

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
DEPARTAMENTO ACADÊMICO DE CIÊNCIAS AGRÁRIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

PEDRO HENRIQUE DA SILVA MONTEIRO

**COMPORTAMENTO ESPECTRO-TEMPORAL DA SOJA UTILIZANDO  
SENSORES ORBITAIS E NÃO ORBITAL E CORRELAÇÃO DOS  
ÍNDICES DE VEGETAÇÃO COM A PRODUTIVIDADE**

DISSERTAÇÃO

PATO BRANCO

2021

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
DEPARTAMENTO ACADÊMICO DE CIÊNCIAS AGRÁRIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA**

**PEDRO HENRIQUE DA SILVA MONTEIRO**

**COMPORTAMENTO ESPECTRO-TEMPORAL DA SOJA UTILIZANDO  
SENSORES ORBITAIS E NÃO ORBITAL E CORRELAÇÃO DOS  
ÍNDICES DE VEGETAÇÃO COM A PRODUTIVIDADE**

**DISSERTAÇÃO**

**PATO BRANCO**

**2021**

**PEDRO HENRIQUE DA SILVA MONTEIRO**

**COMPORTAMENTO ESPECTRO-TEMPORAL DA SOJA UTILIZANDO  
SENSORES ORBITAIS E NÃO ORBITAL E CORRELAÇÃO DOS ÍNDICES  
DE VEGETAÇÃO COM A PRODUTIVIDADE**

**Spectro-temporal behavior of soybean using orbital and non-orbital  
sensors and correlation of vegetation indexes with productivity**

Dissertação apresentada como requisito parcial à  
obtenção do título de Mestre em Agronomia - Área  
de Concentração: Solos e Sistemas Integrados de  
Produção Agropecuária da Universidade  
Tecnológica Federal do Paraná (UTFPR).

Orientador: Alcir José Modolo

Coorientador: José Ricardo da Rocha Campos

**PATO BRANCO**

**2021**



Esta licença permite o download e o compartilhamento da obra desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-la ou utilizá-la para fins comerciais.



**Ministério da Educação  
Universidade Tecnológica Federal do Paraná  
Câmpus Pato Branco**



PEDRO HENRIQUE DA SILVA MONTEIRO

**COMPORTAMENTO ESPECTRO-TEMPORAL DA SOJA UTILIZANDO SENSORES ORBITAIS E NÃO ORBITAL E CORRELAÇÃO DOS ÍNDICES DE VEGETAÇÃO COM A PRODUTIVIDADE**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Agronomia da Universidade Tecnológica Federal do Paraná (UTFPR).  
Área de concentração: Solos E Sistemas Integrados De Produção Agropecuária.

Data de aprovação: 31 de Março de 2021

Prof Alcir Jose Modolo, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Marcio Furlan Maggi, Doutorado - Universidade Estadual do Oeste do Paraná (Unioeste)

Prof Murilo Mesquita Baesso, Doutorado - Universidade de São Paulo (Usp)

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 31/03/2021.

Dedico este trabalho aos meus pais, Maria Monteiro e Júlio Cesar Andrade, por todo cuidado, apoio e amor. Aos meus avós, Rita Monteiro e Raimundo Monteiro, que tiveram papel fundamental na minha criação e sempre estarão vivos em meu coração. Ao meu irmão, Gustavo Monteiro, por toda parceria. À minha companheira Larisse Gonçalves, por todo amor e incentivo. À toda minha família e amigos, por todo carinho e incentivo.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, que me proporcionou o dom da vida e me confortou nos momentos de incertezas, dando forças para não desistir e continuar lutando em busca dos meus objetivos.

A UTFPR – Campus Pato Branco e ao Programa de Pós-Graduação em Agronomia, pela magnífica oportunidade de crescimento profissional e pessoal. Ao meu orientador Alcir José Modolo e ao coorientador José Ricardo da Rocha Campos, por todo apoio, contribuição, paciência e por acreditarem na ideia. A professora Danielli Batistella, que foi fundamental para execução do estudo, contribuindo com equipamentos, esforço e com conselhos essenciais.

Aos amigos que fizeram parte do laboratório de Engenharia Rural, Luana Santos dos Santos, Lucas Dotto e Maicon Sgarbossa, por todo suporte, recomendações e pela boa convivência.

Aos novos amigos que conquistei em Pato Branco, que ajudaram a amenizar a distância da família e proporcionaram grandes momentos, Matheus Hermann, Samuel Brito, Douglas Félix, Thayna Schein, Tais Costa, Matheus Luiz, Matheus Santos, Fernanda Oenning e Renan Benassi.

Aos meus amigos e professores do IFPA – Campus Castanhal Javier Pita e Tiago Sales, pelas excelentes contribuições que ajudaram na execução e no enriquecimento do projeto.

Ao Marcos Faccin por disponibilizar a sua área de lavoura e sempre estar disposto a acatar as ideias do projeto e ceder todas as informações solicitadas.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro durante a realização do estudo.

Muito obrigado a todos.

“Confia ao SENHOR as tuas obras, e os teus desígnios serão estabelecidos”. (Provérbios 16:3)

## RESUMO

MONTEIRO, Pedro Henrique da Silva. Comportamento espectro-temporal da soja utilizando sensores orbitais e não orbital e correlação dos índices de vegetação com a produtividade. 83 f. Dissertação (Mestrado em Agronomia) – Programa de Pós-Graduação em Agronomia (Área de Concentração: Solos e Sistemas Integrados de Produção Agropecuária), Universidade Tecnológica Federal do Paraná (UTFPR). Pato Branco, 2021.

O cultivo da soja detém um importante papel no desenvolvimento econômico de muitas regiões do Brasil e do mundo. Neste sentido, a agricultura de precisão associada as ferramentas de sensoriamento remoto são métodos excelentes para auxiliar no gerenciamento e aprimoramento da eficiência produtiva em lavouras de soja. Diante desse contexto, esse trabalho teve como o objetivo principal avaliar o comportamento espectro-temporal da soja por meio de índices de vegetação em diferentes estádios fenológicos, empregando sensores orbitais e sensor não orbital acoplado em Veículos Aéreos Não Tripulados (VANT). O estudo foi realizado em área de lavoura comercial, localizada no município Pato Branco – PR, onde, durante seu ciclo produtivo, foram realizadas coletas de imagens dos satélites Landsat 8 e Sentinel-2 para extração do Normalized Difference Vegetation Index (NDVI) e, cinco coletas com sensor RGB, com resolução de 4,0 cm/px, acoplado ao VANT, para obtenção do Visible Atmospherically Resistant Index (VARI). O processamento e tratamento das imagens foram feitos no software Agisoft Metashape Professional 1.5<sup>®</sup> e no ArcGIS 10.5<sup>®</sup>, em que foram gerados o índice VARI do sensor RGB e o NDVI dos Satélites (Landsat 8 e Sentinel-2). Estabeleceu-se uma grade amostral de 50 x 50 m, com 59 pontos, na qual foram realizadas coletas dos atributos químicos do solo e dos componentes de rendimento da soja para compreender a distribuição espacial dessas variáveis. Por fim, foi realizado a correlação linear de Pearson para a produtividade da soja e dos índices de vegetação. O índice VARI extraído da câmera RGB e o NDVI gerado dos sensores orbitais foram eficientes no monitoramento dos estádios fenológicos da soja, sendo influenciados principalmente pelas diferentes concentrações de clorofila e biomassa. A maioria dos parâmetros químicos do solo apresentaram dependência espacial, com exceção do P que demonstrou efeito pepita puro. A área em estudo apresentou boas condições químicas, especialmente na porção leste, onde ocorreram os maiores níveis de MO, K, Ca, pH, V% e menor teor de Al<sup>3+</sup>. Todos os componentes de rendimento da soja (número de vagens, número de grãos, número de sementes, peso de mil grãos e produtividade) expressaram dependência espacial moderada. Os maiores valores de número de vagens, número de grãos, peso de mil grãos e produtividade ocorreram na parte leste da propriedade, em que foi observado melhores condições de fertilidade. O VARI apresentou melhor correlação com a produtividade da soja, quando comparado ao NDVI gerado a partir do Sentinel-2 e do Landsat 8. Este resultado demonstra que os sensores RGB associados aos VANTs podem ser empregados de forma eficiente no monitoramento agrícola, proporcionando maior eficiência produtiva.

**Palavras-chave:** Sensoriamento Remoto. Índices de Vegetação. Soja.



## ABSTRACT

MONTEIRO, Pedro Henrique da Silva. Spectro-temporal behavior of soybean using orbital and non-orbital sensors and correlation of vegetation indexes with productivity. 83 f. Dissertation (Masters in Agronomy) - Graduate Program in Agronomy (Concentration Area: Soils and Integrated Plant Production Systems), Federal University of Technology - Paraná (UTFPR). Pato Branco, 2021.

The cultivation of soy has an important role in the economic development of many regions of Brazil and in the world. In this sense, precision agriculture associated with remote sensing tools are excellent methods to assist in the management and improvement of productive efficiency in soybean crops. In this context, this work aimed to evaluate the spectral-temporal behavior of soybeans through vegetation indices at different phenological stages, using orbital sensors and a non-orbital sensor coupled in Unmanned Aerial Vehicles (UAV). The study was carried out in a commercial farming area, located in the municipality of Pato Branco - PR, where, during its production cycle, image collections from the Landsat 8 and Sentinel-2 satellites were performed to extract the Normalized Difference Vegetation Index (NDVI) and, five collections with RGB sensor, with a resolution of 4.0 cm/px, coupled to the UAV, to obtain the Visible Atmospherically Resistant Index (VARI). Image processing and treatment were performed using the Agisoft Metashape Professional 1.5<sup>®</sup> software and ArcGIS 10.5<sup>®</sup>, in which the VARI index of the RGB sensor and the NDVI of the Satellites (Landsat 8 and Sentinel-2) were generated. A 50 x 50 m sampling grid, with 59 points, was established, in which collections of soil chemical attributes and soybean yield components were made to understand the spatial distribution of these variables. Finally, Pearson's linear correlation for soybean productivity and vegetation indexes was performed. The VARI index extracted from the RGB camera and the NDVI generated from the orbital sensors were efficient in monitoring the phenological stages of soybeans, being influenced mainly by the different concentrations of chlorophyll and biomass. Most soil chemical parameters were spatially dependent, with the exception of P which demonstrated a pure nugget effect. The area under study showed good chemical conditions, especially in the eastern portion, where the highest levels of MO, K, Ca, pH, V% and lowest Al<sup>3+</sup> content occurred. All soybean yield components (number of pods, number of grains, number of seeds, weight of a thousand grains and productivity) expressed moderate spatial dependence. The highest values of number of pods, number of grains, weight of a thousand grains and productivity occurred in the eastern part of the property, in which the best fertility conditions were observed. VARI showed a better correlation with soybean productivity, when purchased from NDVI generated from Sentinel-2 and Landsat 8. This result demonstrates that the RGB sensors associated with UAVs can be used efficiently in agricultural monitoring, providing greater productive efficiency.

**Keywords:** Remote Sensing. Vegetation Indexes. Soybean.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1</b> – Localização da área de estudo. ....	31
<b>Figura 2</b> – Precipitação pluviométrica (mm) e temperatura (°C) durante o estudo, no município de Pato Branco, PR. ....	32
<b>Figura 3</b> – Drone DJI phantom 3 Standard®, utilizado na coleta de imagens com sensor não orbital. ....	34
<b>Figura 5</b> – A) Contagem dos grãos, B) separação das subamostras, C) pesagem dos grãos de soja e, D) determinação da umidade. ....	38
<b>Figura 6</b> – A) Demarcação dos pontos amostrais e B) coleta das plantas para estimativa da produtividade. ....	39
<b>Figura 7</b> – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido no dia da semeadura da soja. B) Índice NDVI (Sentinel-2) obtido aos dois dias após a semeadura (DAS). ....	44
<b>Figura 8</b> – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 26 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 22 DAS. ....	45
<b>Figura 9</b> – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 56 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 57 DAS. C) Índice NDVI (Landsat 8) obtido aos 62 DAS. ....	46
<b>Figura 10</b> – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 91 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 89 DAS. C) Índice NDVI (Landsat 8) obtido aos 78 DAS. ....	48
<b>Figura 11</b> – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 118 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 107 DAS. ....	50
<b>Figura 12</b> – Semivariogramas ajustados para os atributos químicos do solo em lavoura comercial de soja: A) MO, B) P, C) K, D) pH, E) Al <sup>3+</sup> , F) Ca, G) Mg e H) V%. ....	55
<b>Figura 13</b> – Mapa de distribuição espacial dos atributos químicos do solo em lavoura comercial de soja: A) MO, B) K, C) pH, D) Al <sup>3+</sup> , E) Ca, F) Mg G) V%. ....	57
<b>Figura 14</b> – Semivariogramas ajustados para os componentes de rendimento da cultura da soja: A) número de vagens por planta (NV Planta <sup>-1</sup> ), B) Número de grãos por planta (NG Planta <sup>-1</sup> ), C) Número de sementes por vagem (NS Vagem <sup>-1</sup> ), D) Peso de mil grãos (PMG) e E) Produtividade (Prod). ....	61
<b>Figura 15</b> – Mapa de distribuição espacial dos componentes de rendimento da soja cultivada em lavoura comercial: A) número de vagens por planta (NV Planta <sup>-1</sup> ), B) Número de grãos por planta (NG Planta <sup>-1</sup> ), C) Número de sementes por vagem (NS Vagem <sup>-1</sup> ), D) Peso de mil grãos (PMG) e E) Produtividade (Prod). ....	62
<b>Figura 16</b> – Correlação de Pearson (r) e diagrama de dispersão das amostras da produtividade da soja cultivada em lavoura comercial e dos índices de vegetação: A) VARI (06/12/2019), B) NDVI – Sentinel-2 (07/12/2019) e C) NDVI – Landsat 8 (12/12/2019). ...	64

## LISTA DE TABELAS

<b>Tabela 1</b> – Bandas dos sensores OLI e TIRS do satélite Landsat 8. ....	21
<b>Tabela 2</b> – Especificações dos sensores MSI acoplados nos satélites Sentinel-2A e Sentinel-2B.....	22
<b>Tabela 3</b> – Estatística descritiva dos atributos químicas do solo em lavoura comercial de soja: MO ( $\text{g dm}^{-3}$ ), P ( $\text{mg dm}^{-3}$ ), K ( $\text{cmol}_c \text{dm}^{-3}$ ), pH ( $\text{CaCl}_2$ ), $\text{Al}^{3+}$ ( $\text{cmol}_c \text{dm}^{-3}$ ), Ca ( $\text{cmol}_c \text{dm}^{-3}$ ), Mg ( $\text{cmol}_c \text{dm}^{-3}$ ) e V%. ....	53
<b>Tabela 4</b> – Parâmetros dos semivariogramas ajustados para os atributos químicos do solo em lavoura comercial de soja: Efeito pepita ( $C_0$ ); Patamar ( $C_0+C$ ); Alcance (a); Índice de Dependência Espacial (IDE); Coeficiente de determinação ( $r^2$ ); Soma de quadrados do resíduo (SQR). ....	54
<b>Tabela 5</b> – Estatística descritiva dos componentes de rendimento da soja em lavoura comercial: vagem por planta ( $\text{NV Planta}^{-1}$ ), número de grãos por planta ( $\text{NG Planta}^{-1}$ ), número de sementes por vagem ( $\text{NS Vagem}^{-1}$ ) e peso de mil grãos (PMG) e Produtividade (Prod). ....	59
<b>Tabela 6</b> – Parâmetros dos semivariogramas para os componentes de rendimento da cultura da soja cultivada em lavoura comercial: Efeito pepita ( $C_0$ ); Patamar ( $C_0+C$ ); Alcance (a); Índice de Dependência Espacial (IDE); Coeficiente de determinação ( $r^2$ ); Soma de quadrados do resíduo (SQR).....	60

## LISTA DE SIGLAS E ACRÔNIMOS

Al	Alumínio
BOA	Bottom of Atmosphere
C <sub>0</sub>	Efeito pepita
C <sub>0</sub> +C	Patamar
Ca	Cálcio
CTC	Capacidade de troca de cátions
CV	Coeficiente de variação
DAS	Dia após a semeadura
DEM	Modelo Digital de Elevação
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
EPP	Efeito Pepita Puro
ESA	Europe Space Agency
EUA	Estados Unidos da América
GMES	Global Monitoring for Environment and Security
GNSS	Sistema Global de Navegação por Satélite
H	Hidrogênio
IDE	Índice de dependência espacial
INPE	Instituto Nacional de Pesquisas Espaciais
IV	Índices de Vegetação
Kcl	Cloreto de potássio
Mg	Magnésio
MO	Matéria orgânica
MSI	Multi Spectral Instrument
NASA	National Aeronautical and Space Administration
ND	Números Digitais
NDVI	Normalized Difference Vegetation Index
NG	Número de grão por planta
NIR	Infravermelho Próximo
NPK	Nitrogênio, Fósforo e Potássio
NS	Número de sementes por vagem
NV	Número de vagem por planta
OLI	Operational Land Imager
PDI	Processamento Digital de Imagens
pH	Potencial Hidrogeniônico
PMG	Peso de mil grãos
r <sup>2</sup>	Coeficiente de determinação
RGB	Red, Blue e Green
SB	Soma de bases
SIMEPAR	Sistema Meteorológico do Paraná
SPD	Sistema de plantio direto
SQR	Soma de quadrados de resíduos
SR	Sensoriamento Remoto
SWIR	Infravermelho de borda e de ondas curtas
TIRS	Thermal Infrared Sensor

TOA	Top of Atmosphere
USGS	United States Geological Survey
V%	Saturação por bases
VANT	Veículos Aéreos Não Tripulados
VARI	Visible Atmospherically Resistant Index

## SUMÁRIO

1 INTRODUÇÃO .....	13
2 REVISÃO DE LITERATURA .....	16
2.1 Aspectos gerais e importância econômica da cultura da soja.....	16
2.2 Sensoriamento remoto (SR) .....	18
2.3 Sensores orbitais e não orbitais.....	20
2.4 Processamento digital de imagens (PDI).....	23
2.5 Monitoramento espectral da cultura da soja .....	24
2.6 Índices de vegetação (IV) .....	26
2.7 Geoestatística .....	28
3 MATERIAL E MÉTODOS .....	31
3.1 Caracterização do local de estudo.....	31
3.2 Caracterização da cultivar .....	32
3.3 Aquisição de dados.....	33
3.4 Processamento Digital de Imagens (PDI).....	34
3.5 Definição dos pontos amostrais e amostragem de solo.....	36
3.6 Avaliação de componentes de rendimento e produtividade.....	37
3.7 Análise dos dados.....	39
4 RESULTADOS E DISCUSSÃO .....	42
4.1 Índices de vegetação .....	42
4.2 Variabilidade espacial .....	52
4.2.1 Variabilidade espacial dos atributos químicos do solo .....	52
4.2.2 Variabilidade espacial da produtividade da soja.....	59
4.3 Correlação entre os índices de vegetação e produtividade da soja.....	63
5 CONCLUSÕES .....	66
6 CONSIDERAÇÕES FINAIS .....	67
REFERÊNCIAS.....	68

## 1 INTRODUÇÃO

As ferramentas aplicadas a Agricultura de Precisão vêm sendo pesquisadas e aprimoradas de modo intensivo nas últimas décadas e seu objetivo principal é identificar variações no ambiente produtivo, auxiliando na tomada de decisão quanto o uso mais eficiente de insumos e equipamentos. Essas ferramentas se tornaram essenciais para o gerenciamento de propriedades, tendo em vista que promovem ganho em produtividade, em conservação ambiental e o uso mais racional de insumos (NOETZOLD et al., 2019; MOLIN et al., 2015).

Uma das características mais importantes da Agricultura de Precisão é o seu caráter multidisciplinar, apresentando ferramentas sofisticadas para análise da variabilidade espacial e temporal de parâmetros específicos da cultura, do clima e do solo, visando a máxima eficiência produtiva. Neste âmbito, o Sensoriamento Remoto (SR) tem papel de destaque, sendo empregado como método de aquisição de informações de forma não invasiva e sem causar danos as culturas (REGHINI; CAVICHIOLI, 2020; OLIVEIRA, 2017).

O Sensoriamento Remoto é uma ciência que objetiva a geração de informações sobre um alvo na terra por meio das interações destes com a radiação eletromagnética captada por um sensor orbital (SANTOS; LIMA, 2019; MENESES; ALMEIDA, 2012). Os procedimentos de SR vêm sendo empregados de forma extensiva, especialmente na Agricultura de Precisão, com o uso de sensores que permitem estimar componentes relacionados a produção de culturas agrícolas, pela relação matemática entre diferentes faixas espectrais (ZERBATO et al., 2016).

A utilização de Veículos Aéreos Não Tripulados (VANT) tem ganhado espaço na obtenção de imagens digitais. Em relação as imagens orbitais, estes representam alternativa interessante em virtude da sua maior flexibilidade em relação ao momento de aquisição das imagens, menor efeito atmosférico e custo operacional. Estes equipamentos possibilitam a pilotagem remota e voos próximos ao solo, fornecendo informações com maior exatidão (YUN et al., 2016; ZHANG et al., 2019).

Em relação a aplicação do SR na agricultura, um dos métodos mais utilizados é a análise da dinâmica espectral da cultura, que consiste na aferição da

quantidade e do vigor das culturas, conhecidos como índices de vegetação. Esses índices são definidos por combinações de valores de refletância em dois ou mais intervalos de comprimento de onda, os quais apresentam relação direta com a quantidade e as condições da vegetação (SILVA et al., 2020; JUSTINA, 2014).

A radiação eletromagnética refletida pelas plantas contém informações sobre sua composição biofísica e o estado fisiológico, podendo ser mensurada por meio de inúmeros sensores. O comportamento espectral das plantas está relacionado basicamente às faixas do visível e infravermelho próximo. Na faixa do visível é onde ocorre maior absorção, especialmente dos espectros do azul e vermelho, enquanto, que no infravermelho próximo, as folhas exibem altos valores de reflectância. Ademais, a estrutura do dossel da planta e a área foliar, quando associados aos seus padrões de reflectância, são parâmetros fundamentais para monitorar o seu crescimento (SEGARRA et al., 2020; XUE; SU, 2017).

Neste sentido, o Normalized Difference Vegetation Index (NDVI) considera as informações de reflectância nas faixas do vermelho e infravermelho próximo (ROUSE et al., 1973). Os valores gerados por esta diferença variam entre -1 a 1. Quanto maior o valor do NDVI, maior será a diferença entre a reflectância na faixa infravermelho próximo e no vermelho, podendo indicar maior quantidade de clorofila e massa seca e, conseqüentemente, mostrando o maior potencial produtivo (ROBINSON et al., 2017; RISSINI et al., 2015).

Durante o ciclo fenológico das culturas, especialmente da soja (*Glycine max L.*) existem diversos fatores que condicionam o seu desenvolvimento e produção, como os atributos químicos e físicos do solo, manejo e condições ambientais (TRINDADE et al., 2019). Neste âmbito, os índices de vegetação podem auxiliar na análise da distribuição espacial de fatores que afetam o desenvolvimento da soja, permitindo realizar intervenções e correção de forma localizada, possibilitando um desenvolvimento homogêneo (SILVA, 2018).

Outra alternativa para monitoramento agrícola é a utilização de conceito de índice de vegetação baseado no espectro do visível ou nos canais Vermelho, Verde e Azul (RGB), em que são empregados sensores RGB com a finalidade de verificar o desenvolvimento da vegetação. Neste sentido, um importante exemplo de índice de vegetação (IV) fundamentado na faixa espectral do



visível é o Visible Atmospherically Resistant Index (VARI), desenvolvido por Gitelson et al. (2002) para estimar a fração de vegetação com a mínima interferência de fatores atmosféricos. Podendo ser empregado em estimativas de produtividade e no monitoramento das variações fenológicas de diversas espécies vegetais (PRESTES et al., 2020; MORENO et al., 2018).

