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

ESTIMATIVA DE PRODUTIVIDADE DA SOJA UTILIZANDO DADOS ESPECTRO-AGROCLIMÁTICOS DE SENSORIAMENTO REMOTO NO MODELO WOFOST

IZABELY MACHADO TOMAZI

CASCAVEL – PARANÁ – BRASIL

JUNHO – 2024

IZABELY MACHADO TOMAZI

ESTIMATIVA DE PRODUTIVIDADE DA SOJA UTILIZANDO DADOS ESPECTRO-AGROCLIMÁTICOS DE SENSORIAMENTO REMOTO NO MODELO WOFOST

Dissertação de mestrado submetida a banca examinadora do Programa de Pós-Graduação em Engenharia Agrícola para obtenção do título de mestre em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, com a temática Geoprocessamento, Estatística Espacial e Agricultura de Precisão.

Orientador: Dr. Jerry Adriani Johann

Coorientador: Dr. Willyan Ronaldo Becker

CASCAVEL – PARANÁ – BRASIL

JUNHO – 2024

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

> Machado Tomazi, Izabely ESTIMATIVA DE PRODUTIVIDADE DA SOJA UTILIZANDO DADOS ESPECTRO-AGROCLIMÁTICOS DE SENSORIAMENTO REMOTO NO MODELO WOFOST / Izabely Machado Tomazi; orientador Jerry Adriani Johann; coorientador Willyan Ronaldo Becker. -- Cascavel, 2024. 58 p. Dissertação (Mestrado Acadêmico Campus de Cascavel) --Universidade Estadual do Oeste do Paraná, Centro de Ciências Exatas e Tecnológicas, Programa de Pós-Graduação em Engenharia Agricola, 2024. 1. Geoprocessamento. 2. Google Earth Engine. 3. NasaPower. 4. NDVI. I. Adriani Johann, Jerry , orient. II. Ronaldo Becker, Willyan , coorient. III. Título.

Revisão de língua portuguesa, inglesa e normas por Dra. Dhandara Capitani, em 05 de setembro de 2024





Universidade Estadual do Oeste do Paraná Reitoria CNPJ 78.680.337/0001-84 Rua Universitária, 1619, Jardim Universitário Tel.: (45) 3220-3000 - www.unioeste.br CEP: 85819-110 - Cx. P .: 701 Cascavel - PARANÁ

IZABELY MACHADO TOMAZI

ESTIMATIVA DE PRODUTIVIDADE DA SOJA UTILIZANDO DADOS ESPECTRO-AGROCLIMÁTICOS DE SENSORIAMENTO REMOTO NO MODELO WOFOST

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



Orientador(a) - Jerry Adriani Johann

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



Alex Paludo

Plantar Comércio de Insumos LTDA



MARCIO FURLAN MAGGI Data: 10/06/2024 15:53:84-0300 Verifique em https://validar.iti.gov.br

Marcio Furlan Maggi

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

Cascavel, 10 de junho de 2024.

BIOGRAFIA

Brasileira, natural de Pato Branco – PR, nascida no ano de 1997. Bacharel em Agronomia pela Universidade Federal do Paraná – UTFPR/Dois Vizinhos (2021). Foi monitora voluntária das disciplinas de Topografia I e II e participou durante dois anos nos laboratórios de Geociências como bolsista voluntária e no laboratório de Fitopatologias. Desenvolveu sua pesquisa de mestrado no Programa de Pós-Graduação em Engenharia Agrícola, na área de concentração em Sistemas Biológicos e Agroindustriais, linha de pesquisa em Geoprocessamento, Estatística Espacial e Agricultura de Precisão. Realizou suas atividades de pesquisa no Núcleo GeoScience da UNIOESTE, na área de sensoriamento remoto aplicado a agricultura.

Dedico esta dissertação ao meu esposo, Juarez Tomazi Filho, que me ajudou e apoiou durante o mestrado.

Com amor e carinho, dedico!

AGRADECIMENTOS

Agradeço primeiramente, a Deus, pelo dom da vida e por permitir e abençoar meus passos, guiando meus caminhos e tornando possível a realização deste trabalho;

Ao meu esposo, Juarez Tomazi Filho, por estar ao meu lado em todos os momentos desta caminhada, sendo estes bons ou nem tanto, pelo carinho e o amor;

A minha família, pelo incentivo e o apoio em todas as etapas da minha vida. Agradeço especialmente a minha mãe, Marlene, minha sogra, Claudete, e meu sogro, Juarez, pelo amor e o carinho que recebi durante esta jornada;

Aos meus amigos, pelo apoio e a amizade. Em especial a minha amiga Thaynnan Begozzi, pela amizade, o apoio e o incentivo, e a minha psicóloga, Polyane Werner;

Ao meu orientador, Dr. Jerry A. Johann, pelas oportunidades, a dedicação e os aprendizados, que levarei para o resto da vida;

Ao meu coorientador, Dr. Willyan Ronaldo Becker, pelos ensinamentos e dedicação, e por não medir esforços buscando auxiliar na execução e na elaboração desta dissertação;

Aos colegas de laboratório que tornaram esta caminhada um pouco mais leve, com quem aprendi muitas coisas. Agradeço em especial aos colegas: Alex Paludo, Daniele M. Grande, Fernando Freire e Thiago Ló;

À coordenação do curso do Programa de Pós-Graduação em Engenharia Agrícola – PGEAGRI, pelo auxílio em momentos desafiadores;

À Universidade Estadual do Oeste do Paraná – UNIOESTE, em especial ao Programa de Pós-Graduação em Engenharia Agrícola – PGEAGRI, pela oportunidade de realização deste mestrado;

A todos os professores do Programa de Pós-Graduação em Engenharia Agrícola, pelo conhecimento compartilhado;

À CAPES, pelo apoio financeiro em formato de bolsa de mestrado;

Por fim, agradeço a todos que de alguma forma prestaram auxílio na execução deste trabalho.

vii

TOMAZI, Izabely Machado. **Estimativa de produtividade da soja utilizando dados espectro-agroclimáticos de sensoriamento remoto no modelo WOFOST**. Orientador: Jerry Adriani Johann; Coorientador: Willyan Ronaldo Becker. 2024. 61 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2024

RESUMO

A cultura da soja é atualmente a principal cultura produzida no Brasil, sendo responsável por movimentar uma parte significativa da economia nacional e gerar rendimento aos produtores. O uso de técnicas de sensoriamento remoto contribui para que este viés seja alcançado, pois por meio deste os produtores podem melhorar a utilização de seus recursos, gerando maior lucratividade. Em vista disto, o objetivo deste trabalho foi estimar a produtividade da soja com uso da técnica de assimilação de dados agrometeorológicos junto ao modelo de crescimento de cultura World Food Studies (WOFOST), a nível de talhões para áreas localizadas nos municípios de Castro e Piraí do Sul, Paraná. Para isto, utilizou-se o modelo WOFOST associado a dados de índice de área foliar, provenientes de cálculos do índice de vegetação usando imagens do satélite Sentinel-2, e dados climáticos obtidos através da plataforma NasaPower. Os resultados encontrados mostram que ocorrem mudanças espaciais e ao longo dos anos na produtividade da soja. Quando comparada a produtividade estimada com a produtividade de campo foram obtidos valores de coeficiente de determinação (R²) de 0,5 e 0,6, RMSE de 679,36 e 346,95 kg ha⁻¹ para os municípios de Castro-PR e Piraí do Sul-PR, respectivamente. A acurácia do modelo foi calculada utilizando o índice melhorado de Willmott (2012) e apresentou resultados satisfatórios para ambos os municípios, enquanto para a avaliação do desempenho [Pi] o município de Castro-PR (Dr: 0,523; Pi: 0,369) foi classificado como tolerável e Piraí do Sul-PR (Dr: 0,700; Pi: 0,544) como bom. A utilização do modelo WOFOST permitiu estimar a produtividade da soja a nível de pixel, para talhões de variados tamanhos de áreas, proporcionando resultados que permitem demais estudos.

Palavras-chave: Geoprocessamento, Google Earth Engine, NasaPower, NDVI, Python.

TOMAZI, Izabely Machado. **Soybean yield estimation using remote sensing spectro-agroclimatic data in the WOFOST model**. Advisor: Jerry Adriani Johann; Co-advisor: Willyan Ronaldo Becker. 2024. 61 f. Dissertation (Master's Degree in Agricultural Engineering) - State University of Western Paraná, Cascavel – Paraná, 2024

ABSTRACT

The soybean crop is currently the main crop produced in Brazil, being responsible for a significant part of the national economy and generating income for producers. The use of remote sensing techniques contributes to achieving this context, because through its utilization producers can improve the use of their resources, generating greater profitability. Thus, the objective of this work was to estimate soybean yield using the technique of assimilation of agrometeorological data with the World Food Studies (WOFOST) crop growth model, at the field level for areas located in the municipalities of Castro and Piraí do Sul, state of Paraná. For this purpose, the WOFOST model was used associated with leaf area index data, from vegetation index calculations using Sentinel-2 satellite images, and climate data obtained through the NasaPower platform. The results show that spatial and soybean yield changes occur over the years. When comparing the estimated yield with the field yield, values of coefficient of determination (R²) of 0.5 and 0.6, RMSE of 679.36 and 346.95 kg ha⁻¹ were obtained for the municipalities of Castro-PR and Piraí do Sul-PR, respectively. The accuracy of the model was calculated using the improved index of Willmott (2012) and presented satisfactory results for both municipalities, while for the evaluation of performance [Pi] the municipality of Castro-PR (Dr: 0.523; Pi: 0.369) was classified as tolerable and Piraí do Sul-PR (Dr: 0.700; Pi: 0.544) as good. The use of the WOFOST model allowed to estimate soybean yield at the pixel level, for plots of varying sizes of areas, providing results that allow further studies.

Keywords: Geoprocessing, Google Earth Engine, NasaPower, NDVI, Python.

