2016) ressaltam que, fundamentalmente, os melhores parâmetros para se delinear as UGDs devem estar correlacionados espacialmente com a produtividade da lavoura.

A coleta de informações durante determinado período, como o da colheita, considerando-se diferentes safras possibilita a geração de uma tendência temporal nos mapas, indicando áreas de alta ou baixa produtividade (BLACKMORE; LARSCHEID, 1997).

Apesar da grande necessidade de encontrar a melhor forma de realizar um eficiente manejo das lavouras, Sentelhas (2015) afirma que o maior problema, principalmente em países como o Brasil, ainda é a difusão desse conhecimento e das tecnologias, bem como a sua adequada utilização.

3.4 Mapeamento da produtividade

Frente às diversas opções para delimitação de UGDs, Betzek et al. (2018) afirmam que os dados utilizados devem ser escolhidos com muito critério, sendo que as informações de colheita são as mais importantes nessa decisão. Lee et al. (2016) ressaltam que é imprescindível que os dados possuam o menor número de erros possível para sua aplicação.

Para Molin (2000), gerar mapas de produtividade requer um bom conhecimento das técnicas de filtragem, pois os dados fundamentais podem ser ofuscados no processo. Segundo o autor, cada ponto registrado dentro do conjunto representa uma porção menor da lavoura.

Durante o processo de filtragem as informações de entrada devem ser precisas para que os dados errôneos sejam removidos e, desta forma, elevar a qualidade das informações que serão geradas pelos mapas de produtividade (MENEGATTI; MOLIN, 2004). Dentre os erros mais comuns pode-se destacar registros nulos de produtividade e umidade, pontos sobrepostos, erros de posicionamento e dados discrepantes ocasionados pelo tempo de enchimento da colhedora durante as entradas e saídas na lavoura.

3.5 Sensoriamento remoto

As técnicas de observação de lavouras por meio do sensoriamento remoto, em especial com imagens de satélite, possibilitaram a produção de um número elevado de dados, já analisados e aplicados de diversas formas (CHI et al., 2016; LIU, 2015a).

Os dados produzidos pelo sensoriamento remoto, de maneira geral, produzem informações precisas (em qualidade e quantidade), que auxiliam a monitorar todo o

desenvolvimento das culturas, desde falhas na emergência de plântulas a deficiências nutricionais durante o ciclo e detecção antecipada de falhas na colheita (LI et al., 2016; VELOSO et al., 2017; WILSON et al., 2014).

O sensoriamento remoto por meio de imagens orbitais conta, atualmente, com milhares de satélites ao redor do planeta. Grande parte desses satélites contam com sensores espectrais em resoluções e periodicidade diferentes que, geralmente, são utilizados para finalidades distintas.

Além da utilização na área agrícola, os dados coletados podem ser utilizados para monitoramento ambiental e previsões climáticas. Muitos desses satélites estão em funcionamento há diversos anos, gerando uma grande quantidade de dados históricos. Para a delimitação de UGDs, alguns satélites já possuem as características desejadas, como a periodicidade adequada, data específica, alta resolução e disponibilidade dos dados (CANDIAGO et al., 2015; JOHNSON, 2014; KASAMPALIS et al., 2018; WU et al., 2015).

Uma das principais alternativas é o programa da *European Space Agency Sentinel-2*, (ESA) que consiste em uma constelação de 2 satélites. A bordo dos satélites existe um sensor ótico, o *Multi-Spectral Instrument* (MSI) que registra a radiação proveniente da superfície terrestre. As principais características são a sua resolução espacial de 10 metros e seu tempo de revisita, que é de 5 dias. Além disso, seus produtos (imagens) são disponibilizados de forma gratuita (ESA, 2020).

Para Duncan et al. (2015), a utilização das imagens provenientes do *Sentinel-2* pode superar as limitações que pesquisadores e produtores têm ao consultar informações de satélites com resolução muito maior, pois nestas há a presença de diferentes tipos de cobertura vegetal dentro de um mesmo *pixel*.

3.6 Índices de vegetação

De acordo com Liu (2015b), todos os elementos apresentam uma assinatura espectral, que é uma resposta à energia no espectro eletromagnético, considerada uma característica física. Assim, é possível trabalhar com as imagens captadas pelos sensores óticos dos satélites na forma de valores de reflectância. Na Figura 1, o espectro eletromagnético demonstra os diferentes comprimentos de onda da radiação e suas respectivas classificações.

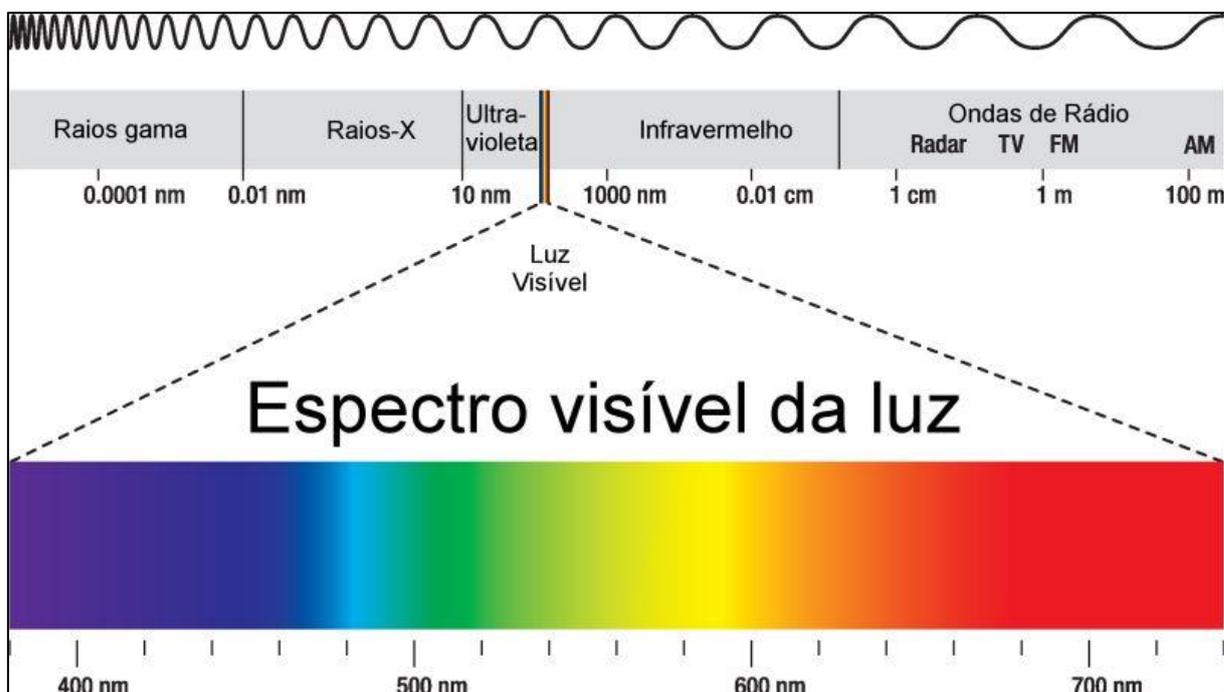


Figura 1 Espectro eletromagnético.

Fonte: Shutterstock. Hermes Furian (2015).

Os índices de vegetação (IVs) são algoritmos aplicados sobre valores de reflectância (separados por bandas), para caracterizar e classificar a vegetação, devido à resposta espectral das folhas vegetais (HUETE et al., 1997).

De forma geral, o rendimento de uma área coincide com a biomassa das plantas, caso estejam sob as mesmas condições de solo. Então, objetiva-se estimar a biomassa por meio dos IVs e outras variáveis fisiológicas, antes mesmo de se avaliar a produtividade (BREUNIG et al., 2020; TRINDADE et al., 2019; RIBEIRO et al., 2017; SCHAPARINI et al. 2019).

Atualmente existe uma grande quantidade de fórmulas para essa finalidade e, dentre elas, há um destaque para o Índice de Vegetação pela Diferença Normalizada (ROUSE et al., 1973) ou NDVI (*Normalized Difference Vegetation Index*), pois demonstra uma elevada correlação com mapas de produtividade e, atualmente, é amplamente utilizado em diversas pesquisas e em forma prática (LOPRESTI; BELLA; DEGIOANNI, 2015; PERALTA et al., 2016).

O NDVI pode ser considerado como um indicador da biomassa ativa (fotossíntese) por meio do cálculo entre a resposta espectral das plantas nas bandas do vermelho e do infravermelho próximo. Na Figura 2 observa-se a curva espectral característica de uma planta saudável. Há baixos valores na região do vermelho e valores maiores na região do infravermelho.

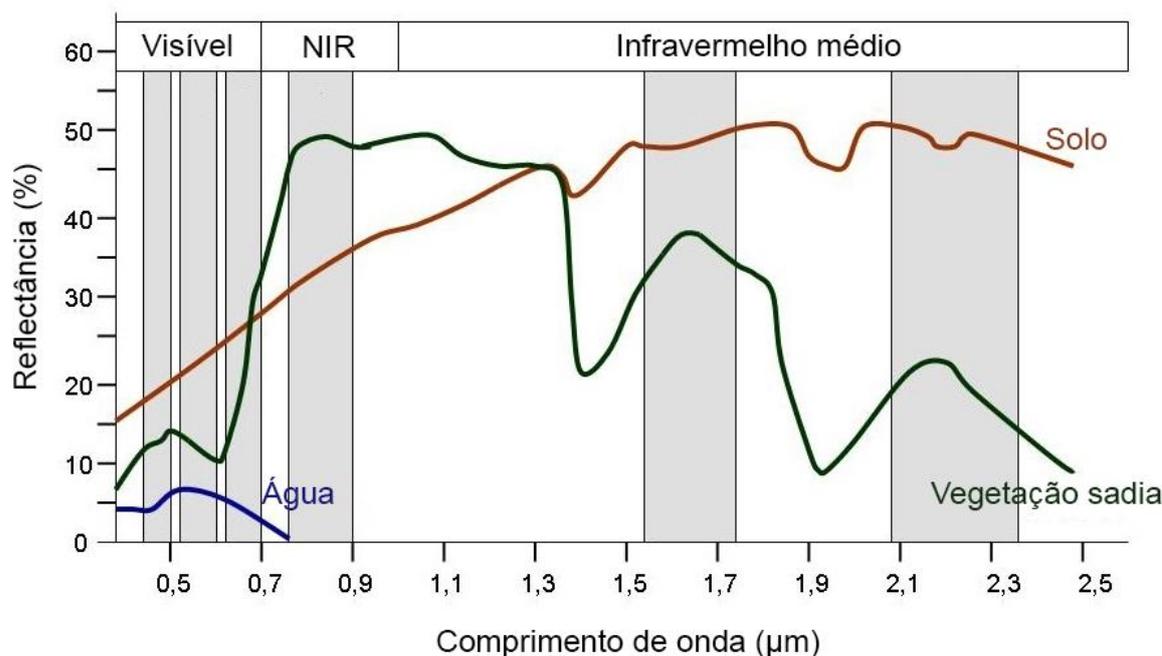


Figura 2 Curva espectral de vegetação sadia.

O *Transformed NDVI* (TNDVI) foi proposto por Tucker (1979) como uma modificação do NDVI, calculando sua raiz quadrada e adicionando 0,5. O índice foi criado na tentativa de se comparar melhor a biomassa entre plantas sob diferentes condições ambientais. Wongchai, Insuan e Promwungkwa (2020) encontraram forte correlação ($R = 0,833$) entre o TNDVI e a biomassa de eucalipto, sendo o maior valor comparado a outros índices.

O *Soil-Adjusted Vegetation Index* (SAVI) foi proposto por Huete (1988) também como uma modificação do NDVI. Em seu cálculo, é adicionada uma constante L, que leva em consideração a cobertura do dossel vegetal. A constante pode assumir valores entre 0 (alta densidade de cobertura) e 1 (baixa densidade de cobertura). O principal objetivo para criação do índice foi de minimizar os efeitos do tipo, da densidade e da variabilidade do dossel (HUETE, 1988).

Hatfield e Pruegrer (2010) obtiveram excelentes resultados ao estimarem parâmetros biofísicos de soja, milho, trigo e canola e indicam o SAVI como melhor estimador nos estágios iniciais das culturas, pois reduz os efeitos de reflectância do solo.

O *Atmospherically Resistant Vegetation Index* (ARVI) teve como objetivo minimizar os efeitos da atmosfera nas imagens de satélite, como aerossóis e partículas, por meio da inserção da banda do azul no seu cálculo. Esse índice foi proposto por Kaufman e Tanré (1992), que demonstraram uma sensibilidade quatro vezes menor à atmosfera quando comparado ao NDVI.

O *Renormalized Difference Vegetation Index* (RDVI) foi proposto por Reujean e Breon (1995) como uma modificação do NDVI com o objetivo de aprimorar o índice a mudanças na cobertura vegetal sob condições de baixo índice da área foliar.

O *Modified Simple Ratio Index* (MSR) foi proposto por Chen (1996) com o objetivo de minimizar os efeitos do solo abaixo do dossel, pois, segundo os autores, este pode ser variável e comprometer os resultados.

O *Green NDVI* (GNDVI) possui a mesma estrutura de cálculo do NDVI, porém, com a utilização da banda do verde no lugar da banda do vermelho e foi proposto por Gitelson et al. (1996) com o objetivo de identificar melhor diferentes espécies vegetais.

O *Enhanced Vegetation Index* (EVI) foi proposto por Huete et al. (1997) com o objetivo de unir os índices SAVI e ARVI, diminuindo tanto os efeitos da atmosfera quanto os efeitos do solo em um único cálculo, utilizando as bandas do azul, vermelho e infravermelho juntamente a constantes que representam a correlação entre os efeitos.

O *Green Chlorophyll Vegetation Index* (GCVI) foi proposto por Gitelson et al. (2003) como uma forma de aferir indiretamente a clorofila presente, diferente de outros índices que, em geral, buscam os valores de verdor da vegetação. Lobell e Azzari (2017) destacam a vantagem do GCVI, em relação aos outros índices, de não saturar sob altos valores de índice foliar.

O *Modified Photochemical Reflectance Index* (MPRI) foi proposto por Yang et al. (2008) com o objetivo de utilizar apenas bandas do visível, viabilizando a aplicação do índice em câmeras convencionais, como as utilizadas em VANT's. Para o cálculo são utilizadas as bandas do verde e do vermelho.

Essas análises e algoritmos, mesmo que ainda não sejam o foco principal das pesquisas voltadas à agricultura, tornam-se cada vez mais necessários para auxiliar nas decisões de muitas pessoas que buscam implementar ou prestar assistência em um sistema de alto rendimento como a agricultura de precisão (WACHOWIAK et al., 2017).

4 MATERIAL E MÉTODOS

4.1 Caracterização da área de estudo

A área de estudo (Figura 3) pertence a uma propriedade de 510 ha, dividida em 26 talhões, localizada no município de Campina da Lagoa, cidade do centro-oeste paranaense, situada nas coordenadas 24° 35' 21" S e 52° 49' 34" O. O clima é definido como subtropical úmido (Cfa), de acordo com Köppen-Geiger (DUBREUIL et al., 2018).

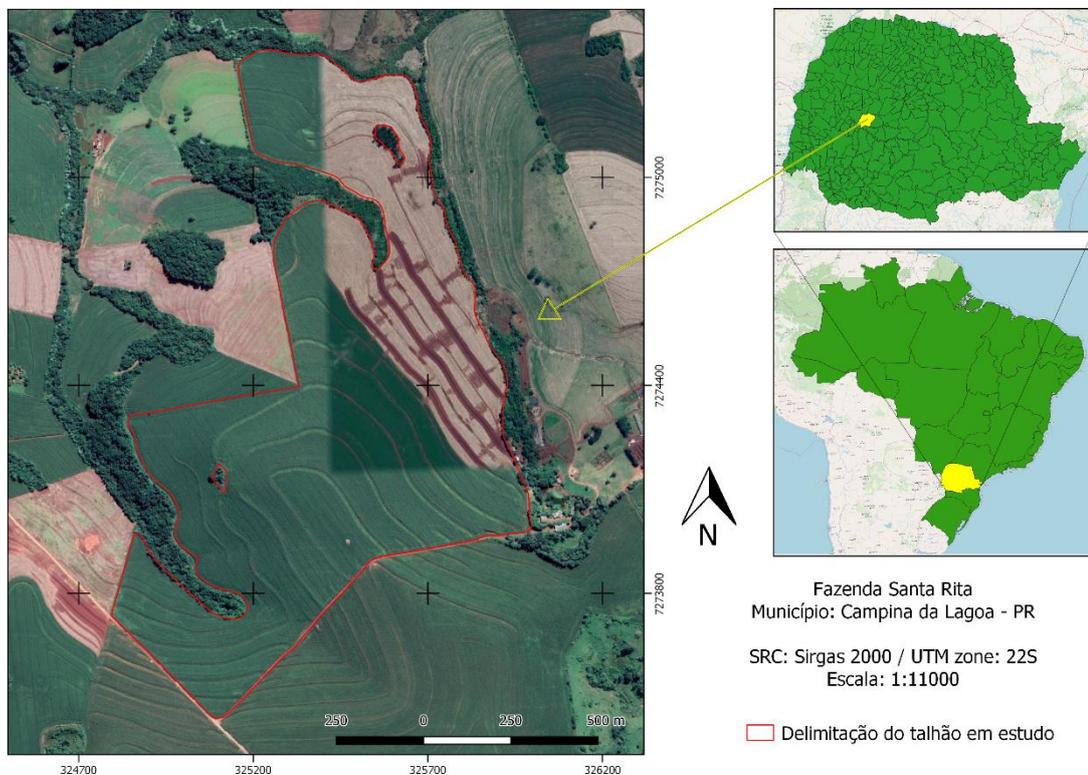


Figura 3 Localização da área de estudo.

O talhão determinado como objeto deste estudo é destinado à produção de grãos em sistema de plantio direto sem irrigação (sequeiro), onde é realizada a sucessão entre as culturas de soja e milho. Essa área possui 110,48 ha.

A precipitação anual média é de 1900 mm e a média mensal em torno de 160 mm. Na Figura 4, observa-se o gráfico de chuvas do período da pesquisa, de setembro de 2017 a agosto de 2019. Não se observou padrão sobre as medições entre os anos.

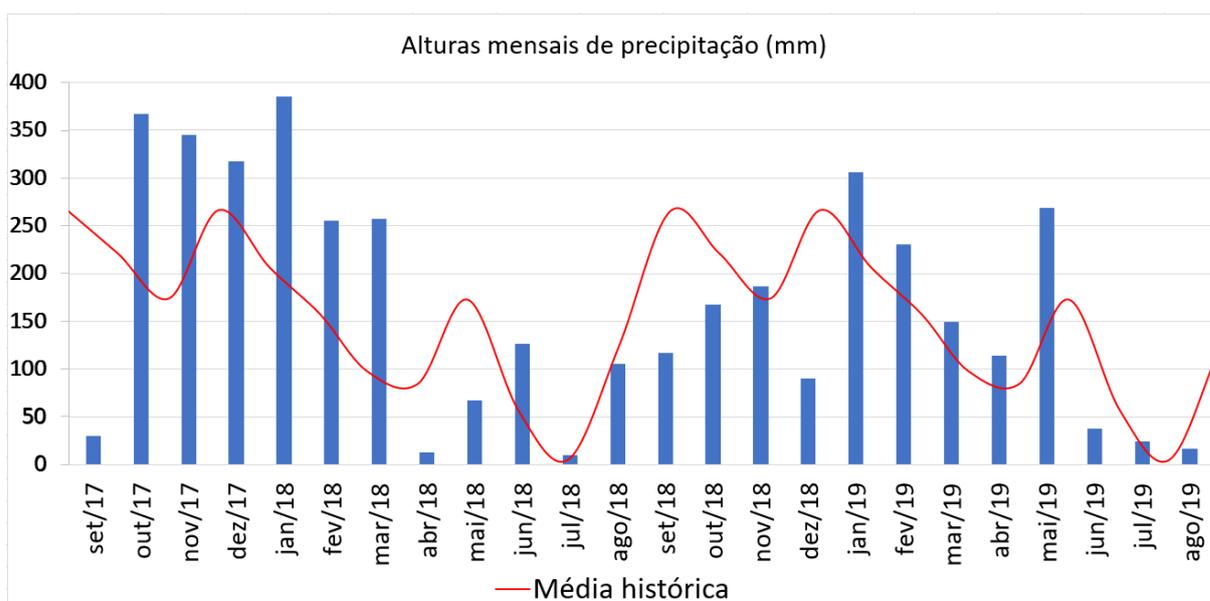


Figura 4 Alturas mensais de precipitação (mm) registradas no município de Campina da Lagoa – PR, entre set/2017 e ago./2019.