A partir da contextualização apresentada, tem-se as seguintes hipóteses: a) a compreensão da dinâmica espacial dos IVs na cultura da soja, permite um diagnóstico rápido e preciso sobre as condições de desenvolvimento da cultura, permitindo intervenções mais eficiente e com melhores resultados; b) os sensores não orbitais propiciam dados mais aproximados da realidade das áreas de cultivo, devido a maior precisão e a menor interferência de fatores atmosféricos que estes equipamentos estão sujeitos; c) devido as configurações e potencialidades peculiares dos equipamentos utilizados neste estudo associados as maiores interferências dos fatores atmosféricos, os sensores orbitais proporcionam resultados com menor precisão, contudo estas ferramentas apresentam efeitos razoáveis e excelente custo benefício.

Com isso, o objetivo geral deste estudo foi avaliar o comportamento espectro-temporal da soja através de índice de vegetação em diferentes estádios fenológicos, usando sensores orbitais e sensor não orbital acoplado em VANT.

#### Objetivos Específicos:

- Avaliar o perfil espectro-temporal da soja, por meio do NDVI e VARI, utilizando sensores orbitais (Landsat-8/OLI e Sentinel-2) e não orbital (VANT) em períodos diferentes.
- Avaliar a variabilidade espacial dos atributos químicos do solo e dos componentes de rendimento da soja.
- Analisar a correlação da produtividade da soja com os valores de NDVI e VARI, obtidos através de diferentes sensores.

## 2 REVISÃO DE LITERATURA

### 2.1 Aspectos gerais e importância econômica da cultura da soja

No Brasil, a soja foi inicialmente implantada em 1882, no estado da Bahia, posteriormente, passou a ser cultivada no estado de São Paulo, no ano de 1891. Neste período, outras cultivares de soja também foram introduzidas no Rio Grande do Sul. As cultivares de origem norte americana apresentaram boa adaptação nesta região, devido as condições climáticas que favoreceram o seu desenvolvimento (BONATO; BONATO, 1987).

A expansão no cultivo da soja no Brasil resultou em mudanças expressivas para a agricultura e na economia do país. Essas mudanças foram responsáveis pela expansão das fronteiras agrícolas, aceleração da mecanização e modernização das lavouras, inserção no comércio internacional, desenvolvimento da agroindústria e, como consequência, o crescimento das atividades de avicultura e suinocultura, que estão diretamente relacionadas com o cultivo da soja (SEIXAS et al., 2020).

Existe uma grande quantidade de cultivares de soja resultantes dos programas de melhoramento genético. As cultivares apresentam ampla diversidade genética e morfológica, onde foram priorizadas características como alta produtividade, resistência a pragas, doenças e boa adaptação as diversas condições ambientais (EMBRAPA, 2013; COSTA et al., 2004).

Essa grande variabilidade e potencialidades genéticas devem ser associadas a condições específicas que permitam um ambiente ótimo para desenvolver seu potencial produtivo. Entre os fatores que influenciam o desenvolvimento da soja, destacam-se as condições climáticas favoráveis, época de semeadura, velocidade de semeadura, profundidade de semeadura, densidade de semeadura, água no solo e disponibilidade de nutrientes (CAVERZAN, 2018; MONDINI et al., 2001; MARCHIORI et al., 1999).

O desenvolvimento da soja é dividido em estádios, com a finalidade de desenvolver um sistema produtivo por meio de manejos adequados nas áreas cultivadas, promovendo a utilização eficiente dos recursos e a obtenção de altas

produtividades. Os estádios de desenvolvimento desta espécie são nomenclatura padrão fundamental para o entendimento da maturidade das cultivares, visto que as variedades de soja apresentam características específicas quanto ao ciclo de desenvolvimento (RAZA et al., 2019).

Deste modo, o ciclo de desenvolvimento total da soja pode ser dividido em fases vegetativa e reprodutiva. A metodologia para descrição dos estádios de desenvolvimento da soja mais utilizada e difundida no mundo é o sistema proposto por Fehr e Caviness (1977). O estágio vegetativo é simbolizado pela letra V, e compreende o período de emergência da plântula até o início da floração. O estágio reprodutivo é caracterizado pela letra R, que corresponde a época do florescimento até a maturação.

Neste sentido, as fases vegetativa e reprodutiva ainda podem ser subdivididas. As subdivisões da fase vegetativa são denominadas como V1, V2, V3, até Vn, com exceção dos dois estádios iniciais, que são identificados como VE (emergência) e VC (estádio de cotilédone). O estágio vegetativo final é denominado de Vn, onde “n” consiste no número do último nó vegetativo, este valor pode variar de acordo com as variedades e as condições ambientais. A fase reprodutiva consiste em oito estádios, estes são subdivididos na fase de florescimento (R1 e R2), desenvolvimento da vagem (R3 e R4), desenvolvimento da semente (R5 e R6) e maturação da planta (R7 e R8) (FEHR; CAVINESS, 1977).

A soja é uma das culturas agrícolas mais importantes para economia brasileira, sendo a espécie agrícola que mais expandiu nas últimas três décadas, ocupando aproximadamente 56% das áreas cultivadas com grão em todo território nacional. O grande crescimento produtivo está diretamente relacionado ao manejo e aos avanços tecnológicos disponíveis. Esta espécie é matéria prima importante para manutenção de uma vasta variedade de produtos, sendo empregada na produção de rações animais, alimentação humana e na cadeia produtiva de óleos (CONAB, 2020).

Para nutrição humana, pode ser consumida na forma de grão, extratos, farinha, margarinas, óleos vegetais, entre outros. Na alimentação animal, é empregada principalmente na criação de aves e suínos, podendo ser utilizada na forma de farelo, casca, proteína isolada, integral extrusada, integral tostada, etc.

Para a nutrição de animais ruminantes, a forma mais empregada é o farelo de soja (GOUVEIA, 2020; ESCHER; WILKINSON, 2019; GARCIA, 2000; GOMES, 1976).

Atualmente, o Brasil é o segundo maior produtor mundial de soja, atrás apenas dos Estados Unidos. Na safra de 2019/2020, a soja ocupou uma área de 36,95 milhões de hectares e a produção nacional atingiu aproximadamente 125 milhões de toneladas, com produtividade média de 3.379 kg ha<sup>-1</sup> (CONAB, 2020).

Esta *commodities* apresenta grande importância no cenário internacional, e essa relevância aumenta à medida que esta é empregada como matéria prima na elaboração de uma grande variedade de produtos. Atualmente, é a principal cultura do agronegócio nacional, uma vez que é responsável por estimular diversos setores da economia do país como produtores, órgãos de pesquisa e tecnologia, insumos, indústrias de implementos agrícolas, fábricas de bioenergia, etc. (RIBEIRO et al., 2019; PROQUE, 2019).

Além desses fatores, a soja se destaca na produção global de sementes oleaginosas, com mais de 50%, e é responsável por mais de 60% da produção mundial de farinhas. O cultivo da soja apresenta grande concentração geográfica, no qual quatro países (EUA, Brasil, Argentina e China) produzem aproximadamente 90% do suprimento mundial de soja (ZHAN et al., 2019). Neste sentido, pesquisas que visam entender as limitações no processo produtivo da soja são de suma importância, pois permitem aumentar a eficiência produtiva para atender à crescente demanda da população mundial por alimentos.

## 2.2 Sensoriamento remoto (SR)

O sensoriamento remoto é caracterizado como uma ciência que objetiva identificar, analisar e mensurar objetos alvos sem o contato direto com os sensores que captam as informações. Este meio de aquisição de dados é possível devido as informações espectrais emitidas pelas propriedades da luz e a sua interação, como reflexão, transmissão e absorção pelos objetos. O SR tem com fonte principal de informação a radiação eletromagnética emitida ou refletida pelos alvos estudados (JENSEN, 2009).

Tal tecnologia possibilita obter informações da superfície terrestre,

principalmente na forma de imagens, por meio da aquisição e análise da energia emitida ou refletida pela superfície (FLORENZANO, 2011). Nesta técnica, os dados são obtidos por meio de sensores inseridos em bases orbitais, aéreas e terrestres. Já, o termo remoto, refere-se à capacidade dos sensores em captarem informações de objetos na superfície terrestre sem o contato físico.

O princípio de obtenção de dados por SR é fundado no sol como principal fonte de energia eletromagnética. A energia emitida pela fonte atinge a superfície terrestre e algumas frações dessa energia são refletidas em todas as direções, nas quais os sensores captam e registram a energia refletida pelo alvo (MENESES; ALMEIDA, 2012; FLORENZANO, 2011).

A energia eletromagnética pode ser caracterizada por sua ordenação de modo contínuo em relação ao comprimento ou a frequência, sendo essa disposição conhecida como espectro eletromagnético, o qual apresenta subdivisões de acordo com as características de cada região. As subdivisões são determinadas por alguns fatores, como os processos físicos que originam a energia eletromagnética, pela interação que ocorre entre a radiação e os objetos incidentes e pelas condições atmosféricas (SHAW; BURKE, 2003; MORAES, 2002).

A quantidade de energia eletromagnética que atinge um alvo sofre interações com os elementos que o constitui, podendo ser refletido, absorvido e transmitido. Os processos de absorção, reflexão e transmissão da energia incidente podem ser total ou parcial, considerando os fundamentos da conservação de energia. A aptidão que os objetos apresentam de absorver, refletir e transmitir a radiação é chamada de absorvância, refletância e transmitância, respectivamente (CATUREGLI et al., 2014; LILLESAND et al., 2004; MORAES, 2002).

Essa tecnologia possibilita o monitoramento e diagnóstico dos objetos de estudo e as condições ambientais em que estão inseridos por meio da particularidade das repostas espectrais. Neste âmbito, o comportamento espectral de cada objeto é caracterizado pelos valores sucessivos de refletância ao longo do espectro eletromagnético, sendo esse processo conhecido como a assinatura espectral. O termo “assinatura espectral” sugere uma correspondência única entre o alvo e seu espectro de refletância (CATUREGLI et al., 2015; SHAW; BURKE, 2003; HUNT, 1977; JACQUEMOUD; BARET, 1990).

## 2.3 Sensores orbitais e não orbitais

Os sensores são os equipamentos responsáveis pela captação das ondas eletromagnéticas refletidas pelos alvos e transformação desses dados em imagem ou gráfico, que possibilite relacionar a energia assimilada com as particularidades geométricas, físicas, químicas e biológicas dos objetos (POTT et al., 2016). Estes dispositivos são classificados como ativos e passivos. Os sensores ativos possuem sua própria fonte de energia eletromagnética, enquanto, que os sensores passivos não apresentam fonte própria de radiação eletromagnética (LECHNER et al., 2020).

Existem uma grande variedade de sensores orbitais e seus produtos são disponibilizados, em muitos casos de forma gratuita, por instituições de tecnologias e pesquisas, como a National Aeronautical and Space Administration (NASA), Europe Space Agency (ESA) e o Instituto Nacional de Pesquisas Espaciais (INPE). As imagens geradas por esses sensores representam uma importante fonte de dados para estudos e monitoramentos agrícola e ambiental, uma vez que possuem regularidade na captura de cenas, capacidade de monitorar de forma atualizada as alterações na superfície terrestre, maior quantidade de faixas espectrais e estão associadas a um grande apoio tecnológico de edição e tratamento (PEREIRA et al., 2016; IZOLA et al., 1998).

Neste âmbito, a série de satélites Landsat representa uma das principais ferramentas que continuam sendo largamente empregada em estudos técnicos e científicos. Esta rede de satélites está operando de forma contínua desde 1972, quando foi lançado o primeiro satélite Landsat, Earth Resources Technology Satellite 1. Em fevereiro de 2013, a NASA lançou o Landsat 8, o mais recente da série, e a partir de maio 2013, a United States Geological Survey (USGS) é responsável pelo controle operacional. O Landsat 8 captura diariamente centenas de imagens completas e de alta qualidade da superfície terrestre (LESLIE et al., 2017).

O satélite Landsat 8 é equipado com dois sensores, o Operational Land Imager (OLI) e o Thermal Infrared Sensor (TIRS). O sensor OLI é caracterizado por apresentar nove bandas espectrais, sendo que oito bandas apresentam resolução espacial de 30 metros (bandas 1, 2, 3, 4, 5, 6, 7 e 9) e uma banda pancromática (banda 8) com 15 metros de resolução espacial (Tabela 1). As faixas térmicas do

sensor TIRS (bandas 10 e 11) são úteis no fornecimento de temperaturas de superfície terrestre. Este sensor apresenta resolução radiométrica de 16 bits por pixel (USGS, 2018).

**Tabela 1** – Bandas dos sensores OLI e TIRS do satélite Landsat 8.

Bandas	Comprimento de onda ( $\mu\text{m}$ )	Resolução (m)
Band 1 - Costal aerossol	0,43 - 0,45	30
Band 2 - Azul	0,45 - 0,51	
Band 3 - Verde	0,53 - 0,59	
Band 4 - Vermelho	0,64 - 0,67	
Band 5 - Infravermelho Próximo (NIR)	0,85 - 0,88	
Band 6 - Infravermelho Médio/SWIR 1	1,57 - 1,65	
Band 7 - Infravermelho Médio/SWIR 2	2,11 - 2,29	
Band 9 - Cirrus	1,36 - 1,38	
Band 8 - Pancromática	0,50 - 0,68	
Band 10 - Infravermelho Termal (TIRS) 1	10,6 - 11,19	100
Band 11 - Infravermelho Termal (TIRS) 2	11,50 - 12,51	

Fonte: USGS, 2018.

Outro importante marco para o SR foi a missão Sentinel-2 que faz parte do programa Copernicus e que foi realizada em conjunto com a Global Monitoring for Environment and Security (GMES). Esta missão é constituída por dois satélites gêmeos que operam em conjunto: o Sentinel-2A e o Sentinel-2B, que foram lançados em junho de 2015 e março de 2017, respectivamente. Ambos, possuem órbita polar, heliosíncrona, com altitude de 786 km e fazem a varredura sistêmica da superfície terrestre (ESA, 2020).

Os satélites são equipados com o sensor Multi Spectral Instrument (MSI), que engloba 13 bandas espectrais. As quatro bandas do visível (B02, B03, B04 e B08) possuem resolução espacial de 10 metros, as seis bandas do infravermelho de borda e de ondas curtas (SWIR) (B05, B06, B07, B08A, B11 e B12) apresentam resolução de 20 metros e as três bandas de correção atmosférica (B01, B09 e B10), com resolução de 60 metros (Tabela 2). Os satélites apresentam resolução radiométrica de 12 bits por pixel e resolução temporal de 10 dias, podendo diminuir para 5 dias, quando a constelação de satélites opera em conjunto (ESA,

2020).

**Tabela 2** – Especificações dos sensores MSI acoplados nos satélites Sentinel-2A e Sentinel-2B.

Bandas	Sentinel-2A	Sentinel-2B	Resolução Espacial (m)
	Comprimento de Onda Central (nm)		
B02 - Azul	492,4	492,1	10
B03 - Verde	559,8	559,0	
B04 - Vermelho	664,6	665,0	
B08 - NIR	832,8	833,0	
B05 - Red Edge 1	704,1	703,8	20
B06 - Red Edge 2	740,5	739,1	
B07 - Red Edge 3	782,8	779,7	
B08a - Red Edge 4	864,7	864,0	
B11 - SWIR 1	1613,7	1610,4	
B12 - SWIR 2	2202,4	2185,7	
B01 - Aerosol	442,7	442,3	60
B09 - Water Vapor	945,1	943,2	
B10 - Cirrus	1373,5	1376,9	

Fonte: ESA, 2018.

O lançamento dos satélites Sentinel-2A e 2B proporcionou que muitas das limitações na aplicação de técnicas de SR para agricultura de precisão existentes nos anos anteriores fossem superadas. Esta rede de satélites com melhor resolução espacial, espectral e temporal foi projetada, especificamente, para atender às necessidades da agricultura e de pesquisadores, com foco no desenvolvimento agrícola internacional (SEGARRA et al., 2020).

O emprego de imagens de satélites em estudos ambientais e agrícolas é um método extremamente relevante e consolidado globalmente. Adicionalmente, complementando as metodologias já existentes, o emprego dos sensores não orbitais ou aéreos associados aos VANTs está se tornando algo recorrente, uma vez que podem oferecer alta versatilidade e flexibilidade, quando comparados aos satélites. A variedade de sensores que podem ser acoplados a esses equipamentos está se tornando uma solução viável para uma análise rápida e precisa da vegetação (COSTA et al., 2020; NEGASH et al., 2019).

A utilização de sensores remotos acoplados em VANT possibilita obter



a radiação eletromagnética refletida pelos objetos, sendo transformadas em sinais elétricos, que são transmitidos em tempo real e armazenados, com a finalidade adquirir informações de alvos existentes na superfície terrestre (SOUZA et al., 2020; VIANA et al., 2018).

Neste sentido, as câmeras RGB são os principais sensores presentes nos VANTs, pois, a maioria dessas aeronaves possuem uma câmera RGB instalada de fábrica. Os sensores RGB operam na faixa espectral do visível, logo são capazes de gerar imagens perceptíveis ao olho humano. No espectro do visível é possível extrair informações a respeito de cultivos agrícolas, como falhas de plantio, alterações no dossel da vegetação, entre outros (JORGE; INAMASU, 2014).

A diversidade de uso e áreas em que os VANTs podem ser utilizados é quase ilimitado, pois estão sendo integrados a tecnologias emergentes, sensores a bordo e recursos computacionais (NEGASH et al., 2019). Os sistemas de SR a baixa altitude, quando acoplados aos VANTs, são propícios para a realização de pesquisas e monitoramento de campo, pois apresentam facilidade operacional e resultam em imagens de alta resolução (ZHANG et al., 2020).

#### 2.4 Processamento digital de imagens (PDI)

O constante avanço tecnológico e o aprimoramento dos sistemas computacionais, possibilitaram aumento expressivo na quantidade e na qualidade de imagens geradas por sensores remotos. Este processo permitiu que as técnicas de processamento digital de imagens pudessem gerar informações rápidas e com maior precisão, a partir das imagens captadas (GONZALEZ; WOODS, 2009). Com isso, o PDI de SR está diretamente relacionado a análise de aspectos e padrões existentes nas imagens multiespectrais, por meio de softwares específicos, fundamentados em análises estatísticas (RICHARDS, 1999).

Os sensores orbitais estão sujeitos a diversos fatores atmosféricos (nuvens, gases, fumaça e outros) (PEREIRA et al., 2016). Por esses motivos, devem ser utilizados alguns procedimentos de processamento digital que permitem alcançar melhoras significativas na qualidade visual das imagens. O processamento de imagens de SR é caracterizado por sucessivas modificações que objetivam retirar

com maior facilidade as informações existentes (ALBUQUERQUE; ALBUQUERQUE, 2000).

Neste âmbito, Crósta (1999) afirma que o propósito fundamental do PDI é proporcionar ferramentas precisas que permitam o reconhecimento e a extração de dados existentes nas imagens para futuras análises e interpretação. Para realização de procedimentos de manipulação das imagens brutas e análise das informações, são empregados sistemas computacionais específicos. Este processo resulta na elaboração de outras imagens que apresentam dados específicos, extraídos e aprimorados a partir dos dados brutos.

O PDI é uma técnica complexa que compreende um conjunto de procedimentos que estão interligados, contemplando três fases diferentes: o pré-processamento de imagens, que compreende técnicas de restauração quantitativa de imagem para corrigir degradações radiométricas e geométricas inseridos pelo sensor; o realce, que objetiva melhorar a qualidade visual e modificar as imagens para que os dados extraídos sejam corretamente reconhecidos; e a fase de análise de imagens, que ocorre a extração de informação através de inúmeros procedimentos, como a aplicação de operações matemáticas com as bandas espectrais que compõem uma imagem. Os resultados podem ser sistematizados em sequencias ou conjunto de imagens, mapas, ou representações gráficas, de acordo com cada finalidade (FONSECA, 2000).

## 2.5 Monitoramento espectral da soja

No atual sistema produtivo, tem-se uma demanda crescente por métodos que proporcionam diagnósticos rápidos da sanidade vegetal, fornecendo dados que possam subsidiar melhores intervenções em relação aos manejos culturais (PETRO et al., 2018). Nesse contexto, o monitoramento agrícola por meio do SR é visto como uma técnica moderna, relativamente simples e de baixo custo de implantação, que possibilita o acompanhamento das lavouras e na elaboração de mapas de produtividade. A produtividade pode ser mensurada a partir da relação do vigor da cultura com os índices de vegetação, calculados a partir de imagens multiespectrais (TOLA et al., 2017).

Para Carvalho et al. (2017) o monitoramento de culturas agrícolas é o principal objetivo da agricultura de precisão, permitindo o estudo dos aspectos que afetam o desenvolvimento das lavouras de soja, como as características químicas e físicas do solo, o estado nutricional das culturas e sua produtividade, que propicia o uso eficiente de insumos e na redução dos impactos sobre o meio ambiente (RIA et al., 2015).

No âmbito de estudos da vegetação, os métodos de monitoramento são fundados na interação da radiação eletromagnética com os elementos que compõem a estrutura vegetal. O entendimento do processo natural de fotossíntese é fundamental, visto que este procedimento é baseado na assimilação das ondas eletromagnéticas pelos pigmentos fotossintetizantes presentes nos tecidos vegetais, como clorofilas e caroteno (PONZONI et al., 2007; JENSEN, 2009).

A folha apresenta destaque nesse processo, pois, é um órgão fotossintetizante ativo, em que ocorre a absorção da radiação eletromagnética pelas estruturas naturais da folha (pigmentos de clorofila, xantofila e carotenos). Existem diferentes características celulares entre as espécies vegetais, contudo, de maneira geral as células vegetais são compostas basicamente por água, diferentes soluções e organelas com dimensões diferenciadas, em que os tamanhos são proporcionais ao comprimento de ondas incidentes sobre essas estruturas (PONZONI et al., 2007).

Os pigmentos que constituem a estrutura natural das folhas apresentam na sua composição 65% de clorofila, 6% de carotenos e 29% de xantofilas. Uma folha madura e saudável absorve cerca de 70 a 90% da radiação solar na faixa espectral do visível em consequência dessa composição de pigmentos. Ademais, existe um pequeno pico de reflectância na faixa do verde, que é evidenciada na cor verde durante o estágio do crescimento vegetativo e na cor amarela na maturação (PONZONI et al., 2007; LIU, 2007).

As folhas são estruturas vegetais que exercem maior influência no comportamento espectral das plantas. As características espectrais da folha são determinadas principalmente pelas suas composições química e morfológicas. Na curva de resposta espectral da vegetação sadia, a refletância é baixa na região espectral do visível devido à absorção natural realizada pelos pigmentos, com um pequeno aumento da refletância na faixa do verde. Nas faixas referente ao vermelho

e infravermelho próximo existe alta refletância justificada pela interferência da estrutura celular do mesófilo esponjoso (SWAIN; DAVIS, 1981).

Para Jensen (2009), a refletância da maior parte da radiação que incide sobre a vegetação, causada pelo mesófilo esponjoso, está inserido no processo de controle da temperatura da planta. Na região de transição do infravermelho próximo e no infravermelho médio, o conteúdo de água existente nas folhas exerce maior influência. A água apresenta como principal particularidade espectral a assimilação da energia eletromagnética, nos comprimentos de onda de 1,4  $\mu\text{m}$ , 1,95  $\mu\text{m}$  e 2,6  $\mu\text{m}$ , os quais apresentam os valores de maior absorção.