SUMÁRIO

BIOGRAFIA
AGRADECIMENTOS
RESUMOviii
ABSTRACT
LISTA DE TABELA
2. OBJETIVOS
2.2 Objetivos específicos
3. REVISÃO BIBLIOGRÁFICA
3.1 Produção agrícola brasileira4
3.1.1 Cultura da Soja5
3.2 Sensoriamento Remoto7
3.2.1 Índices de vegetação8
3.2.2 Satélites
3.3 Modelos de estimativa de produtividade12
3.3.1 WOFOST
3.4 Dados agrometeorológicos14
3.4.1 Nasa-Power
4. MATERIAL E MÉTODOS
4.1 Área de estudo
4.2 Dados de Observações de campo17
4.3 Mapeamentos de soja17
4.4 Modelo de Estimativa de Produtividade18
4.5 Dados do Ciclo fenológico19
4.6 Índice de área foliar20
4.7 Dados Meteorológicos, parâmetros de solo, cultura, local e manejo agrícola21
4.8 Ensemble Kalman Filter
4.9 Validação

5.	RESULTADOS E DISCUSSÃO	.24
5.1	Mapeamento de soja	.24
5.2	Datas do Ciclo Fenológico	.25
5.3	Produtividade	. 30
5.4	Validação	. 34
6.	CONCLUSÃO	.36
7.	REFERENCIAS	.37

LISTA DE TABELA

Tabela 1 Estádios de desenvolvimento da soja
Tabela 2 Características das bandas do satélite Sentinel-210
Tabela 3 Características das bandas do satélite Landsat-8
Tabela 4 Critério de interpretação do desempenho pelo índice Pi, proposto por Alvare
et al. (2013)23
Tabela 5 Valores em hectares das áreas mapeadas de soja, comparadas com os dados
de órgãos oficiais24
Tabela 6 Estatísticas obtidas entre os dados de produtividade estimada pelo modelo e
os dados de produtividade obtidos com os produtores rurais

LISTA DE FIGURAS

Figura 1 Área plantada e produção de soja entre os anos safra 1976/77 e 2022/234
Figura 2 Áreas de estudo, município de Castro e Piraí do Sul, Estado do Paraná, Brasil.
Figura 3 Fluxograma da estimativa de produtividade, utilizando o modelo WOFOST. 19
Figura 4 Mapeamento de soja dos municípios de Castro-PR e Piraí do Sul-PR, para as
safras 2019/2020 (a) e 2022/2023 (b)25
Figura 5 Datas de semeadura para o município de Castro-PR, safra 2019/202026
Figura 6 Datas de semeadura para o município de Castro-PR, safra 2022/202326
Figura 7 Datas de semeadura para o município de Piraí do Sul-PR, safra 2019/2020.27
Figura 8 Datas de semeadura para o município de Piraí do Sul-PR, safra 2022/2023.28
Figura 9 Datas de colheita para o município de Castro-PR, safra 2019/202028
Figura 10 Datas de colheita para o município de Castro-PR, safra 2022/2023
Figura 11 Datas de colheita para o município de Piraí do Sul-PR, safra 2019/202029
Figura 12 Datas de colheita para o município de Piraí do Sul-PR, safra 2022/2023 30
Figura 13 Mapa de produtividade de soja dos talhões estudados no município de Castro-
PR, ano-safra 2019/202031
Figura 14 Mapa de produtividade de soja dos talhões estudados no município de Castro-
PR, ano-safra 2022/202331
Figura 15 Mapas de produtividade de soja para os talhões estudados no município de
Piraí do Sul-PR, ano-safra 2019/2020
Figura 16 Mapas de produtividade de soja para os talhões estudados no município de
Piraí do Sul-PR, ano-safra 2022/2023
Figura 17 Boxplot das médias de produtividade estimada para as áreas de estudo33

1. INTRODUÇÃO

A agricultura brasileira apresenta grande importância e destaque a nível mundial, pois o país é um dos maiores produtores e exportadores mundiais de commodities. No ano 2023, o agronegócio brasileiro bateu recorde de exportações, sendo exportados 193,02 milhões de toneladas de grãos, o que equivaleu a 60,3% da safra de grãos de 2022/2023, a qual foi caracterizada com uma safra recorde de grãos (MAPA, 2024a).

As produções agrícolas lideraram o ranking do valor bruto de produção agropecuário (VBP) com 69,13% no ano de 2023. Os principais produtos participantes do VBP são a soja, responsável por 34,01%, seguido por bovinos, 13,70%, milho, 11,68%, e cana-de-açúcar, 11,07% (MAPA, 2024b).

Por meio do VBP, nota-se a importância que a soja representa no agronegócio brasileiro, sendo a soja a principal cultura do agronegócio brasileiro. No ano-safra 2022/2023 foram produzidos 154,61 milhões de toneladas, em uma área de 44,08 milhões de hectares e tendo como produtividade média das áreas 3.507 kg ha⁻¹ (CONAB, 2024). Os crescentes aumentos na área plantada e na produção da cultura estão associados ao incentivo a programas de pesquisas que permitem gerar e difundir tecnologias e conhecimentos que buscam aumentar o potencial produtivo das lavouras (Hirakuri, 2021; Bezerra et al., 2022).

O avanço das tecnologias permitiu que a soja seja produzida em todas as regiões brasileiras, ficando a produção concentrada nas Regiões Sul e Centro-Oeste, tendo como destaque o estado do Mato Grosso como maior produtor de soja do país (Bezerra et al., 2022). Outro estado que apresenta grande destaque na produção de soja é o Paraná. Ao observar a produção a nível estadual, os municípios de Tibagi, Cascavel, Guarapuava, Ponta Grossa, Toledo e Castro ganham destaque como maiores produtores do estado (IBGE, 2023).

Por meio da constante evolução da tecnologia é possível gerar um aumento no rendimento e na rentabilidade da soja. Estratégias para aumento da produção, como investimento em genética, planejamento e manejos adequados, auxiliam no aumento da produtividade de lavouras. Dentre as estratégias que buscam o aumento da produtividade das culturas e diminuição dos custos, podem ser citadas: agricultura de precisão, manejo integrado de pragas e doenças e técnicas de sensoriamento remoto.

O uso de técnicas de sensoriamento remoto cresce linearmente ao decorrer dos anos, o que permite que produtores e técnicos realizem o monitoramento das lavouras remotamente, buscando avaliar a sanidade das culturas (Rodriguez et al., 2020; Melo et al., 2024), fenologia (Estevam et al., 2023) e condições hídricas (Schirmbeck, 2020). Em grande parte, utilizam-se índices de vegetação para a realização de monitoramentos e estudos a respeito das condições das áreas.

A utilização de índices de vegetação permite o estudo a respeito de condições fitossanitárias de forma remota. Silva et al. (2023) utilizaram os índices de NDVI e EVI para a

avaliação do ciclo de desenvolvimento da soja, monitorando por meio de mapas possíveis problemas de desenvolvimento de plantas.

Outra empregabilidade dos índices de vegetação está na assimilação a modelos de crescimento de culturas. Esta assimilação possibilita melhora nos resultados obtidos com os modelos (Huang et al., 2015; Becker, 2021). Dentre os principais modelos de crescimento de culturas utilizados mundialmente podem ser citados o AquaCrop e o WOFOST, dois modelos que utilizam da assimilação de dados climáticos para a estimativa de produtividade de culturas (Araujo et al., 2019a; De Wit et al., 2019).

O modelo WOFOST é um dos modelos mais flexíveis na estimativa de produtividade das culturas, o qual descreve o crescimento da cultura baseado na interceptação de luz e assimilação de dióxido de carbono e utiliza o desenvolvimento fenológico da cultura como um processo de controle de crescimento (Luo et al., 2020).

Huang et al., (2015) realizou a assimilação de dados de índice de área foliar no modelo WOFOST para o melhoramento da estimativa de produtividade do trigo, tendo como resultado a melhora das simulações ao assimilar dados de índice de área foliar obtidos por meio de sensoriamento remoto do Landsat TM ajustados à escala.

2. OBJETIVOS

2.1 Objetivo geral

Estimar a produtividade da soja através da técnica de assimilação de dados agrometeorológicos junto ao modelo de crescimento de cultura WOFOST, para propriedades dos municípios de Castro e Piraí do Sul, Paraná, Brasil.

2.2 Objetivos específicos

- Avaliar a precisão e a acurácia do modelo de crescimento WOFOST assimilado a dados de índice de área foliar para realizar a simulação da produtividade da soja, comparando com dados reais obtidos a campo;
- Adaptar ferramentas de software (scripts) para uso em pequenas propriedades rurais no estado do Paraná, visando automatizar os procedimentos de classificação, agrupamento e estimativa de produtividade.
- Gerar mapas com dados sobre o ciclo fenológico da cultura e dados de produtividade das áreas que sirvam de apoio a produtores e técnicos em tomadas de decisões sobre o manejo das áreas.

3. REVISÃO BIBLIOGRÁFICA

3.1 Produção agrícola brasileira

A agricultura brasileira vem passando por um processo de melhorias e modernizações que auxiliam no aumento da produtividade das culturas, o que permite que os produtores rurais diminuam seus custos de produção, assim aumentando seu lucro com a atividade rural.

Ao realizar uma análise da trajetória de 40 anos da agricultura brasileira, nota-se que a produção de grãos no Brasil apresentou aumento de cinco vezes o seu valor, passando de 47 milhões para 237 milhões em 2018. Apesar do aumento da produção, as áreas não seguiram esta mesma taxa de acréscimo, tendo aumentado apenas 60% em relação a 1977 (EMBRAPA, 2022a). Na Figura 1 está apresentado o aumento das áreas plantadas e da produção para a cultura da soja a partir do ano-safra de 1976/77 até o ano-safra de 2022/2023, com previsão de produção e área plantada para o ano-safra 2023/2024.





O Brasil atualmente é um dos principais exportadores do mundo, sendo responsável pela exportação de produtos agrícolas tais como soja, celulose, milho, café, carne bovina, carne suína e açúcares, sendo este um fator responsável pela alavancada da produção no país, pois gera incentivo aos produtores, inovação e competitividade no mercado (PORTAL DA INDUSTRIA, 2022).

O Paraná apresentou área de plantio de 10,74 milhões de hectares na safra 2022/2023, sendo estas áreas destinadas a diversas culturas, como aveia, feijão, milho, soja e trigo (CONAB, 2023). O estado é o terceiro maior exportador do setor de agronegócio, sendo os principais produtos exportados o complexo soja, que é referente aos grãos, óleo e farelo (DERAL, 2022).

Dentre os maiores produtores de soja na safra de 2022/2023, o município de Castro se destacou, ocupando o sexto lugar entre os maiores produtores de soja no estado, chegando à marca de 247.150 toneladas produzidas em uma área de 63.000 hectares, atrás apenas dos municípios de Tibagi, Cascavel, Guarapuava, Ponta Grossa e Toledo. A produtividade média do município é de 3.923 kg ha⁻¹, a qual encontra-se acima da média do Brasil obtida no ano safra 2022/2023 de 3.508 kg ha⁻¹ (CONAB, 2023).