Fonte: INMET (2021).

De acordo com a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), o solo da área pode ser classificado como Latossolo Vermelho distroférico típico (LVdf4) (SANTOS et al., 2018). Esses solos apresentam grande potencial para a agropecuária, pois são friáveis, possuem alta permeabilidade e preparo fácil. Também apresentam baixa declividade, facilitando operações como a colheita. Na Figura 5, observam-se os mapas de altitude e declividade do terreno. Tais parâmetros podem interferir na geração das UGDs.

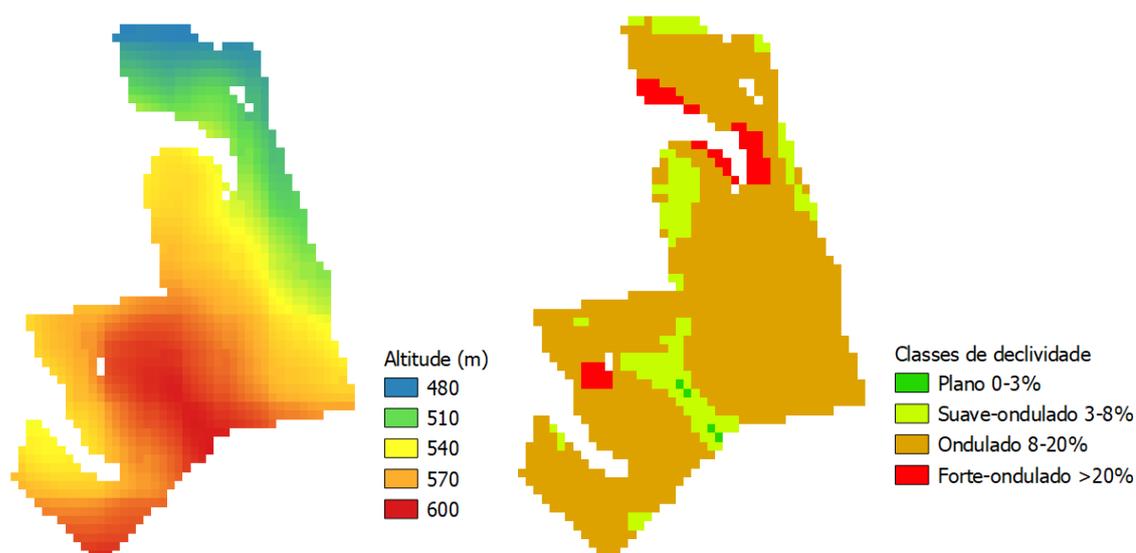


Figura 5 Altitude (a esquerda) e declividade (a direita) da área de estudo.

Os ciclos totais das safras utilizadas neste trabalho são apresentados na Tabela 1. Observa-se que os ciclos de soja da safra 2017/2018 e da safra 2018/2019 foram parecidos, com 118 e 113 dias, respectivamente. Para as safras de milho 2018 e 2019, os ciclos também

foram próximos, com 133 e 136 dias, respectivamente. É possível observar diferença nas datas de plantio entre as safras, no entanto o ciclo permaneceu próximo em número de dias.

Tabela 1 Datas de semeadura e colheita para as safras de soja 2017/2018, milho 2018, soja 2018/2019 e milho 2019

Cultura	Semeadura	Colheita	Ciclo total (dias)
Soja 2017/2018	12/10/2017	06/02/2018	118
Milho 2018	22/02/2018	05/07/2018	133
Soja 2018/2019	24/09/2018	14/01/2019	113
Milho 2019	23/01/2019	07/06/2019	136

Os dados apresentados na Figura 6 demonstram a precipitação (mm) e os valores de graus-dia estimados (OMETTO, 1981) para o período de 12/10/2017 a 06/02/2018 (ciclo de soja). A precipitação acumulada durante o período foi de 1373 mm, superior ao necessário, conforme a literatura (FARIAS; NEPOMUCENO; NEUMAIER, 2007), de 450 a 800 mm. O valor de graus-dia acumulado no período foi estimado em 1160. Kunz et al. (2014), comparando diferentes cultivares de soja, estimaram valores entre 1080 a 1120 graus-dia para atingir maturação (R9).

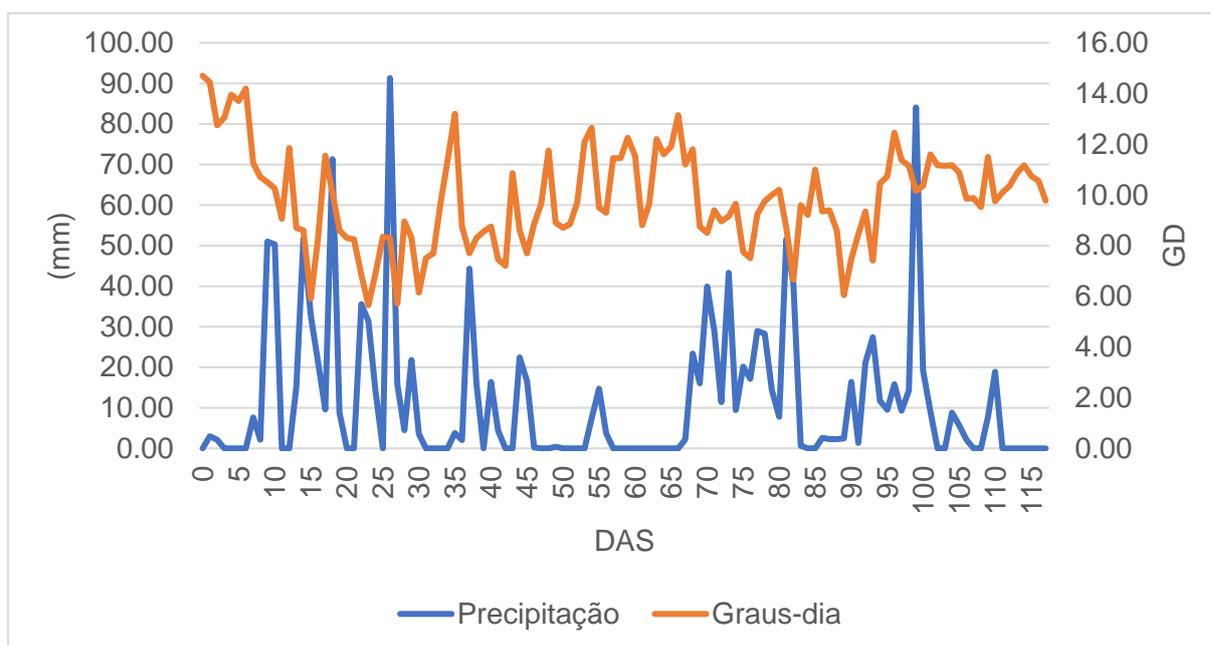


Figura 6 Precipitação e graus-dia, durante o período de 12/10/2017 a 06/02/2018, em Campina da Lagoa - PR.

Fonte: INMET (2021).

Entre o período de 22/02/2018 a 05/07/2018 (ciclo de milho), a precipitação acumulada foi de 556 mm, dentro da faixa compreendida como adequada pela literatura (ANDRADE et al., 2006), de 450 a 800 mm. O valor de graus-dia acumulado no período foi estimado em 1590 (Figura 7).

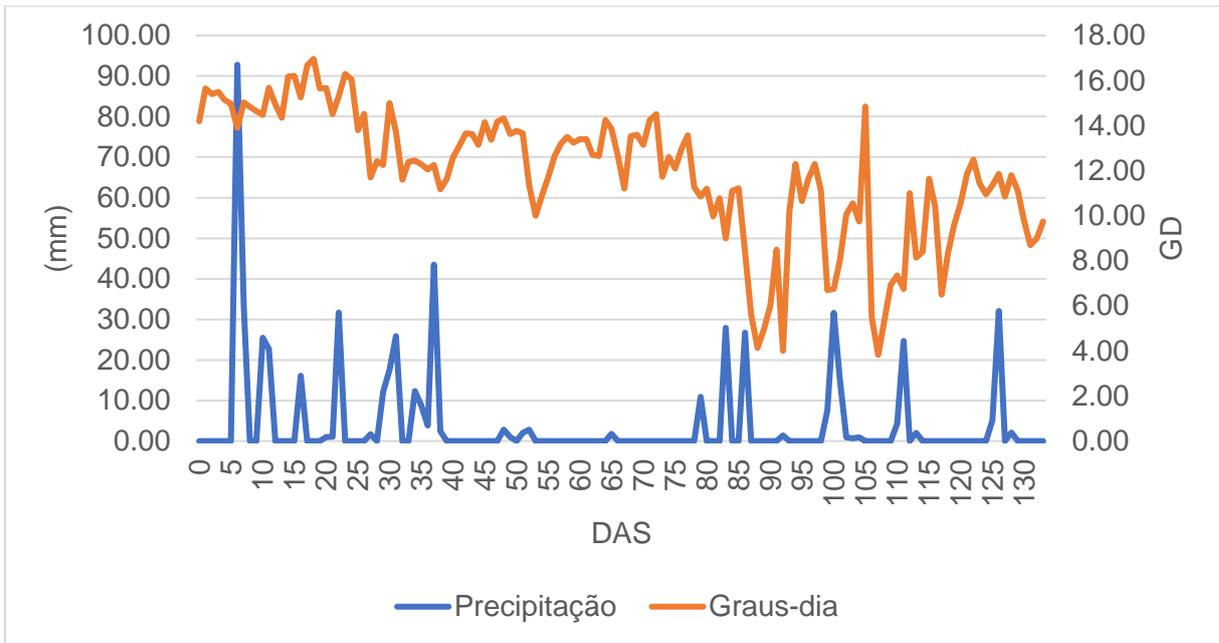


Figura 7 Precipitação e graus-dia, durante o período de 22/02/2018 a 05/07/2018, em Campina da Lagoa - PR.

Fonte: INMET (2021).

Os dados apresentados na Figura 8 demonstram a precipitação e os valores de graus-dia estimados para o período de 24/09/2018 a 14/01/2019 (ciclo de soja). A precipitação acumulada durante o período foi de 687 mm, enquanto a soma de graus-dia durante o ciclo foi de 1170.

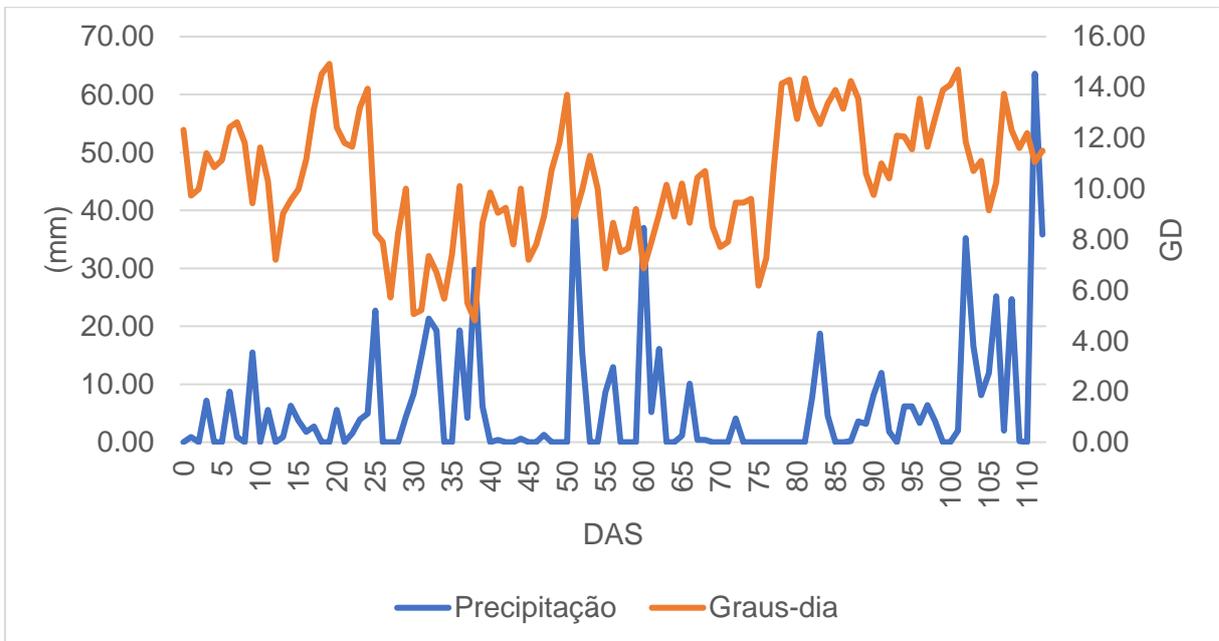


Figura 8 Precipitação e graus-dia, durante o período de 24/09/2018 a 14/01/2019, em Campina da Lagoa - PR.

Fonte: INMET (2021).

Entre o período de 23/01/2019 a 07/06/2019 (ciclo de milho), a precipitação acumulada foi de 860 mm, enquanto a soma de graus-dia durante o ciclo foi de 1740 (Figura 9).

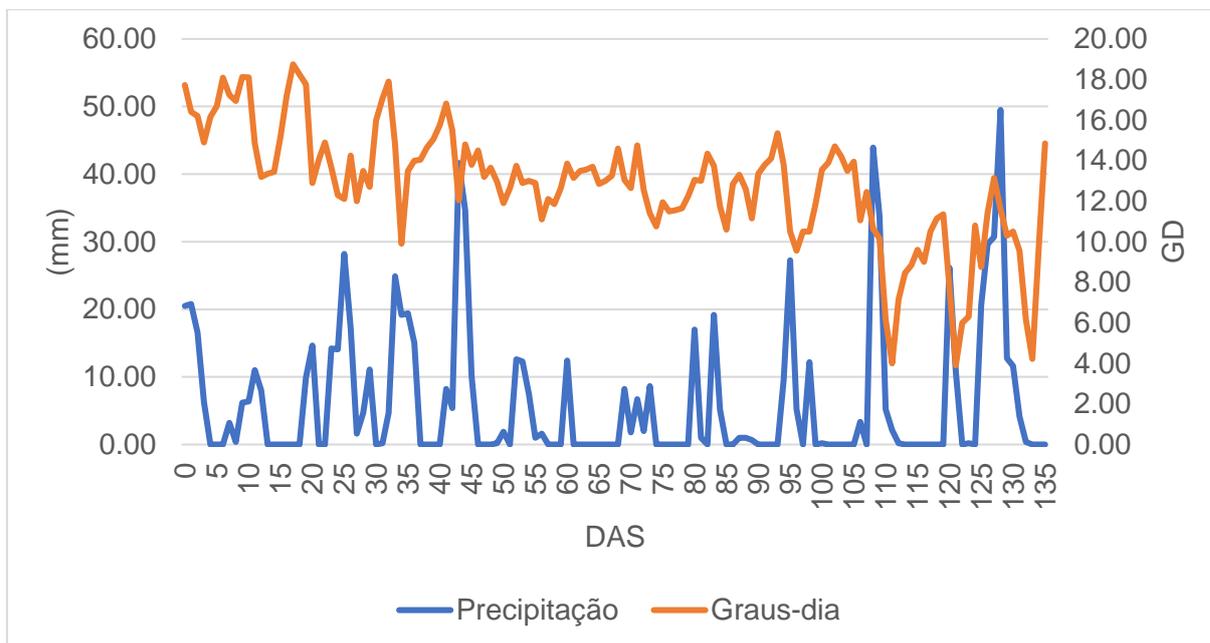


Figura 9 Precipitação e graus-dia, durante o período de 24/09/2018 a 14/01/2019, em Campina da Lagoa - PR.

Fonte: INMET (2021).

4.2 Processamento de dados de colheita e geração de mapas de produtividade

Para determinação das UGDs por meio dos mapas de produtividade, foram utilizados dados de colheita provenientes de um sensor de impacto instalado em uma colheitadeira da marca John Deere®. O sensor de impacto fica posicionado ao final da esteira elevadora de grãos, que gera uma força centrífuga, causando uma colisão proporcional à massa de cada grão (MOLIN, 2000).

A regulação do equipamento é realizada pela assistência técnica especializada que atende toda a propriedade. O equipamento conta, além do sensor de rendimento, um monitor *GreenStar 3*® equipado com GNSS e registra os valores a cada um segundo. Os dados são referentes a dois anos agrícolas, compreendendo as safras de soja 2017/2018 e 2018/2019 e as safras de milho 2018 e 2019 (Figura 10). Como os dados brutos possuem um formato específico da marca do equipamento (.gs3), foi necessário utilizar o programa *SMS Advanced*® para convertê-los para o formato *Shapefile* (.shp).

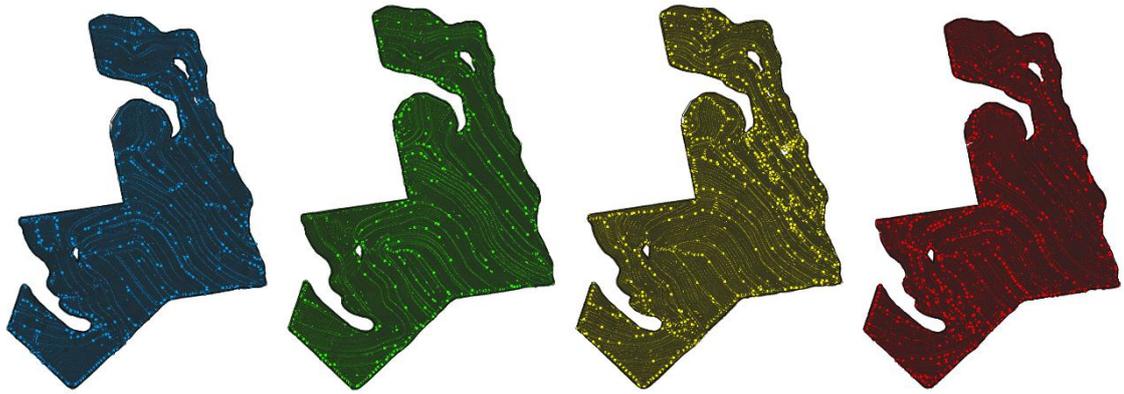


Figura 10 Dados referentes às safras de milho 2018, milho 2019, soja 2017/2018 e soja 2018/2019 (Na ordem da esquerda para direita).

O processamento dos dados em *shapefile* foi realizado no *software* QGIS, onde foram filtrados, seguindo a proposta de Zanella et al. (2019). Esse método consiste em três etapas, sendo a primeira, basicamente, identificar e remover *outliers*. Para isso são determinados limites de produtividade, levando em consideração valores fora da realidade e dados registrados fora das delimitações (Figura 11). No presente trabalho, os valores mínimos e máximos foram definidos de acordo com o histórico de produtividade da área. Para a cultura da soja foram de 100 kg ha^{-1} e 8000 kg ha^{-1} , respectivamente; e para a cultura do milho, foram determinados como mínimo e máximo 400 kg ha^{-1} e 12000 kg ha^{-1} , respectivamente.