No início do ciclo vegetativo, a vegetação demonstra desempenho espectral parecido com o solo, isto é justificado pelo fato da cobertura vegetal presente no solo ser praticamente nula na fase de germinação. A medida em que a vegetação cresce e a cobertura aumenta, há uma diminuição da influência do solo, com isso a curva de refletância se ajusta ao comportamento das plantas desenvolvidas. Ao iniciar a fase de senescência, o porte e o vigor da vegetação são afetados, diminuindo a quantidade de cobertura e modificando o comportamento espectral, que volta a sofrer influência do solo.

## 2.6 Índices de vegetação (IV)

Para o acompanhamento de atividades agrícolas, é fundamental o estudo em diferentes períodos de desenvolvimento da cultura para gerar dados referentes ao comportamento espectro-temporal no decorrer de todos os estádios fenológicos da espécie agrícola (JENSEN, 2009). Os IVs são utilizados em muitas pesquisas para análise temporal, os quais podem ser extraídos de imagens provenientes de diversos sensores. Existem muitos métodos para obtenção destes valores, contudo, estas metodologias necessitam de dados preliminares, como data de semeadura e de máximo desenvolvimento vegetativo da cultura, que podem variar de acordo com a época e a região (PÔÇAS et al., 2020; ZHANG et al., 2016).

Os IVs consistem em combinações de duas ou mais bandas espectrais, selecionadas com a finalidade de sistematizar e fornecer dados por meio da interação dos parâmetros biofísicos da vegetação (MOREIRA, 2000). Estes

índices são caracterizados por serem técnicas amplamente empregadas em estudos associados ao SR, pois apresentam o potencial de apontar a presença e as condições da vegetação, uma vez que a saúde da planta tem relação direta com a energia solar absorvida, influenciando diretamente no crescimento e desenvolvimento da vegetação (SANTOS et al., 2018).

Para McKinnon e Hoff (2017) um IV representa a combinação ou um processo de filtragem de vários conjuntos de dados espectrais para gerar um valor único para cada pixel em uma imagem, geralmente representado por um modelo matemático e traduzido em mapas de escala de cores.

Tucker (1979), com o objetivo de aprimorar o diagnóstico da vegetação e diminuir a variabilidade gerada por fontes externas, desenvolveu diversos índices. Dentre estes, os mais empregados consideram os dados inclusos na reflectância da radiação eletromagnética, referentes as faixas do comprimento de onda do vermelho e do infravermelho próximo (PONZONI, 2007).

Entre os vários IVs existentes, o que tem sido mais difundido e empregado em pesquisas relacionadas a vegetação é o NDVI, o qual é fundado na relação entre os valores espectrais das bandas referentes ao vermelho e infravermelho próximo, e tem como finalidade diminuir as interferências do solo na resposta da vegetação (ROUSE et al., 1973).

De acordo com Esquerdo (2007), este índice é amplamente empregado, devido a capacidade de apresentar correlação direta com a biomassa vegetal e com o índice de área foliar, sendo caracterizado como um excelente indicador desses parâmetros. Este índice é mais indicado quando o objetivo é realizar comparações ao longo do tempo em mesmo perímetro, visto que apresenta menor influência das condições atmosféricas (MENESES; ALMEIDA, 2012).

La Casa et al. (2018) utilizaram o NDVI obtidos através de imagens de satélites para determinar a cobertura vegetal da soja, a fim de avaliar as diferenças de produtividade entre setores de uma parcela, no sul da cidade de Córdoba, Argentina. Os autores concluíram que o NDVI representa um meio adequado para determinar a cobertura da cultura e monitorar sua evolução durante o ciclo de crescimento em diferentes áreas.

De forma semelhante, Boori et al. (2019) avaliaram séries temporais de

NDVI extraídos do satélite Sentinel-2 para monitorarem o crescimento da safra, por meio de informações fenológicas precisas em regiões de Samara, na Rússia. Um dos resultados desse estudo foi a percepção que o mapeamento de culturas por meio do NDVI, analisando padrões fenológicos, é uma ferramenta eficiente e confiável, quando comparado com outros métodos.

Para gerar um mapa NDVI é necessário um sensor multiespectral que opere na faixa do infravermelho próximo (NIR) e do visível. Contudo, sensores multiespectrais são geralmente mais caros e de difícil acesso. Diante disso, atualmente, a utilização de câmeras convencionais de alta resolução, que operam somente na faixa do visível, são amplamente utilizadas para o monitoramento da vegetação, uma vez que foram desenvolvidos inúmeros IVs que utilizam apenas os canais RGB convencionais (COSTA et al., 2020).

Neste contexto, IVs derivados de imagens adquiridas por meio de sensores acoplados em VANTs têm ganhado espaço na avaliação de espécies agrícolas (ZHENG et al., 2020). Neste âmbito, um dos índices mais relevante para estimar frações de vegetação com baixa sensibilidade aos efeitos atmosféricos, utilizando câmeras RGB, foi o Visible Atmospherically Resistant Index (VARI), proposto por Gitelson et al. (2002), que utilizaram os conceitos desenvolvidos Kaufman e Tanre (1992) para reduzir os efeitos atmosféricos sobre o IV, baseados na faixa espectral do visível.

O VARI utiliza faixas espectrais do vermelho (Red), verde (Green) e azul (Blue). Este índice é capaz de reduzir os efeitos atmosféricos por considerar a subtração da banda espectral do azul no denominador da equação (GITELSON et al., 2002).

O VARI apresenta grande versatilidade e resultados promissores em muitas pesquisas relacionadas à agricultura, sendo utilizado para detectar as características espectrais de variedades de arroz (AFDHALIA et al., 2020), avaliar parâmetros de qualidade de frutos de manga (ELSAYED et al., 2016), estimar a porcentagem de cobertura verde do solo com grama (ZHANG et al., 2019) e estimar a produtividade de grãos de milho (MARTÍNEZ et al., 2020).

## 2.7 Geoestatística

A geoestatística ou estatística espacial consiste em um conjunto de procedimentos estatísticos nos quais o posicionamento espacial das variáveis estudadas exerce função importante na análise das informações. A geoestatística visa modelar a variabilidade espacial contínua considerando que exista correlação espacial das variáveis analisadas (YAMAMOTO; LANDIM, 2015; VIEIRA, 2000).

A estatística espacial reconhece que o posicionamento das diferenças de variáveis entre os pontos coletados é a mesma para todo perímetro em estudo, e isto é determinado pela distância e pela orientação entre pontos. A caracterização geoespacial possibilita a descrição quantitativa da variabilidade espacial dos fatores estudados e realiza estimativas de forma não tendenciosa e com variância mínima dos valores das variáveis não amostradas no mesmo local (DEBASTIANI et al., 2018; MOLIN et al., 2015; VIEIRA; GONZALEZ, 2003).

A geoestatística é o método mais conhecido para realizar análises da variabilidade espacial de maneira correta e precisa (VIEIRA, 2000). Em áreas agrícolas é imprescindível ter o conhecimento adequado da variabilidade espacial das características do ambiente produtivo, visto que há risco de aplicações inadequadas dos resultados. Entre as diversas aplicações da geoestatística, destaca-se a obtenção de dados que sirvam de suporte para a agricultura, como a caracterização e modelagem espacial e temporal das áreas de cultivo, que resultam na elaboração de mapas precisos sobre a produtividade da lavoura (ARAÚJO et al., 2018; MCBRATNEY et al., 2005).

A geoestatística é empregada como técnica para subsidiar representação da variabilidade espacial, a qual é realizada por meio de modelos matemáticos para produzir os variogramas e expor os resultados da variabilidade espacial em determinada área. O semivariograma consiste em uma função fundamental da geoestatística que descreve a variabilidade do padrão espacial e temporal de um determinado fenômeno (USOWICZ; LIPIEC, 2017). O efeito da variação espacial é determinado pela interação dos valores amostrados de cada ponto espaçados por uma determinada distância, sendo que a interação é dependente da distância entre os pontos coletados (RUIZ et al., 2016).

Segundo Vieira (2000), para que exista dependência espacial para uma variável é fundamental que o semivariograma apresente comportamento crescente

em relação a distância. Também é necessário que a hipótese intrínseca seja válida, isto é, após o semivariograma ter aumentado com a distância, o mesmo deve se estabilizar no valor da variância dos dados. O modo como o semivariograma aumenta com a distância até o ponto máximo, define o comportamento espacial da variável estudada.

A partir da existência da dependência espacial para a variável estudada, por meio do ajuste de semivariograma, é possível realizar a interpolação de valores para qualquer local na área de estudo, de forma não tendenciosa, sem superestimar em minimizar os valores, e com variância mínima, com isso, a precisão na estimativa dos dados será máxima (GREGO et al., 2014).

Neste sentido, um dos melhores e mais conhecidos estimadores geoestatístico é a krigagem, que recebeu esta denominação em homenagem aos trabalhos pioneiros desenvolvidos por Daniel Kriger. Este método de interpolação tem como objetivo realizar estimativas de valores para qualquer perímetro e a estimativa consiste em arranjos lineares de valores avaliados (ROSEMARY et al., 2017; FARIAS et al., 2003).

No método de krigagem, os pesos determinados para as amostras mais próximas são definidos com base na análise espacial, considerando o semivariograma experimental. Com isso, por meio da krigagem é possível mensurar o valor de uma determinada característica para cada centro da célula de uma malha tridimensional, este valor depende das informações existentes e de uma função de correlação espacial os dados (GREGO et al., 2014; VIEIRA, 2000).

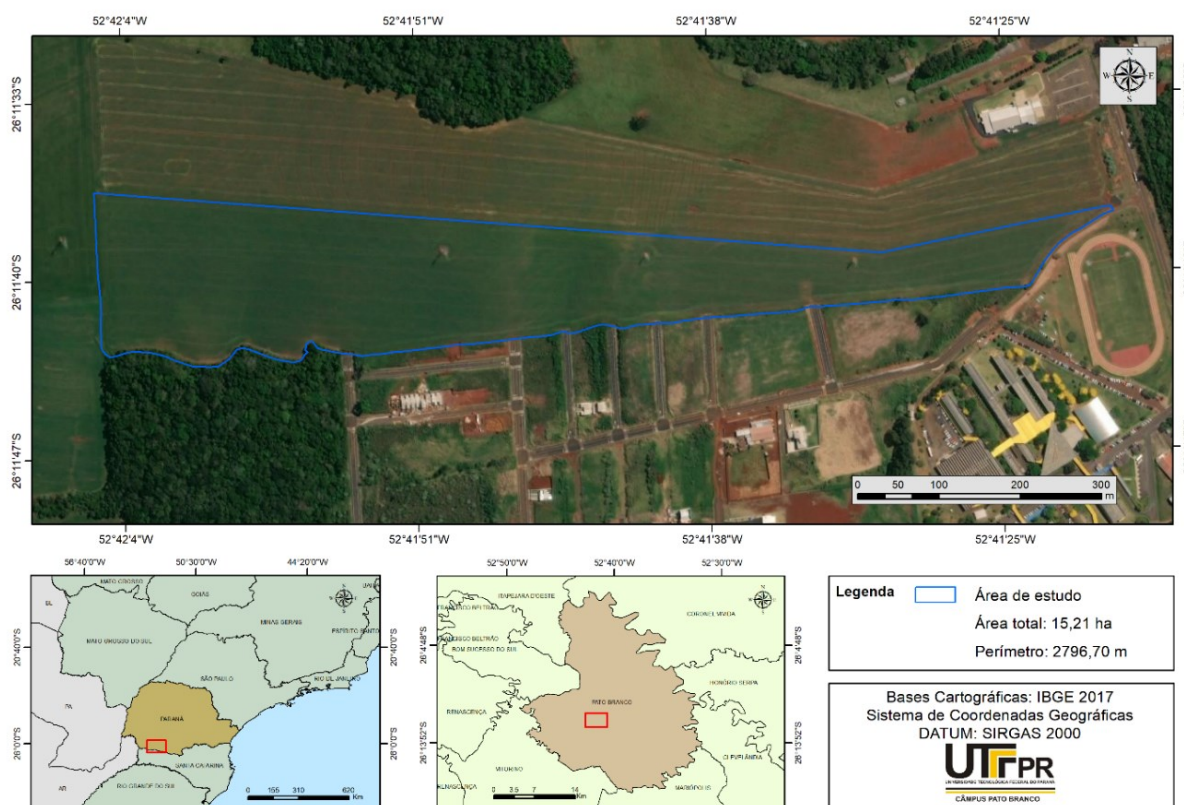


### 3 MATERIAL E MÉTODOS

#### 3.1 Caracterização do local de estudo

O estudo foi conduzido durante a safra agrícola de 2019/2020 em área de lavoura comercial de 15,21 ha, localizada no município de Pato Branco, na região Sudoeste do Paraná, situada entre as latitudes  $26^{\circ}11'36.61''\text{S}$  e  $26^{\circ}11'40.73''\text{S}$ , longitudes  $52^{\circ}42'4.95''\text{O}$  e  $52^{\circ}41'23.84''\text{O}$  (Figura 1), com altitude média de 796,56 m.

**Figura 1** – Localização da área de estudo.



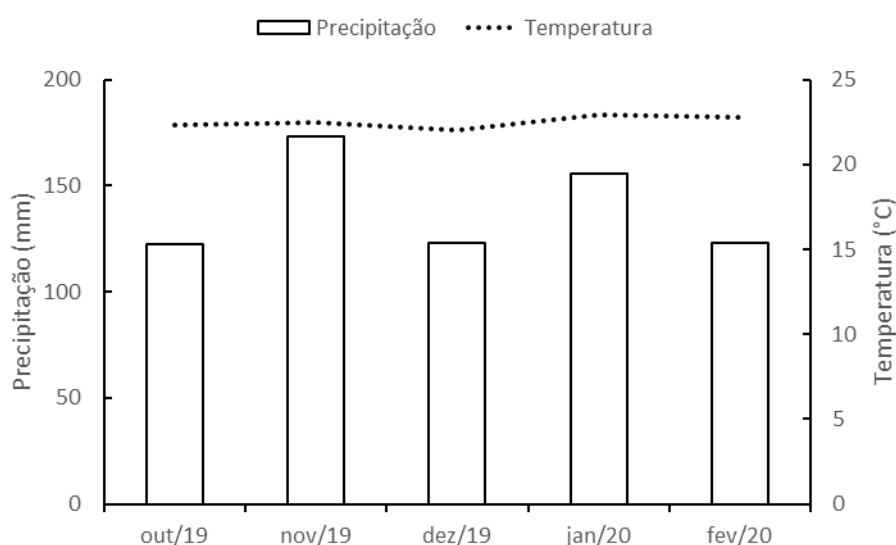
Fonte: Autor (2021).

O clima do município de Pato Branco é classificado como subtropical úmido do tipo Cfa de acordo com a classificação de Köppen. No verão apresenta temperaturas superiores a  $22^{\circ}\text{C}$  e inferiores a  $18^{\circ}\text{C}$  no inverno (CAVIGLIONE et al., 2000). As variações climáticas ocorridas durante o estudo foram sistematizadas na Figura 2.

O solo da região é caracterizado como Latossolo Vermelho Distroférico típico, com textura muito argilosa e relevo suave ondulado (BHERING et al., 2007).

Na área foi utilizado o plantio direto como técnica de cultivo, sistema que é empregado há mais de 20 anos neste local, e a aveia preta (*Avena strigosa* Schieb) foi utilizada como planta de cobertura no período de inverno.

**Figura 2** – Precipitação pluviométrica (mm) e temperatura (°C) durante o estudo, no município de Pato Branco, PR.



Fonte: Sistema Meteorológico do Paraná (SIMEPAR).

### 3.2 Caracterização da cultivar

Foi utilizado a cultivar de soja, PIONEER 95R51®, semeada no dia 11 de outubro de 2019 e colhida em 6 de fevereiro de 2020. Empregou-se o espaçamento de 0,45 m entre linhas e 15,5 sementes por metro linear, com população aproximada de 345 mil plantas ha<sup>-1</sup>. No momento da semeadura foram aplicadas 145 kg ha<sup>-1</sup> de NPK (8-40-00), como adubação de base nas linhas de plantio, e 31 dias após a semeadura foi realizada a aplicação a lanço de 80 kg ha<sup>-1</sup> de cloreto de potássio (KCl).

Na região edafoclimática que compreende o município de Pato Branco, o ciclo da cultivar PIONEER 95R51® varia de 115 a 120 dias. Quando o plantio é realizado entre setembro e outubro, recomenda-se a semeadura de 320.000 a

390.000 plantas por hectare. A cultivar é tolerante ao Glifosato, apresenta superprecocidade, elevado potencial produtivo, hábito de crescimento indeterminado, tolerante ao acamamento, além de apresentar resistência a chuva durante a colheita (PIONEER, 2019).

### 3.3 Aquisição de dados

Para aquisição dos dados referentes aos sensores orbitais, foram selecionadas imagens captadas pelo sensor OLI, embarcado no satélite Landsat 8. As imagens foram adquiridas no sistema *earthexplorer* (<https://earthexplorer.usgs.gov/>) da USGS, onde foram selecionadas as imagens em formato GeoTIFF, correspondente as seguintes datas: 12/12/2019 e 28/12/2019

Também foram utilizadas imagens captadas pelo sensor MSI, presente nos satélites Sentinel-2. As imagens são disponibilizadas de forma gratuita no sistema *Copernicus Open Access Hub* (<https://scihub.copernicus.eu/dhus/#/home>) da ESA. Para este satélite foram selecionadas as imagens referentes as seguintes datas: 13/10/2019, 02/11/2019, 07/12/2019, 08/01/2020 e 26/01/2020.

Para o monitoramento com sensor não-orbital, utilizou-se o Drone DJI phantom 3 Standard® equipado com câmera RGB (sensor 1/2.3" CMOS *Effective pixels*:12 megapixels), com Sistema Global de Navegação por Satélite (GNSS) e apresenta velocidade de voo de até 57 km h<sup>-1</sup> (Figura 3). O mapeamento da área foi realizado em cinco períodos diferentes: 11/10/2019, 06/11/2019, 06/12/2019, 10/01/2020 e 06/02/2020, onde o primeiro voo foi feito no dia de semeadura e o último foi realizado no dia anterior a colheita da soja.

**Figura 3** – Drone DJI phantom 3 Standard®, utilizado na coleta de imagens com sensor não orbital.



Fonte: dji.com (2020).

O planejamento dos voos foi efetuado no software DroneDeploy®, no qual foram ajustadas as configurações de imagens, melhor rota de voo e a altura de voo, que foi definida como 100 m para todos os mapeamentos. Buscou-se executar os voos em períodos do dia com melhor condições atmosféricas, para evitar qualquer tipo de interferência na qualidade das imagens captadas. As imagens apresentaram recobrimento lateral de 65% e longitudinal de 75%. A altura de voo empregada com esse equipamento proporcionou resolução espacial das imagens de aproximadamente 4,0 cm por pixel.

### 3.4 Processamento Digital de Imagens (PDI)

Antes de executar qualquer procedimento para extrair informações das imagens, quando necessário, foi efetuado o pré-processamento. Nesta etapa foram aplicadas correções atmosféricas e geométricas, para retirar ou minimizar as distorções existentes na captura das imagens pelos sensores e dos fatores atmosféricos presentes no momento de aquisição dos dados. Dessa forma, as imagens foram devidamente corrigidas e otimizadas para melhor extração das informações.

As imagens Landsat 8 (*Collection 1 Level-1*) são disponibilizadas em Números Digitais (ND) e para realizar análises relacionadas a vegetação, é preciso executar a conversão de ND para valores de refletância (BAETENS et al., 2019; ALBA et al., 2017). Para isso, foram selecionadas as bandas espectrais 4 (Red) e 5 (NIR), posteriormente foram aplicadas as equações e os parâmetros fornecidos pela

USGS, no qual são considerados os coeficientes de redimensionamento radiométrico existentes nos metadados de cada imagem.

As imagens do satélite Sentinel-2 foram adquiridas no nível de processamento 2A diretamente do sistema da ESA. Os produtos de nível 2A apresentam a refletância de superfície terrestre (*Bottom of Atmosphere* - BOA). Esse processamento é executado a partir das imagens de nível 1C que possuem correção de topo de atmosfera (*Top of Atmosphere* - TOA). Deste modo, os dados de nível 2A são produtos da refletância corrigida das imagens de nível 1C (ESA, 2020).

O processamento digital das imagens para geração do NDVI foi executado no software ArcGIS 10.5®, onde aplicou-se a metodologia desenvolvida por Rouse et al. (1973). Os valores do NDVI são gerados a partir dos pixels das imagens, considerando as faixas de comprimento de onda específicas para cada imagem empregada (Equação 1). Os resultados obtidos podem variar de -1 a 1, quanto maior o valor, maior o vigor de vegetação.

$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}} \quad (1)$$

Em que:

NDVI – Índice de vegetação por diferença normalizada;

NIR – Reflectância na banda do infravermelho próximo;

Red – Reflectância na banda do vermelho.

Para o cálculo do NDVI das imagens referentes ao satélite Landsat 8 foram selecionadas apenas as bandas espectrais 4 e 5, ambas com resolução espacial de 30 m. Para as imagens provenientes dos satélites Sentinel-2, utilizou-se as bandas espectrais 4 (Red) e 8 (NIR), com resolução espacial de 10 m.

O processamento das imagens digitais capturadas com o sensor RGB acoplado ao Drone DJI phantom 3 Standard® foi realizada com auxílio do software Agisoft Metashape Professional 1.5®, no qual foram efetuados os seguintes procedimentos: a) carregamento das imagens; b) alinhamento do posicionamento da câmera; c) calibração das câmeras; d) criação de nuvens de pontos densa; e) criação de malha triangular; f) elaboração do Modelo Digital de Elevação (DEM); g)

construção do ortomosaico.

Após construção dos ortomosaicos, foi possível calcular o VARI, utilizando as bandas espectrais do visível (RGB), de acordo com metodologia proposta por Gitelson et al. (2002), em que os valores variam de -1 a 1, onde os maiores valores representam a vegetação sadia (Equação 2). Os procedimentos para calcular o VARI foram realizados no software ArcGIS 10.5®.

$$\text{VARI} = \frac{G - R}{G + R - B} \quad (2)$$

Em que:

VARI – Índice de vegetação com resistência atmosférica ao visível;

R – Reflectância na banda do vermelho;

G – Reflectância na banda do verde;

B – Reflectância na banda do azul.

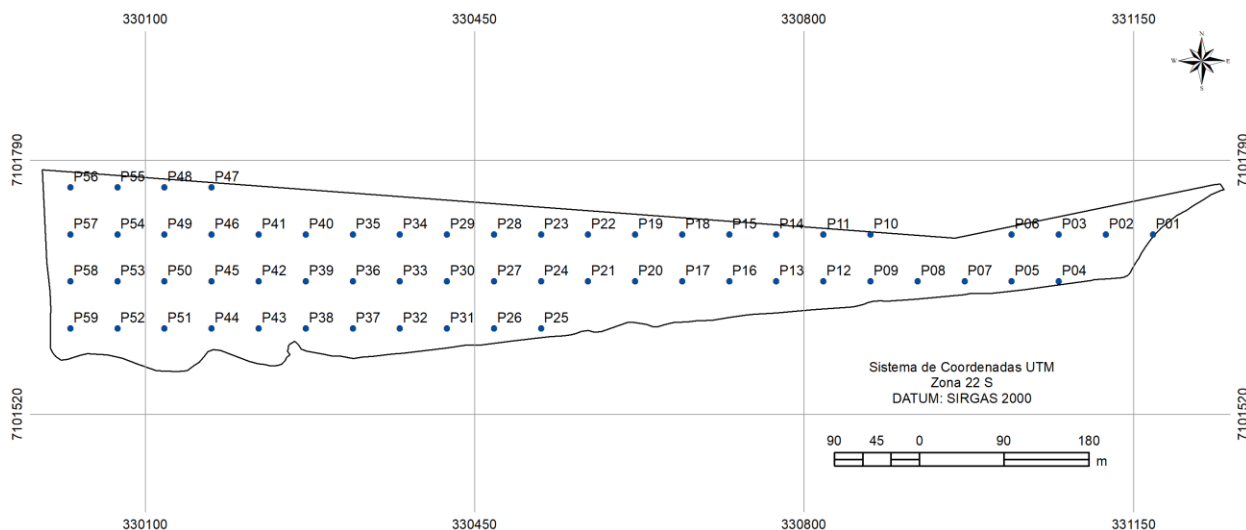
Para remover dados discrepantes ou outliers referentes aos IVs gerados para cada imagem, adaptou-se as metodologias propostas por Córdoba et al. (2016) e Taylor et al. (2007). Para estes autores, excluir os outliers é fundamental para realizar análises mais confiáveis. Neste estudo, primeiramente foram analisados os conjuntos de dados e sua faixa de distribuição. Seguidamente foi calculado a média e o desvio padrão para cada conjunto de dados. Por fim, foram identificados e removidos os valores que estão fora do limite de 3 vezes o desvio padrão, acima e abaixo da média.