3.1.1 Cultura da Soja

A soja (*Glycine max* (L.) Merrill) é uma planta herbácea, da classe Rosideae, ordem Fabales e família Fabaceae. Apresenta folhas trifolioladas e seu fruto é em forma de vagens, os quais podem conter de um a cinco grãos, dependendo da cultivar. A sua estatura varia conforme as condições do ambiente e da cultivar (variedade), sendo o porte ideal entre 60 e 110 cm, o que facilita os manejos e a colheita mecanizada (Farias et al., 2008). Trata-se de uma cultura responsiva ao fotoperíodo, sendo assim uma planta de dias curtos (Dorrance, 2024).

É uma cultura produtora de grãos, sendo a principal commodity brasileira. É um dos alimentos mais cultivados no mundo, com Brasil, Estados Unidos, Argentina, China, Índia e Paraguai como maiores produtores do grão (Leastro et al., 2024). A alta demanda do grão se dá pelo consumo na alimentação humana e animal, devido ao seu alto teor de proteínas (Rafique et al., 2024).

Na safra 2022/2023 foram plantados 44.075,6 mil hectares, o principal fator para o aumento das áreas de soja foi em decorrência das excelentes condições climáticas. A produção brasileira foi de 154.617,4 mil toneladas, registando assim recordes históricos de área de plantio, produção e produtividade (CONAB, 2023).

A soja normalmente tem seu plantio iniciado no segundo decêndio de setembro no estado do Paraná, momento em que é finalizado o calendário do vazio sanitário no estado, até o segundo decêndio de novembro, após a colheita do trigo, porém o zoneamento agrícola para a soja permite o plantio (em algumas áreas) até o último dia de dezembro (CONAB, 2022b).

A escolha da melhor data para o plantio da cultura é dependente, principalmente, do grupo de maturação a qual a cultivar escolhida pertence, pois isto irá influenciar não só a época de semeadura, como a duração do ciclo, sendo necessário que produtores e técnicos fiquem atentos para a escolha das cultivares, levando em consideração também a região e o tipo de solo (Farias et al., 2008). As cultivares, no Paraná, são divididas em 4 grupos: precoce (até 115 dias), semiprecoce (116 a 125 dias), médio (126 a 137 dias) e semitardio (138 a 150 dias) (EMBRAPA, 2021).

O desenvolvimento da soja é descrito através dos seus estádios fenológicos, que são divididos em estádios vegetativos e reprodutivos. Os estádios vegetativos são representados pela letra "V", enquanto os estádios reprodutivos são indicados pela letra "R". Cada estádio é seguido por números que identificam estádios específicos. Apenas os estádios VE (emergência) e VC (cotilédones) não são seguidos por números (Fehr; Caviness, 1977), sendo estes representados na Tabela 1.

Tabela 1 Estádios de desenvolvimento da soja

ESTÁDIO	DESCRIÇÃO
VE	Cotilédones acima da superfície do solo
VC	Cotilédones completamente abertos
V1	Folhas unifolioladas completamente desenvolvidas
V2	Primeira folha trifoliolada completamente desenvolvida
V3	Segunda folha trifoliolada completamente desenvolvida
Vn	Ante-ésima folha trifoliolada completamente desenvolvida
R1	Início do florescimento – uma flor aberta em qualquer nó do caule
R2	Florescimento pleno – uma flor aberta, num dos 2 primeiros nós de caule, com folha completamente desenvolvida
R3	Início da formação de vagem – vagem com 5 mm de comprimento, num dos 4 últimos nós do caule
R4	Vagem completamente desenvolvida – Vagem com 2 cm de comprimento, em um dos últimos 4 nós do caule
R5	Início do enchimento do grão – Grão com 3 mm de comprimento em vagem, num dos 4 últimos nós do caule
R6	Grão cheio ou completo – vagem contendo grãos verdes, preenchendo as cavidades da vagem de um dos 4 últimos nós do caule
R7	Início da maturação – uma vagem normal no caule, com coloração madura
R8	Maturação plena – 95% das vagens com coloração de madura

Fonte: Adaptado de Farias et al. (2008).

A germinação e a emergência da soja são períodos críticos, em que danos às sementes podem afetar a produção final. Para o estabelecimento adequado da cultura, fatores ambientais como disponibilidade hídrica e temperatura são essenciais nas fases iniciais (VE e VC). A água disponível no solo deve ser cerca de 50% do peso da semente, sem excesso ou déficit. A temperatura ideal do solo varia entre 20 e 30 °C, sendo 25 °C a ideal para evitar danos às sementes e ao dossel (Farias et al., 2008).

Para garantir a produtividade, é crucial entender os eventos que podem interferir na produção da soja, como nutrição, pragas, doenças, plantas daninhas e condições

agrometeorológicas, sendo este último o mais difícil de controlar (Rafique et al., 2024). O zoneamento agroclimático ajuda a definir épocas de semeadura em períodos climáticos favoráveis, evitando coincidências entre períodos críticos da cultura e condições adversas, como altas temperaturas ou baixa disponibilidade de água (Farias et al., 2008).

Os principais fatores climáticos que reduzem a produtividade da soja são a temperatura, o fotoperíodo e a disponibilidade hídrica. Apesar do melhoramento genético, a soja prospera melhor em temperaturas entre 20 e 30 °C. Como planta de dias curtos, a soja atrasa o florescimento e o ciclo com dias mais longos (Silva et al., 2022). A água é crucial, representando 90% do peso da planta, especialmente durante a germinação-emergência e floração-enchimento de grãos, que requerem de 7 a 8 mm de água por dia. A distribuição hídrica adequada é fundamental em todos os estádios fisiológicos (Farias et al., 2008).

3.2 Sensoriamento Remoto

O sensoriamento remoto pode ser definido como a aquisição de informações sobre um objeto, área ou fenômeno, por meio de dispositivos sem a necessidade de contato direto com o objeto, área ou fenômeno de interesse (Quartaroli et al., 2014, Rees, 2012), gerando informações por meio de imagens, usando radiação eletromagnética em uma ou mais regiões do espectro eletromagnético, refletida ou emitida a partir da superfície terrestre e obtidas a partir de uma perspectiva elevada (Campbell; Wynne, 2011).

Na agricultura, o sensoriamento vem sendo empregado em diversas áreas, como na detecção de plantas daninhas, pragas e doenças, na avaliação do estado nutricional e hídrico das plantas e monitoramento de riscos ambientais, como queimadas (Borges et al., 2021, Rodriguez et al., 2020, Schaparini et al., 2020). Em sua pesquisa Rodriguez et al. (2020) utilizaram análises geoestatísticas para monitorar a distribuição espacial da antracnose (*Colletotrichum gloeosporioides*) em cultivos de abacate em quatro municípios do Estado do México, México. Tendo como resultado a distribuição exponencial da doença e a partir da análise dos mapas gerados foi possível analisar e estimar a superfície infectada em mais de 50% nos primeiros meses de estudos.

O sensoriamento remoto pode ser utilizado em diversos ramos de pesquisa. Gaida et al. (2016) utilizaram das técnicas do sensoriamento remoto para a detecção da variabilidade de reflectância e dos índices de vegetação levando em consideração a modelagem topográfica do Parque Estadual do Turvo, no estado do Rio Grande do Sul, Brasil. O resultado obtido com este trabalho mostra que ocorreu interferência devido aos efeitos topográficos da área sobre a reflectância e sobre os índices de vegetação, sendo mais pronunciados na orientação norte e com menor interferência na orientação sul.

Uma das utilizações do SR a nível orbital refere-se ao mapeamento de áreas, o qual tem como objetivo o estudo de áreas, para avaliar as características de vegetação, mapear o

desmatamento, áreas degradadas, áreas de preservação e culturas agrícolas e utilização das áreas (Trindade et al., 2019; Johann et al., 2016; Bayma; Sano, 2015).

O mapeamento de áreas é constantemente utilizado para o mapeamento de culturas. Betta et al. (2022) buscaram mapear as áreas de soja plantadas em dois municípios do estado de Santa Catarina (Capão Alto e Lajes) em dois anos-safra (2012/2013 e 2020/2021), por meio do sensoriamento remoto. Como resultados, os autores observaram que ocorreu um aumento de áreas plantadas com soja no segundo ano-safra. Os dados obtidos com o sensoriamento remoto foram comparados a dados oficiais disponibilizados pela Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI), sendo que para o anosafra 2012/2013 o mapeamento apresentou 23% de áreas a mais do que os dados oficiais e para o ano-safra 2020/2021 os dados do sensoriamento a diferença com os dados oficiais foi de 6%.

Outra forma de utilizar o Sensoriamento Remoto (SR) é por meio de sensores que fornecem dados em formato de imagens ou não, com diferentes resoluções: espacial, espectral, temporal e radiométrica. Cada tipo de resolução oferece informações distintas. A resolução espacial refere-se à dimensão dos terrenos, analisando os pixels das imagens. A resolução espectral mede o tamanho e o número dos intervalos de comprimento de onda do espectro eletromagnético. A resolução temporal indica o tempo necessário para obter a imagem, enquanto a resolução radiométrica trata da precisão com que a radiação eletromagnética é medida pelo sensor (Shiratsuchi et al., 2014).

Rodigher et al. (2020) e Trindade et al. (2019) utilizam a associação das resoluções espectral e temporal para buscar informações e analisar os padrões sazonais envolvendo determinadas áreas. Dentre os usos dos padrões sazonais encontram-se a avaliação e a classificação de culturas agrícolas, avaliação de áreas costeiras, entre outros.

3.2.1 Índices de vegetação

Os índices de vegetação (IV) podem ser utilizados para a determinação da biomassa das plantas, produtividade de áreas e monitoramento de culturas. Trata-se de uma medida radiométrica adimensional, que obtém dados por meio da reflectância espectral, utilizando as faixas do espectro eletromagnético do visível e do infravermelho próximo (NIR) e podem ser obtidos por meio de equações aritméticas utilizando bandas espectrais que avaliam o comportamento das faixas espectrais emitidos pela vegetação (Shiratsuchi et al., 2014).

Existem inúmeros índices de vegetação, desenvolvidos com finalidades de avaliações diferente, dentre estes podemos citar o NDVI (Índice de Vegetação por Diferença Normalizada) desenvolvido por Rouse et al. (1974), o qual é utilizado para o monitoramento de culturas e o EVI (Índice de vegetação Aprimorado) (Equação 2), que segue o mesmo princípio do NDVI, porém busca minimizar a interferência dos efeitos atmosféricos (Shiratsuchi et al., 2014).