Figura 11 Ponto de colheita registrado fora das delimitações do talhão.

Na segunda etapa da filtragem dos dados, foram identificados os pontos discrepantes globais. De acordo com Taylor, McBratney e Whelan (2007), é necessário realizar uma estatística descritiva dos dados para se obter a média e o desvio padrão dos valores,

possibilitando tornar os pontos, cujo valor de desvio padrão for duas vezes e meia superior ou inferior à média, candidatos a discrepantes globais. Após a identificação dos valores no QGIS, os pontos identificados foram removidos.

Na terceira etapa de filtragem, foram definidos os pontos discrepantes locais. Nesta etapa, foi utilizado o *software MapFilter* (SPEKKEN; ANSELM; MOLIN, 2013). O método utilizado pelo *software* para identificar pontos discrepantes consiste em realizar uma busca, em um determinado raio, de valores que tenham uma variação em relação à mediana de seus vizinhos. O *software* identifica os valores que possuem variação maior que os limites estabelecidos (inadequados) e valores que apresentem variação maior quando estão no raio de busca de outro ponto (inconsistentes) (Figura 12). Para os valores de soja foi utilizado o valor de 10 metros para o raio, que é a largura da plataforma de colheita utilizada. Já para os dados de milho, o raio foi de 5 metros, também devido a outra plataforma utilizada para colheita. Foi estabelecido um padrão de 15% como limite de variação, em relação à mediana, para os valores das duas culturas. Após a filtragem, foram removidos tanto os dados inadequados, quanto os inconsistentes.

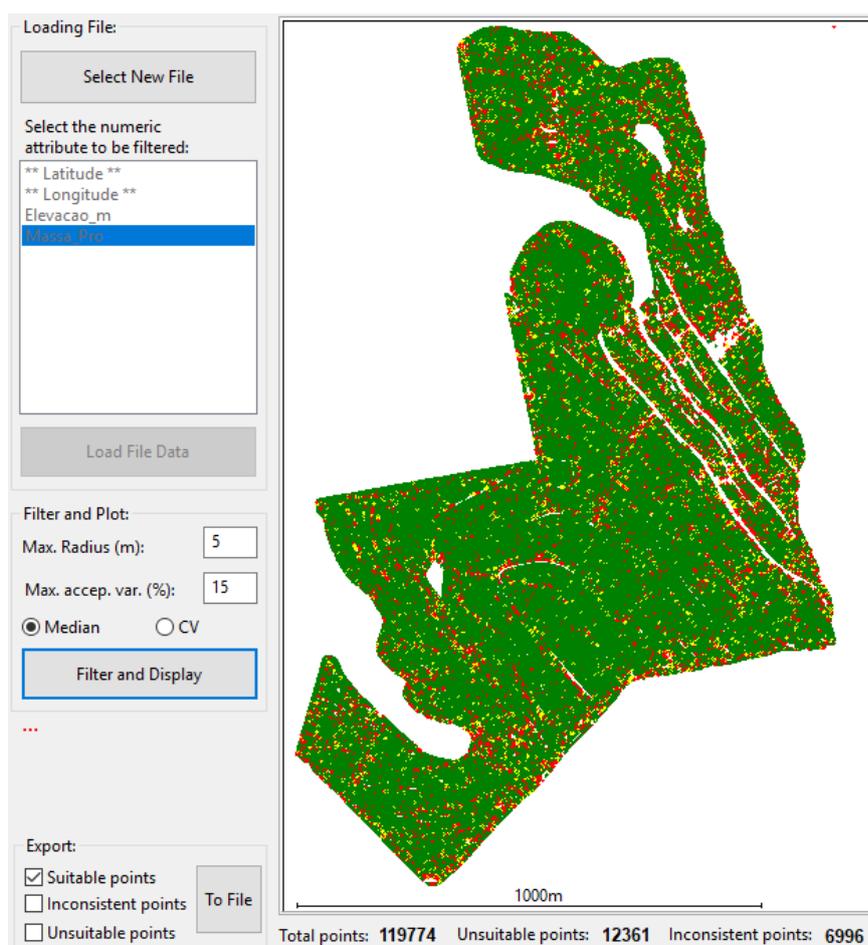


Figura 12 Identificação de pontos discrepantes locais.

Após a remoção de pontos discrepantes, realizou-se a interpolação dos dados. Betzek et al. (2017), em estudo utilizando diferentes métodos de interpolação para dados de colheita,

destacaram o inverso da distância, na segunda potência, como o método que menos influenciou nos valores, portanto, este foi utilizado para interpolar os mapas de colheita no *software* QGIS. Como resultado, obteve-se um arquivo *raster*, com resolução de *pixel* de 10 x 10 metros. Esse tamanho foi determinado para que tenha a mesma resolução das imagens de satélite utilizadas, que também são disponibilizadas com 10 x 10 metros nos *pixels*.

Para os procedimentos posteriores, foi necessário padronizar os valores de produtividade das culturas. A normalização dos dados foi feita seguindo a técnica da amplitude (MIELKE; BERRY, 2007), que classifica os valores na faixa de 0 a 1 (Equação 1).

$$P_n = \frac{P_o - P_{min}}{P_{max} - P_{min}} \quad (1)$$

em que P_n é o valor de produtividade normalizado, P_i é o valor original e P_{min} e P_{max} representam os valores mínimos e máximos, respectivamente, de todo o conjunto de dados.

4.3 Processamento de imagens orbitais

Para as imagens orbitais, foram utilizados os produtos do sensor MSI do satélite *Sentinel-2*. As imagens são disponibilizadas de forma gratuita em diversas plataformas na *internet* e, além disso, já possuem correção atmosférica e seus valores convertidos para refletância na superfície (ESA, 2020), essencial para o cálculo de índices de vegetação (IVs). Novas imagens são disponibilizadas a cada 5 dias, possibilitando utilizar diversas imagens durante uma safra.

O produto de cada imagem orbital é disponibilizado em uma série de bandas que compreendem toda a faixa do espectro, captando valores de 433 nm (Aerossol) até 2190 nm (SWIR 2). Para o cálculo dos índices de vegetação foram selecionadas as bandas descritas na Tabela 2.

Tabela 2 Descrição das bandas do satélite *Sentinel-2* utilizadas para o cálculo dos índices de vegetação

Nº da banda	Nome da banda	Comprimento de onda (NM)
B02	Azul	490
B03	Verde	560
B04	Vermelho	665
B08	Infravermelho Próximo	842

Fonte: *European Space Agency* (2020).

Para o estudo de associação entre os IVs e mapas de produtividade, foram utilizados os dez índices descritos na Tabela 3, escolhidos por serem os mais utilizados em trabalhos e pesquisas (GÓMEZ-GIRALDÉZ et al., 2020; LIN et al., 2019; XUE; SU, 2017).

Tabela 3 Índices de vegetação

Índice	Nome	Fórmula	Autor(es)
NDVI	<i>Normalized Difference Vegetation Index</i>	$\frac{NIR - Red}{NIR + Red}$	Rouse et al. (1973)
TNDVI	<i>Transformed NDVI</i>	$\sqrt{NDVI + 0,5}$	Tucker (1979)
SAVI	<i>Soil-Adjusted Vegetation Index</i>	$\frac{(1 + L)(NIR - Red)}{NIR + Red + L}$	Huete (1988)
ARVI	<i>Atmospherically Resistant Vegetation Index</i>	$\frac{NIR - Red - y(Red - Blue)}{NIR + Red - y(Red - Blue)}$	Kaufman; Tanré (1992)
RDVI	<i>Renormalized Difference Vegetation Index</i>	$\frac{NIR - Red}{\sqrt{(NIR + Red)}}$	Reujean; Breon (1995)
MSR	<i>Modified Simple Ratio Index</i>	$\frac{NIR / Red - 1}{\sqrt{((NIR / Red) + 1)}}$	Chen (1996)
GNDVI	<i>Green NDVI</i>	$\frac{NIR - Green}{NIR + Green}$	Gitelson et al. (1996)
EVI	<i>Enhanced Vegetation Index</i>	$\frac{2,5(NIR - Red)}{NIR + 6Red - 7,5Blue + 1}$	Huete et al. (1997)
GCVI	<i>Green Chlorophyll Vegetation Index</i>	$\frac{NIR}{Green} - 1$	Gitelson et al. (2003)
MPRI	<i>Modified Photochemical Reflectance Index</i>	$\frac{Green - Red}{Green + Red}$	Yang et al. (2008)

O processamento das imagens para criar os índices foi realizado no *software* QGIS, por meio da ferramenta *Raster calculator*. Para cada data selecionada, realizou-se o cálculo dos dez índices, totalizando 40 imagens *raster*.

Ao final do processo, os *rasters* de colheita (com valores normalizados), os *rasters* de índices vegetativos e os *rasters* com dados topográficos foram submetidos a um processo de alinhamento. Esse processo permite que as imagens tenham seus *pixels* alinhados e com as mesmas resoluções, para isso realiza uma reamostragem de cada valor de *pixel* com o método do Vizinho mais Próximo (*Nearest Neighbor*). Dessa forma, é possível que sejam comparadas com eficiência. Para esse processo, foi utilizada a ferramenta do QGIS *Align rasters*, onde se determinou uma medida de *pixels* de 10 metros, tendo como referência as imagens de satélite.

4.4 Geração de unidades de gestão diferenciada

Entre cada mapa com valores normalizados de colheita e valores dos índices, foi realizada uma média aritmética (GAVIOLI et al., 2019), assim foram utilizados três componentes para o agrupamento de dados: um conjunto de dados das médias calculadas, um conjunto com dados de altitude e um conjunto de dados de declividade.

Após esse procedimento, os *rasters* foram convertidos em pontos que representam o centro de cada *pixel*. Para cada um desses pontos, obteve-se o valor do *pixel* e sua respectiva coordenada geográfica. Procedimento requerido para o processamento no *software* *FuzMe* 3.5 (MINASNY; MCBRATNEY, 2002), que aplica o algoritmo *Fuzzy C-means* sobre os dados.

O *Fuzzy C-means* (BEZDEK et al., 1981) é um algoritmo de agrupamento de dados (clusterização) que realiza uma divisão entre os dados dos componentes em k grupos. O algoritmo constrói uma matriz de pertinência para cada elemento, ou seja, os dados podem pertencer a vários grupos, mas em diferentes graus. Com a Equação 2, calcula-se a pertinência de cada elemento:

$$\mu_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{ik}}\right)^{\left(\frac{2}{m-1}\right)}} \quad (2)$$

em que μ_{ij} é a associação do elemento i ao centroide j , m é o índice fuzzy, c é o número de clusters e d_{ik} é a distância euclidiana entre o elemento i ao centroide j . Com a Equação 3, calculam-se os centroides:

$$v_j = \frac{\sum_{i=1}^n (\mu_{ij})^m x_i}{\sum_{i=1}^n (\mu_{ij})^m} \quad (3)$$

em que v_j representa o j -ésimo centro de cluster.

O algoritmo é aplicado sobre um conjunto de dados iterativamente, ou seja, diversas vezes. O processo termina quando a diferença entre a posição do centro de cluster em determinada iteração e sua anterior for menor que o critério de parada estabelecido. O índice fuzzy (m) estabelece a distância permitida entre os pontos e o centro que está sendo calculado, quanto mais próximo a 1, mais rígido o critério de pertinência de um dado a uma classe.

Para Cox (2005) os melhores resultados para valor de m estão entre 1,25 e 2. No processo de agrupamento, os dados foram divididos em dois, três e quatro grupos.

4.5 Análises de validação de agrupamento

Para analisar a qualidade de agrupamentos realizados, foram empregados índices que avaliam parâmetros como o número de grupos, a variância dos conjuntos de dados e a concordância entre mapas gerados por IVs e por produtividade.

4.5.1 Análise de variância (Kruskal-Wallis)

Para avaliar as diferenças entre as UGDs geradas, foi empregada a análise de variância. Souza, Schenatto e Bazzi (2018) utilizaram a ANOVA, indicando que o melhor resultado pode ser considerado quando as UGDs se diferem estatisticamente. Considerando

um conjunto de dados com diferentes tamanhos (valores) entre as classes, optou-se pelo teste não-paramétrico de Kruskal-Wallis (1952), seguido pelo teste Dunn.

4.5.2 Redução da variância (VR)

O índice *Variance Reduction* (VR), proposto por Ping e Dobermann (2003), indica o quanto a variância do conjunto de dados foi reduzida, ao se dividir em UGDs. O índice resulta em uma porcentagem e é descrito pela Equação 4:

$$VR = \left[1 - \frac{\sum_{i=1}^c (W_i * V_{um_i})}{V_{\text{área}}} \right] * 100 \quad (4)$$

em que c é o número de UGDs, W_i é a proporção de área de cada UGD em relação à área total, V_{um_i} é a variância dentro da UGD e $V_{\text{área}}$ é a variância de todo o conjunto de dados.

4.5.3 Índice de desempenho Fuzzy (FPI)

Para avaliar se existe dependência entre as UGDs geradas (dados equivalentes em diferentes UGDs), pode-se aplicar o índice FPI (*Fuzzy Performance Index*). Este método (Equação 5) avalia todos os valores entre as classes e mensura o compartilhamento de dados, resultando em valores que variam de 0 a 1, em que 0 seria um melhor desempenho do agrupamento (FRIDGEN et al., 2004).

$$FPI = 1 - \frac{c}{c-1} \left[1 - \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^2 / n \right] \quad (5)$$

em que c é o número de grupos, n é o número de dados (pontos) e u_{ij} é o elemento ij da matriz de pertinência Fuzzy.

4.5.4 Índice da partição da entropia modificada (MPE)

O índice *Modified Partition Entropy* (MPE) (Equação 6) estima a dificuldade de organização dos dados em um número de *clusters* definido para o algoritmo de agrupamento (desorganização). O índice resulta em valores de 0 a 1, em que valores mais próximos de 0 indicam uma menor dificuldade, portanto uma melhor organização dos grupos (BOYDELL; MCBRATNEY, 2002).

$$MPE = \frac{-\sum_{j=1}^n \sum_{i=1}^c u_{ij} \log(u_{ij}) / n}{\log_c} \quad (6)$$

em que c é o número de grupos, n é o número de dados (pontos) e u_{ij} é o elemento ij da matriz de pertinência Fuzzy.

4.5.5 Índice aprimorado de validação de Cluster (ICVI)

Ao se obter os índices VR, FPI e MPE pode haver um conflito entre os resultados, indicando diferentes números de classes como o melhor resultado, portanto o índice *Improved Cluster Validation Index* (ICVI) (GAVIOLI et al., 2016) é indicado para analisar os resultados anteriores. Os valores variam de 0 a 1, em que 0 indica um melhor desempenho no agrupamento (Equação 7).

$$ICVI_i = \frac{1}{3} * \left[\frac{FPI_i}{Max\{FPI\}} + \frac{MPE_i}{Max\{MPE\}} + \left(1 - \frac{VR_i}{Max\{VR\}}\right) \right] \quad (7)$$

em que FPI_i é o valor do FPI estimado no i -ésimo agrupamento, MPE_i é o valor do MPE estimado no i -ésimo agrupamento, VR_i é o valor do VR estimado no i -ésimo agrupamento e $Max\{indice\}$ é o maior valor do respectivo índice, entre todos estimados para o conjunto de dados.

4.5.6 Validação por concordância Kappa

Após a determinação do agrupamento mais adequado, os dados foram novamente convertidos em arquivos *rasters*, onde já estão definidas as UGDs de acordo com a produtividade e os índices.

Para realizar a análise de comparação, foi adotado o índice Kappa (COHEN, 1960), que consiste em comparar os dados a serem validados (mapas de UGDs por IVs) com os dados de referência (mapas de UGDs por produtividade).

O objetivo desta análise é avaliar a concordância entre os mapas, portanto cada UGD delimitada por IV foi comparada com cada UGD delimitada pela produtividade. Esse método compara os mapas *pixel por pixel*. Por esse motivo, os mapas de produtividade foram interpolados de forma a se obter a mesma resolução que as imagens orbitais.

O índice Kappa contabiliza e gera matrizes de concordâncias e erros para o mesmo *pixel* em dois diferentes mapas. O cálculo desse índice é demonstrado pela Equação 8 e pode assumir valores entre 0 e 1, em que o valor 1 seria a condição de concordância perfeita (sem erros).

$$K = \frac{Po - Pe}{1 - Pe} \quad (8)$$

em que, Po é a taxa de aceitação relativa e Pe é a taxa hipotética de aceitação.

Landis e Koch (1977) classificaram os valores do índice Kappa de acordo com a qualidade de concordância, conforme a Tabela 4.

Tabela 4 Qualidade de concordância associada aos valores do índice Kappa

Índice Kappa	Qualidade
0	Desprezível
0,01 a 0,2	Ruim
0,21 a 0,4	Razoável
0,41 a 0,6	Regular
0,61 a 0,8	Boa
0,81 a 1	Excelente
1	Perfeita

Fonte: Adaptado de Landis e Koch (1977).

5 RESULTADOS E DISCUSSÃO

Os dados de produtividade provenientes das 4 safras foram submetidos a uma análise estatística descritiva e os resultados são apresentados na Tabela 5.

Tabela 5 Análise estatística descritiva dos dados de produtividade originais.

Dados originais*	Soja 2017/2018	Milho 2018	Soja 2018/2019	Milho 2019
Nº de dados	121656	167097	127707	157898
Média	1,86	5,68	2,24	6,84
Mediana	1,81	5,7	2,11	6,84
Mínimo	0,34	0,33	0,34	0,35
Máximo	55,39	166,54	112,09	112,09
Desvio Padrão	0,81	2,54	1,82	2,46
Variância	0,66	6,45	3,31	6,05
Coef. de Var.	0,43	0,45	0,81	0,36
Assimetria	9,82	6,92	23,77	5,26
Curtose	379,53	235,41	920,5	174,39

Nota: *Dados de média, mediana, mínimo, máximo e desvio padrão em t ha⁻¹.

Conforme a Tabela 5, os dados originais da safra de soja 2017/2018 registram valores mínimo, máximo e média de 0,34, 55,34 e 1,86 t ha⁻¹, respectivamente. O desvio padrão é de 0,81 t ha⁻¹, resultando em um Coeficiente de Variação (CV) de 0,43. Observam-se também valores para assimetria de 9,82 e curtose de 379,53. Os dados originais da safra de soja 2018/2019 registram valores mínimo, máximo e média de 0,34, 112,09 e 2,24 t ha⁻¹, respectivamente. O desvio padrão é de 1,82 t ha⁻¹, resultando num CV de 0,81. Os valores de assimetria e curtose são de 23,77 e 920,5, respectivamente. De acordo com Gomes (1990), o CV apresentado pelas duas safras de soja pode ser considerado como muito alto. Os valores de assimetria e curtose para as duas safras indicam distribuição leptocúrtica com cauda a direita.

Os dados originais da safra de milho 2018, apresentados na Tabela 5, registram valores mínimo, máximo e média de 0,33, 166,54 e 5,68 t ha⁻¹, respectivamente. O desvio padrão é de 2,54 t ha⁻¹, resultando em um CV de 0,45. Os valores de assimetria e curtose são de 6,92 e 235,41, respectivamente. Os dados originais de milho 2019 registram valores mínimo, máximo e média 0,35, 112,09 e 6,84 t ha⁻¹, respectivamente. O desvio padrão é de 2,46 t ha⁻¹, resultando num CV de 0,36. Observam-se também os valores para assimetria de 5,26 e curtose de 174,39. Os valores de CV podem ser classificados como muito altos para as duas safras de milho (GOMES, 1990). Os valores de assimetria e curtose das duas safras indicam distribuição leptocúrtica com cauda a direita.