### 3.5 Definição dos pontos amostrais e amostragem de solo

Para analisar a variabilidade espacial dos atributos químicos do solo, primeiramente, com auxílio do receptor GNSS L1 Promark 3®, foi realizado a delimitação e o georreferenciamento da lavoura, com área total de 15,21 ha. Posteriormente, no software ArcGIS 10.5®, foi determinada uma malha amostral de 50 x 50 m, com 59 pontos amostrais (Figura 4) (YAMAMOTO; LANDIM, 2015;

MOLIN et al., 2015).

**Figura 4** – Malha regular de pontos amostrais.



Fonte: autor (2021).

As amostras de solo foram coletadas antes da semeadura da soja, onde cada ponto amostral foi rastreado com o receptor GNSS L1 Promark 3<sup>®</sup>, que operou durante 5 minutos em cada ponto, alcançando uma precisão de aproximadamente 0,30 m. Em um raio de 5 m de cada ponto georreferenciado foram coletadas 5 amostras simples de solo na profundidade de 0 a 20 cm para formação de uma amostra composta.

As amostras foram encaminhadas para o laboratório de solos da UTFPR – Campus Pato Branco, onde foram realizadas as análises do pH, K, Ca, Mg, Al, H<sup>+</sup> + Al<sup>3+</sup>, P. A partir destes, foram calculados a SB, CTC e V% (CLAESSEN et al., 1997).


### 3.6 Avaliação de componentes de rendimento e produtividade

Para avaliar os componentes de rendimento da soja, foi realizada a contagem manual do número de vagem por planta (NV planta<sup>-1</sup>) e do número de grão por planta (NG planta<sup>-1</sup>) e, com esses valores foi possível estimar o número de sementes por vagem (NS vagem<sup>-1</sup>).

Após a debulha manual das vagens utilizadas para avaliar os

componentes de rendimento, foi determinada a massa de mil grãos por meio de oito amostras de 100 grãos tomadas ao acaso, de cada parcela, as quais foram submetidas à pesagem e correção da umidade para 13% (Figura 5).

**Figura 5** – A) Contagem dos grãos, B) separação das subamostras, C) pesagem dos grãos de soja e, D) determinação da umidade.




Fonte: autor (2021).

Para estimar a produtividade, considerou-se os grãos correspondentes das 10 plantas coletadas de cada ponto amostral (Figura 6), os quais foram pesados com auxílio de balança de precisão e a umidade da amostra corrigida para 13%.



**Figura 6** – A) Demarcação dos pontos amostrais e B) coleta das plantas para estimativa da produtividade.



Fonte: autor (2021).

### 3.7 Análise dos dados

Inicialmente, realizou-se a análise exploratória nos dados referentes aos atributos químicos do solo e aos componentes de rendimento da soja, onde verificou-se os valores médios, mínimo e máximo, mediana, variância, desvio padrão, coeficiente de variação (CV), coeficiente de assimetria e coeficiente de curtose (C). Essa etapa é fundamental, pois permite identificar possíveis erros e os outliers (valores discrepantes) para obter um melhor entendimento a respeito dos comportamentos dos dados (MOLIN, 2015).

A análise preliminar dos dados e identificação dos outliers foi realizada por meio de representações gráficas, como histogramas e os diagramas de caixa (boxplot), elaborados no programa estatístico R® (RStudio Team, 2020). Também foi verificada a hipótese de normalidade dos dados por meio do teste de Kolmogorov-Smirnov a 5% de probabilidade. Para caracterizar a distribuição espacial dos atributos químicos do solo e da produtividade da soja, os dados obtidos foram submetidos a análise geoestatística, através da modelagem do semivariograma, como auxílio do software GS+ 7.0® (GAMMA DESIGN SOTWARE, 2004).

Foram mensurados os valores de semivariância  $[\gamma(h)]$  por meio da

Equação 3. Os semivariogramas experimentais foram construídos para cada variável estudada e os modelos teóricos foram ajustados considerando os seus parâmetros de ajustes: efeito pepita ( $C_0$ ), patamar ( $C_0 + C$ ) e o alcance da dependência espacial ( $a$ ). Selecionou-se o modelo com maior coeficiente de determinação ( $r^2$ ), menor soma de quadrados de resíduos (SQR) o maior valor do coeficiente de correlação obtido pelo método de validação cruzada. Foi utilizada a metodologia de Cambardella et al. (1994) para avaliar o índice de dependência espacial (IDE), através da relação entre o efeito pepita ( $C_0$ ) e o patamar ( $C_0 + C$ ), na qual a dependência espacial é classificada como forte ( $\leq 25\%$ ), moderada (entre 25% e 75%) e fraca ( $\geq 75\%$ ).

$$\gamma(h) = \frac{1}{2N} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2 \quad (3)$$

Em que:

- $\gamma(h)$  – Semivariância experimental;
- $Z X_i$  – Valor da variável medida na posição  $x_i$ ;
- $Z(x_i+h)$  – Valor da variável medida na posição  $x(i+h)$ ;
- $N$  – Número de pares de valores separados por um vetor ( $h$ );
- $I$  – Posição da amostra.

A partir da verificação de dependência espacial para os dados analisados, foi realizado o procedimento de krigagem ordinária para estimar valores em locais não amostrados, de forma não tendenciosa e com variância mínima (YAMAMOTO; LANDIM, 2015). Com base no processo de krigagem foram gerados os mapas de distribuição espacial para cada variável estudada, com auxílio do software ArcGIS 10.5®.

Para a análise da correlação entre os índices de vegetação a produtividade da soja, primeiramente foram selecionados o índice de vegetação VARI extraído do sensor não orbital na data de 06/12/2019, o NDVI mensurado do satélite Sentinel-2 no dia 07/12/2019 e o NDVI gerado a partir do Landsat 8 no dia 12/12/2019. A escolha dos IV nas referidas datas se justifica pela maior aproximação nos períodos de avaliações, expressando, aproximadamente, o mesmo estágio de

desenvolvimento da soja.

Seguidamente, foi utilizada a malha amostral de 50 x 50 m (Figura 4) como referência para extração e tabulação das médias dos IV correspondentes para cada ponto amostral. Com isso, foram mesuradas a correlação entre a produtividade da soja e os IV por meio do coeficiente de correlação de Pearson ( $r$ ).

Para avaliar o nível de correlação entre as variáveis, foi empregada a classificação de Dancey e Reidy (2006), que considera os seguintes critérios: correlação fraca (0,1 a 0,39), correlação moderada (0,40 a 0,69) e correlação forte (0,7 a 1).

## 4 RESULTADOS E DISCUSSÃO

### 4.1 Índices de vegetação

Para compreender o comportamento da vegetação por meio do VARI, efetuou-se a comparação com o NDVI extraído de dois sensores (Landsat 8 e Sentinel-2). Desta forma, buscou-se entender o desempenho da lavoura de soja em seus diferentes estádios de desenvolvimento por meio do índice que emprega as faixas espectrais do vermelho e infravermelho próximo (NDVI), e também o que utiliza apenas o espectro do visível (VARI), visualizando como estes diferem ou se assemelham de acordo com as etapas de crescimento da soja.

Contudo, um dos principais fatores que dificultaram essa checagem, foi a dificuldade de coincidir as datas de coletas das imagens, uma vez que cada satélite apresenta resolução temporal própria. Pra contornar esse entrave, utilizou-se somente as imagens dos sensores que coincidiram na mesma data ou que foram coletadas no mesmo estágio fenológico de desenvolvimento da soja.

Destaca-se que o NDVI possui meios categóricos de avaliar medidas gerais de saúde no campo, caso este, que não é indicado para avaliações com VARI, no entanto, o VARI possui a vantagem de reduzir os efeitos atmosféricos (MCKINNON; HOFF, 2017; ANDRADE et al., 2019). Assim, pode-se afirmar, que a utilização integrada destes índices detém uma análise mais completa e eficaz para o monitoramento em lavouras.

O mapeamento realizado com sensor RGB no momento da semeadura (11/10/2019), obteve-se o VARI médio de -0,212, com valor mínimo de -0,338 e valor máximo de -0,095 (Figura 7A). Os baixos índices obtidos neste período ocorreram principalmente devido a captura da imagem ser executada poucas horas após a semeadura. Portanto, neste momento, as sementes ainda não haviam iniciado o processo de germinação e a vegetação predominante na área era composta por aveia preta na fase de maturação.

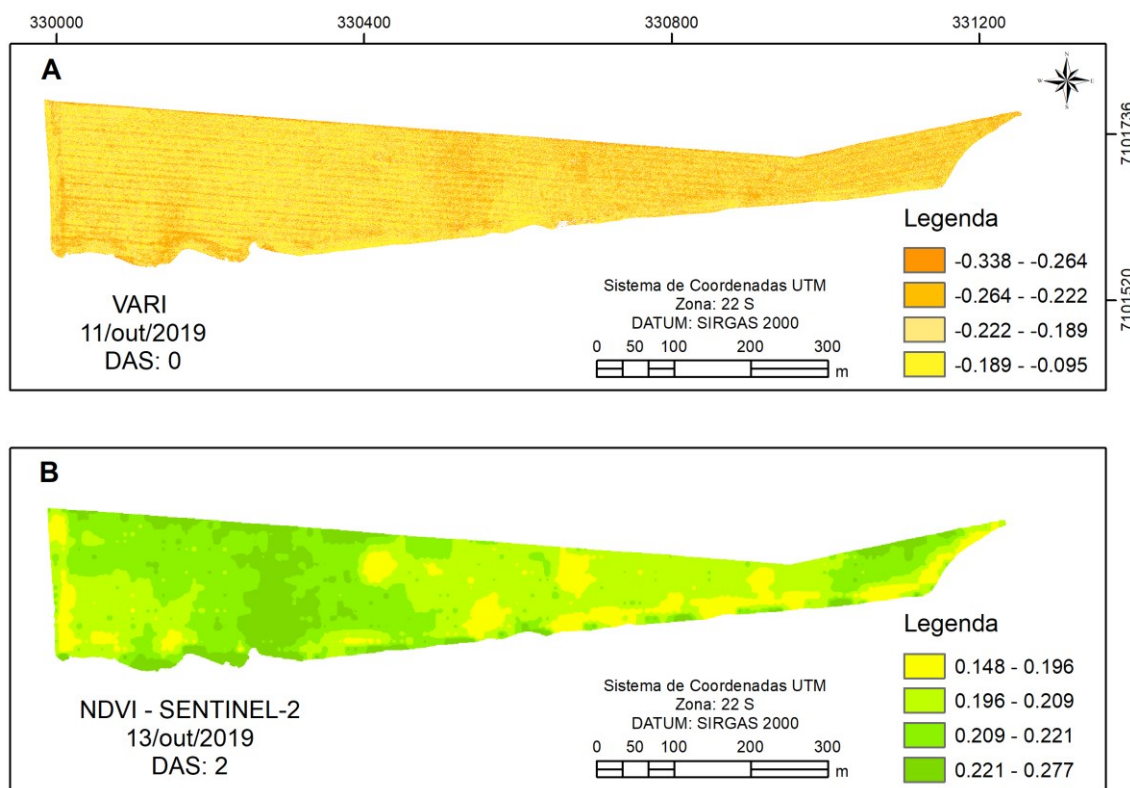
Em um trabalho realizado no estado Paraná, também houve essa descrição acerca dos valores. Os autores associaram os valores baixos ao período germinativo com o estado do plantio, pois, o mesmo ocorreu logo após o inverno,

que é quando a vegetação está seca e o solo está descoberto em sistemas convencionais, levando a uma baixa refletância (NEIVERTH et al., 2013). Esse fator demonstra a importância da cobertura do solo em todos os períodos de desenvolvimento da lavoura.

Para o NDVI extraído do Sentinel-2, no 2º Dia Após a Semeadura (DAS), obteve-se o índice médio de 0,209, com valor mínimo de 0,148 e valor máximo de 0,277 (Figura 7B). Nesta data, foi detectado a menor amplitude (0,129) nos valores de NDVI, uma vez que a soja ainda estava em condições semelhantes ao dia de semeadura e a palhada da aveia preta ainda estava predominante na área, possibilitando menor variabilidade nos valores encontrados.

No entanto, apesar da menor variabilidade, o Sistema de Plantio Direto (SPD) pode ter atenuado o solo exposto, pois, se a palhada de aveia não estivesse presente, esse valor poderia ser ainda menor. É importante frisar que esse manejo auxilia como isolante, minimizando a amplitude térmica do solo, o que ajuda na manutenção da água, filtrando a radiação solar e reduzindo o impacto das geadas, bem como na menor atuação de plantas daninhas (SANTOS et al., 2019). O SPD é uma ferramenta vantajosa e importante para implementação de plantios.

**Figura 7** – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido no dia da semeadura da soja. B) Índice NDVI (Sentinel-2) obtido aos dois dias após a semeadura (DAS).

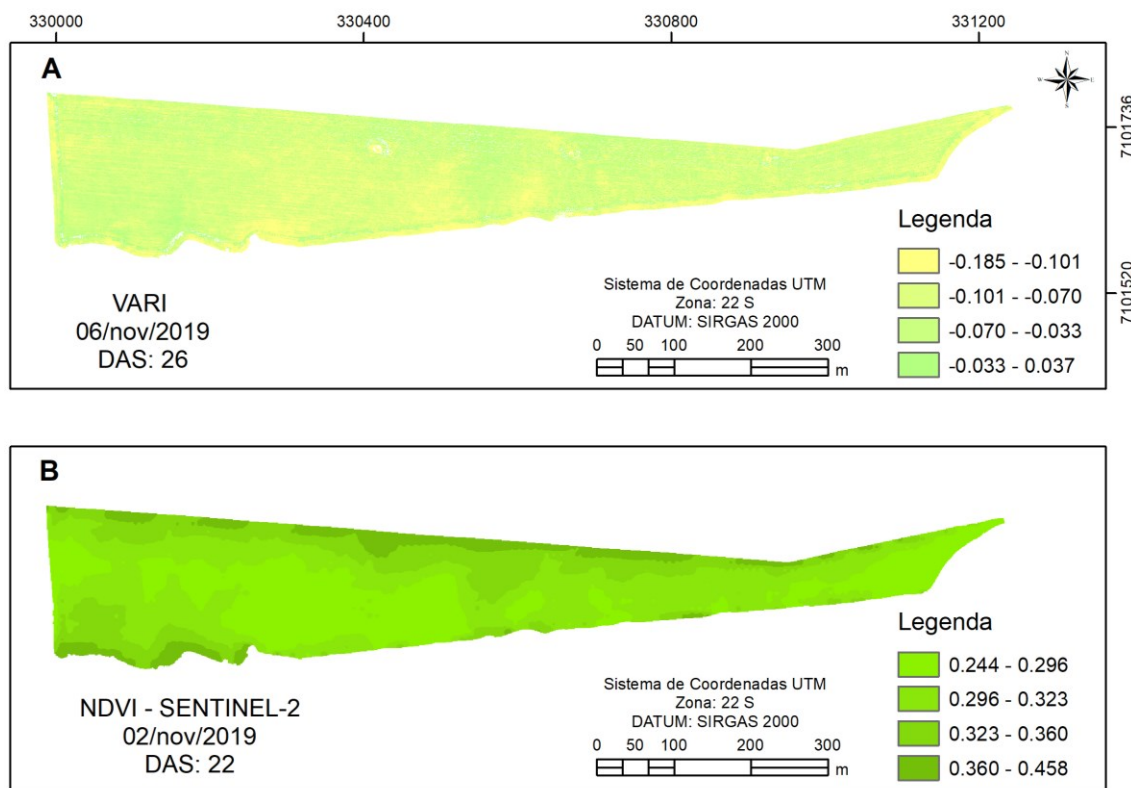


Fonte: autor (2021).

O padrão e escala de valores do NDVI diferem do VARI, apesar de teoricamente os dois índices apresentarem valores que variam de -1,0 a 1,0, o NDVI assume valores positivos, indicando superfícies com vegetação, e os maiores valores indicam maior vigor de crescimento. De forma prática, os valores que se encontram abaixo de 0,1 correspondem a corpos d'água e solo descoberto, enquanto que os valores acima desse parâmetro indicam a existência de atividade fotossintética associada principalmente a áreas de florestas e atividades agrícolas (MENESES-TOVAR, 2011; WEISS et al., 2004).

No imageamento executado aos 26 DAS, o VARI médio alcançado foi de -0,074, com valor mínimo de -0,185 e máximo de 0,037 (Figura 8A). Desta forma, evidenciou-se que os valores obtidos nesta fase apresentaram aumento discreto em relação ao índice obtido na data da semeadura, uma vez que a soja havia iniciado o seu desenvolvimento vegetativo. Neste período, o VARI apresentou a menor amplitude (0,222), permitindo inferir que a soja se desenvolveu de forma mais homogênea.

**Figura 8** – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 26 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 22 DAS.

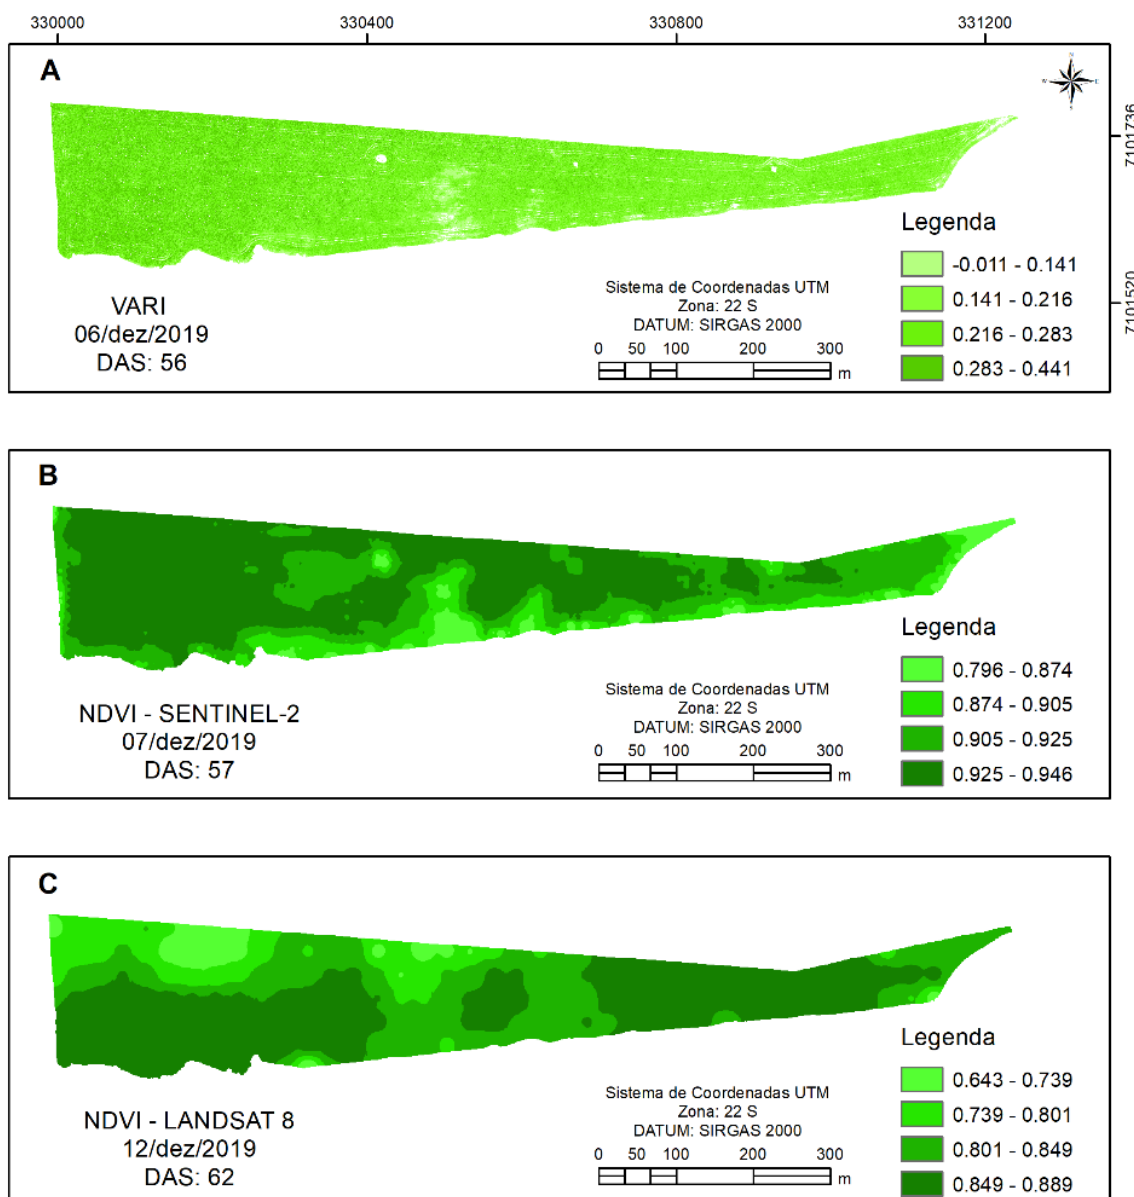


Fonte: autor (2021).

Para o NDVI (Sentinel-2) executado aos 22 DAS, obteve-se o valor médio de 0,313, com valor mínimo de 0,244 e valor máximo de 0,458 (Figura 8B). Nesta fase, notou-se evolução nos valores de NDVI, uma vez que as estruturas vegetativas da soja estavam mais desenvolvidas, permitindo identificar os perímetros com melhor e pior vigor vegetativo.

Para a imagem captada aos 56 DAS, o VARI médio obtido foi de 0,223, com valor mínimo de -0,011 e valor máximo de 0,441 (Figura 9A). Nesta fase, verificou-se a predominância de valores positivos, uma vez que a maior parte da vegetação alcançou o ápice do desenvolvimento vegetativo (V6) e estavam em transição para o estágio reprodutivo (R1).

**Figura 9** – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 56 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 57 DAS. C) Índice NDVI (Landsat 8) obtido aos 62 DAS.



Fonte: autor (2021).

No mapeamento executado aos 57 DAS, obteve-se o NDVI (Sentinel-2) médio de 0,921, com valor mínimo de 0,796 e valor máximo de 0,946 (Figura 9B). Neste momento, a lavoura apresentou a maior média e os maiores valores de NDVI devido ao fato de a maior parte da vegetação ter completado o seu estágio vegetativo e apresentar alto vigor no seu desenvolvimento.