Dentre os diversos índices de vegetação disponíveis para o estudo do comportamento de culturas, o NDVI é o mais utilizado (Equação 1). Este é altamente utilizado para o monitoramento da vegetação, pois apresenta em sua equação uma alta correlação linear com a atividade fotossintética das plantas (Schaparini et al., 2020; Trindade et al., 2021).

Os valores de NDVI variam entre -1 e +1, indicando a densidade de vegetação: valores próximos a +1 indicam a presença de vegetação densa e fotossinteticamente ativa, e valores mais próximos a -1 indicam baixa densidade de vegetação (Shiratsuchi et al., 2014; Rouse et al., 1974).

Outro IV que apresenta grandes utilizações é o EVI (Equação 2), sendo o índice com maior sensibilidade à variação do dossel. Este foi desenvolvido com a finalidade de reduzir influências atmosféricas e do solo no monitoramento da vegetação (Leivas at al., 2014).

$$NDVI = (NIR - RED)/(NIR + RED)$$
 Eq.(1)

$$EVI = 2.5 * \frac{(NIR - RED)}{(1 + NIR + 6 * RED - .5 * BLUE)} Eq.(2)$$

em que:

NIR é a refletância no comprimento de onda do Infravermelho Próximo (0,76 – 0,90 μ m); RED é a refletância no comprimento de onda do Vermelho (0,63 – 0,69 μ m); BLUE é a reflectância no comprimento de onda do Azul (0,44 – 0,49 μ m).

3.2.2 Satélites

3.2.2.1 Sentinel-2

O satélite Sentinel-2 foi lançado com o objetivo de monitorar a vegetação, o solo, a umidade, os rios e as áreas costeiras. Trata-se de um satélite orbital, com imageamento das áreas com tempo de revisita de 5 dias e está equipado com sensores ópticos multiespectrais MSI e SAR, sendo composto por um par de satélites caracterizados de Sentinel-2A e Sentinel-2B. O primeiro satélite foi lançado no ano de 2015 e o segundo em 2017, sendo ambos desenvolvidos pela European Space Agency – ESA (EMBRAPA, 2020; SENTINEL, 2022).

Os satélites Sentinel-2 possuem 13 bandas espectrais: quatro bandas com resolução espacial de 10m, seis com 20m e três com 60m, cobrindo uma faixa orbital de 290km de largura. Esses satélites trabalham em conjunto para gerar imagens com melhor resolução espacial (SENTINEL, 2022). As bandas do satélite são descritas na Tabela 2.

Bandas	Resolução	Comprimento	Descrição
Sentinel-2	Espacial (m)	de Onda (µm)	
B1	60	0,443	Aerossol
B2	10	0,490	Azul
B3	10	0,560	Verde
B4	10	0,665	Vermelho
B5	20	0,705	Borda vermelha
B6	20	0,740	Borda vermelha
B7	20	0,783	Borda vermelha
B8	10	0,842	Infravermelho próximo
B8A	20	0,865	Borda vermelha
B9	60	0,945	Vapor de água
B10	60	1,375	SWIR – nuvens cirros
B11	20	1,610	SWIR1
B12	20	2,190	SWIR2

Tabela 2 Características das bandas do satélite Sentinel-2

*SWIR: Infravermelho de ondas curtas.

Fonte: Copernicus Sentinel (2024)

Alguns trabalhos voltados para o setor agrícola utilizam as imagens obtidas por meio dos satélites Sentinel-2 para a determinação de índices de vegetação, classificação de áreas agrícolas, florestais, rios e uso do solo, bem como para o mapeamento de diversas áreas. Outro importante ponto é a facilidade de utilização das imagens para diferentes espécies agrícolas e em variados locais (Gomes, 2013; Moreira Braz et al., 2021).

Dentre as possibilidades de uso, podemos citar a utilização dos dados disponibilizados para a delimitação de bacias hidrográficas, Moreira Braz et al. (2017) utilizaram imagens do sensor MSI do Sentinel-2, utilizando as bandas 4, 8 e 3 com resolução radiométrica de 12 bits e resolução espacial de 10 m e utilizando o algoritmo de classificação *Bhattacharya*, o qual gerou uma maior quantidade de amostras quando comparados ao Landsat-8. Como resultado, obteve-se uma exatidão de 99,88 e índice *Kappa* de 0,9 para o classificador do Sentinel-2, o que é considerado um resultado satisfatório e de excelência para o índice *Kappa*.

Feio (2017) desenvolveu um projeto com o objetivo de criar uma metodologia para o controle agrícola de áreas em que os produtores declaram as culturas produzidas com o intuito de recebimento de auxílios financeiros. As culturas que buscavam-se identificar foram pastagem, arroz, tomate e milho. Utilizando o sensor Sentinel-2 e séries temporais de índice de vegetação de diferença normalizada (NDVI) e três classificadores (Máxima Verossimilhança, Redes Neurais e Distância de Malahanobis), obteve-se como resultado a distinção das pastagens das outras culturas com uso do NDVI e para as demais culturas foram

utilizados os classificadores para a identificação das culturas de arroz, tomate e milho, sendo as Redes Neurais considerado o melhor classificador para este trabalho.

A combinação de satélites é comum em trabalhos científicos, sendo frequentemente utilizados os satélites Sentinel-2 e Landsat-8. Essa assimilação de sensores é utilizada para inúmeras finalidades, porém pode-se citar a utilização para a comparação de resultados sobre índices de vegetação e o mapeamento de culturas por meio de diferentes técnicas de sensoriamento remoto (Bezerra et al., 2018; Moreira Braz et al., 2017; Valencia, 2020).

3.2.2.2 Landsat – 8

O projeto Landsat-8 foi lançado em 2013, com o objetivo de proporcionar imagens, resoluções e cores mais claras para os usuários. Equipado com dois sensores o tradicional OLI da série Landsat e o sensor termal infravermelho – TIRS de duas bandas, o sensor OLI captura imagens multiespectrais RGB, comprimento de onda infravermelho e banda pancromática, além de a banda 1 (deepblue) para estudo de costas e aerossóis e banda 9 para a detecção de cirros. O sensor multiespectral apresenta resolução de 15m e o sensor pancromático, resolução de 30m (Dev Acharya et al., 2015).

O conjunto de satélites Landsat realizou uma transformação no sensoriamento remoto por satélite, levando em consideração que foi a primeira plataforma a disponibilizar gratuitamente suas imagens, sendo fornecidos pelo Sistema Geológico dos Estados Unidos (USGS) (Zhu et al., 2019). Assim como o satélite Sentinel-2, o Landsat-8 pode ser utilizado para diversas finalidades, como para o monitoramento das linhas costeiras (Sunny et al., 2022) e mudanças hidrológicas em corpos d'água (Lee et al., 2022), monitoramento da superfície terrestre (Zhu et al., 2022), estimativa de biomassa de vegetações (López-Serrano et al., 2020) e para a análise de índices de vegetação de culturas.

Becker et al. (2017) utilizou imagens do Landsat-8, extraindo seus pixels puros para a discriminação das cultivares de soja e milho em mapeamentos, utilizando de técnicas de mineração. As imagens foram utilizadas para a construção do índice de vegetação aprimorado (EVI) para ambas as culturas e o resultado obtido com este trabalho foi a separação das culturas com precisão de 96,3%.

Bandas	Resolução	Comprimento	Descrição
Landsat-8	Espacial (m)	de Onda (µm)	
B1	30	0,43 – 0,45	Aerossol costeiro
B2	30	0,450 – 0,51	Azul
B3	30	0,53 – 0,59	Verde
B4	30	0,64 - 0,67	Vermelho
B5	30	0,85 - 0,88	Infravermelho próximo
B6	30	1,57 – 1,65	SWIR 1
B7	30	2,11 – 2,29	SWIR 2
B8	15	0,50 - 0,68	Pancromática (PAN)
B9	30	1,36 – 1,38	Cirrus
B10	100	10,6 – 11,19	TIRS 1
B11	100	11,5 – 12,51	TIRS 2

Tabela 3 Características das bandas do satélite Landsat-8

Fonte: USGS, (2024).

3.3 Modelos de estimativa de produtividade

Para a estimativa de produção de áreas de plantio são utilizados alguns modelos, que por meio de diferentes algoritmos e bancos de dados modelam as curvas de crescimento e os rendimentos das culturas em estudo. Os modelos de estimativa de produtividade que utilizam dados agrometeorológicos apresentam grande importância em relação ao entendimento da interferência dos fatores climáticos na produção de culturas. Os modelos utilizados permitem analisar os cenários da cultura, avaliando possíveis manejos que possam ser realizados, a fim de alcançar a produção máxima das culturas (Gomes et al., 2014).

Diversos modelos vêm sendo desenvolvidos e validados para diferentes regiões do mundo e com diversas finalidades de utilização. Dentre eles podemos citar os modelos AquaCrop, CropSyst e WOFOST, sendo estes considerado os modelos mais bem estabelecidos (Todorovic et al., 2009). O AquaCrop é utilizado para simular a produção de biomassa diária das plantas e o rendimento final no momento da colheita, levando em consideração a relação da disponibilidade de água e seu consumo com a fisiologia das plantas (Vanuytrecht et al., 2014; Araujo et al., 2019; Farias, 2020).

3.3.1 WOFOST

Um dos modelos mais antigo e mais utilizado para estimar a produtividade de áreas, de forma remota é o modelo World Food Studies (WOFOST), pois utiliza de variáveis agrometereológicas, solo, manejo agrícola e ciclo hidrológico, o que torna o modelo mais preciso para a estimativa de produtividade. Diversos processos podem ser simulados e descritos, como o desenvolvimento fenológico das culturas, o crescimento e os rendimentos das culturas, desde a emergência até a sua maturação (Jin et al., 2018; De Wit et al., 2019, 2020).

Para que a estimativa de produtividade das culturas utilizando o modelo WOFOST seja o mais próximo possível da produção real obtida em campo, são utilizadas diversas fontes de dados, como dados de solo, para as simulações de balanço hídrico do solo, de local, e cultura em estudo (Curnel et al., 2011; Li et al., 2024). Outro dado importante é os dados de local, que se refere à concentração de CO₂. Outras variáveis importantes para o modelo são as provenientes de dados meteorológicos que são utilizadas para simular o desenvolvimento das culturas e a evapotranspiração, em que são utilizados a temperatura do ar mínima e máxima, a precipitação, velocidade do vento, duração do dia e radiação solar (De Wit et al., 2020, 2019).

As simulações do modelo são realizadas com bases em variáveis que devem ser informadas pelo usuário. Para a simulação do acúmulo de matéria seca são necessárias as variáveis de irradiação, temperatura e as características da cultura. Este cálculo serve de ponto de partida para demais simulações, como para o crescimento e o desenvolvimento das culturas (De Wit et al., 2020).