5.1 Filtragem dos dados de produtividade

Os dados referentes à produtividade das quatro safras foram submetidos ao processo de filtragem com remoção de dados irreais, remoção de discrepantes globais e discrepantes locais, definindo para este último um raio de 10 metros para as safras de soja e um raio 5 metros para as safras de milho. As medidas definidas para o raio de busca levaram em consideração o comprimento das plataformas utilizadas para colheita.

Na Tabela 6 é possível observar a quantidade de pontos removida em cada etapa do processo de filtragem. Para os dados de soja 2017/2018, milho 2018, soja 2018/2019 e milho 2019 foram removidos 28,86, 17,46, 23,57 e 29,84%, respectivamente. A terceira etapa do processo de filtragem foi a que mais removeu pontos, estes considerados discrepantes locais. Menegatti e Molin (2004) removeram quantidades correspondentes entre 4,6 e 27,3% dos dados originais em estudo, comparando diferentes monitores de colheita.

Tabela 6 Quantidades de pontos removidos dos dados de colheita após o processo de filtragem

Safras	Dados originais	Dados removidos (1 filtro)		Dados removidos (2 filtros)		Dados removidos (3 filtros)		Total de dados removidos	
			%		%		%		%
Soja 17/18	121656	108	0,09	1774	1,46	19357	15,91	21239	17,46
Milho 2018	167097	1101	0,66	1659	0,99	47108	28,19	49868	29,84
Soja 18/19	127707	451	0,35	2207	1,73	34195	26,78	36853	28,86
Milho 2019	157898	1048	0,66	3774	2,39	32390	20,51	37212	23,57

Nota: Porcentagem (%) em relação aos dados originais.

Taylor, McBratney e Whelan (2007) citam as manobras constantes, as variações na velocidade de colheita e a má regulação dos equipamentos como os principais fatores que geram pontos com informações discrepantes.

Os dados filtrados das quatro safras foram submetidos à análise estatística descritiva e são apresentados na Tabela 7.

Tabela 7 Análise estatística descritiva dos dados de produtividade filtrados

Dados filtrados*	Soja 2017/2018	Milho 2018	Soja 2018/2019	Milho 2019
Nº de dados	100417	117229	90854	120686
Média	1,77	5,1	2,11	6,05
Mediana	1,75	5,18	2,1	6,06
Mínimo	0,34	0,44	0,34	1,28
Máximo	3,39	9,74	4,32	10,67
Desvio padrão	0,5	1,39	0,65	1,36
Variância	0,25	1,93	0,42	1,85
Coef. de var.	0,28	0,27	0,31	0,22
Assimetria	0,2	-0,17	0,23	-0,05
Curtose	-0,12	0,43	-0,18	0,42

Nota: *Dados de média, mediana, mínimo, máximo e desvio padrão em t ha⁻¹.

Conforme Tabela 7, os dados filtrados da safra de soja 2017/2018 registram valores mínimo, máximo e média de 0,34, 3,39 e 1,77 t ha⁻¹, respectivamente. O desvio padrão é de 0,5 t ha⁻¹, resultando num CV de 0,28. Os valores referentes à assimetria e à curtose são de 0,2 e -0,12, respectivamente. Na safra 2018/2019 de soja, os dados filtrados apresentam valores mínimo, máximo e média de 0,34, 4,32 e 2,11 t ha⁻¹, respectivamente. O desvio padrão é de 0,65 t ha⁻¹, resultando num CV de 0,31. Observam-se valores de assimetria e curtose de 0,23 e -0,18, respectivamente. Observa-se que, apesar da redução dos valores de CV, ainda podem ser considerados alto e muito alto (GOMES, 1990). Os valores de assimetria e curtose para as duas safras indicam distribuição levemente platicúrtica com cauda a direita.

Os dados filtrados da safra de milho 2018 (Tabela 7) registram valores mínimo, máximo e média de 0,44, 9,74 e 5,1 t ha⁻¹, respectivamente. O desvio padrão é de 1,39 t ha⁻¹, resultando em um CV de 0,27. Os valores de assimetria e curtose são de -0,17 e 0,43, respectivamente. Os dados filtrados de milho 2019 registram valores mínimo, máximo e média 1,28, 10,67 e 6,05 t ha⁻¹, respectivamente. O desvio padrão é de 1,36 t ha⁻¹, resultando num CV de 0,22. Observam-se também os valores para assimetria de -0,05 e curtose de 0,42. Os valores de CV podem ser classificados como altos para as duas safras de milho (GOMES, 1990). Os valores de assimetria e curtose das duas safras indicam leve distribuição leptocúrtica com cauda a esquerda.

Analisando as Tabelas 5 e 7, observa-se uma redução nos desvios-padrão ao se realizar as filtragens, resultando em uma redução nos coeficientes de variação de 0,15 para os dados da safra de soja 2017/2018, 0,18 para a safra de milho 2018, 0,50 para a safra de soja 2018/2019 e 0,14 para a safra de milho 2019. Sun et al. (2012) constataram uma redução no coeficiente de variação após um processo de filtragem sobre os dados brutos de produtividade, podendo ser esse um indicativo da presença de dados discrepantes.

Alguns autores demonstraram que a média tende a elevar com o processo de filtragem dos dados (ZANELLA, 2019; LYLE; BRYAN; OSTENDORF, 2013). O contrário é demonstrado na Tabela 7, em que as médias das quatro safras diminuíram. Isso pode estar relacionado com a remoção de dados irreais que estavam muito acima do histórico de produtividade da área. De acordo com Molin, Amaral e Colaço (2015), dados que apresentam produtividade muito além de valores reais podem comprometer a interpolação de toda a área.

Os histogramas para os dados de soja 2017/2018 podem ser observados na Figura 13a (dados originais) e Figura 13b (dados filtrados).

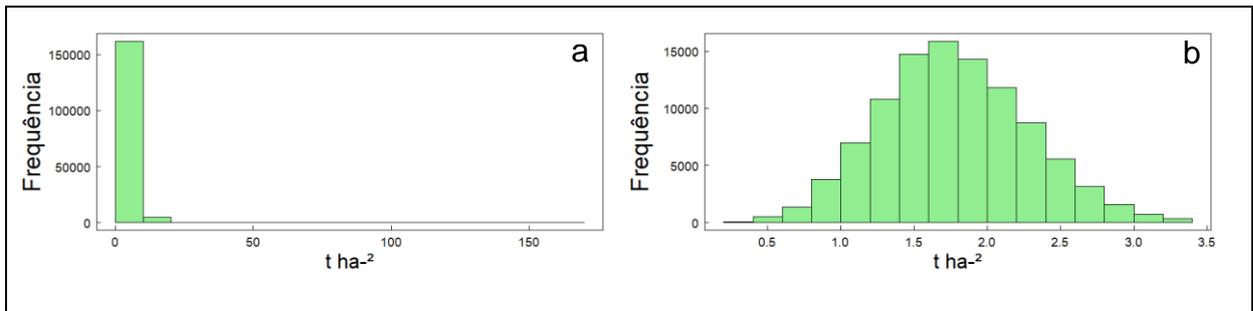


Figura 13 Histogramas da produtividade de soja da safra 2017/2018. a) Dados originais; b) Dados filtrados.

Os histogramas para os dados de milho 2018 podem ser observados na Figura 14a (dados originais) e Figura 14b (dados filtrados).

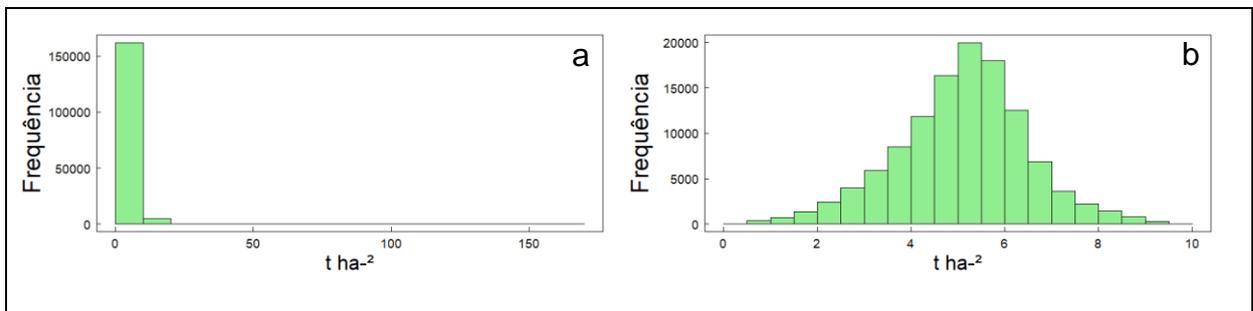


Figura 14 Histogramas da produtividade de milho da safra 2018. a) Dados originais; b) Dados filtrados.

Os histogramas para os dados de soja 2018/2019 podem ser observados na Figura 15a (dados originais) e Figura 15b (dados filtrados).

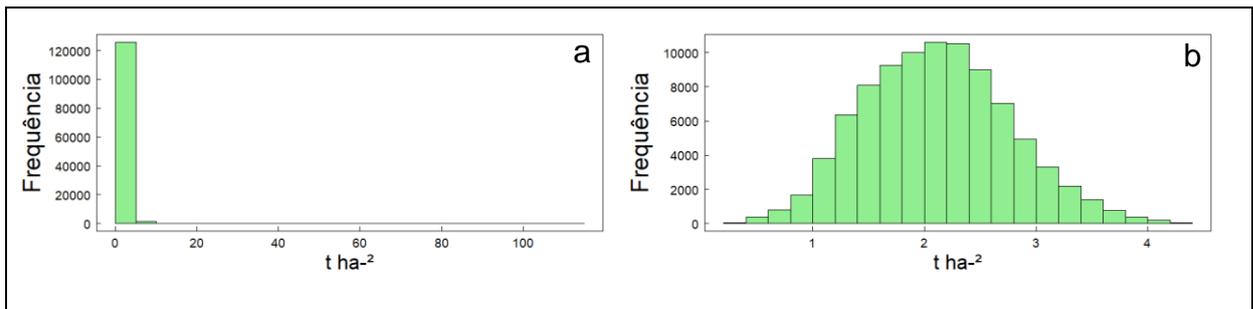


Figura 15 Histogramas da produtividade de soja da safra 2018/2019. a) Dados originais; b) Dados filtrados.

Os histogramas para os dados de milho 2019 podem ser observados na Figura 16a (dados originais) e Figura 16b (dados filtrados).

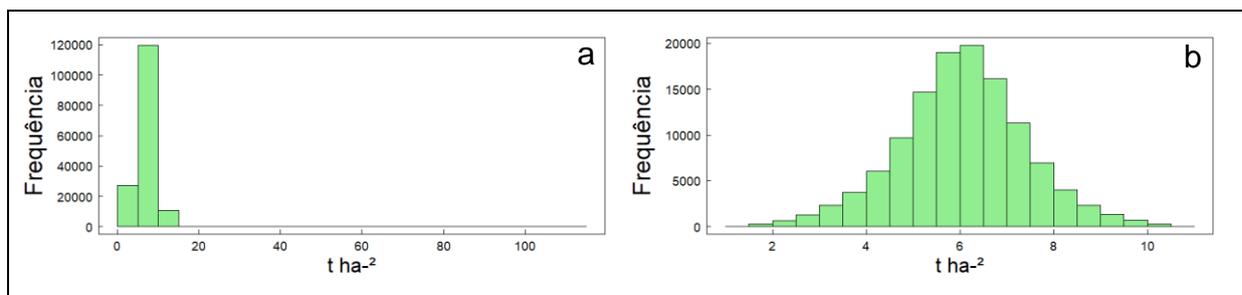


Figura 16 Histogramas da produtividade de milho da safra 2019. a) Dados originais; b) Dados filtrados.

Observa-se nas Figuras 13 a 16 que a remoção de dados discrepantes permitiu a visualização de mais classes no histograma, também é possível observar que os dados tendem a uma distribuição normal, permitindo a utilização nos agrupamentos.

Os dados de produtividade filtrados foram interpolados pelo método inverso da distância ao quadrado em um *raster* com resolução de 10 x 10 metros, possibilitando a comparação com os dados provenientes de satélite. Na Tabela 8 observam-se os dados comparados pelo coeficiente de correlação de Spearman (1904). É possível observar que existem apenas correlações fracas entre os parâmetros de declividade e altitude com os dados de colheita, exceto pela soja 2018/2019 e altitude em que há uma correlação moderada negativa (COHEN, 1988).

Tabela 8 Comparação entre os dados de colheita com altitude e declividade, pelo coeficiente de correlação de Spearman

Dados de declividade e altitude	Soja 2017/2018	Milho 2018	Soja 2018/2019	Milho 2019
Altitude	0,2799	0,2523	-0,4518	0,0055
Declividade	-0,2633	-0,2537	0,0453	-0,1205

De acordo com Fraisse, Sudduth e Kitchen (2001), a altitude é um parâmetro importante no agrupamento de dados para delineamento de UGDs em solos argilosos. A importância de levar em consideração os dados topográficos está relacionada às limitações na utilização de maquinário agrícola (em relação às condições de tráfego e estabilidade dos equipamentos) (HOFIG; ARAUJO-JUNIOR, 2015) e formação de microclima (SILVA; JARDIM, 2017).

5.2 Índices de vegetação

Para calcular os índices de vegetação, foram selecionadas imagens de 61, 63, 64 e 63 dias após a semeadura (DAS) para as safras de soja 2017/2018, milho 2018, soja 2018/2019 e milho 2019, respectivamente. Na Tabela 9 observam-se os dias determinados para aquisição das imagens.

Tabela 9 Datas de aquisição de imagens de satélite

Cultura	Semeadura	Imagem disponível	Imagem (DAS)
Soja 2017/2018	12/10/2017	12/12/2017	61
Milho 2018	22/02/2018	26/04/2018	63
Soja 2018/2019	24/09/2018	27/11/2018	64
Milho 2019	23/01/2019	27/03/2019	63

A determinação do período para aquisição das imagens levou em consideração os estádios fenológicos que apresentam os maiores valores dos IVs: reprodutivo (R3 a R5) para a soja (SCHIRMBECK et al., 2020; TRINDADE et al., 2019) e para o milho (R1 a R2) (ZHANG et al., 2019; TOUREIRO et al., 2017), estabilização dos índices durante o ciclo da cultura (RODIGHERI et al., 2020) e a disponibilidade de imagens na plataforma de distribuição do *Sentinel-2*.

Na Figura 17 observa-se o gráfico do NDVI do ciclo de soja da safra 2017/2018 e as imagens *Sentinel-2* disponíveis e sem a presença de nuvens sobre a área de estudo.

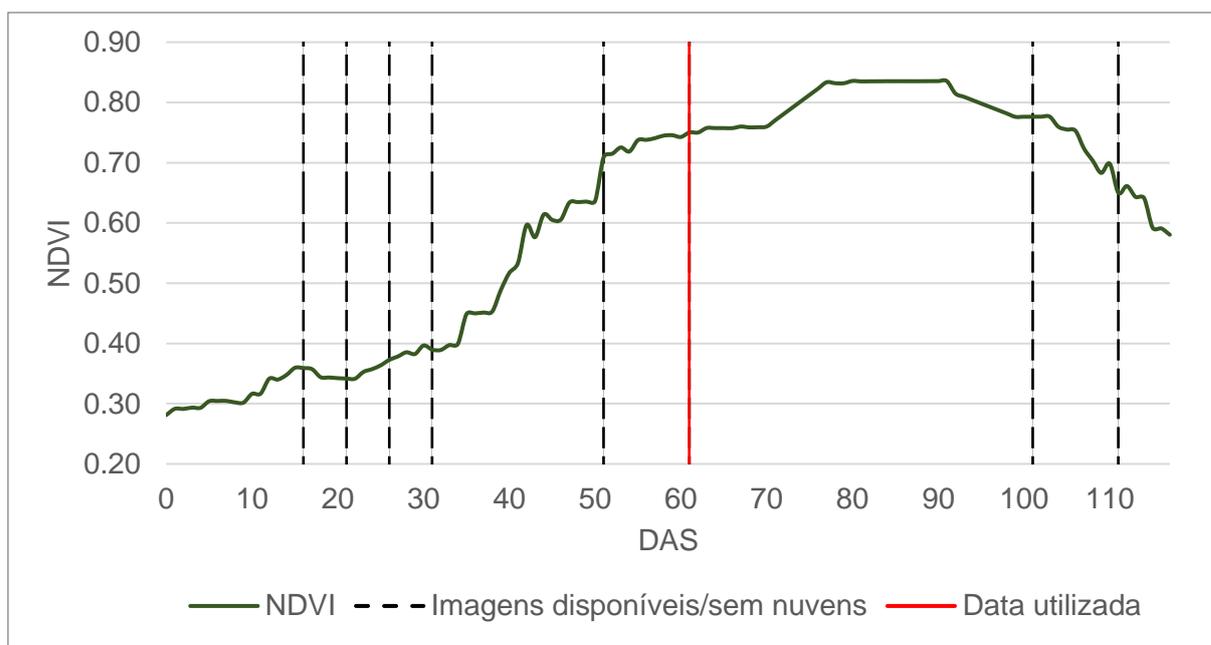


Figura 17 Gráfico NDVI da área de estudo e datas de imagens do *Sentinel-2*, disponíveis no período de 12/12/2017 a 06/02/2018.

Nota: A linha em vermelho indica a data utilizada para avaliação.

Na Figura 18 observa-se o gráfico do NDVI do ciclo de milho da safra 2018 e as imagens *Sentinel-2* disponíveis e sem a presença de nuvens sobre a área de estudo. A data escolhida para este período foi determinada em 63 DAS para se manter o período determinado para as outras safras.

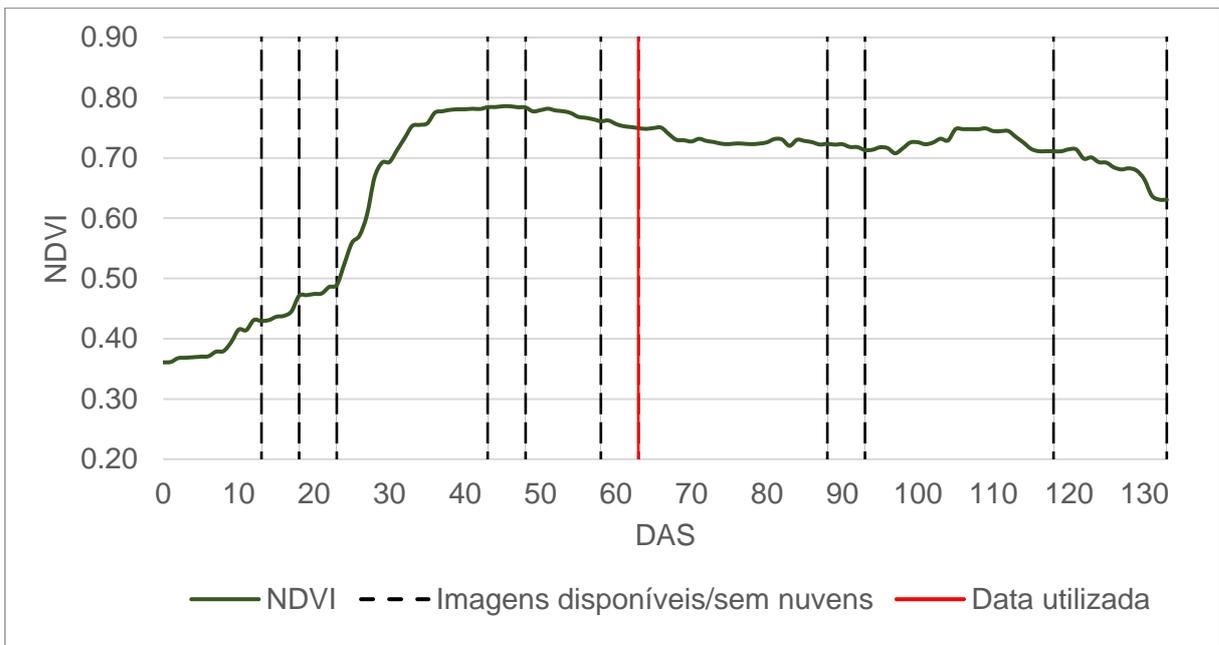


Figura 18 Gráfico NDVI da área de estudo e datas de imagens do *Sentinel-2*, disponíveis no período de 22/02/2018 a 05/07/2018.