Para os valores de NDVI (Landsat 8) medidos aos 62 DAS, obteve-se o valor médio de 0,833, valor mínimo de 0,643 e valor máximo de 0,889 (Figura 9C).



Para este sensor, apesar da diferença no dia de registro, também foram constatados os valores mais elevados deste índice, confirmando que o ápice do NDVI ocorreu aproximadamente no início da fase reprodutiva.

Ao estudarem a relação entre o comportamento espectral da cultura de soja ao longo de seu ciclo de desenvolvimento, através do NDVI, Rodrigues et al. (2013) constataram que a atividade fotossintética da soja é maior durante o final do estágio vegetativo, quando coincide os maiores valores de NDVI. Os resultados apontaram que este índice é um excelente parâmetro de evolução temporal de biomassa verde da soja ao longo do seu ciclo.

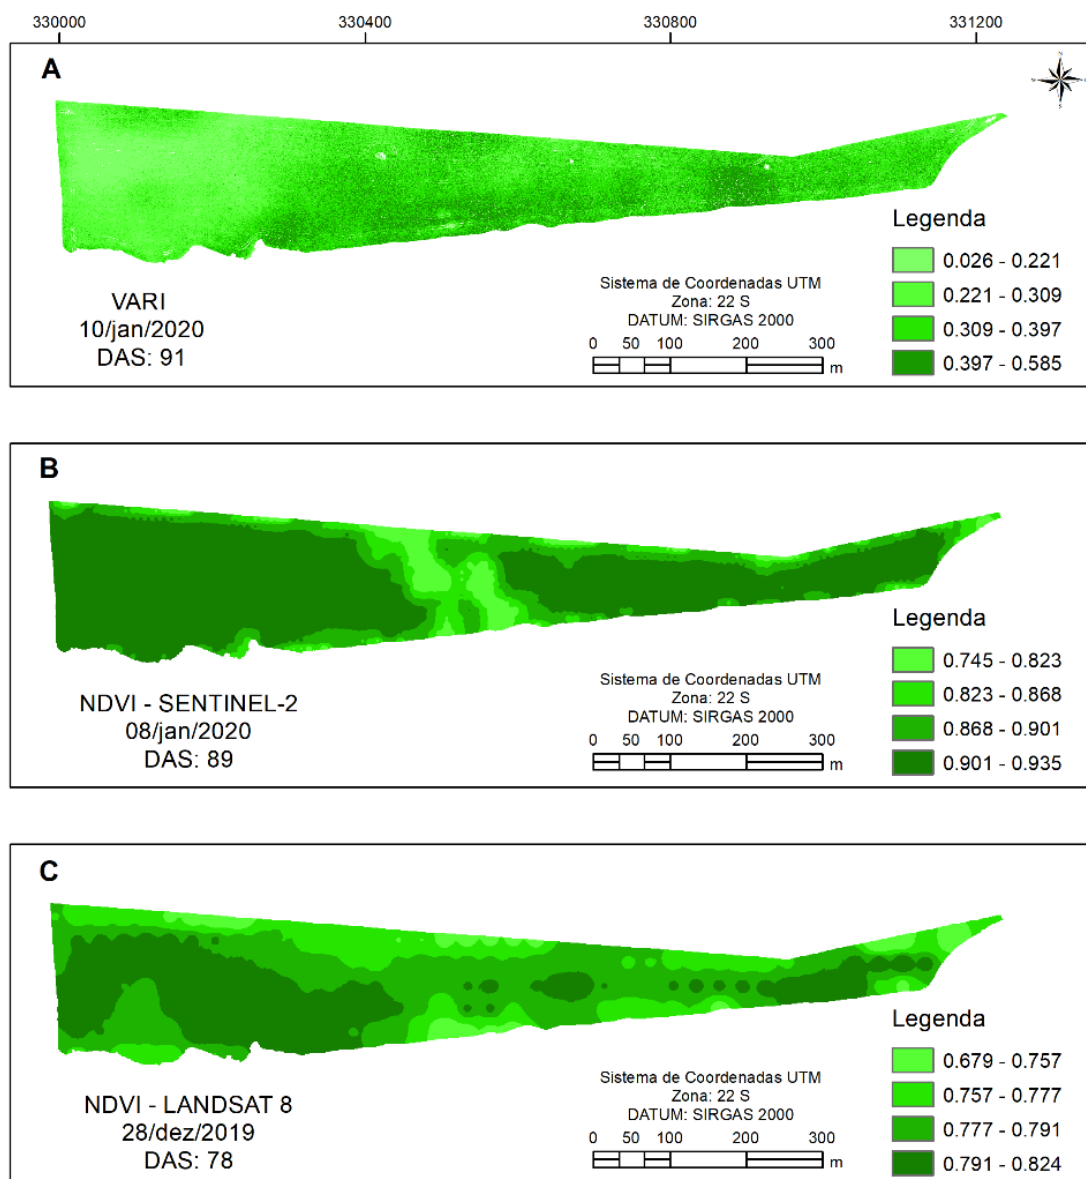
Neste âmbito, o NDVI aumenta conforme o crescimento da biomassa e da concentração de clorofila na estrutura foliar. As mudanças na concentração de clorofila podem ser associadas a alterações na fisiologia da vegetação bem como dos valores de NDVI (YODER; WARING, 1994; ESQUERDO et al., 2011).

Para o imageamento realizado aos 91 DAS, obteve-se o VARI médio de 0,313, com índice mínimo de 0,026 e máximo de 0,585 (Figura 10A). Neste período, foram constatados os maiores valores de VARI, onde a maior parte lavoura estava na fase reprodutiva, mais especificamente nas etapas de formação das vagens e enchimento dos grãos, entre os estádios R2 e R3. Também foi constatado a maior amplitude (0,559) nos valores do VARI, demonstrando maior diferença no estado de desenvolvimento da lavoura.

Para o NDVI (Sentinel-2) realizado aos 89 DAS, verificou-se o valor médio de 0,898, valor mínimo de 0,745 e valor máximo de 0,935 (Figura 10B). Para este período, ocorreu pequena redução em relação a imagem (Sentinel-2) anterior, ainda assim, apresentou índices elevados principalmente pelo fato da maior parte da lavoura se encontrar na fase de formação dos grãos.

Na imagem referente aos 78 DAS, obteve-se o NDVI (Lansat 8) médio de 0,782, valor mínimo de 0,679 e valor máximo de 0,824 (Figura 10C). Também foram constatados valores elevados, apesar de haver pequena redução quando comparado a imagem anterior, os valores se mantiveram estabilizados, demonstrando uma alta atividade fotossintética. Verificou-se também a menor amplitude (0,145) nos valores encontrados para este sensor, evidenciando menor variabilidade no estado de crescimento da vegetação.

**Figura 10** – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 91 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 89 DAS. C) Índice NDVI (Landsat 8) obtido aos 78 DAS.



Fonte: autor (2021).

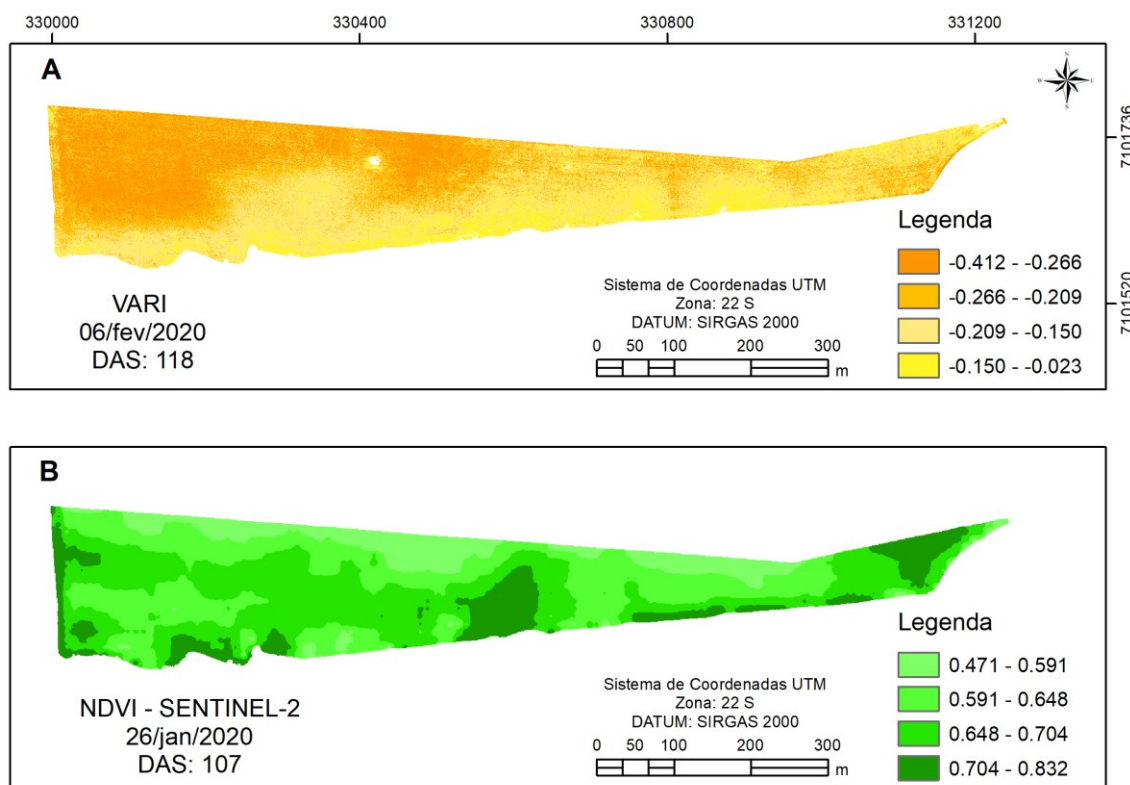
Ao compararem o potencial e o desempenho de três índices de vegetação usados para monitorar a variabilidade da soja, em Jaboticabal (SP), Carneiro et al. (2019) demonstraram haver saturação nos valores de NDVI aos 75 e 90 DAS (estágios R4 e R6), dispostos por conta do aumento da biomassa. Essas repostas estiveram dentro do intervalados de maiores valores de NDVI nesta pesquisa, pois, em que foram encontrados, entre a fase de floração e de enchimento de grãos.

No imageamento realizado aos 118 DAS, no dia da colheita (06/02/2020), o VARI médio obtido foi de -0,213, com valor mínimo de -0,412 e índice máximo de -0,023 (Figura 11A). Os baixos valores nessa fase ocorrem devido a soja está no último estágio de desenvolvimento ou maturação plena, onde 95% das vagens perdem a coloração verde e apresentam aspecto de vagens maduras.

Na fase final do desenvolvimento, a soja entra em senescência, ocorrendo a degradação natural da clorofila. A partir deste momento, as vagens e sementes vão perdendo a coloração verde e assumindo a coloração amarela, havendo também a queda gradativa das folhas (CÂMARA, 2006).

Em relação ao VARI, notou-se que os valores obtidos no momento da colheita foram muito semelhantes aos valores detectados no momento da semeadura, onde a vegetação predominante na área também estava em fase de maturação. Este fato demonstra que este índice apresenta o mesmo comportamento ou padrão quando a vegetação se encontra seca ou com coloração amarelada, que é característica da fase de maturação.

**Figura 11** – Mapa de distribuição dos índices de vegetação: A) Índice VARI obtido aos 118 dias após a semeadura (DAS). B) Índice NDVI (Sentinel-2) obtido aos 107 DAS.



Fonte: autor (2021).

Para o NDVI (Sentinel-2) executado aos 107 DAS, obteve-se o valor médio de 0,649, valor mínimo de 0,471 e valor máximo de 0,832 (Figura 11B). Notou-se maior redução nos índices, devido ao processo natural de desenvolvimento da soja, onde a mesma se encontrava no final do estágio reprodutivo. Neste período também ocorreu a maior variabilidade nos valores do índice, com amplitude de 0,361.

Neste sentido, em um estudo que analisou o NDVI de estádios fenológicos da soja, demonstrou que do estágio R6 ao R7, houveram redução de 19,08% no valor de NDVI que estava ascendente (NEIVERTH et al., 2013). Demonstrando resposta semelhantes a este estudo. Destaca-se que no estágio R7 as plantas exibem características de início de maturação, especialmente, o amarelecimento de vagens, assim, considera-se o início do estágio quando pelo menos uma vagem normal no caule apresenta coloração madura (EMBRAPA, 2010). Fator esse que auxilia no declínio de valores de NDVI.

De forma geral, o VARI apresentou crescimento gradativo com o

desenvolvimento fenológico da soja até o seu ápice, onde ocorre a maior atividade fotossintética e a maior concentração de clorofila. Para Guyot et al. (1989) na faixa espectral do visível, a reflectância da vegetação verde saudável está diretamente associada aos pigmentos fotossintéticos como a clorofila a e b, xantofilas, antocianinas e carotenoides, que absorvem as faixas espectrais do azul e do vermelho, refletindo em maior quantidade a faixa espectral do verde (PADOLFI et al., 2018).

De acordo com Casaroli et al. (2007), na soja, as variações respiratórias e os níveis fotossintéticos ocorrem de acordo com os estádios de desenvolvimento e as condições ambientais, em função da alteração na força dreno, na arquitetura e estrutura foliar do dossel vegetativo. O processo de expansão foliar está diretamente relacionado ao aumento da taxa fotossintética de forma gradativa durante o estágio vegetativo para o reprodutivo, alcançando valores máximos no período de enchimento de grãos.

Shibles e Weber (1965) constataram dois picos de atividade fotossintética: o primeiro devido ao pleno florescimento da soja, para atender o pegamento floral; o segundo, em função do início da granação, quando a presença de fotoassimilados é essencial para o desenvolvimento das vagens e dos grãos no seu interior.

O VARI, mesmo utilizando apenas o espectro do visível, apresenta grande potencial para o acompanhamento das condições da cultura da soja em campo e a identificação do seu estágio fenológico, uma vez que este índice é determinado principalmente pelas características do dossel da cultura, como conteúdo de clorofila, biomassa e a própria arquitetura do dossel (ZHAO et al., 2020). Sendo perfeitamente possível constatar o aumento e diminuição da reflectância na faixa do visível, à medida que a concentração de clorofila sofre variações na vegetação (GROSS et al., 2016).

Considerando as diferentes características dos sensores e as datas em que as imagens estão disponíveis para geração do NDVI, notou-se que para ambos os sensores (Landsat 8 e Sentinel-2) o comportamento temporal do NDVI foi caracterizado por baixos índices no início do desenvolvimento da cultura, com aumento gradativo até a fase de máximo acúmulo da biomassa e redução dos

valores próximos a fase de senescência.

Verificou-se que os valores de NDVI descreveram corretamente o desenvolvimento fenológico da soja, apresentando os índices característicos de cada estágio. Os resultados seguiram o padrão de outras pesquisas que buscaram analisar a fenologia da soja através do NDVI, onde a estabilização dos valores máximos do NDVI ocorreu a partir do início do florescimento até a fase de enchimento dos grãos, onde são constatados os maiores níveis de atividades fotossintéticas (FONTANA et al., 2019; CRUSIOL et al., 2013; NEIVERTH et al., 2013; FERRI et al., 2004).

Com isso, percebeu-se que os diferentes sensores e os índices de vegetação empregados nesta pesquisa, foram eficientes em captar os estágios de desenvolvimento da soja. Contudo, as principais dificuldades foram verificadas para os sensores orbitais, pois estes apresentam especificações próprias que prejudicam a aquisição de imagens em uma mesma data e estão naturalmente mais sujeitos aos fatores atmosféricos, enquanto que o sensor não orbital apresentou maior flexibilidade e está menos exposto às intempéries climáticas. Deste modo, pode-se inferir que o emprego de modo integrado dos sensores e dos índices de vegetação possibilita um diagnóstico mais robusto e preciso, expressado de forma assertiva o estado de desenvolvimento da lavoura.

## 4.2 Variabilidade espacial

### 4.2.1 Variabilidade espacial dos atributos químicos do solo

Considerando a classificação do coeficiente de variação (CV) proposta por Warrick e Nielsen (1980), foi observado que apenas a variável pH apresentou baixo CV (<12%). As variáveis MO, Ca, Mg e V% apresentaram CV médio (12 a 24%), enquanto que para o P, K e  $Al^{3+}$  foi verificado um CV alto (>24%) (Tabela 3).

**Tabela 3** – Estatística descritiva dos atributos químicas do solo em lavoura comercial de soja: MO (g dm<sup>-3</sup>), P (mg dm<sup>-3</sup>), K (cmol<sub>c</sub> dm<sup>-3</sup>), pH (CaCl<sub>2</sub>), Al<sup>3+</sup> (cmol<sub>c</sub> dm<sup>-3</sup>), Ca (cmol<sub>c</sub> dm<sup>-3</sup>), Mg (cmol<sub>c</sub> dm<sup>-3</sup>) e V%.

Estatística	Variáveis químicas do solo							
	MO	P	K	pH	Al <sup>3+</sup>	Ca	Mg	V%
Média	50,68	12,99	0,46	4,95	0,11	5,47	1,76	60,94
Mediana	49,59	11,85	0,44	5,00	0,00	5,50	1,70	62,77
Mínimo	29,48	4,08	0,23	4,00	0,00	3,10	1,00	41,30
Máximo	67,01	34,45	0,80	5,70	0,50	7,90	2,80	76,39
DP	7,41	5,75	0,14	0,41	0,15	1,00	0,35	8,73
CV	14,61%	44,30%	30,38%	8,36%	133,61%	18,37%	19,85%	14,33%
Assimetria	0,07	1,18	0,59	-0,36	1,13	-0,02	0,39	-0,42
Curtose	0,41	2,13	-0,27	-0,81	-0,02	-0,20	0,55	-0,83
p-valor	0,15 <sup>ns</sup>	0,01	0,01	0,01	0,01	0,15 <sup>ns</sup>	0,05 <sup>ns</sup>	0,04

<sup>ns</sup> não significativo pelo teste de Kolmogorov-Smirnov. Fonte: autor (2021).

Em relação aos coeficientes de assimetria e curtose, notou-se que as variáveis MO, K, pH, Ca, Mg e V% evidenciaram valores próximo de zero, mostrando que os dados tendem a distribuição normal (GREGO al., 2012; MION et al., 2012). Os resultados referentes ao teste Kolmogorov-Smirnov, indicaram que apenas as variáveis MO, Ca e Mg apresentaram distribuição normal. Para os outros atributos químicos avaliados, notou-se que o p-valor foi inferior ao nível de significância adotado (5%), rejeitando-se assim a hipótese de normalidade.

A maioria dos atributos químicos do solo expressaram dependência espacial. A única exceção foi verificada para a variável P que apresentou Efeito Pepita Puro (EPP), indicando, portanto, a ausência total de dependência espacial, deste modo, a distribuição espacial do P na área de estudo é aleatória e as amostras são independentes para a menor distância entre os pontos amostrados (Tabela 4) (VIEIRA, 2000).

A elevada variabilidade espacial do P na área em questão ocorreu, provavelmente, em decorrência da adubação localizada na linha de plantio e da forte interação deste elemento com os colóides do solo, o que faz com que este tenha baixa mobilidade vertical. Esta peculiaridade da adubação fosfatada, faz com que o P se acumule nas camadas superficiais, formando manchas de P que são difíceis de serem detectadas e/ou mapeadas (SOUSA; LOBATO, 2004; SILVA et al., 2008).

Deste modo, pode-se inferir que essa é a provável justificativa para a existência de manchas de P na lavoura e a grande variação em pequenas distâncias, o que impossibilitou modelar o semivariograma e encontrar dependência espacial para esse elemento. Corroborando com este fato, uma pesquisa sobre a

variabilidade espacial de atributos físico-químicos do solo em áreas de plantio direto de soja e Latossolo Vermelho-Escuro com textura média a argilosa, verificaram que o P expressou alto CV, apresentando também EPP (ALVES et al., 2014).

**Tabela 4** – Parâmetros dos semivariogramas ajustados para os atributos químicos do solo em lavoura comercial de soja: Efeito pepita ( $C_0$ ); Patamar ( $C_0+C$ ); Alcance ( $a$ ); Índice de Dependência Espacial (IDE); Coeficiente de determinação ( $r^2$ ); Soma de quadrados do resíduo (SQR).

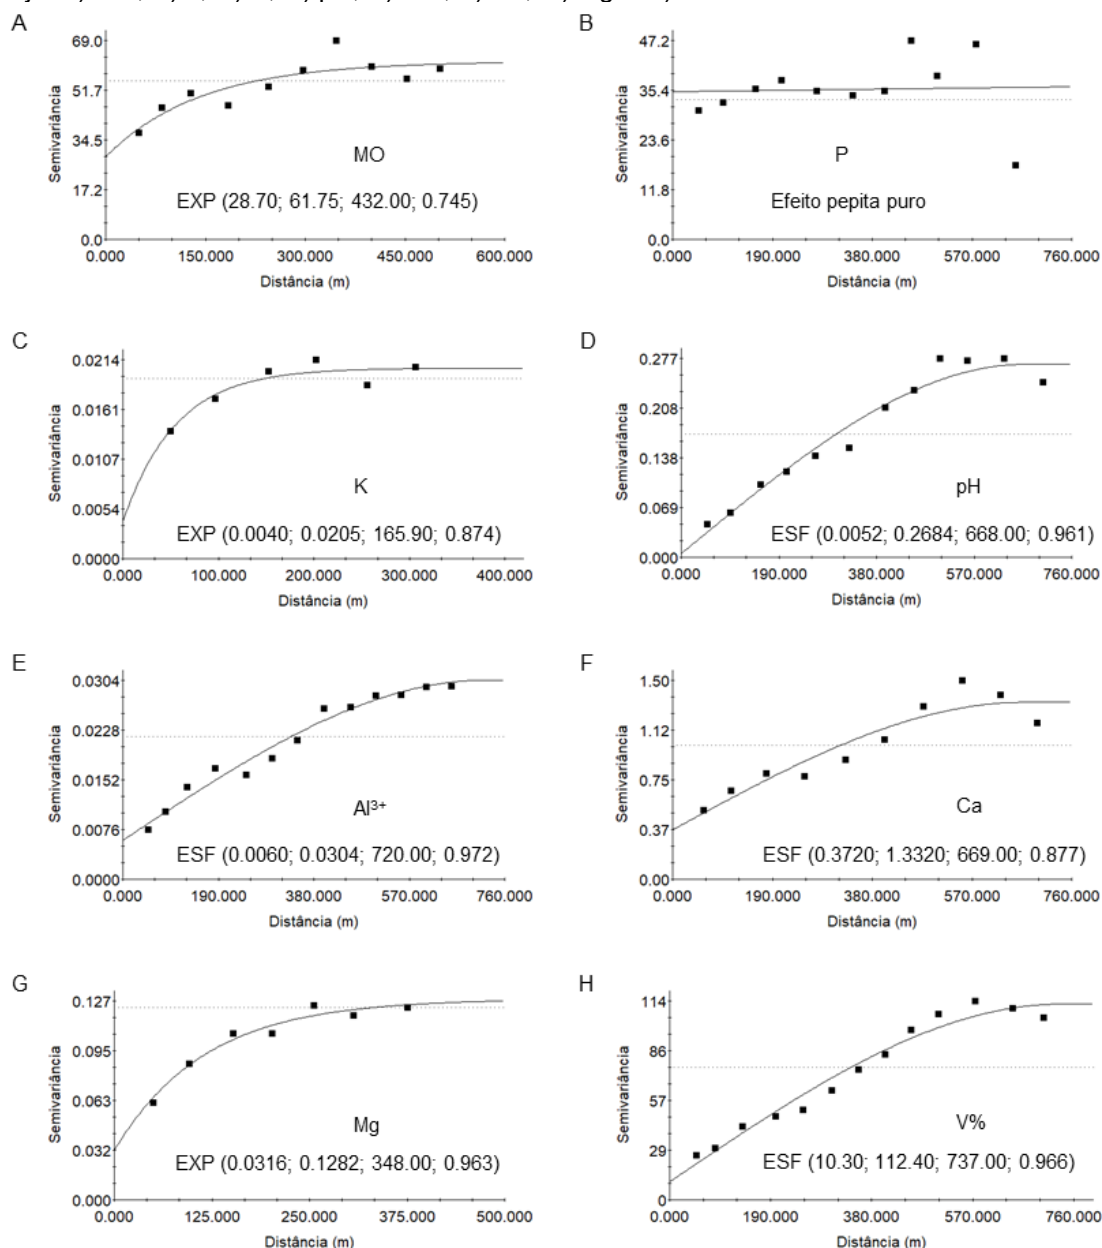
Variáveis químicas do solo	Parâmetros						
	Modelo	$C_0$	$C_0+C$	$a$ (m)	IDE	$r^2$	SQR
MO	Exponencial	28,70	61,75	432,00	Moderada	0,745	188,00
P	EPP	-	-	-	-	-	-
K	Exponencial	0,0040	0,0205	165,90	Forte	0,874	0,0000051
pH	Esférico	0,0052	0,2684	668,00	Forte	0,961	0,003115
Al <sup>3+</sup>	Esférico	0,0060	0,0304	720,00	Forte	0,972	0,000019
Ca	Esférico	0,3710	1,3340	668,00	Moderada	0,835	0,232
Mg	Exponencial	0,0316	0,1282	348,00	Forte	0,963	0,00011
V%	Esférico	10,30	112,40	737,00	Forte	0,966	408,00

Fonte: autor (2021).