O modelo WOFOST inicia suas simulações a partir da emergência da cultura e as conclui quando a planta atinge o ponto de colheita ou a maturação fisiológica. O desenvolvimento da cultura é avaliado por meio de uma variável adimensional chamada "Development Stage" (DVS), que varia de 0 a 2 (Li et al., 2024). O DVS 0,0 marca o início da emergência da cultura, momento em que a planta começa a se desenvolver com base nas condições do solo (disponibilidade hídrica) e do ambiente (fotossíntese). O DVS 1,0 caracteriza o início do florescimento da cultura, fase em que a planta inicia seu processo de reprodução. O valor máximo, DVS 2,0, refere-se ao ponto em que a cultura atinge seu estágio de maturação completa, seja pela senescência ou pelo ponto de colheita (De Wit et al., 2019).

O modelo pode ser utilizado para diversas culturas agrícolas e em diferentes regiões, o que o torna um modelo global. Associações de técnicas são utilizadas junto ao modelo com o intuito de melhorar a precisão das previsões de produtividade e, dentre estas associações, é possível encontrar trabalhos citando a assimilação com dados de sensoriamento remoto e dados meteorológicos (Bai et al., 2020; Wu et al., 2021; Shi et al., 2022; Zhuo et al., 2022).

Por meio da assimilação de dados espectro-agroclimáticos de sensoriamento remoto utilizando o modelo de crescimento WOFOST para a soja, Becker (2021) estimou a produtividade para o município de Cascavel-PR e obteve como resultado que a assimilação destes dados proporciona uma melhora na qualidade das estimativas de produtividade das áreas avaliadas. Ao final das avaliações, os resultados obtidos foram considerados satisfatórios para a soja, tendo em vista que o modelo WOFOST não foi desenvolvido para tal simulação.

Por se tratar de um modelo versátil é possível a assimilação do modelo WOFOST com o índice de área foliar MODIS (LAI), Zhuo et al. (2022) realizaram estudos na cultura do trigo de inverno na região de Hebei, China em que obtiveram resultados promissores a respeito da associação do sensor MODIS LAI com o modelo WOFOST, tal assimilação reduziu a incerteza da previsão de produtividade da região, quando comparado com as estatísticas oficiais dos municípios.

Bai et al. (2020) realizou a modificação do modelo com o intuito de prever a produção da espécie frutífera jujuba (*Zizyphus jujuba*) utilizando como parâmetro-chave a idade da planta. O modelo criado possibilitou a previsão dos rendimentos de jujuba com precisão e permitiu a simulação do crescimento para outras espécies frutíferas.

3.4 Dados agrometeorológicos

As condições climáticas são as principais impactantes na produtividade das culturas. Em vista disto, são necessárias formas de monitoramento e previsão de eventos para que se possa realizar algumas estratégias visando a diminuição de impactos, como antecipação/adiamento da semeadura, aplicação de fertilizantes e defensivos, entre outros manejos.

Desta forma, atualmente estão disponíveis dados oriundos de estações meteorológicas e plataformas que utilizam dados de satélites. Estes dados sobre o clima podem ser úteis para o monitoramento de safras, utilizando modelos de simulação de produtividade para isto. Tais modelos permitem a previsão de produtividade de culturas e produção de biomassa, além de ser possível a combinação com dados oriundos de estações meteorológicas, a fim de melhorar a precisão (Araújo et al., 2011; Johann et al., 2011; Duarte; Sentelhas, 2019). A associação de dados de satélites com os de estações meteorológicas tem maior quantidade de usuários, devido ao número reduzido de estações que forneçam dados gratuitos e por estas não abrangerem uma grande área, inviabilizando estudos de variabilidade espacial (Grego et al., 2017).

Algumas plataformas disponibilizam dados meteorológicos de forma gratuita e de fácil acesso aos usuários, sendo possível a aquisição de dados diários, semanais, mensais e anuais, com diferentes resoluções espaciais e temporais. Dentre as principais plataformas de aquisição de dados climáticos podem ser citados o ECWMF e o NasaPower (ECMWF, 2022; NASA, 2022).

3.4.1 Nasa-Power

O projeto Power (Prediction of Worldwide Energy Resources), da NASA, tem como objetivo fornecer conjuntos de dados solares e meteorológicos para que se possa entender as mudanças que vêm ocorrendo na Terra e prevê-las. O projeto busca oferecer suporte a

comunidades de pesquisa em energias renováveis, eficiência energética em edifícios e para as necessidades agrícolas (NASA, 2022).

Os parâmetros fornecidos pela plataforma são baseados na radiação solar e dados meteorológicos de modelos de assimilação. Estes estão disponíveis em séries temporais no formato climatológico, anual, mensal e diário. A plataforma disponibiliza parâmetros agrometeorológicos relacionados aos fluxos solares (Irradiância, radiação fotossintética e Índice UV), temperatura e fluxo térmico, umidade e precipitação, vento e pressão, assim como propriedades do solo (umidade do solo). A resolução espacial dos dados é de aproximadamente 50 km, os dados são originais da fonte, sendo os dados meteorológicos provenientes do projeto MERRA-2 e os dados solares do projeto CERES FLASHFlex (NASA, 2022)

Valeriano et al. (2017) realizaram a comparação e avaliação dos modelos NasaPower e ECMWF para a obtenção de dados de temperatura e precipitação, chegando a resultados satisfatórios para os dados de temperatura, em que os modelos apresentaram valores de R² médio de 0,87 para o ECMWF e 0,74 para o NasaPower e os valores do índice de concordância de Willmott (d) de 0,96 e 0,91 para o ECMWF e NasaPower, respectivamente. Isso demonstra que para ambos os modelos a acurácia e a precisão obtiveram bons resultados, indicando que estes podem ser utilizados quando os dados das estações meteorológicas não estiverem disponíveis. Já para os dados de precipitação, os autores indicam a necessidade de mais trabalhos a respeito deste assunto para comprovar a precisão dos modelos.

Para estimar os rendimentos de milho em diferentes regiões do Brasil, Duarte e Sentelhas (2019) utilizaram os dados meteorológicos disponibilizados pelo NasaPower, comparados aos dados obtidos por estações meteorológicas do Instituto Nacional de Meteorologia (INMET), chegando a resultados satisfatórios, demonstrando que os dados simulados foram promissores, sendo que para os valores de produtividade potencial os resultados médios de precisão (R²) foram de 0,91 e os de acurácia (d) atingiram o valor de 0,99, e o erro médio foi de 40,4 kg ha⁻¹, superestimando em 0,3% os valores reais.

4. MATERIAL E MÉTODOS

4.1 Área de estudo

A área de estudos compreendeu propriedades localizadas nos municípios de Castro e Piraí do Sul (Figura 2), localizados na região Centro Oriental do estado do Paraná. O município de Castro apresenta área territorial de 2.531,503 km², sendo 1.405,69 km² destinados para estabelecimentos agropecuários (IBGE, 2023). A altitude média é de 979 metros em relação ao nível do mar (IPARDES, 2024). Os solos predominantes no município são Cambissolos, Nitossolos, Latossolos e Neossolos (Fasolo et al., 2002).

O município de Piraí do Sul conta com território de 1.345,417 km², a área destinada para estabelecimentos agropecuários do município é de 1.074,94 km² (IBGE, 2023). A altitude média do município é de 1.022 metros em relação ao nível do mar (IPARDES, 2022). Os principais solos encontrados são Cambissolos, Latossolos, Neossolos e Nitossolos (Potter et al., 2002).

A classificação climática de Koppen (Köppen; Geiger, 1928) para ambos os municípios é Cfb (FUNDAÇÃO ABC, 2022). A classificação é descrita por meio de códigos, que são compostos por três letras indicando grupo, tipo e subtipo, respectivamente, sendo a primeira letra em maiúsculo e as demais em minúsculo. O código Cfb caracteriza regiões de clima temperado com verões amenos, a precipitação varia entre 1.100 e 2.000 mm e as chuvas são distribuídas uniformemente. Regiões que apresentam esta classificação não apresentam estação seca, tendo como temperaturas médias entre 10 e 22 °C nos meses mais quentes do ano (Medeiros, 2020).



Figura 2 Áreas de estudo, município de Castro e Piraí do Sul, Estado do Paraná, Brasil.

4.2 Dados de Observações de campo

Para a obtenção dos dados de campos foram realizadas parcerias com 2 produtores locais, os quais forneceram dados de produtividade das áreas e datas de semeadura das áreas. Por meio do auxílio dos produtores, foram realizadas simulações em 24 talhões para a safra 2019/2020, sendo 14 talhões localizados em Castro-PR, com área total de 435,32 ha e 10 em Piraí do Sul-PR, com área total de 1.247,4 ha. Para a safra 2022/2023, o estudo foi realizado em 13 talhões, 4 talhões com área total de 238,3 ha em Castro-PR e 9 talhões com área total de 1.080,8 ha em Piraí do Sul-PR.

Com a utilização dos dados obteve-se as coordenadas geográficas de cada talhão, bem como o histórico de culturas implantadas nas áreas e a produtividade real. Os dados foram utilizados para a obtenção das variáveis necessárias para a simulação da produtividade das áreas, como as datas do ciclo fenológico, índice de área foliar e dados agrometeorológicos.

4.3 Mapeamentos de soja

Os mapeamentos foram utilizados para o cálculo do índice de área foliar das áreas pilotos e para estimar as datas do ciclo fenológicos para os munícipios de estudo e para as propriedades de interesse. O mapeamento das áreas de soja dos municípios para o ano-safra de 2019/2020 foram cedidos por Paludo et al. (2020).

Para o ano-safra 2022/2023, o mapeamento foi desenvolvido seguindo a metodologia descrita por Paludo et al. (2020). Para obtenção das imagens utilizou-se a plataforma geoespacial online Google Earth Engine, as imagens foram obtidas dos satélites Landsat-8 OLI, com resolução espacial de 30 m e temporal de 16 dias e satélite Sentinel-2 MSI, com resolução espacial de 10 m e temporal de 5 dias. O período entre 1° de dezembro e 31 de março foi selecionado para obtenção das imagens, por se tratar do período em que a soja apresenta o seu máximo desenvolvimento, permitindo que estes dados fossem utilizados para a classificação.