Nota: A linha em vermelho indica a data utilizada para avaliação.

Na Figura 19 observa-se o gráfico do NDVI do ciclo de soja da safra 2018/2019 e as imagens *Sentinel-2* disponíveis e sem a presença de nuvens sobre a área de estudo.

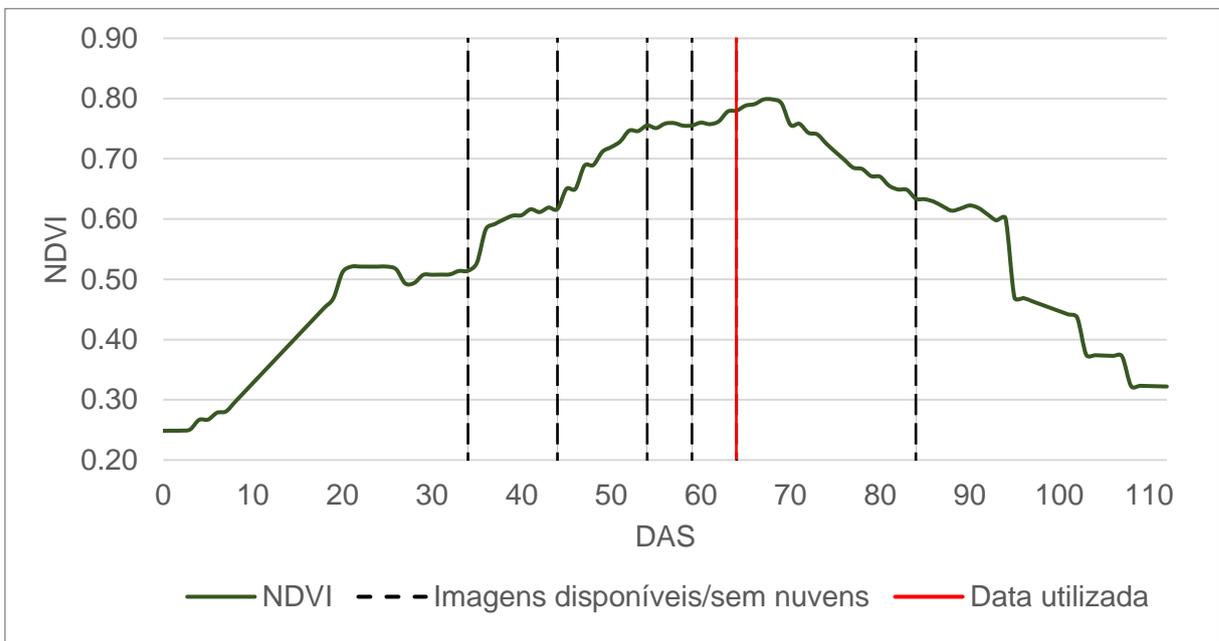


Figura 19 Gráfico NDVI da área de estudo e datas de imagens do *Sentinel-2*, disponíveis no período de 24/09/2018 a 14/01/2019.

Nota: A linha em vermelho indica a data utilizada para avaliação.

Na Figura 20 observa-se o gráfico do NDVI do ciclo de milho da safra 2019 e as imagens *Sentinel-2* disponíveis e sem a presença de nuvens sobre a área de estudo.

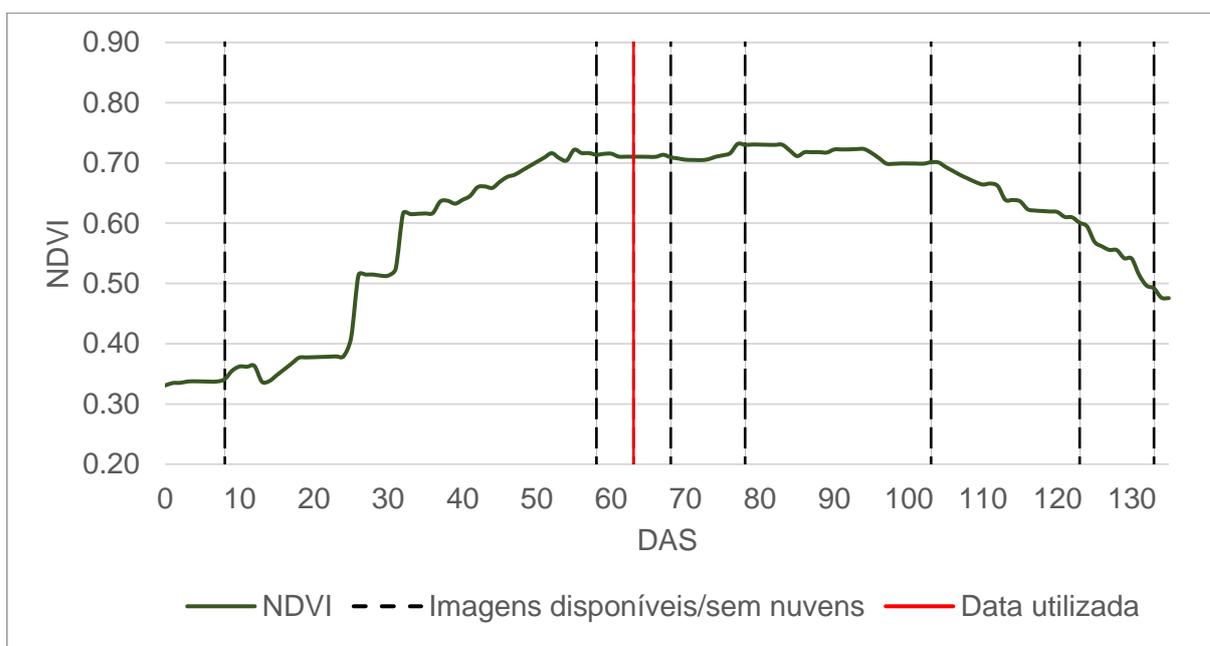


Figura 20 Gráfico NDVI da área de estudo e datas de imagens do *Sentinel-2*, disponíveis no período de 23/01/2019 a 07/06/2019.

Nota: A linha em vermelho indica a data utilizada para avaliação.

Após a confecção dos índices de vegetação no programa QGIS, as imagens *raster* foram submetidas a uma análise descritiva básica, conforme a Tabela 10. Observa-se que o maior valor de CV, foi de 0,44 para o índice MPRI na data 12/12/2017.

Tabela 10 Estatística descritiva dos índices de vegetação

Datas		Índices de vegetação									
		ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
12/12 2017	Mín.	0,24	0,29	1,38	0,41	-0,15	0,48	0,29	41,96	0,43	0,89
	Máx.	0,88	0,93	6,60	0,77	0,35	3,49	0,87	191,30	1,31	1,17
	Méd.	0,76	0,81	3,92	0,65	0,20	2,23	0,75	137,16	1,12	1,12
	DP	0,09	0,09	1,00	0,06	0,09	0,59	0,09	25,02	0,13	0,04
	CV	0,12 ^m	0,11 ^m	0,26 ^a	0,09 ^b	0,44 ^{ma}	0,27 ^a	0,12 ^m	0,18 ^m	0,12 ^m	0,04 ^b
26/04 2018	Mín.	0,23	0,37	0,88	0,30	-0,12	0,41	0,25	40,66	0,38	0,87
	Máx.	0,84	0,92	4,93	0,71	0,28	2,79	0,82	155,64	1,24	1,15
	Méd.	0,77	0,85	3,73	0,65	0,21	2,17	0,75	133,29	1,13	1,12
	DP	0,05	0,05	0,46	0,03	0,05	0,27	0,05	12,35	0,07	0,02
	CV	0,06 ^b	0,06 ^b	0,12 ^m	0,05 ^b	0,22 ^a	0,13 ^m	0,06 ^b	0,09 ^b	0,06 ^b	0,02 ^b
27/11 2018	Mín.	0,44	0,52	1,79	0,47	-0,05	0,82	0,44	64,10	0,65	0,97
	Máx.	0,88	0,94	6,43	0,76	0,33	3,37	0,87	179,34	1,30	1,17
	Méd.	0,80	0,86	4,30	0,68	0,22	2,41	0,78	139,86	1,17	1,13
	DP	0,04	0,04	0,67	0,03	0,05	0,36	0,04	14,02	0,07	0,02
	CV	0,05 ^b	0,05 ^b	0,16 ^m	0,05 ^b	0,21 ^a	0,15 ^m	0,06 ^b	0,10 ^b	0,06 ^b	0,02 ^b
27/03 2019	Mín.	0,24	0,29	1,07	0,35	-0,08	0,45	0,27	42,83	0,41	0,88
	Máx.	0,81	0,88	4,22	0,68	0,25	2,46	0,79	145,38	1,19	1,14
	Méd.	0,74	0,82	2,93	0,59	0,20	1,87	0,71	119,55	1,06	1,10
	DP	0,03	0,04	0,36	0,03	0,02	0,18	0,04	9,78	0,05	0,02
	CV	0,05 ^b	0,04 ^b	0,12 ^m	0,05 ^b	0,12 ^m	0,10 ^b	0,05 ^b	0,08 ^b	0,05 ^b	0,02 ^b

Notas: CV: b-Baixo, m-Médio, a-Alto, ma-Muito alto.

Fonte: Gomes (1990).

As imagens *raster* dos índices de vegetação foram comparadas às imagens dos dados de colheita pelo coeficiente de correlação de Spearman (1904). Na Tabela 11 é possível observar uma moderada correlação entre todos os índices de vegetação e os dados de produtividade de soja, apenas entre os índices as correlações podem ser interpretadas como muito altas ou perfeitas (1) (COHEN, 1988).

Tabela 11 Correlação entre os índices de vegetação e produtividade de soja 2017/2018

12/12/2017	Soja	ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
Soja	1										
ARVI	0,427	1									
EVI	0,420	0,922	1								
GCVI	0,425	0,979	0,904	1							
GNDVI	0,425	0,979	0,904	1,000	1						
MPRI	0,413	0,980	0,903	0,920	0,920	1					
MSR	0,428	1	0,921	0,982	0,982	0,977	1				
NDVI	0,428	1	0,921	0,982	0,982	0,977	1	1			
RDVI	0,440	0,989	0,907	0,990	0,990	0,950	0,992	0,992	1		
SAVI	0,428	1	0,921	0,982	0,982	0,977	1	1	0,992	1	
TNDVI	0,428	1	0,921	0,982	0,982	0,977	1	1	0,992	1	1

Na Tabela 12 observa-se uma moderada correlação entre todos os índices e os dados de produtividade de milho, exceto pelo índice MPRI que apresentou correlação fraca. Apenas entre os índices as correlações podem ser interpretadas como altas, muito altas ou perfeitas (COHEN, 1988).

Tabela 4 Correlação entre os índices de vegetação e produtividade de milho 2018

26/04/2018	Milho	ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
Milho	1										
ARVI	0,498	1									
EVI	0,529	0,773	1								
GCVI	0,502	0,928	0,669	1							
GNDVI	0,502	0,928	0,669	1	1						
MPRI	0,290	0,758	0,662	0,499	0,499	1					
MSR	0,486	0,996	0,753	0,949	0,949	0,724	1				
NDVI	0,486	0,996	0,753	0,949	0,949	0,724	1	1			
RDVI	0,384	0,898	0,607	0,947	0,947	0,549	0,930	0,930	1		
SAVI	0,486	0,996	0,753	0,949	0,949	0,724	1	1	0,930	1	
TNDVI	0,486	0,996	0,753	0,949	0,949	0,724	1	1	0,930	1	1

Na Tabela 13 observa-se uma moderada correlação entre todos os índices e os dados de produtividade de soja, apenas entre os índices as correlações podem ser interpretadas como muito altas ou perfeitas (COHEN, 1988).

Tabela 5 Correlação entre os índices de vegetação e produtividade de soja 2018/2019

27/11/2018	Soja	ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
Soja	1										
ARVI	0,434	1									
EVI	0,414	0,866	1								
GCVI	0,468	0,976	0,847	1							
GNDVI	0,468	0,976	0,847	1	1						
MPRI	0,377	0,972	0,839	0,900	0,900	1					
MSR	0,438	1	0,865	0,979	0,979	0,968	1				
NDVI	0,438	1	0,865	0,979	0,979	0,968	1	1			
RDVI	0,470	0,978	0,840	0,980	0,980	0,927	0,982	0,982	1		
SAVI	0,438	1	0,865	0,979	0,979	0,968	1	1	0,982	1	
TNDVI	0,438	1	0,865	0,979	0,979	0,968	1	1	0,982	1	1

Na Tabela 14 observa-se uma fraca correlação entre todos os índices e os dados de produtividade de soja, apenas entre os índices as correlações podem ser interpretadas como altas, muito altas ou perfeitas (COHEN, 1988).

Tabela 6 Correlação entre os índices de vegetação e produtividade de milho 2019

06/05/2019	Milho	ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
Milho	1										
ARVI	0,131	1									
EVI	0,060	0,868	1								
GCVI	0,193	0,945	0,777	1							
GNDVI	0,193	0,945	0,777	1	1						
MPRI	0,024	0,703	0,672	0,468	0,468	1					
MSR	0,162	0,994	0,838	0,967	0,967	0,657	1				
NDVI	0,162	0,994	0,838	0,967	0,967	0,657	1	1			
RDVI	0,261	0,880	0,654	0,945	0,945	0,468	0,924	0,924	1		
SAVI	0,162	0,994	0,838	0,967	0,967	0,657	1	1	0,924	1	
TNDVI	0,162	0,994	0,838	0,967	0,967	0,657	1	1	0,924	1	1

Para realização do delineamento das UGDs, aplicou-se a média aritmética para cada IV (por exemplo, entre as quatro imagens NDVI, uma para cada safra) e para os dados de produtividade. Os dados médios, juntamente com os dados de declividade e altitude, foram submetidos ao teste de normalidade de Anderson-Darling. Todos os conjuntos apresentaram um p-valor inferior a 0,05, indicando a não-normalidade dos dados. Os histogramas dos conjuntos são apresentados na Figura 21. Observa-se nos histogramas de colheita (a), declividade (b) e índices de vegetação (d, e, f, g, h, i, j, k, l, m) que os dados tendem a se aproximar da linha de distribuição normal relativa ao conjunto de dados.

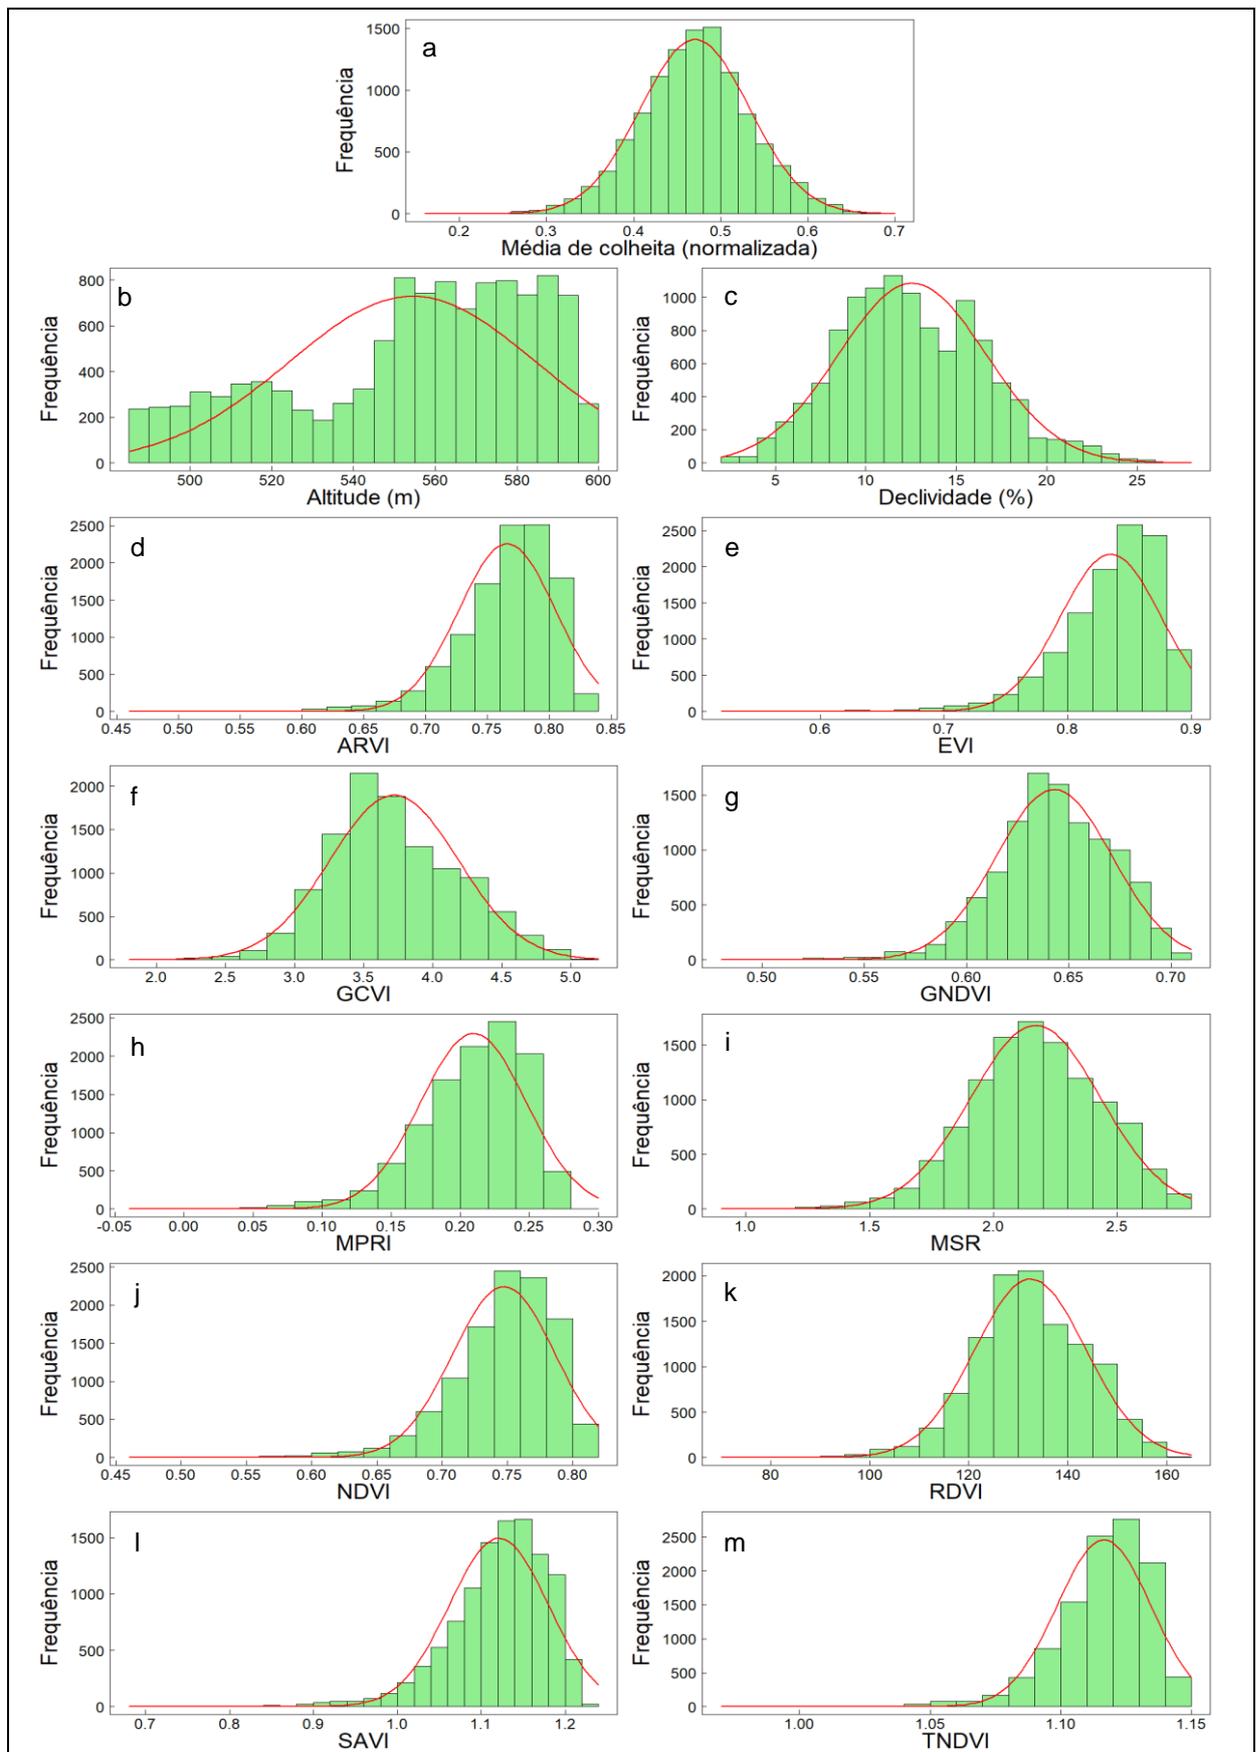


Figura 21 Histogramas dos conjuntos de dados. a) Média de colheita; b) Altitude; c) Declividade; d) ARVI; e) EVI; f) GCVI; g) GNDVI; h) MPRI; i) MSR; j) NDVI; k) RDVI; l) SAVI; m) TNDVI.