Os semivariogramas ajustados mostraram patamar definido, demonstrando que a hipótese intrínseca foi satisfeita, com exceção para a variável P (Figura 12). Considerando a classificação de Cambardella et al. (1994), verificou-se que as variáveis K, pH, Al<sup>3+</sup>, Mg e V% apresentaram forte dependência espacial, enquanto, que a MO e o Ca expressaram dependência espacial moderada (Tabela 4).



**Figura 12** – Semivariogramas ajustados para os atributos químicos do solo em lavoura comercial de soja: A) MO, B) P, C) K, D) pH, E) Al<sup>3+</sup>, F) Ca, G) Mg e H) V%.



Fonte: autor (2021).

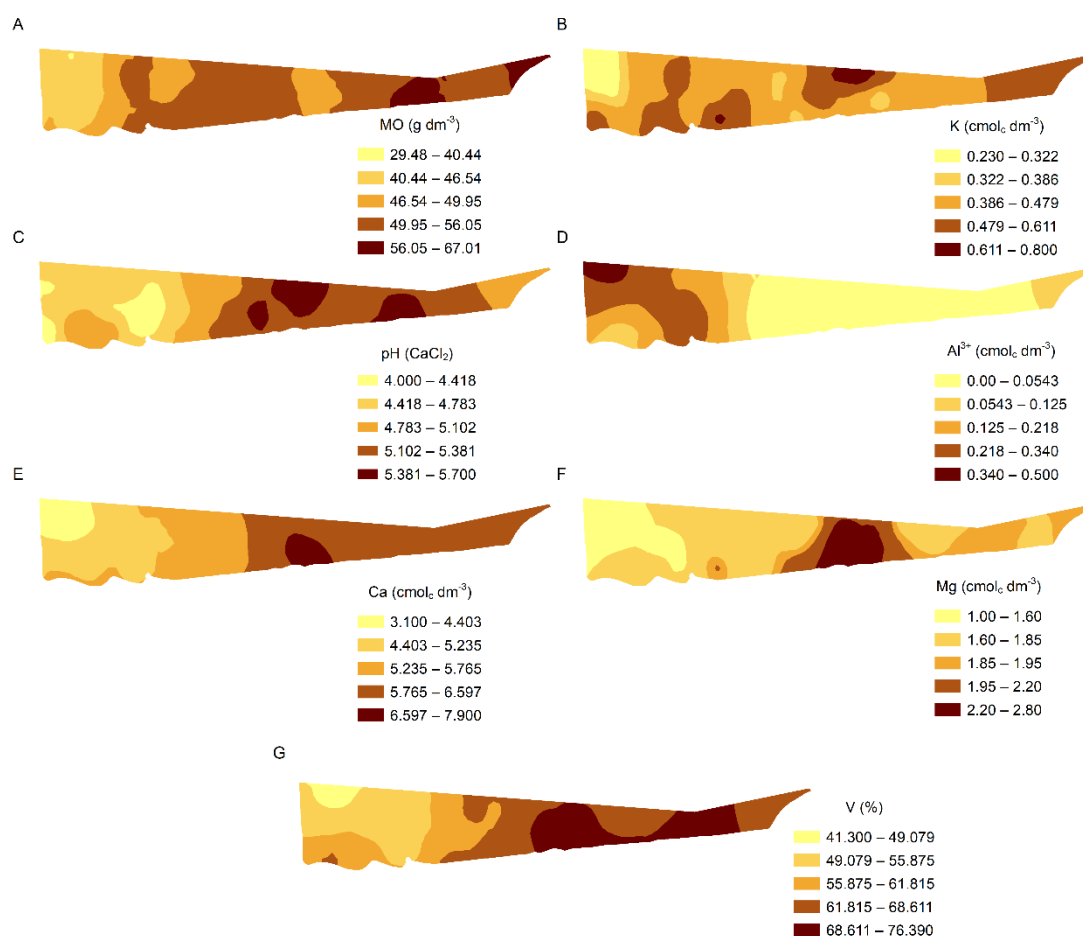
Para as variáveis MO, K, Mg o melhor modelo de semivariograma ajustado foi o exponencial, com os respectivos coeficientes de determinação ( $r^2$ ): 0,745, 0,874 e 0,963 (Figuras 12A, 12C e 12G). Enquanto, que para o pH, Al<sup>3+</sup>, Ca e V% o modelo mais adequado ao ajuste foi o esférico, apresentando os seguintes  $r^2$ : 0,961, 0,972, 0,877 e 0,966, respectivamente (Figuras 12D, 12E, 12F e 12H). Os modelos ajustados (esférico e exponencial) são coerentes, uma vez que em muitos

resultados de pesquisas relacionadas a variabilidade dos atributos químicos do solo, apresentam estes modelos com maior ocorrência (MATIAS et al., 2019; SILVA et al., 2017; DALCHIAVON et al., 2012; SILVA et al., 2008).

Em relação ao alcance da dependência espacial (a), notou-se que os menores valores ocorreram para as variáveis MO (432,00 m), K (165,90 m) e Mg (348,00 m) (Figuras 12A, 12C e 12G), respectivamente. Os maiores alcances foram verificados para os atributos pH (668,00 m),  $Al^{3+}$  (720,00 m), Ca (669,00 m) e V% (737,00 m) (Figuras 12D, 12E, 12F e 12H), respectivamente. O alcance define a distância máxima ou o raio máximo em que os valores de um determinado atributo apresentam dependência espacial, e quando os limites são maiores que o alcance, a variável passa a apresentar comportamento espacial completamente aleatório (LOPES et al., 2020; DALCHIAVON et al., 2017).

A MO apresentou média de 50,68 g dm<sup>-3</sup>, com valor mínimo de 29,48 g dm<sup>-3</sup> e máximo de 67,01 g dm<sup>-3</sup>. O maior perímetro da lavoura demonstrou teores de MO acima de 46,54 g dm<sup>-3</sup> (Figura 13A). O Sistema Plantio Direto (SPD) é o principal responsável pelos níveis de MO existente na área, visto que essa técnica de cultivo está sendo executada há mais de 20 anos no local, sendo empregada a aveia preta como planta de cobertura durante o inverno.

**Figura 13** – Mapa de distribuição espacial dos atributos químicos do solo em lavoura comercial de soja: A) MO, B) K, C) pH, D)  $Al^{3+}$ , E) Ca, F) Mg G) V%.



Fonte: autor (2021).

O P apresentou valor médio de 12,99 mg dm<sup>-3</sup>, a qual é considerada alta para a cultura da soja (PAVINATO et al., 2017), contudo, em razão da alta variabilidade desse nutriente na lavoura, foram detectados perímetros com valores muito altos e muito baixos, fato este que foi comprovado pela descontinuidade espacial desse nutriente, visto que sua distribuição ocorreu de forma totalmente aleatória.

O K apresentou média de 0,46 cmol<sub>c</sub> dm<sup>-3</sup>, com valor mínimo de 0,23 cmol<sub>c</sub> dm<sup>-3</sup> e máximo de 0,80 cmol<sub>c</sub> dm<sup>-3</sup> (Figura 13B). Para esse nutriente, obteve-se o valor médio considerado alto para a cultura da soja (PAVINATO et al., 2017). Notou-se também que a maior parte da lavoura foi compreendida por teores mais elevados (>0,386 cmol<sub>c</sub> dm<sup>-3</sup>), enquanto os menores valores (<0,386 cmol<sub>c</sub> dm<sup>-3</sup>) ocorrem em menor proporção na área de cultivo.

Para o pH em  $\text{CaCl}_2$  foi verificado valor médio de 4,95, com valor mínimo de 4,0 e máximo de 5,7. Notou-se que na maior porção da lavoura foi evidenciado teores de pH entre 4,78 e 5,7 (Figura 13C). Percebeu-se também que a maior parte da lavoura apresentou valores de pH considerados médios e altos (PAVINATO et al., 2017). Para Seixas et al. (2020), o intervalo de pH ( $\text{CaCl}_2$ ) que permite um melhor aproveitamento dos nutrientes no solo e a insolubilização do alumínio tóxico, está compreendido entre 5,4 e 5,8.

O  $\text{Al}^{3+}$  apresentou média de  $0,11 \text{ cmol}_c \text{ dm}^{-3}$ , com valor mínimo de  $0,0 \text{ cmol}_c \text{ dm}^{-3}$  e máximo de  $0,5 \text{ cmol}_c \text{ dm}^{-3}$ . Para o alumínio trocável, verificou-se valores baixos (PAVINATO et al., 2017), onde a maior parte da área de cultivo apresentou valores iguais ou próximos a zero (Figura 13D). Constatou-se também, que os menores teores de  $\text{Al}^{3+}$  coincidiram com os perímetros onde foram observados os maiores valores de pH e maior saturação por base.

Em relação a saturação por base foi verificado valor médio de 60,94%, com mínimo de 41,30% e máximo de 76,39%. Para esse atributo, observou-se que a maior porção da área expressou valores acima de 55,88% (Figura 13G), coincidindo com os perímetros de maior pH e menor teor de  $\text{Al}^{3+}$ .

O cálcio expressou média de  $5,47 \text{ cmol}_c \text{ dm}^{-3}$ , com valor mínimo  $3,10 \text{ cmol}_c \text{ dm}^{-3}$  e de máximo de  $7,90 \text{ cmol}_c \text{ dm}^{-3}$ . Os maiores teores de Ca foram constatados nos locais onde ocorreram os maiores níveis de MO, pH e V%, coincidindo também com os perímetros com menor nível de  $\text{Al}^{3+}$ .

Para o magnésio foi encontrado o valor médio de  $1,76 \text{ cmol}_c \text{ dm}^{-3}$ , com mínimo  $1,00 \text{ cmol}_c \text{ dm}^{-3}$  e de máximo de  $2,80 \text{ cmol}_c \text{ dm}^{-3}$ . Para esse elemento, notou-se que na maior porção da lavoura foi evidenciado teores acima de  $1,60 \text{ cmol}_c \text{ dm}^{-3}$ . Também foi constatado que os maiores valores de Mg ocorreram nas áreas que apresentaram maior MO, pH, V% e com menor nível de alumínio trocável.

De modo geral, foi possível constatar que a área da lavoura apresentou boas condições químicas para o cultivo da soja, especialmente na porção leste da propriedade, onde foram observados os maiores níveis de MO, K, Ca, pH, V% e menor teor de  $\text{Al}^{3+}$ . Também é importante ressaltar a possibilidade de identificar os perímetros em que podem ser realizadas correções localizadas a fim de homogeneizar as condições de fertilidade do solo e permitir melhor resposta na

produtividade da lavoura.

#### 4.2.2 Variabilidade espacial da produtividade da soja

As variáveis número de vagem por planta (NV), número de grãos por planta (NG), número de sementes por vagem (NS) e peso de mil grãos (PMG) apresentaram baixo CV (<12%), enquanto que para a Produtividade foi registrado CV médio (12 a 24%) (WARRICK; NIELSEN, 1980). De forma geral, os valores de CV encontrados (baixo e médio) indicam que os componentes avaliados expressaram baixa e média variabilidade na área de cultivo (Tabela 5).

**Tabela 5** – Estatística descritiva dos componentes de rendimento da soja em lavoura comercial: vagem por planta (NV Planta<sup>-1</sup>), número de grãos por planta (NG Planta<sup>-1</sup>), número de sementes por vagem (NS Vagem<sup>-1</sup>) e peso de mil grãos (PMG) e Produtividade (Prod).

Parâmetros	Componentes de rendimento da soja				
	NV Planta <sup>-1</sup>	NG Planta <sup>-1</sup>	NS Vagem <sup>-1</sup>	PMG	Prod (kg ha <sup>-1</sup> )
Média	35,65	92,46	2,59	180,90	5649,58
Mediana	35,20	91,30	2,59	180,14	5606,02
Mínimo	28,00	75,90	2,46	166,73	3385,82
Máximo	44,50	118,20	2,73	197,52	7769,95
DP	3,65	9,72	0,06	8,25	815,09
CV	10,24%	10,52%	2,34%	4,56%	14,43%
Assimetria	0,24	0,43	0,17	0,17	0,25
Curtose	-0,42	-0,23	-0,47	-0,81	0,76
p-valor	0,150 <sup>ns</sup>	0,150 <sup>ns</sup>	0,150 <sup>ns</sup>	0,150 <sup>ns</sup>	0,150 <sup>ns</sup>

<sup>ns</sup> não significativo pelo teste de Kolmogorov-Smirnov. Fonte: autor (2021).

Para todas as variáveis analisadas foi constatado que os coeficientes de assimetria e curtose demonstraram valores próximos a zero, indicando que os dados tendem a distribuição normal (GREGO al., 2012; MION et al., 2012). Estes resultados foram confirmados pelo teste de Kolmogorov-Smirnov a 5% de significância, onde foi constatado que todos os componentes apresentaram distribuição normal.

Os modelos de ajustes para os semivariogramas exibiram patamar bem definido, confirmando que a hipótese intrínseca foi satisfeita para todas as variáveis avaliadas (Figura 14). De acordo com Cambardella et al. (1994), notou-se que todos os componentes de rendimento apresentaram Índice de Dependência Espacial (IDE) moderado (Tabela 6).

Para todas as variáveis, o melhor modelo de semivariograma ajustado foi o esférico, onde os maiores  $r^2$  foram verificados para os componentes Prod (0,934), NV (0,909), NG (0,899) e PMG (0,874). O menor valor foi evidenciado para o NS (0,695). Resultados semelhantes foram verificados no trabalho realizado por Dalchiavon et al. (2011), onde a maioria dos componentes de rendimento da soja apresentaram o modelo esférico como melhor opção de ajuste e expressaram dependência espacial moderada.

**Tabela 6** – Parâmetros dos semivariogramas para os componentes de rendimento da cultura da soja cultivada em lavoura comercial: Efeito pepita ( $C_0$ ); Patamar ( $C_0+C$ ); Alcance (a); Índice de Dependência Espacial (IDE); Coeficiente de determinação ( $r^2$ ); Soma de quadrados do resíduo (SQR).

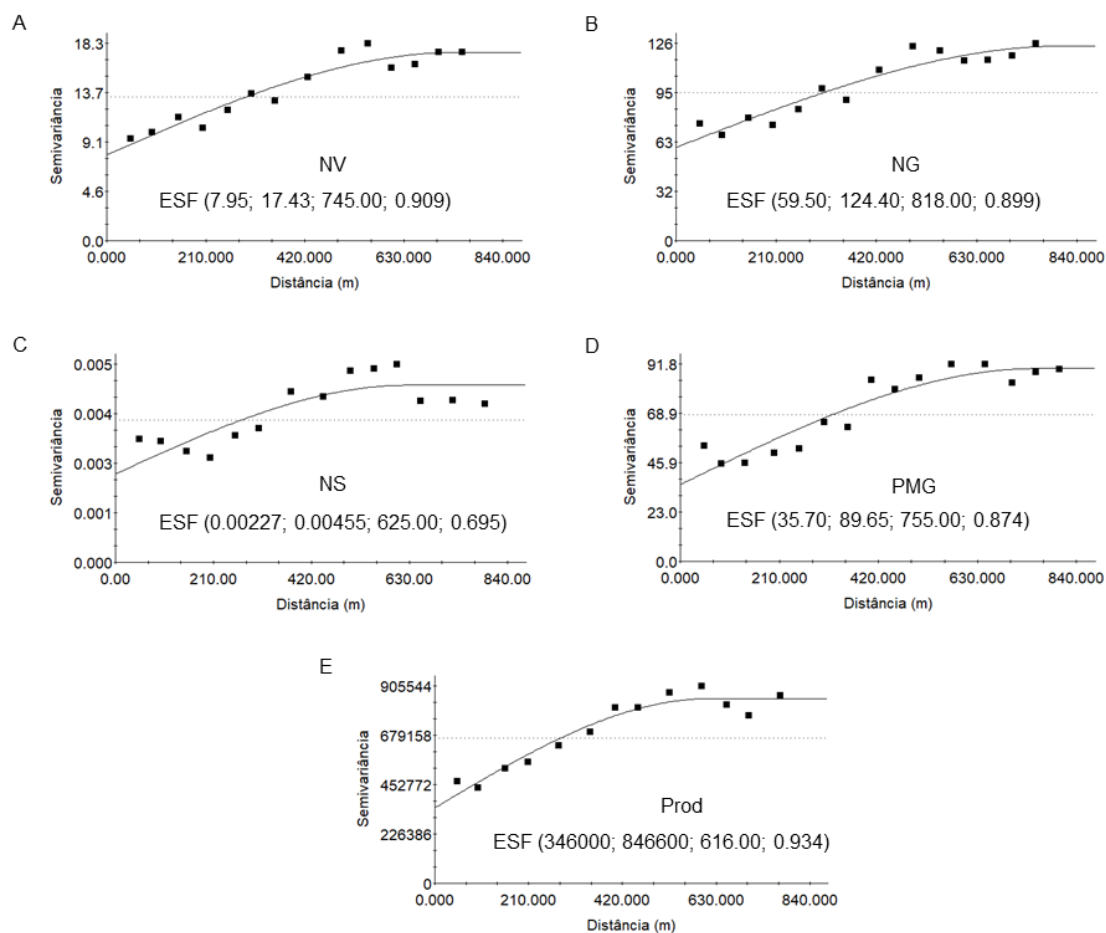
Componentes de rendimento da soja	Parâmetros						
	Modelo	$C_0$	$C_0+C$	a (m)	IDE	$r^2$	SQR
NV Planta <sup>-1</sup>	Esférico	7,95	17,43	745,00	Moderada	0,909	11,40
NG Planta <sup>-1</sup>	Esférico	59,50	124,40	818,00	Moderada	0,899	584,00
NS Vagem <sup>-1</sup>	Esférico	0,00227	0,004554	625,00	Moderada	0,695	2,6E-06
PMG	Esférico	35,70	89,65	755,00	Moderada	0,874	574,00
Prod (kg ha <sup>-1</sup> )	Esférico	346000	846600	616,00	Moderada	0,934	2,091

Fonte: autor (2021).

Para o alcance, verificou-se que os menores valores ocorreram para as variáveis Prod (616,00 m) e NS (625,00m). Os componentes NG (818,00 m), PMG (755,00 m) e NV (745,00 m) apresentaram os maiores alcances. O alcance apresenta grande importância no planejamento e avaliação da pesquisa, determinando o limite da dependência espacial e contribuindo na definição dos procedimentos amostrais (LONDERO et al., 2020).

Neste âmbito, os valores de alcance podem influenciar na qualidade das estimativas realizadas por meio de interpolação por krigagem. Portanto, estimativas executadas com maiores alcances tentem a ser mais confiáveis para fins práticos, uma vez que resultam em mapas que melhor representam a realidade do perímetro estudado (DALCHIAVON et al., 2017; CORÁ et al., 2004).

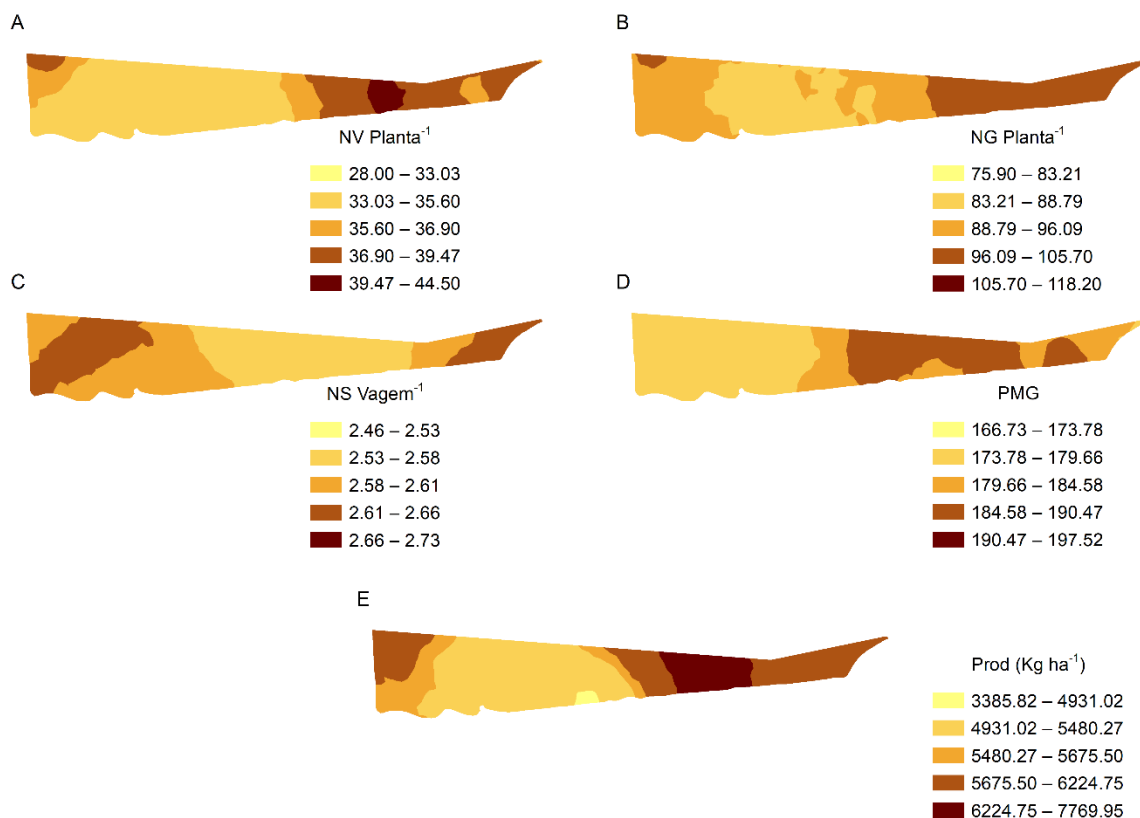
**Figura 14** – Semivariogramas ajustados para os componentes de rendimento da cultura da soja: A) número de vagens por planta (NV Planta<sup>-1</sup>), B) Número de grãos por planta (NG Planta<sup>-1</sup>), C) Número de sementes por vagem (NS Vagem<sup>-1</sup>), D) Peso de mil grãos (PMG) e E) Produtividade (Prod).