Antes da classificação, aplicou-se a segmentação RGB de cores falsas utilizando o algoritmo Simple Non-Iterative Clustering (SNIC), que tem como objetivo simplificar imagens de um milhão de pixels em clusters menores de pixels semelhantes, chamados superpixels (Papon et al., 2013). Os parâmetros utilizados na segmentação SNIC foram: seeds, que representa o número de pixels semelhantes por cluster, definido como 25; size, sendo o espaçamento entre os centros dos superpixels, definido como 300 pixels; compactness, fator de compressão, definido como 1; connectivity, que se refere à conectividade entre clusters, definido como 8; e neighborhood size, sendo o tamanho da vizinhança do cluster e se refere aos seus limites, definido como nulo. A imagem segmentada foi utilizada como entrada no processo de classificação

Para a classificação foram utilizadas as bandas B4 (red, $0,64 - 0,67 \mu$ m), B5 (NIR, $0,85 - 0,88 \mu$ m) e B6 (SWIR, $1,57 - 1,65 \mu$ m) do Landsat-8, e bandas B8 (NIR, 842 μ m), B11 (SWIR 1, 1610 μ m) e B4 (red, 665 μ m) do Sentinel-2, para obtenção das imagens. A nebulosidade máxima foi configurada para 30%. As bandas de vermelho, infravermelho próximo e infravermelho médio foram selecionadas a fim distinguir a soja do milho, levando em consideração que ambas as culturas são semeadas em períodos próximos ou simultaneamente.

As composições de imagens do Landsat-8 e Sentinel-2 foram mapeadas por datas e processadas separadamente. Para a realização do mapeamento, utilizou-se o algoritmo Continuous Naive Bayes (CNB), por se tratar de um classificador probabilístico simples que calcula conjuntos de probabilidades utilizando combinações de frequência e valor de um conjunto de dados (Pati; Sherekar, 2013). Como treinamento do algoritmo, foram utilizadas, em média, 4 amostras por microrregião com polígonos de 30 pixels homogêneos.

Após a classificação, utilizou-se o software ArcMap 10.0, aplicou-se o filtro FocalAtatistics para remoção de ruídos (pixels sozinhos ou distantes), e áreas menores que 5.000 m² foram removidas, por serem pequenas para o cultivo de soja. Ao final, cada mapeamento foi convertido em shapefiles e estes foram combinados para criar o mapeamento final da região.

4.4 Modelo de Estimativa de Produtividade

A metodologia utilizada foi adaptada da descrita por Becker (2021). Para simular a estimativa de produtividade da cultura utilizou-se o modelo WOFOST, empregando a versão Python, PCSE – Python Crop Simulation Environment. A obtenção dos dados para gerar a simulação da produtividade foi obtida por meio da assimilação de dados meteorológicos e espectrais de satélites ao simulador, como descrito na Figura 3.

Para que o modelo realizasse as simulações corretamente foi necessário obter variáveis como as datas do ciclo fenológico, o índice de área foliar, dados agrometeorológicos, bem como dados de solo, de cultura, de local e de manejo.

Os dados sobre as datas do ciclo fenológico são importantes variáveis de entrada e apresentam alto impacto no modelo WOFOST, pois definem o momento e o tempo de permanência da cultura, para cada pixel (Becker, 2021). Os dados IAF foram assimilados ao modelo, com o objetivo de melhorar as estimativas de produtividade (Kang; Özdoğan, 2019).

A assimilação de dados associados a modelos de crescimento de cultura é comumente utilizada para simular da produtividade de culturas agrícolas (Gaso et al., 2023; Becker, 2021; Kang; Özdoğan, 2019; Pan et al., 2019). O simulador de produtividade WOFOST integra dados de solo, climáticos e da cultura para chegar a um resultado próximo ao real da área. Sendo assim, escolheu-se este modelo pela possibilidade de realização de ajustes e modificação dos parâmetros de entrada, além da capacidade de incorporar dados de sensoriamento remoto. Os processos foram realizados utilizando linguagem de programação Python. Os dados de sensoriamento remoto foram obtidos por meio da plataforma Google Earth Engine e importados automaticamente conforme eram requeridos pelo modelo.



Figura 3 Fluxograma da estimativa de produtividade, utilizando o modelo WOFOST. Fonte: Autor.

4.5 Dados do Ciclo fenológico

As datas do ciclo fenológico são variáveis importantes para a simulação do modelo WOFOST, sendo assim é necessário que sejam determinadas as datas de semeadura (DS) e colheita (DC) da cultura.

Os dados do ciclo fenológico foram obtidos utilizando a plataforma Google Earth Engine, por meio de imagens do satélite Sentinel-2. As imagens foram obtidas no período de 01 de setembro a 31 de maio, dos anos-safra 2019/2020 e 2022/2023. Este período foi selecionado buscando obter imagens de todo o ciclo da soja, desde a pré-semeadura até o pós-colheita, visto que estes dados são utilizados para o cálculo do balanço hídrico da cultura, por meio do modelo WOFOST.

Por meio das imagens obtidas, realizou-se uma análise de série temporal de NDVI, com o intuito de identificar padrões de vegetação ao longo do período selecionado, buscando determinar as datas de semeadura, máximo desenvolvimento vegetativo e colheita, identificando os valores máximos e mínimos de NDVI, durante as fases de desenvolvimento, ao longo da série temporal. Para o processamento das imagens foi necessária a filtragem das imagens para incluir apenas aquelas dentro do período de estudo e com nebulosidade máxima de 30%. Para isto, aplicou-se uma máscara de remoção de pixels com cobertura de nuvens, utilizando a banda QA60, do Sentinel-2. O cálculo do índice NDVI para cada imagem foi realizado utilizando as bandas B8 (NIR, 842 µm) e B4 (red, 665 µm).

As imagens foram agrupadas em mosaicos diários, buscando reduzir a quantidade de dados e melhorar a consistência temporal. Por meio da série temporal de NDVI gerou-se um gráfico para a área de estudo, utilizando uma redução média sobre a região de interesse. Para isto foram necessários os dados provenientes do mapeamento.

Buscando melhorar a análise, foram realizadas interpolação e suavização dos dados. Aplicou-se interpolação linear para preenchimento de lacunas temporais em intervalos de 5 dias. Para suavização da série temporal utilizou-se o filtro Savitzky-Golay, que tem como objetivo reduzir a variabilidade do ruido sem distorcer significativamente os sinais da série. Este passo se fez necessário devido a restrições ocasionadas pelas interferências atmosféricas, as quais geram ruídos, os quais ocorrem normalmente quando se utilizam séries temporais de índices de vegetação (Johann et al., 2016).

Devido ao alto custo operacional e ao grande número de pixels provenientes das áreas de estudo, foi necessária a realização da reamostragem dos pixels de 10 m para 100 m, utilizando a ferramenta "Reprojetar coordenadas" do software QGIS versão 3.22.7, sendo que o método de reamostragem utilizado foi o vizinho mais próximo. Utilizou-se esta metodologia buscando diminuir o tempo de processamento das áreas.

4.6 Índice de área foliar

Outro importante dado para o modelo WOFOST é o índice de área foliar (IAF), sendo obtido por meio de séries temporais de imagens de satélites e cálculo baseado em índice de vegetação. As imagens necessárias para obtenção dos dados sobre o IAF da cultura foram obtidos por meio da plataforma geoespacial Google Earth Engine, utilizando linguagem de programação Javascript.

Os dados de IAF foram obtidos utilizando imagens do satélite Sentinel-2, provenientes da colação COPERNICUS/S2, no período de 01 de setembro a 31 de maio dos anos-safra 2019/2020 e 2022/2023, permitindo ao simulador adquirir dados de IAF que antecedem o estabelecimento da cultura e abrangendo todo o ciclo da cultura. A área geográfica de interesse foi definida pelo mapeamento da soja associado aos talhões de estudo.

Para a obtenção dos dados utilizou-se a fórmula desenvolvida por Boegh et al. (2002) (Equação 3), para o cálculo do IAF das imagens. Este cálculo apresenta como métrica r² = 0,77, demonstrando que o IAF verde apresenta interação linear com o EVI.

$$IAF = 3,618 * EVI - 0,118$$
 Eq. (3)

Para o cálculo do EVI utilizaram-se imagens provenientes do satélite Sentinel-2, sendo utilizado: Banda 08 (NIR) – banda do infravermelho próximo, indicada para o mapeamento de conteúdo de biomassa, detecção e análise de vegetação; Banda 04 (vermelho) – utilizada para a identificação de tipos de vegetação, solos e áreas urbanas; e Banda 02 (azul) – a banda azul é útil para a discriminação de solo e vegetação, além do mapeamento de tipos de florestas. Todas as bandas apresentam resolução espacial de 10 m/pixel e temporal de 5 dias (SENTINEL, 2022).

Após o cálculo, realizou-se a construção de uma série temporal por meio da criação de um mosaico de imagens para cada data, sendo combinadas para reduzir a quantidade de imagens por dia. A técnica de interpolação linear foi utilizada para suavizar a série temporal e preencher possíveis lacunas nos dados.

Buscando minimizar ruídos, aplicou-se uma máscara de nuvens, utilizando a banda QA60 do Sentinel-2, que tem como objetivo filtrar imagens com cobertura de nuvens. O filtro Savatsky-Golay também foi utilizado para suavizar a série temporal e remover possíveis ruídos. Nas imagens obtidas, realizou-se uma reamostragem dos pixels de 10 m para 100 m, utilizando a ferramenta "Reprojetar coordenadas" do software QGIS versão 3.22.7, sendo que o método de reamostragem utilizado foi o vizinho mais próximo.

A estimativa do IAF por meio de dados de índice de vegetação apresenta resultados confiáveis para as culturas agrícolas. Com o uso de bandas de infravermelho próximo e utilizando os cálculos de EVI e NDVI foram possíveis obtenções de dados próximos aos dados obtidos a campo para a cultura de soja (Nguy-Robertson et al., 2012), sendo possível validar os dados obtidos por meio da estimativa do índice de área foliar das propriedades de estudo.

4.7 Dados Meteorológicos, parâmetros de solo, cultura, local e manejo agrícola

Para a determinação da estimativa de produtividade, o modelo necessita de valores meteorológicos diários, como temperatura máxima e mínima do ar, precipitação, velocidade do vento, duração do dia e radiação solar, sendo necessário dados diários destas variáveis (De Wit et al., 2019, 2020).

A obtenção dos dados meteorológicos se deu pela plataforma NasaPower, os quais apresentam resolução espacial de 50 km e temporal diária (NASA, 2022). A importação dos dados ocorreu por meio do mecanismo presente na biblioteca PCSE. Para datas em que não existiam informações, o mecanismo de importação denominou estas de 'missing data', sendo necessário realizar a estimação dos dados utilizando a média simples entre o dia anterior e o posterior.