Na Tabela 15 é possível observar os valores de correlação pelo coeficiente de Spearman. Os valores indicam uma moderada correlação entre todos os índices de vegetação a média de produtividade, sendo o maior valor de 0,531 para RDVI e o menor de 0,398 para MPRI.

Tabela 7 Correlação entre os índices de vegetação e produtividade média

Média	Prod.	ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
Prod.	1										
ARVI	0,462	1									
EVI	0,420	0,908	1								
GCVI	0,514	0,946	0,840	1							
GNDVI	0,516	0,953	0,842	0,994	1						
MPRI	0,398	0,960	0,896	0,839	0,839	1					
MSR	0,482	0,993	0,900	0,968	0,966	0,945	1				
NDVI	0,475	0,999	0,902	0,958	0,966	0,946	0,995	1			
RDVI	0,531	0,944	0,830	0,984	0,986	0,843	0,963	0,959	1		
SAVI	0,475	0,999	0,902	0,958	0,966	0,946	0,995	1	0,959	1	
TNDVI	0,474	0,999	0,902	0,957	0,966	0,946	0,994	1	0,959	1	1

5.3 Agrupamento de dados

Para o agrupamento dos dados no programa *FuzMe*, foram utilizados os valores dos *pixels* das imagens *raster*. Cada índice e os dados de colheita foram agrupados separadamente com os dados de altitude e declividade, conforme Figura 22.

a	A	B	C	b	A	B	C
1	Colheita	alt	dec	1	ARVI	alt	dec
2	0.407192	485.518	4.688797	2	0.762823	485.518	4.688797
3	0.383961	485.708	3.939634	3	0.740863	485.708	3.939634
4	0.319898	485.708	3.939634	4	0.742313	485.708	3.939634
5	0.322158	485.708	3.939634	5	0.779581	485.708	3.939634
6	0.414433	485.96	4.494291	6	0.776363	485.96	4.494291
7	0.45211	485.96	4.494291	7	0.773212	485.96	4.494291
8	0.42668	485.518	4.688797	8	0.779081	485.518	4.688797
9	0.409684	485.518	4.688797	9	0.781616	485.518	4.688797
10	0.421231	485.518	4.688797	10	0.77037	485.518	4.688797
11	0.466345	486.891	8.530084	11	0.752831	486.891	8.530084
12	0.451757	486.891	8.530084	12	0.760454	486.891	8.530084
13	0.476864	486.891	8.530084	13	0.796704	486.891	8.530084

Figura 22 Seleção de dados para agrupamento. a) Média de colheita; b) Índice ARVI.

Nos parâmetros do algoritmo *Fuzzy C-means* foram definidos os parâmetros: expoente fuzzy = 1,5, número máximo de iterações = 800, mínimo de classes = 2 e máximo de

classes = 4. O programa *FuzMe* realiza normalização e análise de componentes principais (PCA) para distribuição dos dados entre as classes.

Ao final do processo, os dados agrupados foram submetidos a uma análise de variância de Kruskal-Wallis, seguido pelo teste Dunn. Os resultados, demonstrados na Tabela 16, indicam que houve diferenças significativas entre os dados em todos os agrupamentos. Na tabela do Anexo I são listados todos os valores de comparação entre as classes. Para todos os agrupamentos foram determinados os índices de validação fuzzy: VR, FPI, MPE e ICVI, sendo este último o critério para desempate, caso os outros índices indiquem conflito. Na Tabela 16 é possível observar que o índice VR demonstrou maior redução na variância do conjunto quando os dados são agrupados em 4 classes. O índice FPI demonstrou performance maior do *Fuzzy C-means* quando os dados são agrupados em duas classes. O índice MPE demonstrou melhor organização dos dados quando agrupados em três classes, exceto para o RDVI, indicando duas classes para este conjunto. Com o conflito entre os resultados, o índice ICVI foi utilizado em todos os agrupamentos, demonstrando que quatro é o número ideal de classes para os conjuntos.

Tabela 8 Teste de variância Kruskal-Wallis e índices de validação Fuzzy para os agrupamentos

Conjunto de dados	Nº de classes	P-value (Kruskall-Wallis)	VR (%)	FPI	MPE	ICVI
Média de colheita	2	2,20e-16***	1,402	0,104	0,130	0,842
	3	1,42e-06***	0,435	0,114	0,123	0,906
	4	2,20e-16***	5,445	0,133	0,126	0,657
ARVI	2	1,26e-06***	0,002	0,104	0,130	0,928
	3	2,20e-16***	1,026	0,114	0,123	0,896
	4	2,20e-16***	9,269	0,133	0,126	0,657
EVI	2	4,55e-11***	0,055	0,104	0,130	0,926
	3	2,20e-16***	1,188	0,114	0,123	0,890
	4	2,20e-16***	9,238	0,133	0,126	0,657
GCVI	2	3,51e-10***	0,725	0,104	0,130	0,910
	3	2,20e-16***	2,879	0,114	0,123	0,862
	4	2,20e-16***	13,496	0,133	0,127	0,657
GNDVI	2	1,11e-05***	0,090	0,104	0,130	0,925
	3	2,20e-16***	1,347	0,114	0,123	0,893
	4	2,20e-16***	11,349	0,133	0,126	0,657
MPRI	2	1,08e-09***	0,125	0,104	0,130	0,923
	3	2,20e-16***	1,652	0,114	0,123	0,864
	4	2,20e-16***	7,976	0,133	0,126	0,657
MSR	2	1,48e-11***	0,420	0,104	0,130	0,916
	3	2,20e-16***	2,357	0,114	0,123	0,866
	4	2,20e-16***	11,747	0,133	0,127	0,657
NDVI	2	1,34e-07***	0,019	0,104	0,130	0,927
	3	2,20e-16***	1,179	0,114	0,123	0,892
	4	2,20e-16***	9,663	0,133	0,126	0,657
RDVI	2	2,20e-16***	1,319	0,136	0,169	0,818
	3	2,20e-16***	4,158	0,184	0,203	0,915
	4	2,20e-16***	25,242	0,203	0,202	0,665
SAVI	2	1,34e-07***	0,019	0,104	0,130	0,927
	3	2,20e-16***	1,179	0,114	0,123	0,892
	4	2,20e-16***	9,663	0,133	0,126	0,657
TNDVI	2	2,88e-07***	0,009	0,104	0,130	0,927
	3	2,20e-16***	1,091	0,114	0,123	0,894
	4	2,20e-16***	9,458	0,133	0,126	0,657

Notas: Teste de significância Dunn: * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$; ^{ns}não significativo. Melhores resultados para os índices VR, FPI, MPE e ICVI destacados em negrito.

Resultados semelhantes foram encontrados por Schenatto et al. (2016), em estudo com atributos químicos e físicos do solo, onde os índices FPI e MPE indicaram duas classes, enquanto VR indicou cinco classes como melhor agrupamento. Xiang et al. (2007) indicam que os valores resultantes de VR tendem a aumentar juntamente ao número de classes definidas, pois a cada divisão o número de dados dentro da classe diminui.

5.4 Coeficiente de concordância Kappa

Para avaliação do coeficiente Kappa os dados numéricos foram transformados em imagens *raster*. O procedimento foi realizado no programa QGIS. Na Figura 23 são observadas as UGDs geradas pelos conjuntos em duas classes.



Figura 23 Unidades de gestão diferenciada geradas para duas classes. a) Média de colheita; b) ARVI; c) EVI; d) GCVI; e) GNDVI; f) MPRI; g) MSR; h) NDVI; i) RDVI; j) SAVI; k) TNDVI.

Na Figura 24 são observadas as UGDs geradas pelos conjuntos em três classes.



Figura 24 Unidades de gestão diferenciada geradas para três classes. a) Média de colheita; b) ARVI; c) EVI; d) GCVI; e) GNDVI; f) MPRI; g) MSR; h) NDVI; i) RDVI; j) SAVI; k) TNDVI.

Na Figura 25 são observadas as UGDs geradas pelos conjuntos em quatro classes.

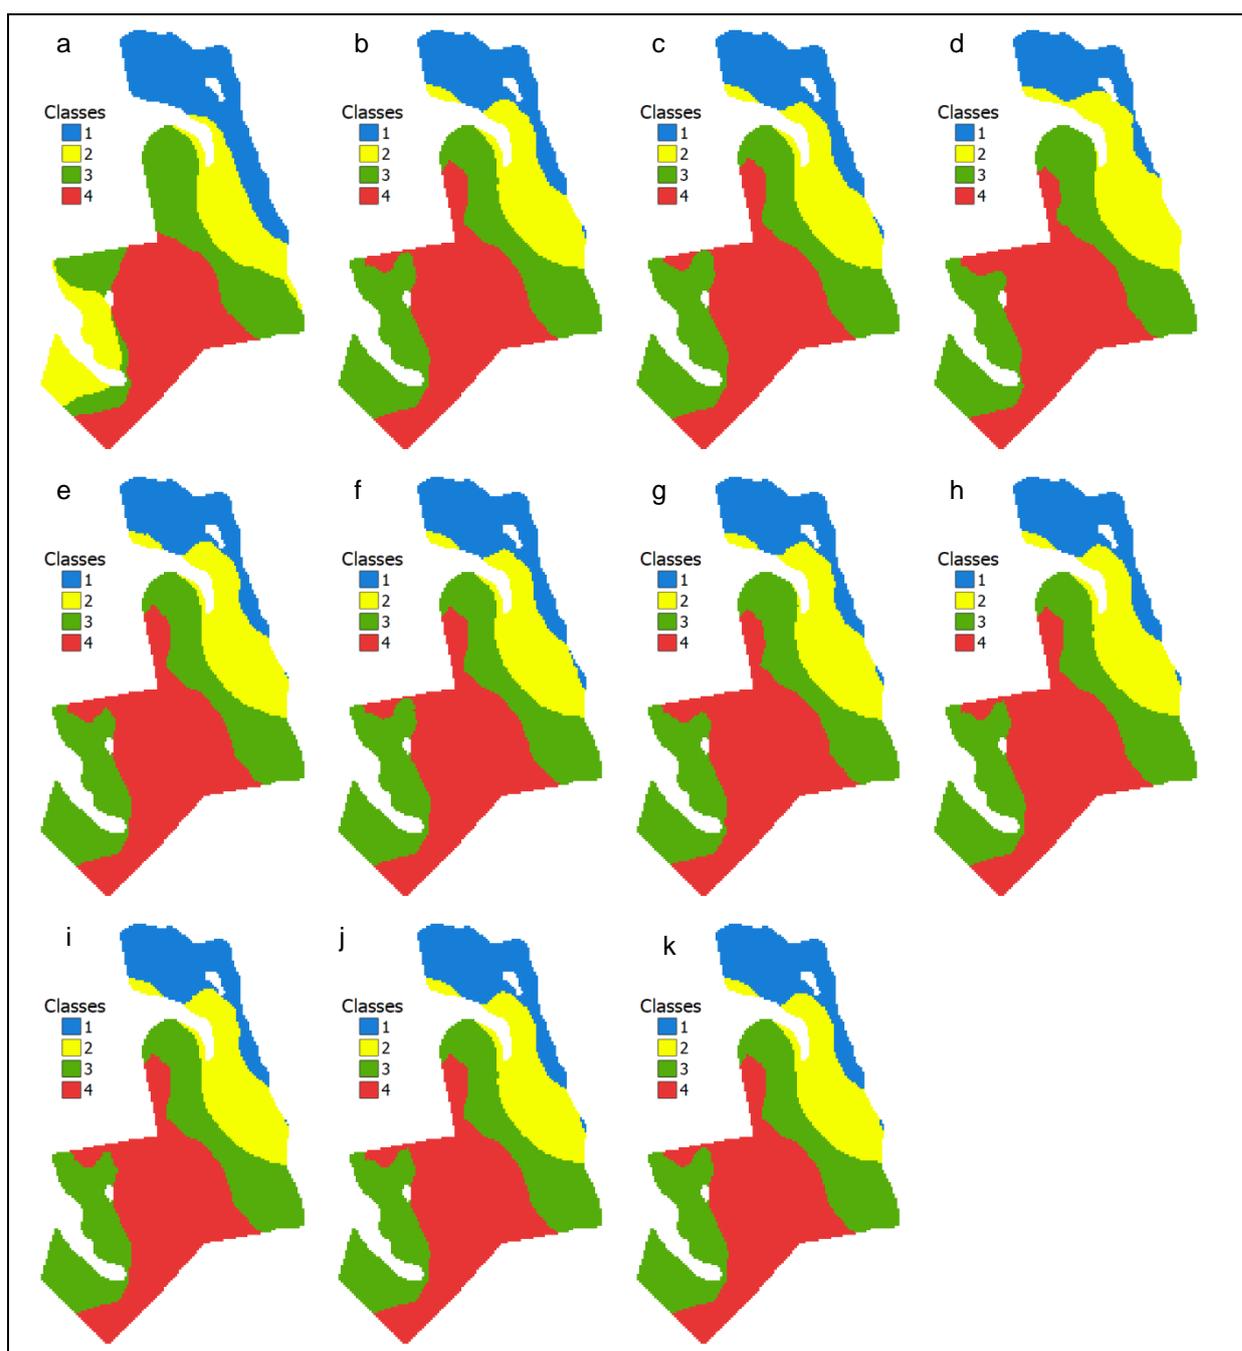


Figura 25 Unidades de gestão diferenciada geradas para quatro classes. a) Média de colheita; b) ARVI; c) EVI; d) GCVI; e) GNDVI; f) MPRI; g) MSR; h) NDVI; i) RDVI; j) SAVI; k) TNDVI.

Observa-se que as UGDs foram geradas com forte influência da variável altitude, o que corrobora os resultados encontrados por Schenatto et al. (2017), Bazzi et al. (2015) e Peralta e Costa (2013) e sugerem que o grau de influência no delineamento depende da diferença de elevação encontrada na área.

Para avaliação entre as UGDs geradas pelos índices de vegetação e as UGDs geradas pela média de produtividade foi utilizado o coeficiente de concordância Kappa (COHEN,

1960). Na Tabela 17 observa-se que as UGDs geradas pelos índices de vegetação para duas e três classes possuem concordância excelente ($K = 0,92$ a $0,98$). Também se observa que as UGDs geradas para quatro classes possuem boa concordância ($K = 0,64$ a $0,7$), das quais os maiores valores para os índices EVI e MPRI (LANDIS; KOCH, 1977). O menor valor de concordância ($K = 0,64$) foi observado no agrupamento de quatro classes no índice GCVI.

Tabela 9 Coeficientes de concordância Kappa entre as UGDs geradas por índices de vegetação e UGDs geradas por dados de produtividade

	Índices de vegetação									
	ARVI	EVI	GCVI	GNDVI	MPRI	MSR	NDVI	RDVI	SAVI	TNDVI
2 classes	0,98	0,98	0,97	0,98	0,98	0,97	0,98	0,97	0,98	0,98
3 classes	0,94	0,94	0,92	0,94	0,94	0,93	0,95	0,94	0,95	0,95
4 classes	0,69	0,70	0,64	0,66	0,70	0,66	0,68	0,67	0,68	0,68

6 CONCLUSÕES

De acordo com os objetivos estabelecidos e os resultados alcançados nesta pesquisa foi possível concluir que:

- a filtragem dos dados de colheita permitiu melhor visualização do conjunto e evitou erros nos mapas gerados, com remoção de 17,46 a 29,84% de registros;
- o algoritmo *Fuzzy C-means* permitiu agrupar o conjunto de dados nas diferentes classes;
- o índice aprimorado de validação de cluster determinou como 4 o número ideal de classes para todos os agrupamentos (ICVI = 0,657 a 0,665);
- o coeficiente Kappa demonstrou boas concordâncias ($K = 0,64$ a $0,70$) para 4 classes delimitadas;
- Juntamente aos dados topográficos, os índices de vegetação apresentaram viabilidade para delimitar unidades de gestão diferenciada, podendo ser uma alternativa quando não há registro de colheitas.

7 CONSIDERAÇÕES FINAIS

Apesar de os resultados terem sido satisfatórios é necessário que em estudos futuros sejam considerados outros parâmetros relativos à produtividade, como atributos químicos e físicos.

Para uma análise mais elaborada sugere-se que, a partir destes resultados, sejam utilizados mais registros do histórico, quando disponíveis, aumentando a quantidade de informação de entrada no processo.

Apresentada a complexidade dos métodos de processamento dos dados e da exigência de conhecimento técnico-científico, faz-se necessária a otimização dos procedimentos e utilização dos resultados em tempo hábil pelos usuários finais.