Fonte: autor (2021).

Para o componente NV por planta foi verificado valor médio de 35,65, com mínimo de 28,00 e máximo de 44,50. Notou-se que a maior parte da área apresentou valores acima de 33,03 (Figura 15A). Prestes Junior (2020) em um experimento realizado com a mesma cultivar de soja (PIONEER 95R51) em um Latossolo Vermelho com condições de cultivo semelhantes, registrou média de 48,88 vagens por planta.

**Figura 15** – Mapa de distribuição espacial dos componentes de rendimento da soja cultivada em lavoura comercial: A) número de vagens por planta (NV Planta<sup>-1</sup>), B) Número de grãos por planta (NG Planta<sup>-1</sup>), C) Número de sementes por vagem (NS Vagem<sup>-1</sup>), D) Peso de mil grãos (PMG) e E) Produtividade (Prod).



Fonte: autor (2021).

A variável NG por planta apresentou média de 92,46, com valor mínimo de 75,90 e máximo de 118,20. Observou-se ainda que na maior parte da lavoura foi verificado valores acima de 88,79, principalmente na porção leste, onde foi constatado as melhores condições de fertilidade do solo (Figura 15B).

O componente NS por vagem apresentou média de 2,59, valor mínimo de 2,46 e máximo de 2,73. Esta variável, apresentou a menor variabilidade na lavoura, quando comparado aos outros componentes de rendimento (Figura 15C). Este comportamento é evidenciado em muitas pesquisas, apresentando em média dois grãos por vagem, dependendo das propriedades genéticas de cada variedade associada as condições de cultivo (SILVA, 2017; LOVERA, 2015; DALCHIAVON; CARVALHO, 2012).

Para o componente PMG foi verificado o valor médio de 180,90 g, com mínimo de 166,73 g e máximo de 197,52 g. Observou-se que a maior porção da



lavoura expressou valores acima de 179,66 g, especialmente nos perímetros leste, coincidindo com os componentes NV, NG e Prod.

Para a variável Prod foi mensurado valor médio de 5.649,58 kg ha<sup>-1</sup>, com mínimo de 3.385,82 kg ha<sup>-1</sup> e máximo de 7.769,95 kg ha<sup>-1</sup>. Notou-se também que em maior parte da lavoura foi constatado valores acima de 5.480,27 kg ha<sup>-1</sup> (Figura 15E). A produtividade apresentou a maior variação, quando comparado aos demais componentes de rendimento, com amplitude de 4.384,13 kg ha<sup>-1</sup>.

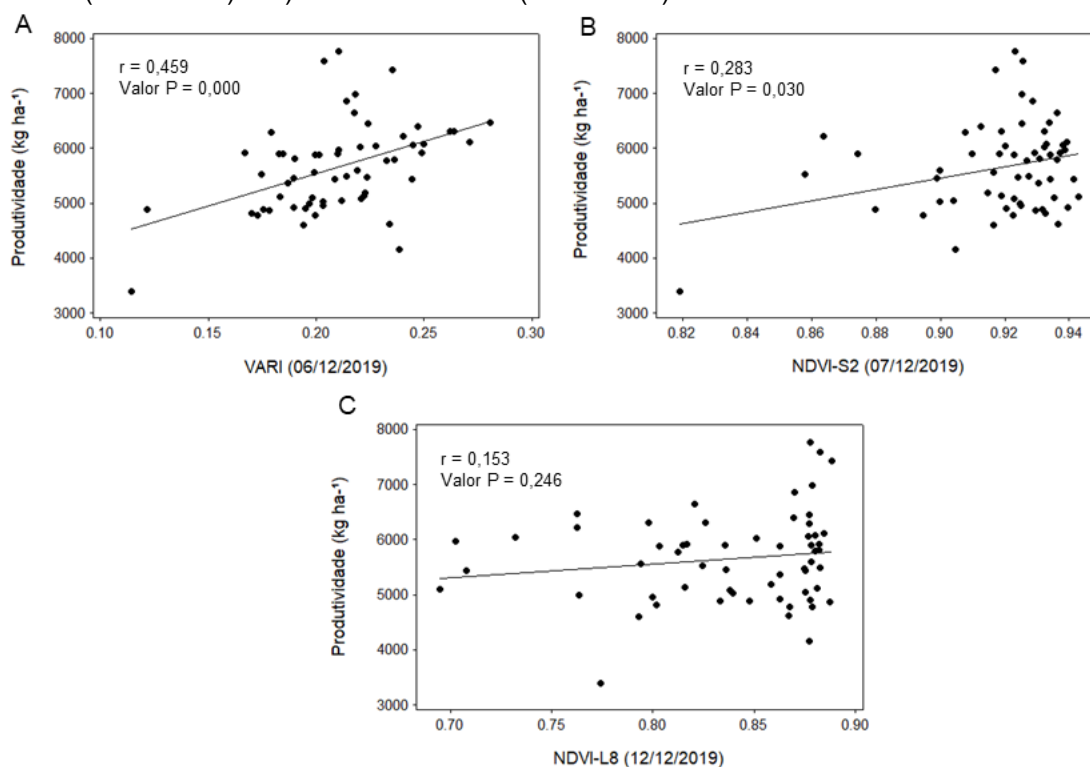
O valor médio para esse componente está acima da produtividade média mensurada para o Estado do Paraná (3.925 kg ha<sup>-1</sup>) na safra de 2019/2020 (CONAB, 2020). Neste contexto, Oligini (2019) em pesquisa executada em Dois Vizinhos, PR, com solos e clima semelhantes, empregando três cultivares de soja (P95R51, P95Y52 e P96Y90) durante a safra de 2016/2017, registrou produtividade média de 5.881,09 kg ha<sup>-1</sup>. Com isso, pode-se inferir que os resultados de produtividade estimados para esta pesquisa estão de acordo com os níveis obtidos para mesma região.

Cabe ressaltar que os resultados das interpolações demonstraram a relação dos componentes de rendimento da soja com as variáveis químicas do solo, onde foi verificado que na área leste da propriedade, que apresentou melhores condições de fertilidade, também foram evidenciados os maiores valores de NV, NG, PMG e Prod. A partir disso, deve-se considerar que mapear os perímetros com maior e menor produtividade são procedimentos essenciais, pois possibilita melhorias pontuais na lavoura, tornado o processo produtivo mais eficiente.

#### 4.3 Correlação entre os índices de vegetação e produtividade da soja

Considerando a classificação de Dancey e Reidy (2006), constatou-se que a produtividade apresentou correlação moderada ( $r = 0,459$ ) com o VARI (06/12/2019) (56 DAS) e fraca ( $r = 0,283$ ) com o NDVI - Sentinel-2 (07/12/2019) (57 DAS), contudo ambas apresentaram significância ( $p < 0,05$ ). Já a correlação com o NDVI - Landsat 8 (12/12/2019) (62 DAS) não foi significativa ( $p > 0,05$ ), expressando, portanto, correlação muito fraca ou inexistente ( $r = 0,153$ ) (Figura 16).

**Figura 16** – Correlação de Pearson ( $r$ ) e diagrama de dispersão das amostras da produtividade da soja cultivada em lavoura comercial e dos índices de vegetação: A) VARI (06/12/2019), B) NDVI – Sentinel-2 (07/12/2019) e C) NDVI – Landsat 8 (12/12/2019).



Fonte: autor (2021).

O NDVI extraído do satélite Landsat 8 (12/12/2019) apresentou a menor correlação com produtividade, este fato pode ter ocorrido devido as próprias características deste sensor (Figura 1C), uma vez que as imagens provenientes deste equipamento apresentam baixa resolução espacial (30 m), onde cada pixel abrange uma área de 900 m<sup>2</sup>, proporcionando um diagnóstico menos preciso, principalmente em áreas de menor escala.

Para a correlação entre a produtividade da soja e o NDVI gerado do Sentinel-2 (07/12/2019), verificou-se uma correlação fraca, porém, maior que a relação obtida para o Landsat 8 (Figura 1B). Este comportamento também pode estar relacionado com a resolução espacial deste sensor (10 m), em que cada pixel abrange uma de 100 m<sup>2</sup>. Essas especificações permitiram uma melhor análise da área, detectando as variações no vigor da vegetação com maior eficiência, quando comparado ao Landsat 8.

A correlação da produtividade com o VARI extraído do sensor RGB (06/12/2019) expressou o maior valor, sendo considerada média (Figura 1A). A maior

correlação evidenciada para a produtividade e o VARI pode ser justificada pela alta resolução do sensor (4,0 cm por pixel), que melhor captou as variações no vigor da lavoura, podendo ser associados com maior exatidão às estimativas de produtividade.

Corroborando com estes resultados, uma pesquisa que avaliou as relações entre índices de vegetação, extraído do sensor Hyperion/EO-1, e a produtividade de três variedades de soja, foi verificado a correlação de  $r = 0,32$  do VARI com a produtividade da soja, evidenciando valor superior a correlação do NDVI com a produtividade ( $r = 0,12$ ) (GALVÃO et al., 2009).

Em estudo semelhante, que objetivou avaliar o desempenho de diferentes IV quando correlacionados com a produtividade de soja, utilizando sensores RGB e NIR de alta resolução acoplados a VANT, constatou-se que o VARI expressou melhor desempenho em estimar produtividade de soja quando comparado aos outros IV testados, apresentando correlação superior ao NDVI (PRESTES et al., 2020).

Gerke (2017) verificou comportamento semelhante ao estimar a produtividade do trigo empregando sensor de alta resolução espacial RGB e NIR, acoplados em VANT. Destaca-se que a pesquisa em questão constatou que as maiores correlações da produtividade foram verificadas com os dados das imagens provenientes do sensor RGB, expressando valor superior ao sensor NIR e ao NDVI.

Com isso, considerando todos os dados apresentados, pode-se inferir que a utilização de sensores RGB associados a VANT na agricultura representa uma estratégia eficiente, de baixo custo e que apresenta grandes potencialidades em descrever os estados de desenvolvimento e em estimar a produtividade em lavoura de soja.

## 5 CONCLUSÕES

O VARI gerado a partir do sensor RGB demonstrou grande potencial para o monitoramento e identificação dos estádios fenológicos da soja, uma vez que os valores deste índice foram determinados, principalmente, pelas variações na concentração de clorofila característica das diferentes fases de desenvolvimento da vegetação, expressando corretamente a fase inicial, o ápice e a etapa final.

O NDVI extraído dos sensores orbitais (Landsat 8 e Sentinel-2) expressou comportamento semelhante, sendo definido por valores baixos na fase inicial do crescimento da soja, com aumento gradativo até a fase de maior concentração da biomassa e redução dos índices próximos a fase de senescência. Para estes sensores foram encontradas dificuldades operacionais em razão das suas configurações, que dificultaram a aquisição de imagens em períodos próximos e estão sujeitas às condições atmosféricas.

Os atributos químicos do solo, com exceção do P, apresentaram dependência espacial. O K, pH,  $Al^{3+}$ , Mg e V% demonstraram forte dependência espacial, enquanto que a MO e o Ca expressaram dependência espacial moderada. De forma geral, a área em estudo apresentou boas condições de fertilidade, especialmente na porção leste, onde ocorreram os maiores níveis de MO, K, Ca, pH, V% e menor teor de  $Al^{3+}$ .

Todos os componentes de rendimento da soja (NV, NG, NS, PMG e Prod) apresentaram dependência espacial moderada. Os maiores valores de NV, NG, PMG e Prod ocorreram na porção leste da lavoura, coincidindo com os perímetros que evidenciaram melhores níveis de fertilidade do solo.

O VARI gerado com o sensor RGB (06/12/2019) apresentou melhor correlação com a produtividade da soja, quando comparado ao NDVI gerado a partir do Sentinel-2 (07/12/2019) e do Landsat 8 (12/12/2019). Este fato pode ser justificado pela maior precisão e eficiência da câmera RGB em detectar as variações no vigor da vegetação.

## 6 CONSIDERAÇÕES FINAIS

De modo geral, os IV gerados a partir dos sensores orbitais e não orbital, foram eficientes em monitorar o desenvolvimento da lavoura. Contudo, a utilização da câmera RGB associada ao VANT demonstrou maior eficiência, pois apresentaram flexibilidade e praticidade no uso, além de resultar em imagens de boa qualidade e alto nível de detalhamento da vegetação. Já, para os satélites (Landsat 8 e Sentinel-2), foram encontradas maiores dificuldades, uma vez que estas ferramentas apresentam resolução temporal diferente e estão sujeitas as interferências atmosféricas, que em muitos casos, causam a inutilização de algumas imagens.

A melhor correlação da produtividade da soja com o VARI gerado com a câmera RGB representa um passo importante com grandes potencialidades para pesquisas posteriores, pois estes equipamentos possuem alta resolução, menor custo quando comparado aos sensores que utilizam a faixa espectral do NIR e, geralmente, estas câmeras já são associadas aos VANTs diretamente de fábrica, tornando sua utilização mais prática e eficiente. Este fato é promissor e apresenta grande importância, pois demonstra que sensores RGB podem ser utilizados no monitoramento agrícola de forma eficiente.

Como complementação deste estudo, sugere-se pesquisas futuras que busquem avaliar a correlação da produtividade da soja ou outras culturas agrícolas por meio de sensores RGB e NIR com especificações semelhantes acoplados ao VANT, pois será possível gerar diversos IV em diferentes fases de desenvolvimento da lavoura e com condições parecidas, podendo confirmar os IV e as faixas espectrais que melhores são associadas a produtividade.

Destaca-se que estudos como este apresentam grande importância para os agricultores, uma vez que os resultados dessas pesquisas servem como retorno para melhorar o processo produtivo, proporcionando inúmeros benefícios para a lavoura.

## REFERÊNCIAS

- AFDHALIA, F. et al. Detection of rice varieties based on spectral value data using UAV-based images. In: **Sixth International Symposium on LAPAN-IPB Satellite**. International Society for Optics and Photonics, 2019. p. 1137222.
- ALBA, E. et al. Spectral characterization of forest plantations with Landsat 8/OLI images for forest planning and management. **Pesquisa agropecuária brasileira**, v. 52, n. 11, p. 1072-1079, 2017.
- ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. **Processamento de imagens: métodos e análises**. Centro Brasileiro de Pesquisas Físicas MCT, 2000. Disponível em: <<https://mesonpi.cat.cbpf.br/e2002/cursos/NotasAula/PDSI.pdf>>. Acesso em: 04 nov. 2019.
- ALVES, S. M. de F. et al. Variabilidade espacial de atributos físico-químicos do solo usando técnicas de análise de componentes principais e geoestatística. **Bioscience Journal**, v. 30, n. 3, p. 22-30, 2014.
- ANDRADE, R. G. et al. Uso de veículo aéreo não tripulado (VANT) como plataforma para monitoramento da produção agropecuária: estudo de caso para o milho forrageiro. Embrapa Gado de Leite-Documentos (INFOTECA-E), 2019.
- ARAÚJO, D. C. S. et al. Spatial variability of soil attributes in an experimental basin in the semi-arid region of Pernambuco, Brazil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 1, p. 38-44, 2018.
- BAETENS, L.; DESJARDINS, C.; HAGOLLE, O. Validation of copernicus Sentinel-2 cloud masks obtained from MAJA, Sen2Cor, and FMask processors using reference cloud masks generated with a supervised active learning procedure. **Remote Sensing**, v. 11, n. 4, p. 433, 2019.
- BHERING, S. B. et al. Mapa de Solos do Estado do Paraná. Embrapa Solos-Documentos (INFOTECA-E), 2007. Disponível em: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/339505>>. Acesso em: 15 mai. 2020.
- BONATO, E. R.; BONATO, A. L. V. **A soja no Brasil: história e estatística**. Embrapa - Centro Nacional de Pesquisa de Soja – CNPSo. Documentos (INFOTECA-E), Londrina, PR. 1987.
- BOORI, M. S. et al. Monitoring Crop Phenology Using NDVI Time Series from Sentinel 2 Satellite Data. In: **2019 5th International Conference on Frontiers of Signal Processing (ICFSP)**. IEEE, 2019. p. 62-66.
- BRASIL. Regras para Análise de Sementes. Brasília: MAPA/ACS, 2009. Disponível em: <[https://www.abrates.org.br/files/regras\\_analise\\_de\\_sementes.pdf](https://www.abrates.org.br/files/regras_analise_de_sementes.pdf)>. Acesso em: 05 fev. 2020.
- CÂMARA, G. M. de S. Fenologia é ferramenta auxiliar de técnicas de produção. **Visão Agrícola**, v. 5, p. 63-66, 2006.

- CAMBARDELLA, C. A. et al. Field-scale variability of soil properties in central Iowa soils. **Soil science society of America journal**, v. 58, n. 5, p. 1501-1511, 1994.
- CARNEIRO, F. M. et al. Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. **Precision Agriculture**, p. 1-29, 2019.
- CARVALHO, L. C. C. et al. Comparação entre amostragem foliar convencional e de precisão para análise de micronutrientes na cafeicultura. **Coffee Science**, Lavras, v.12, n.2, p.272-281, 2017. Disponível em: <<http://www.sbicafe.ufv.br:80/handle/123456789/8664>>. Acesso em: 07 ago. 2019.
- CASAROLI, D. et al. Radiação solar e aspectos fisiológicos na cultura de soja-uma revisão. **Revista da FZVA**, v. 14, n. 2, 2007.
- CATUREGLI, L. et al. Monitoring turfgrass species and cultivars by spectral reflectance. **Eur. J. Hort. Sci.** 2014;79(3): 97–107. Disponível em: <<https://arpi.unipi.it/handle/11568/621472#.Xz02k-hKiM8>>. Acesso em: 18 ago. 2020.
- CATUREGLI, L. et al. Turfgrass spectral reflectance: simulating satellite monitoring of spectral signatures of main C3 and C4 species. **Precision Agriculture**, v. 16, n. 3, p. 297-310, 2015.
- CAVERZAN, A. et al. How does seed vigor affect soybean yield components?. **Agronomy Journal**, v. 110, n. 4, p. 1318-1327, 2018.
- CAVIGLIONE, J. H. ; KIIHL, L. R. B.; CARAMORI, P. H. ; OLIVEIRA, D. Cartas climáticas do Paraná. Londrina : IAPAR, 2000. Disponível em: <<http://www.iapar.br/pagina-857.html>>. Acesso em: 02 mai. 2020.
- CLAESSEN, M. E. C.; BARRETO, W. D. O.; PAULA, J. L. De; DUARTE, M. N. **Manual de Métodos de Análise de Solo**. 1. ed. Rio de Janeiro, RJ: EMBRAPA-CNPS, 1997. v. 2.
- CONAB, COMPANHIA NACIONAL DE ABASTECIMENTO. Séries históricas de produtividade de grãos. 2020. Disponível em: <<http://www.conab.gov.br>>. Acesso em: 09 out. 2020.
- CORÁ, J. E. et al. Variabilidade espacial de atributos do solo para adoção do sistema de agricultura de precisão na cultura de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, v. 28, n. 6, p. 1013-1021, 2004.
- CÓRDOBA, M. A. et al. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems engineering**, v. 143, p. 95-107, 2016.
- COSTA, L.; NUNES, L.; AMPATZIDIS, Y. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. **Computers and Electronics in Agriculture**, v. 172, p. 105334, 2020.
- COSTA, M. M. et al. Ganho genético por diferentes critérios de seleção em populações segregantes de soja. **Pesquisa Agropecuária Brasileira**, v. 39, n. 11, p. 1095-1102, 2004.

- CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. UNICAMP/Instituto de Geociências, ed. rev. Campinas, SP 1999. ISBN 85-85369-02-7.
- CRUSIOL, L. G. T. et al. NDVI de estádios de desenvolvimento da soja BRS 284 em condições de campo. In: **Embrapa Soja-Artigo em anais de congresso (ALICE)**. In: JORNADA ACADÊMICA DA EMBRAPA SOJA, 8., 2013, Londrina. Resumos expandidos... Londrina: Embrapa Soja, 2013. p. 87-91.(Embrapa Soja. Documentos, 339)., 2013.
- DALCHIAVON, F. C. et al. Produtividade da soja e resistência mecânica à penetração do solo sob sistema plantio direto no cerrado brasileiro. **Pesquisa Agropecuária Tropical**, v. 41, n. 1, p. 8-19, 2011.
- DALCHIAVON, F. C. et al. Variabilidade espacial de atributos da fertilidade de um Latossolo Vermelho Distroférrico sob Sistema Plantio Direto. **Revista Ciência Agronômica**, v. 43, n. 3, p. 453-461, 2012.
- DALCHIAVON, F. C. et al. Variabilidade espacial de atributos químicos do solo cultivado com soja sob plantio direto. **Revista de Ciências Agroveterinárias**, v. 16, n. 2, p. 144-154, 2017.
- DALCHIAVON, F. C.; CARVALHO, M. P. Correlação linear e espacial dos componentes de produção e produtividade da soja. **Semina: Ciências Agrárias**, v. 33, n. 2, p. 541-552, 2012.
- DANCEY, C.; REIDY, J. **Estatística sem matemática para psicologia: usando SPSS para windows**. 3 ed. São Paulo: Artmed Editora Ltda., 2006.
- DEBASTIANI, A. B. et al. Predições geoestatísticas e zonas de incerteza no inventário de povoamentos florestais. **Advances in Forestry Science**, v. 5, n. 1, p. 283-287, 2018.
- ELSAYED, S. et al. Passive reflectance sensing and digital image analysis for assessing quality parameters of mango fruits. **Scientia Horticulturae**, v. 212, p. 136-147, 2016.
- EMBRAPA, EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Tecnologias de produção de soja: Região Central do Brasil 2011. Londrina: Embrapa Soja. 2010. 255 p. (Embrapa Soja. Sistemas de Produção, 14).
- ESA, EUROPEAN SPATIAL AGENCY. 2020. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 12 jun. 2020.
- ESA, EUROPEAN SPATIAL AGENCY. SENTINEL 2 MSI INTRODUCTION, 2015. Disponível em: <<https://earth.esa.int/web/sentinel/user-guides/Sentinel%202-msi>>. Acesso em: 16 out. 2019.
- ESCHER, F.; WILKINSON, J. A economia política do complexo Soja-Carne Brasil-China. **Revista de Economia e Sociologia Rural**, v. 57, n. 4, p. 656-678, 2019.
- ESQUERDO, J. C. D. M. **Utilização de perfis multi-temporais do NDVI/AVHRR no acompanhamento da safra de soja no oeste do Paraná**. 2007. Tese (Doutorado



em Engenharia Agrícola) – Universidade Estadual de Campinas, Campinas, 2007. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/257089>>. Acesso em: 09 dez. 2019.

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

FARIAS, P. R. S. et al. Agricultura de precisão: mapeamento da produtividade em pomares cítricos usando geoestatística. **Revista Brasileira de Fruticultura**, p. 235-241, 2003.

FEHR, W. R.; CAVINESS, C. E. Stages of soybean development. United States: Iowa State University of Science and Technology, 1977. Disponível em: <<https://lib.dr.iastate.edu/specialreports/87/>>. Acesso em: 03 dez. 2019.

FERRI, C. P.; FORMAGGIO, A. R.; SCHIAVINATO, M. A. Narrow band spectral indexes for chlorophyll determination in soybean canopies [Glycine max (L.) Merrill]. **Brazilian Journal of Plant Physiology**, v. 16, n. 3, p. 131-136, 2004.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3 ed. São Paulo: Ed. Oficina de Texto. 2011. 128 p.

FONSECA, L. G. M. **Apostila de processamento digital de imagens**. São José dos Campos: INPE, jun. 2000.

FONTANA, D. C. et al. NDVI e alguns fatores de variabilidade. In: **Embrapa Trigo-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. Anais... São José dos Campos: INPE, 2019.