Para o modelo WOFOST são necessários dados de solo, da cultura, do local e manejo (De Wit et al., 2020), além dos dados agrometeorológicos. Os parâmetros de solo requisitados são obtidos por meio do próprio modelo. Para este trabalho utilizou-se o solo "EC3 médio

fino", sendo este o arquivo de solo para areia média fina da biblioteca de solos de drenagem livre (De Wit et al., 2019). Este solo foi escolhido pois apresenta características mais próximas às encontradas na região. Os parâmetros da cultura são fornecidos pelo modelo (De Wit et al., 2019), e ajustados e calibrados para a cultura da soja (Abadi et al., 2018; Luo et al., 2020; Pinheiro et al., 2019).

Para os parâmetros de locais foram fornecidos dados do valor ajustado de CO₂. Estes dados não são fornecidos pelo arquivo de solo, sendo necessário ajustá-lo para cada local de estudo, pois trata-se de uma variável necessária para a estimativa da produção de matéria seca diária (Becker, 2021).

Outro parâmetro necessário é o manejo agrícola, que se refere às datas de início do ciclo agrícola, utilizando o balanço hídrico, definido para 15 dias antes do início da semeadura. As datas de semeadura e colheita e duração máxima da simulação da cultura estão relacionadas ao manejo, pois buscam evitar simulações que não correspondam com o ciclo da cultura (De Wit et al., 2020). Estes dados foram definidos para cada pixel. A duração máxima do ciclo foi definida em 160 dias, seguindo o informado pela Embrapa Soja (2022).

4.8 Ensemble Kalman Filter

Para a assimilação dos dados e a obtenção da estimativa de produtividade, utilizou-se o algoritmo Ensemble Kalman Filter (EnKF), que foi incorporado ao modelo WOFOST para obter a produtividade para cada pixel das áreas de estudo.

O EnKF é o algoritmo de assimilação de dados sequenciais mais usado para estimativa de produtividade (Gaso et al., 2023; Kang; Özdoğan, 2019; Pan et al., 2019). Neste estudo, realizou-se a assimilação de dados de IAF, as quais foram obtidas a partir de imagens de sensoriamento remoto. Incluiu-se uma perturbação de 5% na variável IAF e o tamanho de ensemble escolhido foi de 50 (Kang; Özdoğan, 2019; Pan et al., 2019).

4.9 Validação

Para quantificar a qualidade dos resultados obtidos, algumas métricas foram utilizadas para determinar a acurácia do modelo. Utilizou-se, além de estatísticas descritivas entre os resultados do modelo e dados observados, cálculos de erros: erro médio (ME – Equação 4), erro médio absoluto (MAE – Equação 5) e raiz quadrada do erro médio (RMSE – Equação 6). Os cálculos dos erros indicam a qualidade das estimativas do modelo, buscam-se resultados próximos a zero. ME e RMSE indicam a distância da média estimada em relação à média observada, sendo possível avaliar se o modelo está superestimando ou subestimando os resultados, assim como o MAE, porém este realiza a verificação em termos absolutos.

O desempenho do modelo foi avaliado utilizando três métricas principais: o coeficiente de correlação de Pearson ("r"), o índice de concordância melhorado de Willmott (Dr - Equação

7, Willmott et al., 2012), e o índice de desempenho (Pi - Equação 8, Alvares et al., 2013). O índice Pi, uma atualização do índice de confiança "c" (Sentelhas; Camargo, 1997), tem seu critério de interpretação apresentado na Tabela 2. Essas métricas fornecem uma avaliação abrangente do modelo, com o índice de concordância de Willmott indicando a acurácia e o coeficiente de correlação "r" representando a precisão, medindo o grau de dispersão dos dados em relação à média.

$$ME = \frac{1}{n} \sum_{i=1}^{n} (Yest - Yobs)$$
 Eq.(4)

$$MAE = \frac{1}{n} * \sum_{i=1}^{n} |Yest - Yobs|$$
 Eq.(5)

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^{n} (Xsi - Yec)^2}$$
 Eq.(6)

$$Pi = r * Dr$$
 Eq.(7)

$$Dr = 1 - \frac{\sum_{i=1}^{n} |Yest - Yobs|}{2 * \sum_{i=1}^{n} |Yest - \overline{Yact}|}$$
Eq.(8)

em que: *n* é o número de áreas; Y_{est} – produtividade estimada pelo modelo; Y_{obs} – produtividade observada em áreas agrícolas monitoradas e Y_{act} – diferença entre Y_{est} e Y_{obs} .

 Tabela 4 Critério de interpretação do desempenho pelo índice Pi, proposto por Alvares et al.

 (2013)

Valor de Pi	Desempenho
≥ 0,75	Ótimo
0,60 ⊢ 0,75	Muito Bom
0,45 ⊢ 0,60	Bom
0,30 ⊢ 0,45	Mediano ou Tolerável
0,15 ⊢ 0,30	Sofrível ou Pobre
0,00 ⊢ 0,15	Mau
< 0,00	Péssimo
(2010)	

Fonte: Alvares et al. (2012).

5. RESULTADOS E DISCUSSÃO

Este estudo estimou a produtividade de soja utilizando técnicas de assimilação de dados agrometeorológicos e índices de área foliar no modelo de crescimento de cultura WOFOST. As avaliações foram realizadas em propriedades localizadas nos municípios de Castro e Piraí do Sul, no estado do Paraná, Brasil. A metodologia estimou a produtividade em nível de pixel. A avaliação da metodologia foi utilizando dados de produtividade informado por produtores locais.

5.1 Mapeamento de soja

O modelo de simulação de produtividade WOFOST necessita que seja realizada a assimilação de dados agrometeorológicos, biofísicos e fenológicos, para que seja possível gerar uma produtividade estimada para cada área de estudo.

Por meio do mapeamento da cultura é possível selecionar apenas os pixels onde a cultura está realmente ocorrendo durante o período, evitando assim possíveis erros decorrentes da contaminação dos pixels com matas e estradas, por exemplo.

O mapeamento das áreas de soja foi utilizado neste trabalho na obtenção das variáveis necessárias para o simulador, sendo utilizado para estimar as datas do ciclo fenológico e no cálculo do índice de área foliar das áreas.

Na Tabela 5 são apresentados os valores referentes aos mapeamentos de soja dos municípios de Castro-PR e Piraí do Sul-PR, dados estes que foram comparados aos informados pelo IBGE (2024). Para a comparação entre os dados utilizaram-se os dados referentes às áreas plantadas de cada município. Os resultados dos mapeamentos são demonstrados também em formas de mapas nas Figuras 4a e 4b.

Municípios	Safras	Mapeamento Dados oficiais		Diferença
		de soja (ha)	(IBGE) (ha)	
Castro DP	2019/2020	56.060	78.950	29%
Castio-FR	2022/2023	30.084	63.000	23%
Piraí do Sul-	2019/2020	43.621	39.300	31%
PR	2022/2023	30.847	35.600	13%

Tabela 5 Valores em hectares das áreas mapeadas de soja, comparadas com os dados de órgãos oficiais

Fonte: Autor; IBGE (2024).



Figura 4 Mapeamento de soja dos municípios de Castro-PR e Piraí do Sul-PR, para as safras 2019/2020 (a) e 2022/2023 (b).

Os dados do mapeamento, quando confrontados com os dados oficiais, fornecidos pelo IBGE (2023), percebe-se que ocorrem subestimações das áreas. Este resultado pode ser relacionado ao fato de áreas inferiores a 5.000 m² não serem utilizadas na somatória de áreas. Paludo (2020) relata também que a presença de nuvens pode interferir no mapeamento das áreas.

Betta et al. (2022) realizaram o mapeamento dos municípios de Capão Alto e Lages no estado de Santa Catarina, Brasil. Os dados obtidos demonstraram divergências com dados oficiais, sendo mapeadas em média 6% menos áreas em relação aos órgãos oficiais.

5.2 Datas do Ciclo Fenológico

A estimativa de datas do ciclo fenológico da cultura é uma variável necessária para que ocorra a simulação da produtividade. Para o município de Castro, na safra 2019/2020 (Figura 5), observa-se que as datas de semeadura foram distribuídas principalmente entre os meses de setembro e novembro, porém, o plantio da soja concentrou-se entre os meses de outubro e novembro, representando 71,16% das áreas mapeadas.

Para o município de Castro-PR, ocorreu maior concentração de plantio entre a segunda quinzena do mês de outubro e a segunda quinzena do mês de novembro, representando uma concentração de 70,67% das áreas semeadas durante este período (Figura 6).

A estimativa de semeadura para a safra 2022/2023 apresentou como resultado áreas semeadas mais tardiamente em relação à safra 2019/2020. Este fato pode ter ocorrido devido à influência climática, ocasionada pelo excesso de chuvas entre os meses de setembro e novembro de 2022 (CONAB, 2023).



Figura 5 Datas de semeadura para o município de Castro-PR, safra 2019/2020.



Figura 6 Datas de semeadura para o município de Castro-PR, safra 2022/2023.

As datas de semeadura para o município de Piraí do Sul-PR concentraram-se entre os meses de outubro e novembro de 2019 (Figura 7), representando 81,22% das áreas do município semeadas dentro deste período.

Assim como observado na safra 2019/2020, a semeadura ficou concentrada entre os meses de outubro e novembro na safra 2022/2023 (Figura 8), o que representa 70,86% das áreas de soja semeadas neste período.

Em seu estudo, Becker (2021) identificou a semeadura das áreas do município de Cascavel-PR, para o ano-safra 2019/2020, durante o terceiro decêndio de setembro e o segundo decêndio de outubro, tendo como predominância a semeadura no primeiro decêndio de outubro.

As datas de colheita estimadas para a safra 2019/2020 para o município de Castro (Figura 9) se distribuíram pelos meses de janeiro a maio, tendo maior concentração no mês de abril, com 55% das áreas colhidas durante este período. Já para a safra 2022/2023 (Figura 10) as colheitas ocorreram principalmente nos meses de abril e maio, com 48% das áreas sendo colhidas no mês de maio.

O município de Piraí do Sul-PR não apresentou tendência de datas de colheita, assim como para o município de Castro-PR, padrão este que pode ser visto nas datas de semeadura. Para o ano-safra de 2019/2020 (Figura 11), as datas de colheita ficaram concentradas principalmente no mês de abril, com 51% das áreas sendo colhidas durante este período; enquanto para a safra 2022/2023 (Figura 12), as colheitas apresentaram-se espaçadas, entre os meses de abril e maio.



Figura 7 Datas de semeadura para o município de Piraí do Sul-PR, safra 2019/2020.