REFERÊNCIAS

- ANDRADE, C. L. T.; PEREIRA, P. E.; BRITO, R. A. L.; RESENDE, M. **Viabilidade e manejo da irrigação da cultura do milho**. Sete Lagoas: EMBRAPA - Milho e Sorgo, 2006. 12 p. (Circular Técnica, 85). ISSN 1679-1150 Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPMS/19629/1/Circ_85.pdf>.
- BALAFOUTIS, A.; BECK, B.; FOUNTAS, S.; VANGEYTE, J.; WAL, T.; SOTO, I.; GÓMEZ-BARBERO, M.; BARNES, A.; EORY, V. Precision agriculture technologies positively contributing to GHG emissions mitigation, farm productivity and economics. **Sustainability**, v. 9, n. 8, p. 1339-1340, 31 jul. 2017. Disponível em: <<http://dx.doi.org/10.3390/su9081339>>.
- BATTISTI, R.; SENTELHAS, P. C.; PASCOALINO, J. A. L.; SAKO, H.; DANTAS, J. P. S.; MORAES, M. F. Soybean yield gap in the areas of yield contest in Brazil. **International Journal of Plant Production**, Goiânia, v. 12, n. 3, p. 159-168, 7 jun. 2018. Springer Science and Business Media LLC. Disponível em: <<http://dx.doi.org/10.1007/s42106-018-0016-0>>.
- BAZZI, C. L.; SOUZA, E. G.; KONOPATZKI, M. R.; NÓBREGA, L. H. P.; URIBE-OPAZO, M. A. Management zones applied to pear orchard. *International Journal of Food Agriculture and Environment*, Finland, v. 13, n. 1, p. 86-92, 2015. Disponível em: <<https://www.cabdirect.org/cabdirect/abstract/20153141821>>.
- BENDRE, M. R.; THOOL, R. C.; THOOL, V. R. Big data in precision agriculture: weather forecasting for future farming. INTERNATIONAL CONFERENCE ON NEXT GENERATION COMPUTING TECHNOLOGIES (NGCT). Dehradun, India, set. 2015. **Proceedings... IEEE**, 2016. Disponível em: <<http://dx.doi.org/10.1109/ngct.2015.7375220>>.
- BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; SOBJAK, R.; BIER, V. A.; MERCANTE, E. Interpolation methods for thematic maps of soybean yield and soil chemical attributes. **Semina: Ciências Agrárias**, Cascavel, v. 38, n. 2, p. 1059-1060, 2 maio 2017. Disponível em: <<http://dx.doi.org/10.5433/1679-0359.2017v38n2p1059>>.
- BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; GAVIOLI, A. Rectification methods for optimization of management zones. **Computers and Electronics in Agriculture**, Medianeira, v. 146, p. 1-11, mar. 2018. Disponível em: <<https://doi.org/10.1016/j.compag.2018.01.014>>.
- BEZDEK, J. C. Pattern recognition with fuzzy objective function algorithms, 1981. ISBN: 0-306-40671-3. Disponível em: <<https://www.springer.com/gp/book/9781475704525>>.
- BLACKMORE, B. S.; LARSCHEID, G. **Strategies for managing variability**. In: EUROPEAN CONFERENCE ON PRECISION AGRICULTURE, 1, 1997, Warwick, UK: Warwick University Conference Centre. Disponível em: <www.silsoe.cranfield.ac.uk/cpf/>.
- BORGHI, E.; AVANZI, J. C.; BORTOLON, L.; LUCHIARI JUNIOR, A.; BORTOLON, E. S. O. Adoption and use of precision agriculture in Brazil: perception of growers and service dealership. **Journal of Agricultural Science**, Sete Lagoas, v. 8, n. 11, p. 89, 11 out. 2016. Disponível em: <<http://dx.doi.org/10.5539/jas.v8n11p89>>.
- BOYDELL, B.; McBRATNEY, A. B. **Identifying potential within-field management zones from cotton-yield estimates**. *Precis. Agric.*, v. 3, p. 9-23, mar. 2002. Disponível em: <<https://doi.org/10.1023/A:1013318002609>>.

BREUNIG, F. M.; GALVÃO, L. S.; DALAGNOL, R.; DAUVE, C. E.; PARRAGA, A.; SANTI, A. L.; DELLA FLORA, D. P.; CHEN, S. Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, Frederico Westphalen, v. 85, mar. 2020. Disponível em: <<https://doi.org/10.1016/j.jag.2019.102004>>.

CANDIAGO, S.; REMONDINO, F.; GIGLIO, M.; DUBBINI, M.; GATTELLI, M. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. **Remote Sensing**, Venezia, v. 7, n. 4, p. 4026-4047, 2 abr. 2015. Disponível em: <<http://dx.doi.org/10.3390/rs70404026>>.

CATTELAN, A. J.; DALL'AGNOL, A. The rapid soybean growth in Brazil. **Oci**, Londrina, v. 25, n. 1, jan. 2018. Disponível em: <<http://dx.doi.org/10.1051/oci/2017058>>.

CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229-242, set. 1996. Informa UK Limited. Disponível em: <<http://dx.doi.org/10.1080/07038992.1996.10855178>>.

CHI, M.; PLAZA, A.; BENEDIKTSSON, J. A.; SUN, Z.; SHEN, J.; ZHU, Y. Big data for remote sensing: challenges and opportunities; **Proceedings of the IEEE**, Shanghai, v. 104, n. 11, p. 2207-2219, nov. 2016. Disponível em: <<http://dx.doi.org/10.1109/jproc.2016.2598228>>.

COHEN, J. A coefficient of agreement for nominal scales. **Educ. Psycho. Meas.** v. 20, p. 37-46, 1960. Disponível em: <<https://doi.org/10.1177/001316446002000104>>.

COHEN, J. **Statistical power analysis for the behavioral sciences**. 2. ed. Hillsdale, NJ, Erlbaum. Jul. 1988. Disponível em: <<http://www.utstat.toronto.edu/~brunner/oldclass/378f16/readings/CohenPower.pdf>>.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira (Grãos)**. Safra 2019/2020. n. 7, abr., 2020. Disponível em: <<https://www.conab.gov.br/info-agro/safra/graos/boletim-da-safra-de-graos>>.

COX, E. **Fuzzy modeling and genetic algorithms for data mining and exploration**. Morgan Kaufmann, 2005. 540 p. (The Morgan Kaufmann Series in Data Management Systems).

DAMIAN, J. M.; SANTI, A. L.; FORNARI, M.; ROS, C. O.; ESCHNER, V. L. Monitoring variability in cash-crop yield caused by previous cultivation of a cover crop under a no-tillage system. **Computers and Electronics in Agriculture**, São Paulo, v. 142, p. 607-621, nov. 2017. Disponível em: <<https://doi.org/10.1016/j.compag.2017.11.006>>.

DUBREUIL, V.; FANTE, K. P.; PLANCHON, O.; SANT'ANNA NETO, J. L. Os tipos de climas anuais no Brasil: uma aplicação da classificação de Köppen de 1961 a 2015. **Confins**, n. 37, 24 set. 2018. OpenEdition. Disponível em: <<https://doi.org/10.4000/confins.15738>>.

DUNCAN, J. M. A.; DASH, J.; ATKINSON, P. M. The potential of satellite-observed crop phenology to enhance yield gap assessments in smallholder landscapes. **Front. Environ. Sci.** 2015, v. 3, n. 56. Disponível em: <<https://doi.org/10.3389/fenvs.2015.00056>>.

EDREIRA, J. I. R.; MOURTZINIS, S.; CONLEY, S. P.; ROTH, A. C.; CIAMPITTI, I. A.; LICHT, M. A.; KANDEL, H.; KYVERYGA, P. M.; LINDSEY, L. E.; MUELLER, D. S. Assessing causes of yield gaps in agricultural areas with diversity in climate and soils. **Agricultural and Forest Meteorology**, Lincoln, v. 247, p. 170-180, dez. 2017. Disponível em: <<https://doi.org/10.1016/j.agrformet.2017.07.010>>.

EORY, V.; MACLEOD, M.; TOPP, C. F. E.; REES, R. M.; WEBB, J.; MCVITTIE, A.; WALL, E.; BORTHWICK, F.; WATSON, C.; WATERHOUSE, A.; WILTSHIRE, J.; BELL, H.; MORAN, D.; DEWHURST, R. Review and update of the UK agriculture MACC to assess the abatement potential for the 5th carbon budget period and to 2050. **The Committee on Climate Change**, Edinburgh, 2015. Disponível em: <<https://bitly.com/6af6T>>.

EUROPEAN SPACE AGENCY - ESA. **Sentinel-2**. 2020. Disponível em: <http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel-2>.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO. **The state of food security and nutrition in the world**. Rome - IT, 2019. Disponível em: <<http://www.fao.org/3/ca5162en/ca5162en.pdf>>.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. **Ecofisiologia da soja**. Londrina: EMBRAPA - Soja, 2007. 9 p. (Circular Técnica, 48). ISSN 1516-7860. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/470308/1/circotec48.pdf>>.

FIEUZAL, R.; SICRE, C. M.; BAUP, F. Estimation of corn yield using multi-temporal optical and radar satellite data and artificial neural networks. **International Journal of Applied Earth Observation and Geoinformation**, Toulouse, v. 57, p. 14-23, mai. 2017. Disponível em: <<https://doi.org/10.1016/j.jag.2016.12.011>>.

FRAISSE, C. W.; SUDDUTH, K. A.; KITCHEN, N. R. Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity. **Transactions of the ASAE**, v. 44, n. 1, p. 155-166, 2001. Disponível em: <<https://doi.org/10.13031/2013.2296>>.

FRIDGEN, J. J.; KITCHEN, N. R.; SUDDUTH, K. A.; DRUMMOND, S. T.; WIEBOLD, W. J.; FRAISSE, C. W. Software management zone analyst (MZA): software for subfield management zone delineation. **Agronomy Journal**, v. 96 n. 1, p. 100-108, 2004. Disponível em: <<https://access.onlinelibrary.wiley.com/doi/epdf/10.2134/agronj2004.1000>>.

FURIAN, P. H. Electromagnetic spectrum of all possible frequencies of electromagnetic radiation with the colors of the visible spectrum. **Shutterstock**, 2015. Disponível em: <<https://bitly.com/jx3Qa>>.

GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; GUEDES, L. P. C.; SCHENATTO, K. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, Medianeira, v. 127, p. 302-310, set. 2016. Disponível em: <<https://doi.org/10.1016/j.compag.2016.06.029>>.

GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; BETZEK, N. M. Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods: an evaluation of alternative cluster analysis methods. **Biosystems Engineering**, Medianeira, v. 181, p. 86-102, maio 2019. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2019.02.019>>.

GEORGI, C.; SPENGLER, D.; ITZEROTT, S.; KLEINSCHMIT, B. Automatic delineation algorithm for site-specific management zones based on satellite remote sensing data. **Precision Agriculture**, Potsdam, v. 19, n. 4, p. 684-707, 15 nov. 2018. Disponível em: <<http://dx.doi.org/10.1007/s11119-017-9549-y>>.

GILI, A.; ÁLVAREZ, C.; BAGNATO, R.; NOELLEMAYER, E. Comparison of three methods for delineating management zones for site-specific crop management. **Computers and Electronics in Agriculture**, Santa Rosa, v. 139, p. 213-223, jun. 2017. Disponível em: <<https://doi.org/10.1016/j.compag.2017.05.022>>.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p.289-298, dez. 1996. Disponível em: <[http://dx.doi.org/10.1016/s0034-4257\(96\)00072-7](http://dx.doi.org/10.1016/s0034-4257(96)00072-7)>.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, p. 271-282, 2003.

GOMES, F. P. **Curso de estatística experimental**. 12. ed. São Paulo: Nobel, 1990. 467 p.

GÓMEZ-GIRÁLDEZ, P. J.; PÉREZ-PALAZÓN, M. J.; POLO, M. J.; GONZÁLEZ-DUGO, M. P. Monitoring grass phenology and hydrological dynamics of an oak–grass savanna ecosystem using Sentinel-2 and terrestrial photography. **Remote Sens.** 11 fev. 2020, v. 12, p. 600. Disponível em: <<https://doi.org/10.3390/rs12040600>>.

GUO, J.; LI, X.; LI, Z.; HU, L.; YANG, G.; ZHAO, C.; FAIRBAIRN, D.; WATSON, D.; GE, M. Multi-GNSS precise point positioning for precision agriculture. **Precision Agriculture**, Newcastle upon Tyne, v. 19, n. 5, p. 895-911, 14 mar. 2018. Disponível em: <<http://dx.doi.org/10.1007/s11119-018-9563-8>>.

HATFIELD, J. L.; PRUEGER, J. H. Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. **Remote Sensing**, v. 2, n. 2, p. 562-578, 23 fev. 2010. Disponível em: <<http://dx.doi.org/10.3390/rs2020562>>.

HOFIG, P.; ARAUJO-JUNIOR, C. F. Classes de declividade do terreno e potencial para mecanização no estado do Paraná. **Coffee Science**, Lavras, v. 10, n. 2, p. 195-203, jun. 2015. Disponível em: <<http://www.sbicafe.ufv.br:80/handle/123456789/8117>>.

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

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

HUFKENS, K.; MELAAS, E. K.; MANN, M. L.; FOSTER, T.; CEBALLOS, F.; ROBLES, M.; KRAMER, B. Monitoring crop phenology using a smartphone based near-surface remote sensing approach. **Agricultural and Forest Meteorology**, Ghent, v. 265, p. 327-337, fev. 2019. Disponível em: <<https://doi.org/10.1016/j.agrformet.2018.11.002>>.

INSTITUTE FOR ADVANCED SUSTAINABILITY STUDIES – IASS. **Global soil forum**. Knowledge for change. Postdam - DE, 2015. Disponível em: <<https://bit.ly/2Z1gi0q>>.

INSTITUTO NACIONAL DE METEOROLOGIA – INMET. Estações automáticas. Disponível em: <<https://portal.inmet.gov.br/servicos/estações-automáticas>>.

JIN, Z.; PRASAD, R.; SHRIVER, J.; ZHUANG, Q. Crop model- and satellite imagery-based recommendation tool for variable rate N fertilizer application for the US Corn system. **Precision Agriculture**, West Lafayette, v. 18, n. 5, p. 779-800, 8 dez. 2017. Disponível em: <<http://dx.doi.org/10.1007/s11119-016-9488-z>>.

JOHNSON, D. M. An assessment of pre- and within-season remotely sensed variables for forecasting corn and soybean yields in the United States. **Remote Sensing of Environment**, Fairfax, v. 141, p. 116-128, fev. 2014. Disponível em: <<https://doi.org/10.1016/j.rse.2013.10.027>>.

KASAMPALIS, D.; ALEXANDRIDIS, T.; DEVA, C.; CHALLINOR, A.; MOSHOU, D.; ZALIDIS, G. Contribution of remote sensing on crop models: a review. **Journal of Imaging**, Thessaloniki, v. 4, p. 52, mar. 2018. Disponível em: <<https://doi.org/10.3390/jimaging4040052>>.

KAUFMAN, Y. J.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, p.261-270, 1992. Disponível em: <<https://doi.org/10.1109/IGARSS.1992.578402>>.

KINDRED, D. R.; MILNE, A. E.; WEBSTER, R.; MARCHANT, B. P.; SYLVESTER-BRADLEY, R. Exploring the spatial variation in the fertilizer-nitrogen requirement of wheat within fields. **The Journal of Agricultural Science**, v. 153, n. 1, p. 25-41, 5 jan. 2015. Disponível em: <<http://dx.doi.org/10.1017/s0021859613000919>>.

KRUSKAL, W. H.; WALLIS, W. A. Use of ranks in one-criterion variance analysis. **Journal of the American Statistical Association**, v. 47, p. 583-621, 1 dez. 1952. Disponível em: <<https://dx.doi.org/10.1080%2F01621459.1952.10483441>>.

KUNZ, J.; CARLESSO, R.; PETRY, M. T.; GATTO, J. C.; AITA, R.; ANTONELLO, M. C. Simulação do efeito da temperatura e do fotoperíodo na fenologia da cultura da soja. INOVAGRI INTERNATIONAL MEETING, 2, Fortaleza – CE. 2014. **Anais...** Fortaleza: INOVAGRI, 2014. p.3249-3256. Disponível em: <<http://dx.doi.org/10.12702/ii.inovagri.2014-a438>>.

LAMPARELLI, R. A. C. **Agricultura de Precisão**. Brasília – DF: Empresa Brasileira de Pesquisa Agropecuária, 2013. Disponível em: <http://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_72_711200516719.html>.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159, mar. 1977. Disponível em: <<https://doi.org/10.2307/2529310>>.

LEE, K. H.; CHUNG, S. O.; KIM, Y. J.; LEE, J. S.; KIM, S. K. Software for grain yield monitoring system suitable to korean full-feed combines user console. **ASABE Annual International Meeting**, St. Joseph, 2016. Disponível em: <<http://dx.doi.org/10.13031/aim.20162461050>>.

LEE, W. S.; EHSANI, R. Sensing systems for precision agriculture in Florida. **Computers and Electronics in Agriculture**, Gainesville, v. 112, p. 2-9, mar. 2015. Disponível em: <<https://doi.org/10.1016/j.compag.2014.11.005>>.

LI, J.; HUANG, W.; TIAN, X.; WANG, C.; FAN, S.; ZHAO, C. Fast detection and visualization of early decay in citrus using Vis-NIR hyperspectral imaging. **Computers and Electronics in Agriculture**, Beijing, v. 127, p. 582-592, set. 2016. Disponível em: <<https://doi.org/10.1016/j.compag.2016.07.016>>.

LI, Z.; TAYLOR, J.; FREWER, L.; ZHAO, C.; YANG, G.; LI, Z.; LIU, Z.; GAULTON, R.; WICKS, D.; MORTIMER, H. A comparative review of the state and advancement of Site-Specific Crop Management in the UK and China. **Frontiers of Agricultural Science and Engineering**, Newcastle Upon Tyne, v. 6, n. 2, p. 116, 2019. Disponível em: <<http://dx.doi.org/10.15302/j-fase-2018240>>.

LIN, S.; LI, J.; LIU, Q.; LI, L.; ZHAO, J.; YU, W. Evaluating the effectiveness of using vegetation indices based on red-edge reflectance from Sentinel-2 to estimate gross primary productivity. **Remote Sens.** 31 mai. 2019, v. 11, 1303. Disponível em: <<https://doi.org/10.3390/rs11111303>>.

LINDBLOM, J.; LUNDSTRÖM, C.; LJUNG, M.; JONSSON, A. Promoting sustainable intensification in precision agriculture: review of decision support systems development and strategies. **Precision Agriculture**, Skovde, v. 18, n. 3, p. 309-331, 21 dez. 2017. Disponível em: <<http://dx.doi.org/10.1007/s11119-016-9491-4>>.

LIU, P. A survey of remote-sensing big data. **Frontiers in Environmental Science**, v. 3, p. 1-6, 17 jun. 2015a. Disponível em: <<http://dx.doi.org/10.3389/fenvs.2015.00045>>.

LIU, R.; REN, H.; LIU, S.; LIU, Q.; LI, X. Modelling of fraction of absorbed photosynthetically active radiation in vegetation canopy and its validation. **Biosystems Engineering**, v. 133, p. 81-94, maio 2015b. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2015.03.004>>.

LOBELL, D. B.; AZZARI, G. Satellite detection of rising maize yield heterogeneity in the U.S. Midwest. **Environmental Research Letters**, Stanford, v. 12, n. 1, 17 jan. 2017. Disponível em: <<https://doi.org/10.1088/1748-9326/aa5371>>.

LOPRESTI, M. F.; BELLA, C. M.; DEGIOANNI, A. J. Relationship between MODIS-NDVI data and wheat yield: a case study in northern buenos aires province, argentina. **Information Processing In Agriculture**, v. 2, n. 2, p. 73-84, set. 2015. Disponível em: <<http://dx.doi.org/10.1016/j.inpa.2015.06.001>>.

LYLE, G.; BRYAN, B. A.; OSTENDORF, B. Postprocessing methods to eliminate erroneous grain yield measurements: Review and directions for future development. **Precision Agriculture**, v. 15, n. 4, p. 377-402, 20 nov. 2013. Disponível em: <<http://dx.doi.org/10.1007/s11119-013-9336-3>>.

MENEGATTI, L. A. A.; MOLIN, J. P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Piracicaba, v. 8, n. 1, p. 126-134, abr. 2004. Disponível em: <<https://doi.org/10.1590/S1415-43662004000100019>>.

MIELKE Jr., P. W.; BERRY, K. J. **Permutation Methods**: a distance function approach. New York: Springer-Verlag, 2007. v. 2, 446 p.