GALVÃO, L. S.; FORMAGGIO, A. R.; BREUNIG, F. M.. Relações entre índices de vegetação e produtividade de soja com dados de visada fora do nadir do sensor Hyperion/EO-1. **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, v. 14, p. 1095-1102, 2009.

GAMMA DESIGN SOFTWARE. GS+:Geostatistics for the Environmental Sciences Versão 7.0. Gamma Design Software. Plainwell, Michigan, 2004.

GARCIA, E. R. de M. et al. Efeito da suplementação enzimática em rações com farelo de soja e soja integral extrusada sobre a digestibilidade de nutrientes, o fluxo de nutrientes na digesta ileal e o desempenho de frangos. **Revista Brasileira de Zootecnia**, v. 29, n. 5, p. 1414-1426, 2000.

MARTÍNEZ, H. G. et al. Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. **Agriculture**, v. 10, n. 7, p. 277, 2020.

GERKE, T. **Mineração de dados de imagens obtidas com aeronave remotamente pilotada para estimativa de produtividade do trigo**. 2017. Dissertação (Mestrado em Computação Aplicada) – Universidade Estadual de Ponta Grossa, Ponta Grossa, 2017. em: <

<https://tede2.uepg.br/jspui/bitstream/prefix/141/1/TIAGO%20GERKE.pdf>>. Acesso em: 20 fev. 2021.

GITELSON, A. A. et al. Novel algorithms for remote estimation of vegetation fraction. **Remote sensing of Environment**, v. 80, n. 1, p. 76-87, 2002.

GOMES, P. **A soja**. Livraria Nobel, 1976.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. Pearson Educación, 2009.

GOUVEIA, A. B. V. S. et al. Subprodutos da soja na alimentação de aves: Revisão. **Research, Society and Development**, v. 9, n. 7, p. e471974187-e471974187, 2020.

GREGO, C. R. et al. Variabilidade espacial do solo e da biomassa epígea de pastagem, identificada por meio de geostatística. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1404-1412, 2012.

GROSS, J. A. et al. Resposta espectral de dosséis de soja em função de concentrações de clorofilas. **Revista Brasileira de Cartografia**, v. 68, n. 7, 2016.

GUYOT, G.; GUYON, D.; RIOM, J. Factors affecting the spectral response of forest canopies: a review. **Geocarto International**, v. 4, n. 3, p. 3-18, 1989.

HUNT, G. Spectral signatures of particulate minerals in the visible and near infrared. **Geophysics**, v. 42, n. 3, p. 501-513, 1977.

IZOLA, D. T.; PICOLLO, P.; CATALANO, F. M. Automação e instrumentação: aerofotografias de baixo custo como instrumento de monitoramento ambiental. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 2, n. 2, p. 225-228, 1998.

JACQUEMOUD, S.; BARET, F. PROSPECT: A model of leaf optical properties spectra. **Remote sensing of environment**, v. 34, n. 2, p. 75-91, 1990. Disponível em:

<[http://www2.geog.ucl.ac.uk/~mdisney/teaching/teachingNEW/GEOGG141/papers/jacquemoud\\_baret\\_prospect.pdf](http://www2.geog.ucl.ac.uk/~mdisney/teaching/teachingNEW/GEOGG141/papers/jacquemoud_baret_prospect.pdf)>. Acesso em: 06 nov. 2019.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em Recursos Terrestres**. Tradução de José Carlos Neves Epiphanyo. São José dos Campos, SP: Parênteses, 2009. 598 p.

JORGE, LA de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. **Embrapa Instrumentação-Capítulo em livro científico (ALICE)**, 2014. Disponível em:

<<https://www.alice.cnptia.embrapa.br/bitstream/doc/1003485/1/CAP8.pdf>>. Acesso em: 20 ago. 2020.

JUSTINA, D. D. D. **Dinâmica espectral da soja por meio do NDVI utilizando sensores orbital e terrestre**. 2014. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel, 2014. Disponível em: <[http://tede.unioeste.br/bitstream/tede/2650/1/diego\\_della\\_justina.pdf](http://tede.unioeste.br/bitstream/tede/2650/1/diego_della_justina.pdf)>. Acesso em: 05 mar. 2020.

- KAUFMAN, Y. J.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.
- LA CASA, A. de. et al. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. **ISPRS journal of photogrammetry and remote sensing**, v. 146, p. 531-547, 2018.
- LECHNER, A. M.; FOODY, G. M.; BOYD, D. S. Applications in Remote Sensing to Forest Ecology and Management. **One Earth**, v. 2, n. 5, p. 405-412, 2020.
- LESLIE, C. R.; SERBINA, L. O.; MILLER, H. M. Landsat and agriculture—Case studies on the uses and benefits of Landsat imagery in agricultural monitoring and production. US Geological Survey Open-File Report, v. 1034, p. 27, 2017. Disponível em: <<https://pubs.usgs.gov/of/2017/1034/ofr20171034.pdf>>. Acesso em: 03 jun. 2020.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. Hoboken, USA: Wiley, 2004.
- LIU, W. T. H. **Aplicações de sensoriamento remoto**. Oficina de Textos, 2007.
- LONDERO, R. et al. Dependência espacial da fertilidade do solo sob plantio direto e suas relações com a produtividade da soja. **Caderno de Ciências Agrárias**, v. 12, n. 1, p. 1-8, 2020.
- LOPES, K. A. do L. et al. Variabilidade espacial de atributos químicos de um argissolo amarelo distrocoeso em diferentes densidades de amostragem. **Revista Científica Rural**, v. 22, n. 2, p. 29-42, 2020.
- LOVERA, L. H. **Atributos do solo e componentes produtivos da soja: Uma abordagem linear, multivariada e geoestatística**. 2015. Dissertação (Mestrado em Agronomia) – Faculdade de Engenharia - UNESP, Ilha Solteira, 2015. Disponível em: <<https://repositorio.unesp.br/bitstream/handle/11449/131899/000853458.pdf?sequence=1&isAllowed=y>>. Acesso em: 04 fev. 2021.
- MARCHIORI, L. F. S. et al. Desempenho vegetativo de cultivares de soja [Glycine max (L.) Merrill] em épocas normal e safrinha. **Scientia Agricola**, v. 56, n. 2, p. 383-390, 1999.
- MATIAS, S. S. R. et al. Recomendação de calagem com base na variabilidade espacial de atributos químicos do solo no Cerrado brasileiro. **Revista de Ciências Agrárias**, v. 42, n. 4, p. 31-40, 2019.
- MCBRATNEY, A. B. et al. Future directions of Precision Agriculture. **Precision Agriculture**, v. 6, n. 1, p. 1-17, 2005.
- MCKINNON, T.; HOFF, P.. Comparing RGB-based vegetation indices with NDVI for drone based agricultural sensing. **Agribotix**. Com, p. 1-8, 2017.
- MENESES, P. R.; ALMEIDA, T. de. **Introdução ao processamento de imagens de sensoriamento remoto**. Universidade de Brasília, Brasília, 2012. Disponível em:

<<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 10 out. 2019.

MENESES-TOVAR, C. L. NDVI as indicator of degradation. **Unasylva**, v. 238, n. 62, p. 39-46, 2011. Disponível em: <<http://www.fao.org/3/i2560e/i2560e07.pdf>>. Acesso em: 10 dez. 2020.

MION, R. L. et al. Variabilidade espacial da porosidade total, umidade e resistência do solo à penetração de um Argissolo Amarelo. **Semina: Ciências Agrárias**, v. 33, n. 6, p. 2057-2066, 2012.

MOLIN, J. P.; DO AMARAL, L. R.; COLAÇO, A. **Agricultura de precisão**. Oficina de Textos, 2015.

MONDINI, M. L.; VIEIRA, C. P.; CAMBRAIA, L. A. **Época de semeadura: um importante fator que afeta a produtividade da cultura da soja**. Embrapa Agropecuária Oeste-Documentos (INFOTECA-E), 2001. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/229672/1/DOC34.pdf>>. Acesso em: 07 ago. 2020.

MORAES, E. C. de. Fundamentos de sensoriamento remoto. In: RUDORFF, B. F. T. et al. (Eds.). **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, 2002. Disponível em: <[http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1\\_ECMoraes.pdf](http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf)>. Acesso em: 18 ago. 2020.

MOREIRA, R. C. **Influência do posicionamento e da largura de bandas de sensores remotos e dos efeitos atmosféricos na determinação de índices de vegetação**. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2000.

MORENO, L. et al. Comparative study of multispectral satellite images and RGB images taken from drones for vegetation cover estimation. In: **2018 IEEE 38th Central America and Panama Convention (CONCAPAN XXXVIII)**. IEEE, 2018. p. 1-8.

NEGASH, L.; KIM, Ho-Yeon; CHOI, Han-Lim. Emerging UAV Applications in Agriculture. In: **2019 7th International Conference on Robot Intelligence Technology and Applications (RiTA)**. IEEE, 2019. p. 254-257.

NEIVERTH, W. et al. NDVI de estádios fenológicos da soja BRS 284 de crescimento indeterminado em casa de vegetação. In: **Embrapa Soja-Artigo em anais de congresso (ALICE)**. In: JORNADA ACADÊMICA DA EMBRAPA SOJA, 8., 2013, Londrina. Resumos expandidos... Londrina: Embrapa Soja, 2013. p. 204-209.(Embrapa Soja. Documentos, 339)., 2013.

NOETZOLD, R. et al. Variabilidade espacial da eficiência do uso de potássio e fósforo na cultura da soja. **Revista Engenharia na Agricultura**, v. 27, n. 6, p. 529-541, 2019.

OLIGINI, K. F. **Relação entre épocas de semeadura e grupos de maturação de cultivares de soja na viabilidade técnica e econômica do milho safrinha no sul**

**do Brasil**. 2019. Dissertação (Mestrado em Agronomia) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2019. Disponível em: <[http://riut.utfpr.edu.br/jspui/bitstream/1/3983/1/PB\\_PPGAG\\_M\\_Oligini%2c%20Karine%20Fuschter\\_2019.pdf](http://riut.utfpr.edu.br/jspui/bitstream/1/3983/1/PB_PPGAG_M_Oligini%2c%20Karine%20Fuschter_2019.pdf)>. Acesso em: 02 fev. 2021.

OLIVEIRA, M. F. de. **Modelos de predição de produtividade da cultura do milho por meio de NDVI em arranjos espaciais**. Dissertação (Mestrado em Agronomia) – Universidade Estadual Paulista, Jaboticabal, 2017. Disponível em: <[https://repositorio.unesp.br/bitstream/handle/11449/151597/oliveira\\_mf\\_me\\_jabo.pdf?sequence=3&isAllowed=y](https://repositorio.unesp.br/bitstream/handle/11449/151597/oliveira_mf_me_jabo.pdf?sequence=3&isAllowed=y)>. Acesso em: 14 ago. 2020.

PADOLFI, A. S.; RAMALDES, G. P.; SANTOS, O. L. dos. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v. 14, n. 1, p. 145-165, 2018.

PAVINATO, P. S. et al. **Manual de adubação e calagem para o estado do Paraná**. 2017.

PEREIRA, L. E. et al. Aplicação de técnicas de processamento digital de imagens em diferentes sensores orbitais. **Anuário do Instituto de Geociências**, v. 39, n. 3, p. 15-24, 2016.

PETRO, E. et al. Aerial mapping of rice crops using mosaicing techniques for vegetative index monitoring. In: **2018 International Conference on Unmanned Aircraft Systems (ICUAS)**. IEEE, 2018. p. 846-855.

PIONEER.**SOJA 95R51**. 2019. Disponível em: <<http://www.pioneersementes.com.br/soja/central-de-produtos/produtos/95r51>>. Acesso em: 10 ago. 2020.

PÔÇAS, I. et al. Remote sensing for estimating and mapping single and basal crop coefficients: A review on spectral vegetation indices approaches. **Agricultural Water Management**, v. 233, p. 106081, 2020.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007.

POTT, L. P.; SEBEM, E.; AMADO, T. J. C. **Tecnologias para detecção e controle em sítios específicos de plantas daninhas**. In: Agricultura de precisão no Rio Grande do Sul. 1ª Edição. Santa Maria: CESPOL, 2016, v.1, p. 159-187. Disponível em: <[https://www.ufsm.br/cursos/pos-graduacao/santa-maria/ppgap/wp-content/uploads/sites/526/2019/01/AP\\_RS.pdf](https://www.ufsm.br/cursos/pos-graduacao/santa-maria/ppgap/wp-content/uploads/sites/526/2019/01/AP_RS.pdf)>. Acesso em: 10 mar. 2020.

PRESTES JUNIOR, J. V. **Sucessão soja-milho safrinha em função do arranjo de épocas de semeadura e ciclos de maturação da soja**. Dissertação (Mestrado em Agronomia) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2020. Disponível em: <<https://repositorio.utfpr.edu.br/jspui/bitstream/1/5029/1/sojamilhosemeaduramaturacao.pdf>>. Acesso em: 01 fev. 2021.

PRESTES, C. D. P. et al. Avaliação de metodologia de estimativa de produtividade de soja por meio de aeronave não tripulada e técnica de aprendizado de máquina

baseada em regressão. **Revista Mundi Engenharia, Tecnologia e Gestão**, v. 5, n. 3, p. 245-01, 2020.

PROQUE, A. L. Interdependência do Brasil e dos Estados Unidos no mercado da soja em grão: uma análise da situação e das perspectivas. **Revista de Desenvolvimento e Políticas Públicas**, v. 3, n. 1, p. 41-60, 2019.

RAZA, M. A. et al. Growth and development of soybean under changing light environments in relay intercropping system. **PeerJ**, v. 7, p. e7262, 2019.

REGHINI, F. L.; CAVICHIOLI, F. A. UTILIZAÇÃO DE GEOPROCESSAMENTO NA AGRICULTURA DE PRECISÃO. **Revista Interface Tecnológica**, v. 17, n. 1, p. 329-339, 2020.

RIA, W. O. et al. Tecnologias aplicadas ao agronegócio agricultura de precisão. **Revista Gestão do Conhecimento**, v. 7, n. 7, p. 2-7, 2015.

RIBEIRO, L. A. E. et al. Viabilidade Econômica Do Uso De Fungicidas No Controle Da Ferrugem Asiática Da Soja. **Ipê Agronomic Journal**, v. 3, n. 2, p. 35-43, 2019.

RICHARDS, J. A. **Remote sensing digital image analysis**. Berlin: Springer, 1999.

RISSINI, A. L. L.; KAWAKAMI, J.; GENÚ, A. M. Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. **Revista Brasileira de Ciência do Solo**, v.39, p.1703-1713, 2015.

ROBINSON, N. P. et al. A dynamic Landsat derived normalized difference vegetation index (NDVI) product for the conterminous United States. **Remote Sensing**, v. 9, n. 8, p. 863, 2017.

RODRIGUES, C. P. et al. NDVI e fluxo de CO2 em lavoura de soja no Rio Grande do Sul. **Revista Brasileira de Meteorologia**, v. 28, n. 1, p. 95-104, 2013.

ROSEMARY, F. et al. Exploring the spatial variability of soil properties in an Alfisol soil catena. **Catena**, v. 150, p. 53-61, 2017.

ROUSEL, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. In: **Proceedings of the Third Earth Resources Technology Satellite—1 Symposium; NASA SP-351**. 1973.

RSTUDIO TEAM. Integrated development for R. Disponível em: <<https://rstudio.com/>>. Acesso em: 12 abr. 2020.

RUIZ, J. G. C. L.; ZANATA, M.; PISARA, T. C. T. Variabilidade espacial de atributos químicos do solo em áreas de pinus do instituto florestal de batatais–SP. **Brazilian Journal of Applied Technology for Agricultural Science/Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 9, n. 2, 2016.

SANTOS, L. A. C.;LIMA, P. E. M. de. Comparação entre diferentes algoritmos de classificação supervisionada em imagens Landsat-8 no mapeamento temático da bacia hidrográfica do rio caldas, Goiás. **Revista Brasileira de Geografia Física**, v. 12, n. 03, p. 961-972, 2019. Disponível em:

<<https://pdfs.semanticscholar.org/7c35/1cf3ac171575e96176cc5db5714af0882cae.p>>

[df](#) >. Acesso em: 18 ago. 2020.

SANTOS, O. L.; PADOLFI, A. S.; RAMALDES, G. P. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v. 14, n. 1, p. 145-165, 2018.

SEGARRA, J. et al. Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications. **Agronomy**, v. 10, n. 5, p. 641, 2020.

SEIXAS, C. D. S. et al. Tecnologias de produção de soja. Embrapa Soja. Documentos (INFOTECA-E), Londrina, PR. 2020. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1123928/1/SP-17-2020-online.pdf>>. Acesso em: 02 ago. 2020.

SHAW, G. A.; BURKE, H. K. Spectral imaging for remote sensing. **Lincoln laboratory journal**, v. 14, n. 1, p. 3-28, 2003. Disponível em: <<https://courses.cs.washington.edu/courses/cse591n/07sp/papers/Shaw2003.pdf>>. Acesso em: 10 ago. 2020.

SHIBLES, R. M.; WEBER, C. R. Leaf area, solar radiation interception and dry matter production by soybeans. **Crop Science**, Madison, v. 5, p. 575-577, 1965.

SILVA, D. V. R. et al. Variabilidade espacial de NDVI E EVI no estágio vegetativo da soja. Agropampa: **Revista de Gestão do Agronegócio**, v. 2, n. 2, 2018. Disponível em: <<http://200.132.146.161/index.php/agropampa/article/view/23133/8701>>. Acesso em: 20 mar. 2020.

SILVA, F. M. et al. Variabilidade espacial de atributos químicos e produtividade da cultura do café em duas safras agrícolas. **Ciência e Agrotecnologia**, v. 32, n. 1, p. 231-241, 2008.

SILVA, M. C. C. et al. Atributos químicos do solo e produtividade do feijoeiro de inverno sob plantio direto no cerrado de baixa altitude. **Revista Engenharia na Agricultura**, v. 25, n. 6, p. 549-560, 2017.

SILVA, P. R. T. **Geoestatística e análise múltipla de atributos químicos de um latossolo cultivado com soja sob dois sistemas de manejo**. 2017. Dissertação (Mestrado em Agronomia) – Faculdade de Engenharia - UNESP, Ilha Solteira, 2017. Disponível em: <[https://repositorio.unesp.br/bitstream/handle/11449/151892/silva\\_prt\\_me\\_ilha.pdf?sequence=3&isAllowed=y](https://repositorio.unesp.br/bitstream/handle/11449/151892/silva_prt_me_ilha.pdf?sequence=3&isAllowed=y)>. Acesso em: 04 fev. 2021.

SILVA, V. S. da. et al. Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification. **Geology, Ecology, and Landscapes**, v. 4, n. 2, p. 159-169, 2020.

SOUSA, D. M. G de; LOBATO, E. **Cerrado: correção do solo e adubação**. Planaltina: Embrapa Cerrados, v. 416, 2004.

SOUZA, I. V. et al. Veículos aéreos não tripulados e sensores remotos: ferramentas para o gerenciamento dos recursos florestais. **Journal of Biotechnology and Biodiversity**, v. 8, n. 2, p. 148-157, 2020.

- SWAIN, P. H.; DAVIS, S. M. Remote sensing: The quantitative approach. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, n. 6, p. 713-714, 1981.
- TAYLOR, J. A.; MCBRATNEY, A. B.; WHELAN, B. M. Establishing management classes for broadacre agricultural production. **Agronomy Journal**, v. 99, n. 5, p. 1366-1376, 2007.
- TOLA, E. et al. Characterization of spatial variability of soil physicochemical properties and its impact on Rhodes grass productivity. **Saudi journal of biological sciences**, v. 24, n. 2, p. 421-429, 2017.
- TRINDADE, F. S. et al. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. **Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences**, v. 62, 2019.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v.8, n.2, p.127-150. 1979.
- USGS, United States Geological Survey. **What are the band designations for the Landsat satellites?** 2018. Disponível em: <[https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites?qt-news\\_science\\_products=0#qt-news\\_science\\_products](https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites?qt-news_science_products=0#qt-news_science_products)>. Acesso em: 05 jun. 2020.
- USOWICZ, B.; LIPIEC, J. Spatial variability of soil properties and cereal yield in a cultivated field on sandy soil. **Soil & Tillage Research**, Lublin, v.174, p.241-250, 2017.
- VIANA, L. A. et al. Potencial uso de câmera termal acoplada a vant para monitoramento de culturas/potential use of thermal camera coupled in uav for culture monitoring. **Revista Brasileira de Engenharia de Biosistemas**, v. 12, n. 3, p. 286-298, 2018.
- VIEIRA, S. R. **Geoestatística aplicada à agricultura de precisão**. GIS Brasil, v. 98, 2000. Disponível em: <[http://www.ufrrj.br/institutos/it/deng/varella/Downloads/IT190\\_principios\\_em\\_agricultura\\_e\\_precisao/livros/Capitulo\\_5.pdf](http://www.ufrrj.br/institutos/it/deng/varella/Downloads/IT190_principios_em_agricultura_e_precisao/livros/Capitulo_5.pdf)>. Acesso em: 08 set. 2019.
- VIEIRA, S. R.; GONZALEZ, A. P. Analysis of the spatial variability of crop yield and soil properties in small agricultural plots. **Bragantia**, v. 62, n. 1, p. 127-138, 2003.
- WARRICK, A.W.; NIELSEN, D.R. Spatial variability of soil physical properties the soil. In: HILL, D., ed. **Applications of soil physics**. New York, Academic Press, 1980. p.319-344.
- WEISS, J. L. et al. Long-term vegetation monitoring with NDVI in a diverse semi-arid setting, central New Mexico, USA. **Journal of Arid Environments**, v. 58, n. 2, p. 249-272, 2004.
- XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of Sensors**, v. 2017, 2017.
- YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. Oficina de textos, 2015.



- YODER, B. J.; WARING, R. H. The normalized difference vegetation index of small Douglas-fir canopies with varying chlorophyll concentrations. **Remote Sensing of Environment**, v. 49, n. 1, p. 81-91, 1994.
- YUN, H. S. et al. Use of unmanned aerial vehicle for multi-temporal monitoring of soybean vegetation fraction. **Journal of Biosystems Engineering**, v. 41, n. 2, p. 126-137, 2016.
- ZERBATO, C. et al. Agronomic characteristics associated with the normalized difference vegetation index (NDVI) in the peanut crop. **Australian Journal of Crop Science**, Lismore, v. 10, n. 5, p. 758–764, 2016.
- ZHAN, J. et al. Prospective sustainable production of safe food for growing population based on the soybean (*Glycine max* L. Merr.) crops under Cd soil contamination stress. **Journal of Cleaner Production**, v. 212, p. 22-36, 2019.
- ZHANG, B. et al. Application of synthetic NDVI time series blended from Landsat and MODIS data for grassland biomass estimation. **Remote Sensing**, v. 8, n. 1, p. 10, 2016.
- ZHANG, J. et al. Applications of unmanned aerial vehicle based imagery in turfgrass field trials. **Frontiers in plant science**, v. 10, p. 279, 2019.
- ZHANG, M. et al. Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. **Biosystems Engineering**, v. 189, p. 24-35, 2020.
- ZHANG, X. et al. New research methods for vegetation information extraction based on visible light remote sensing images from an unmanned aerial vehicle (UAV). **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 215-226, 2019.
- ZHAO, Y. et al. Predicting wheat yield at the field scale by combining high-resolution Sentinel-2 satellite imagery and crop modelling. **Remote Sensing**, v. 12, n. 6, p. 1024, 2020.
- ZHENG, H. et al. Early season detection of rice plants using RGB, NIR-GB and multispectral images from unmanned aerial vehicle (UAV). **Computers and Electronics in Agriculture**, v. 169, p. 105223, 2020.