MINASNY, B.; MCBRATNEY, A. B. **FuzME**. v. 3.5. Australia. Australian Centre for Precision Agriculture, The University of Sydney, 2002. Disponível em: <<http://sydney.edu.au/agriculture/acpa/software/fuzme.shtml>>

MOLIN, J. P. Geração e interpretação de mapas de produtividade para a agricultura de precisão. **Agricultura de Precisão**, Viçosa – MG, Universidade Federal de Viçosa, p. 237-258, 2000.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de Textos, 2015.

OMETTO, J. C. **Bioclimatologia vegetal**. São Paulo: Agronômica Ceres, 1981. 440 p.

PERALTA, N. R.; COSTA, J. L. Delineation of management zones with soil apparent electrical conductivity to improve nutrient management. **Computers and Electronics in Agriculture**, v. 99, p. 218-226, nov. 2013. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2013.09.014>>.

PERALTA, N. R.; COSTA, J. L.; BALZARINI, M.; FRANCO, M. C.; CÓRDOBA, M.; BULLOCK, D. Delineation of management zones to improve nitrogen management of wheat. **Computers and Electronics in Agriculture**, Buenos Aires, v. 110, p. 103-113, jan. 2015. Disponível em: <<https://doi.org/10.1016/j.compag.2014.10.017>>.

- PING, J. L.; DOBERMANN, A. Creating spatially contiguous yield classes for site-specific management. **Agron. Journal**, v. 95, p. 1121–1131, 2003.
- RAJ, A.; CHAKRABORTY, S.; DUDA, B. M.; WEINDORF, D. C.; LI, B.; ROY, S.; SARATHJITH, M. C.; DAS, B. S.; PAULETTE, L. Soil mapping via diffuse reflectance spectroscopy based on variable indicators: an ordered predictor selection approach. **Geoderma**, Kharagpur, v. 314, p. 146-159, mar. 2018. Disponível em: <<https://doi.org/10.1016/j.geoderma.2017.10.043>>.
- REUJEAN, J.; BREON, F. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote Sensing of Environment**, 1995, n. 51, p. 375 - 384.
- RIBEIRO, R. B.; FILGUEIRAS, R.; RAMOS, M. C. A.; ALMEIDA, L. T.; GENEROSO, T. N.; MONTEIRO, L. I. B. Variabilidade espaço-temporal da condição da vegetação na agricultura irrigada por meio de imagens Sentinel-2. **Revista Brasileira de Agricultura Irrigada**, Viçosa, v. 11, n. 6, p. 1884-1893, 7 nov. 2017. Disponível em: <<http://dx.doi.org/10.7127/rbai.v11n600648>>.
- RODIGHERI, G.; FONTANA, D. C.; SCHAPARINI, L. P.; MENDES, A. P. S. F.; DALMAGO, G. A. Análise espectro-temporal DE NDVI e área da soja cultivada frente ao La Niña de 2012. **Agrometeoros**, v. 27, n. 1, 6 mar. 2020. Disponível em: <<http://dx.doi.org/10.31062/agrom.v27i1.26569>>.
- ROSSI, R.; POLLICE, A.; BITELLA, G.; LABELLA, R.; BOCHICCHIO, R.; AMATO, M. Modelling the non-linear relationship between soil resistivity and alfalfa NDVI: a basis for management zone delineation: A basis for management zone delineation. **Journal of Applied Geophysics**, Bella Muro, v. 159, p. 146-156, dez. 2018. Disponível em: <<https://doi.org/10.1016/j.jappgeo.2018.08.008>>.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In 3rd ERTS Symposium, NASA. 1973.
- SABARINA, K.; PRIYA, N. Lowering data dimensionality in big data for the benefit of precision agriculture. **Procedia Computer Science**, Chennai, v. 48, p. 548-554, 2015. Disponível em: <<https://doi.org/10.1016/j.procs.2015.04.134>>.
- SANTI, A. L.; AMADO, T. J. C.; EITELWEIN, M. T.; CHERUBIN, M. R.; SILVA, R. F.; ROS, C. O. Definição de zonas de produtividade em áreas manejadas com agricultura de precisão. **Revista Brasileira de Ciências Agrárias**, Frederico Westphalen, v. 8, n. 3, p. 510-515, 21 set. 2013. Disponível em: <<http://dx.doi.org/10.5039/agraria.v8i3a2489>>.
- SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAUJO FILHO, J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. 5. ed. rev. e ampl. Brasília, DF: Embrapa, 2018. 353 p.
- SCHAPARINI, L. P.; FONTANA, D. C.; DALMAGO, G. A.; RODIGHERI, G.; FERNANDES, J. M. C.; SANTI, A.; VARGAS, P. R. Análise comparativa entre índices de vegetação e sua relação com o balanço hídrico em soja. **Agrometeoros**, Porto Alegre, v. 27, n. 1, p. 183-190, 6 mar. 2019. Disponível em: <<http://dx.doi.org/10.31062/agrom.v27i1.26574>>.
- SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BETZEK, N. M.; GAVIOLLI, A. Two approach comparison to define crop management zones (MZs). **African Journal of Agricultural Research**, v. 11, n. 38, p. 3680-3689, 22 set. 2016. Academic Journals. Disponível em: <<http://dx.doi.org/10.5897/ajar2016.11453>>.

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BETZEK, N. M.; GAVIOLI, A.; BENEDEZZI, H. M. Use of the farmer's experience variable in the generation of management zones. **Semina: Ciências Agrárias**, v. 38, n. 41, p. 2305-2321, 25 ago. 2017. Disponível em: <<http://dx.doi.org/10.5433/1679-0359.2017v38n4supl1p2305>>.

SCHIRMBECK, L. W.; FONTANA, D. C.; DALMAGO, G. A.; SCHIRMBECK, J.; VARGAS, P. R.; FERNANDES, J. M. C. Condições hídricas de lavoura de soja usando sensoriamento remoto terrestre. **Agrometeoros**, v. 27, n. 1, 6 mar. 2020. Disponível em: <<http://dx.doi.org/10.31062/agrom.v27i1.26565>>.

SENTELHAS, P. C.; BATTISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **The Journal of Agricultural Science**, Piracicaba, v. 153, n. 8, p. 1394-1411, 24 abr. 2015. Disponível em: <<http://dx.doi.org/10.1017/s0021859615000313>>.

SILVA, C. B.; MORAES, M. A. F. D.; MOLIN, J. P. Adoption and use of precision agriculture technologies in the sugarcane industry of São Paulo state, Brazil. **Precision Agriculture**, Piracicaba, v. 12, n. 1, p. 67-81, 6 jan. 2010. Disponível em: <<http://dx.doi.org/10.1007/s11119-009-9155-8>>.

SILVA, M. R.; JARDIM, C. H. Influência da Topografia e Uso da Terra na Variação dos Elementos Climáticos em Belo Horizonte, Ibirité, Sete Lagoas e Conceição do Mato Dentro - MG: o segmento temporal entre 11 a 23/09/2016. **Geography Department University of São Paulo**, n., p. 48, 27 jun. 2017. Disponível em: <<http://dx.doi.org/10.11606/rdg.v0ispe.132753>>.

SMITH, C. M.; DHUYVETTER, K. C.; KASTENS, T. L.; KASTENS, D. L.; SMITH, L. M. Economics of precision agricultural technologies across the great plains. **Journal of the American Society of Farm Managers and Rural Appraisers**. v. 2013, p. 1-22, jun. 2013. Disponível em: <<https://www.jstor.org/stable/jasfmra.2013.185>>.

SOUZA, E. G.; SCHENATTO, K.; BAZZI, C. L. Creating thematic maps and management zones for agriculture fields. **International conference on precision agriculture, 14**. Quebec, 2018. **Proceeding...** Quebec: ISPAG, 2018. v. 1, p. 1-17. Disponível em: <<https://www.ispag.org/proceedings/?action=download&item=5108>>.

SPEARMAN, C. The proof and measurement of association between two things. **The American J. of Psyc.** v. 15, p. 72-101 jan. 1904. Disponível em: <<https://doi.org/10.2307/1412159>>.

SPEKKEN, M.; ANSELMINI, A. A.; MOLIN, J. P. A simple method for filtering spatial data. In: European Conference of Precision Agriculture, 2013, Leida, Spain. **Precision Agriculture 13**, Wageningen, 2013. p. 259-266. Disponível em: <<https://bit.ly/3p9vtQ4>>.

SPRINGMANN, M.; CLARK, M.; MASON-D'CROZ, D.; WIEBE, K.; BODIRSKY, B. L.; LASSALETTA, L.; VRIES, W.; VERMEULEN, S. J.; HERRERO, M.; CARLSON, K. M. Options for keeping the food system within environmental limits. **Nature**, v. 562, n. 7728, p. 519-525, out. 2018. Disponível em: <<http://dx.doi.org/10.1038/s41586-018-0594-0>>.

SRBINOVSKA, M.; GAVROVSKI, C.; DIMCEV, V.; KRKOLEVA, A.; BOROZAN, V. Environmental parameters monitoring in precision agriculture using wireless sensor networks. **Journal of Cleaner Production**, Skopje, v. 88, p. 297-307, fev. 2015. Disponível em: <<https://doi.org/10.1016/j.jclepro.2014.04.036>>.

SUN, W.; WHELAN, B.; MCBRATNEY, A. B.; MINASNY, B. An integrated framework for software to provide yield data cleaning and estimation of an opportunity index for site-specific crop management. **Precision Agriculture**, v. 14, n. 4, p. 376-391, 18 dez. 2012. Disponível em: <<http://dx.doi.org/10.1007/s11119-012-9300-7>>.

TAYLOR, J. A.; MCBRATNEY, A. B.; WHELAN, B. M. Establishing management classes for broadacre agricultural production, **Agronomy Journal**, Madison, v. 99, n. 5, p. 1366-1376, set. 2007. Disponível em: <<http://dx.doi.org/10.2134/agronj2007.0070>>.

TOUREIRO, C.; SERRALHEIRO, R.; SHAHIDIAN, S.; SOUSA, A. Irrigation management with remote sensing: evaluating irrigation requirement for maize under mediterranean climate condition. **Agricultural Water Management**, Évora, v. 184, p. 211-220, abr. 2017. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2016.02.010>>.

TRINDADE, F. S.; ALVES, M. C.; NOETZOLD, R.; ANDRADE, I. C.; POZZA, A. A. A. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. **Revista de Ciências Agrárias**, v. 62, 2019. Disponível em: <<http://dx.doi.org/10.22491/rca.2019.2928>>.

TRIPATHI, R.; NAYAK, A. K.; SHAHID, M.; LAL, B.; GAUTAM, P.; RAJA, R.; MOHANTY, S.; KUMAR, A.; PANDA, B. B.; SAHOO, R. N. Delineation of soil management zones for a rice cultivated area in eastern India using fuzzy clustering. **Catena**, Orissa, v. 133, p. 128-136, out. 2015. Disponível em: <<https://doi.org/10.1016/j.catena.2015.05.009>>.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p.127-150, mai. 1979. Disponível em: <[http://dx.doi.org/10.1016/0034-4257\(79\)90013-0](http://dx.doi.org/10.1016/0034-4257(79)90013-0)>.

VALENTE, D. S. M.; QUEIROZ, D. M.; PINTO, F. A. C.; SANTOS, F. L.; SANTOS, N. T. Spatial variability of apparent electrical conductivity and soil properties in a coffee production field. **Engenharia Agrícola**, Jaboticabal, v. 34, n. 6, p. 1224-1233, dez. 2014. Disponível em: <<http://dx.doi.org/10.1590/s0100-69162014000600017>>.

VELOSO, A.; MERMOZ, S.; BOUVET, A.; TOAN, T. L.; PLANELLS, M.; DEJOUX, J. F.; CESCHIA, E. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote Sensing of Environment**, Toulouse, v. 199, p. 415-426, set. 2017. Disponível em: <<https://doi.org/10.1016/j.rse.2017.07.015>>.

WACHOWIAK, M. P.; WALTERS, D. F.; KOVACS, J. M.; WACHOWIAK-SMOLÍKOVÁ, R.; JAMES, A. L. Visual analytics and remote sensing imagery to support community-based research for precision agriculture in emerging areas. **Computers and Electronics in Agriculture**, North Bay, v. 143, p. 149-164, dez. 2017. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2017.09.035>>.

WILSON, J. H.; ZHANG, C.; KOVACS, J. M. Separating crop species in northeastern Ontario using hyperspectral data. **Remote Sensing**, North Bay, v. 6, p. 925-945, 24 jan. 2014. Disponível em: <<https://doi.org/10.3390/rs6020925>>.

WOLFERT, S.; GE, L.; VERDOUW, C.; BOGAARDT, M. J. Big data in smart farming. A review. **Agricultural Systems**, Wageningen, v. 153, p. 69-80, mai. 2017. Disponível em: <<https://doi.org/10.1016/j.agsy.2017.01.023>>.

WONGCHAI, W.; INSUAN, W.; PROMWUNGKWA, A. Above-ground biomass estimation of eucalyptus plantation using remotely sensed data and field measurements. **Iop Conference Series: earth and environmental science**, v. 463, 7 abr. 2020. Disponível em: <<http://dx.doi.org/10.1088/1755-1315/463/1/012042>>.

WU, B. Global crop monitoring: a satellite-based hierarchical approach. **Remote Sensing**, Beijing, v. 7, p. 3907-3933, abr. 2015. Disponível em: <<https://doi.org/10.3390/rs70403907>>.

XIANG, L.; YU-CHUN, P.; ZHONG-GIANG, G.; CHUN-JIANG, Z. Delineation and scale effect of precision agriculture management zones using yield monitor data over four years. **Agric. Sci. China**. v. 6, p. 180-188, 2007.

XUE, J.; SU, B. Significant remote sensing vegetation indices: a review of developments and applications. **J. Sensors**. v. 2017, p. 1–17, 23 mai. 2017, Disponível em: <<https://doi.org/10.1155/2017/1353691>>.

YANG, Z.; WILLIS, P.; MUELLER, R. Impact of band-ratio enhanced AWIFS image to crop classification accuracy. In: Pecora 17 - The Future of Land Imaging. Going Operational. 2008, Denver, Colorado, USA. **Proceedings...** Maryland: (ASPRS), 2008. Disponível em: <<http://www.asprs.org/a/publications/proceedings/pecora17/0041.pdf>>.

YANG, G.; LIU, J.; ZHAO, C.; LI, Z.; HUANG, Y.; YU, H.; XU, B.; YANG, X.; ZHU, D.; ZHANG, X. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. **Frontiers in Plant Science**, Beijing, v. 8, p. 1-2, 30 jun. 2017. Disponível em: <<https://doi.org/10.3389/fpls.2017.01111>>.

YAO, R. J.; YANG, J. S.; ZHANG, T. J.; GAO, P.; WANG, X. P.; HONG, L. Z.; WANG, M. W. Determination of site-specific management zones using soil physico-chemical properties and crop yields in coastal reclaimed farmland. **Geoderma**, Nanjing, v. 232-234, p. 381-393, nov. 2014. Disponível em: <<https://doi.org/10.1016/j.geoderma.2014.06.006>>.

ZANELLA, M. A.; QUEIROZ, D. M.; VALENTE, D. S. M.; PINTO, F. A. C.; SANTOS, N. T. Management class delimitation in a soybean crop using orbital images. **Engenharia Agrícola**, Jaboticabal, v. 39, n. 5, p. 676-683, Oct. 2019. Disponível em: <<http://dx.doi.org/10.1590/1809-4430-eng.agric.v39n5p676-683/2019>>.

ZHANG, L.; ZHANG, H.; NIU, Y.; HAN, W. Mapping maize water stress based on UAV multispectral remote sensing. **Remote Sensing**. Xianyang, v. 11, n. 6, p. 605, 2019. Disponível em: <<https://doi.org/10.3390/rs11060605>>.

ANEXO I - TESTE DUNN ENTRE CLASSES

	GRUPOS	Dunn p-adj	GRUPOS	Dunn p-adj
Colheita	2 grupos		4 grupos	
	1*2	4.93e-32***	1*2	6,29e-99***
			1*3	0,261 ns
	3 grupos		1*4	3,69e-11***
	1*2	3.79e-06***	2*3	3,41e-119***
	1*3	2.58e-05***	2*4	5,37e-76***
	2*3	1 ns	3*4	8,23e-10***
ARVI	2 grupos		4 grupos	
	1*2	1.26e-06***	1*2	1,61e-245***
			1*3	7,30e-105***
	3 grupos		1*4	1,16e-145***
	1*2	7.15e-28***	2*3	3,64e-73***
	1*3	2.79e-42***	2*4	2,02e-46***
	2*3	1.32e-02*	3*4	2,18e-06***
EVI	2 grupos		4 grupos	
	1*2	4.55e-11***	1*2	3,02e-261***
			1*3	1,20e-121***
	3 grupos		1*4	1,06e-165***
	1*2	2.95e-31***	2*3	8,78e-70***
	1*3	2.33e-45***	2*4	1,35e-43***
	2*3	0.0249*	3*4	1,87e-06***
GCVI	2 grupos		4 grupos	
	1*2	3.51e-10***	1*2	1,11e-254***
			1*3	1,12e-104***
	3 grupos		1*4	2,43e-171***
	1*2	2.06e-24***	2*3	6,85e-80***
	1*3	9.40e-56***	2*4	4,15e-38***
	2*3	3.74e-09***	3*4	4,90e-15***
GNDVI	2 grupos		4 grupos	
	1*2	1.11e-05***	1*2	3,55e-258***
			1*3	3,23e-99***
	3 grupos		1*4	1,90e-154***
	1*2	1.56e-21***	2*3	1,25e-86***
	1*3	1.01e-42***	2*4	4,77e-48***
	2*3	1.69e-05***	3*4	2,88e-11***
MPRI	2 grupos		4 grupos	
	1*2	1.08e-09***	1*2	3,33e-202***
			1*3	7,47e-104***
	3 grupos		1*4	1,35e-126***
	1*2	9.51e-37***	2*3	2,43e-47***
	1*3	1.61e-42***	2*4	8,28e-35***
	2*3	1 ns	3*4	0,0225*
MSR	2 grupos		4 grupos	
	1*2	1.48e-11***	1*2	2,57e-248***
			1*3	1,09e-114***
	3 grupos		1*4	6,80e-167***
	1*2	1.61e-32***	2*3	2,28e-67***
	1*3	2.69e-56***	2*4	4,46e-37***
	2*3	6.41e-05***	3*4	3,86e-09***
NDVI	2 grupos		4 grupos	
	1*2	1.34e-07***	1*2	1,69e-246***
			1*3	1,41e-106***
	3 grupos		1*4	4,96e-151***
	1*2	5.88e-29***	2*3	2,23e-72***
	1*3	9.77e-46***	2*4	5,68e-44***
	2*3	0.00365**	3*4	2,60e-07***
RDVI	2 grupos		4 grupos	
	1*2	1.13e-32***	1*2	0***
			1*3	4,99e-187***
	3 grupos		1*4	0***
	1*2	1.89e-55***	2*3	5,00e-180***
	1*3	5.03e-100***	2*4	6,75e-72***
	2*3	5.89e-09***	3*4	3,62e-43***
SAVI	2 grupos		4 grupos	
	1*2	1.33e-07***	1*2	1,69e-246***
			1*3	1,40e-106***
	3 grupos		1*4	4,92e-151***
	1*2	5.86e-29***	2*3	2,24e-72***
	1*3	9.71e-46***	2*4	5,70e-44***
	2*3	0.00365**	3*4	2,59e-07***
TNDVI	2 grupos		4 grupos	
	1*2	2.88e-07***	1*2	2,49e-246***
			1*3	9,46e-106***
	3 grupos		1*4	1,28e-149***
	1*2	1.51e-28***	2*3	5,94e-73***
	1*3	8.31e-45***	2*4	1,19e-44***
	2*3	4.73e-03**	3*4	3,42e-07***

Teste de significância Dunn: *p<0,05; **p<0,01; ***p<0,001; ns não significativo.