Figura 8 Datas de semeadura para o município de Piraí do Sul-PR, safra 2022/2023.

É possível observar que o período de colheita da cultura se apresentou maior em relação ao período de semeadura. Essa amplitude de datas pode ser explicada devido à ocorrência de diversos fatores, como disponibilidade hídrica, aumento do fotoperíodo e ataque de pragas e doenças em algumas áreas (Farias et al., 2008).



Figura 9 Datas de colheita para o município de Castro-PR, safra 2019/2020.



Figura 10 Datas de colheita para o município de Castro-PR, safra 2022/2023.



Figura 11 Datas de colheita para o município de Piraí do Sul-PR, safra 2019/2020.



Figura 12 Datas de colheita para o município de Piraí do Sul-PR, safra 2022/2023.

5.3 Produtividade

O modelo de simulação utilizado gerou resultados de produtividade média para as áreas de estudos que variaram entre 2.255 e 4.175,13 kg ha⁻¹. Apesar da variabilidade dos valores, a produtividade das áreas concentrou-se entre 3.000 e 4.000 kg ha⁻¹.

O município de Piraí do Sul-PR contou com 70,3% das áreas no intervalo de 3.000 e 4.000 kg ha⁻¹, para a safra 2019/2020 e 72% das áreas neste mesmo intervalo na safra 2022/2023. Já para o município de Castro-PR houve uma exceção para o ano-safra 2019/20, quando os valores concentraram-se entre 3.500 e >4.000 kg ha⁻¹, enquanto para a safra 2022/2023, 96,1% concentrou-se entre 3.000 e 4.000 kg ha⁻¹.

A variabilidade temporal e espacial da produtividade da soja, para as áreas de estudo, nas safras 2019/2020 e 2022/2023 são representadas em forma de mapas (Figuras 13, 14, 15 e 16). Para o município de Castro-PR a média de produtividade das áreas foi de 3483,1 kg ha⁻¹ para a safra 2019/2020 e 3536,4 kg ha⁻¹ para a safra 2022/2023. Os dados oficiais disponibilizados pelo IBGE (2023) informam que a produção de soja foi de 3.700 e 3.923 kg ha⁻¹ para as safras 2019/2020 e 2022/2023, respectivamente.

O município de Piraí do Sul-PR apresentou média de produtividade das áreas de estudo de 3174,41 kg ha⁻¹ para a safra 2019/2020 e 3174,41 kg ha⁻¹ para a safra 2022/2023. Os dados oficiais de rendimento médio para o município foram de 3.600 kg ha⁻¹ para a safra 2019/2020 e 3.835 kg ha⁻¹ para a safra 2022/2023.



Figura 13 Mapa de produtividade de soja dos talhões estudados no município de Castro-PR, ano-safra 2019/2020.



Figura 14 Mapa de produtividade de soja dos talhões estudados no município de Castro-PR, ano-safra 2022/2023.



Figura 15 Mapas de produtividade de soja para os talhões estudados no município de Piraí do Sul-PR, ano-safra 2019/2020.



Figura 16 Mapas de produtividade de soja para os talhões estudados no município de Piraí do Sul-PR, ano-safra 2022/2023.

A produção de uma cultura é resultado de inúmeros fatores, que em conjunto resultam em uma produtividade satisfatória ou insatisfatória, como fertilidade, disponibilidade hídrica, fotoperíodos, fitossanidade, manejo de pragas ou fatores climáticos adversos (granizo, seca, chuvas em excesso, entre outros). Assimilando dados de IAF ao modelo, é possível obter estimativas de produtividade que mostram valores variando dentro do talhão e entre talhões. Para Gaso et al. (2023), a assimilação dos dados de IAF levou a uma melhoria apreciável na precisão das estimativas de rendimento, sendo possível ainda estimar a variabilidade espacial dentro de um mesmo talhão.

Os mapas de produtividade (Figura 16) e Boxplot (Figura 17) mostram que a produtividade da soja apresenta mudanças espaciais para ambos os municípios e através dos anos, para o município de Castro-PR. Esta mudança espacial dentro dos talhões e entre talhões pode ser explicada devido às características de solo e do relevo da região (Potter et al., 2002; Fasolo et al., 2002).

A produtividade da soja mudou ao longo dos anos de estudo para o município de Castro-PR. Esta mudança pode estar relacionada à semeadura tardia no ano-safra 2022/2023, em relação ao ano-safra 2019/2020. Esta mudança pode ser explicada pela dependência espacial dos dados agrometeorológicos, fenológicos (DS, DMDV e DC) e biofísicos (IAF), em que o clima é um fator determinante nas datas de semeadura e colheita, além de influenciar nos valores de LAI (Becker, 2021).





Para a safra 2022/2023, o máximo desenvolvimento vegetativo ocorreu no mês de fevereiro; sendo assim, o clima favorável para a cultura no mês de janeiro (CONAB, 2023) auxiliou o bom desenvolvimento da cultura, devido a cultura estar se encontrando na fase de enchimento de grãos, período em que ocorre o seu maior requerimento hídrico (Farias et al., 2008).

5.4 Validação

A capacidade do modelo de simular a produtividade de soja foi avaliada em nível municipal e apresentou resultados de precisão consistentes com trabalhos anteriores, que estudaram a assimilação de IAF em modelos de crescimento, buscando determinar a estimativa de produtividade de culturas (Gaso et al., 2023; Zhuo et al., 2022; Becker, 2021; Kang; Özdoğan, 2019; Pan et al., 2019).

Observa-se, pela Tabela 6, que os dados obtidos são satisfatórios e condizem com o esperado com este trabalho, pois busca-se que os resultados simulados sejam próximos aos encontrados em campo. O Coeficiente Correlação [r] mostrou haver uma correlação linear positiva alta para ambos os municípios, indicando que os valores estimados pelo modelo estão correlacionados com os valores informados pelos produtores.

	Municípios		
Variáveis	Castro-PR	Piraí do Sul-PR	
r	0,705	0,778	
RMSE	679,359	346,951	
ME	-500,248	-139,903	
MAE	548,637	238,550	
Dr	0,523	0,700	
Pi	0,369	0,544	

Tabela 6 Estatísticas obtidas entre os dados de produtividade estimada pelo modelo e os dados de produtividade obtidos com os produtores rurais

Nota: $r = coeficiente de correlação; R^2 = coeficiente de determinação; ME = Erro médio; RMSE = Raiz do Erro Médio Quadrático;$ *Dr*: índice de concordância melhorado de Willmott (2012);*Pi*= índice de desempenho (Alvares et al., 2013).

A acurácia do modelo foi avaliada por meio do índice de concordância melhorado de Willmott (2012), o qual avalia a dispersão dos dados em relação à reta 1:1 (Johann, 2012); sendo assim, avaliou-se a exatidão entre os valores da produtividade estimada com os valores da produtividade real de campo, mostrando que, para os municípios de estudo, ocorreu uma exatidão moderada entre os dados.

Ao analisar o índice de desempenho [*Pi*] do modelo, estes variaram entre 0,369 e 0,544, sendo classificados por Alvares et al. (2013) como um desempenho tolerável para o município de Castro-PR e bom desempenho para Piraí do Sul-PR.

Em comparação com as produtividades obtidas a campo, nota-se que para ambos os municípios de estudo ocorreram subestimações dos resultados pelo modelo WOFOST, o qual pode ser observado pelos valores de ME.

A subestimação das produtividades pelo modelo já era esperada, devido ao fato de o WOFOST ser um modelo desenvolvido para culturas de cereais, em que o desenvolvimento fenológico das culturas é determinado, porém o modelo foi adaptado para o uso em soja, cultura considerada de ciclo indeterminado, sendo os seus estádios de desenvolvimento vegetativo e reprodutivo ocorrem em paralelo nas plantas, durante grande parte do seu ciclo (De Wit et al., 2019; Machado Junior et al., 2017).

Os resultados obtidos neste estudo foram superiores a resultados encontrados por demais autores que utilizaram a técnica de assimilação de dados associada com modelos de crescimento para estimar a produtividade de culturas (Becker, 2021; Kang; Özdoğan, 2019; Pan et al., 2019).

Becker (2021), ao analisar os resultados provenientes da comparação entre a produtividade obtida por meio da estimativa com a real de campo, obteve dados de correlação de 0,714, o erro médio absoluto foi de 657,25 kg ha⁻¹ e a raiz quadrada do erro médio foi de 762,85 kg ha⁻¹.

Gaso et al. (2021) desenvolveu um modelo de soja que buscava prever a variabilidade da produtividade de áreas, assimilando dados de IAF recuperados do Sentinel-2 ao modelo de cultivo, o qual obteve valores de RMSE variando de 343 a 602 kg ha⁻¹ e ME entre -365 e 411 kg ha⁻¹.

Os resultados podem ser considerados satisfatórios, se considerado o custo computacional e a escala dos dados de entrada no modelo, os quais necessitaram serem reprojetados para uma resolução de pixels maior, devido à dificuldade do algoritmo em processar os dados em sua resolução original de 10 metros.

Quando comparados os resultados a outros trabalhos que utilizaram técnicas similares, a metodologia utilizada apresentou bons resultados. Entretanto, melhores resultados podem ser alcançados realizando otimizações no algoritmo utilizado e nos dados, buscando uma diminuição do tempo de processamento das áreas.

6. CONCLUSÃO

Este estudo mostrou que a assimilação de dados espectro-agroclimáticos obtidos a partir de sensoriamento remoto associados ao modelo de crescimento de cultura WOFOST apresentou resultados promissores na estimativa de produtividade da soja.

Os resultados indicaram uma precisão moderada, com resultados satisfatórios para ambos os municípios, quando avaliada pelo índice de Willmott. Em termos de desempenho geral, Castro-PR foi classificado como "tolerável" e Piraí do Sul-PR apresentou um desempenho melhor, sendo classificado como "bom".

Por meio dos resultados demonstra-se que dados obtidos por meio de índices de vegetação têm potencial para obtenção de informações fenológicas e biofísicas da soja, tornando possível a aplicação de modelos de crescimento em diferentes tamanhos de áreas, devido à resolução espacial ser possível de adaptação para cada área, não ficando refém apenas de dados oriundos de sensores com resoluções baixas.

O fator limitante para a aplicação da técnica para todo o território dos municípios de estudo foi o custo computacional para a realização das simulações, o qual permitia que as simulações fossem feitas em apenas áreas pequenas.

Com isto, conclui-se que o método utilizado para estimar a produtividade de soja pode ser aplicado em diversos tamanhos de áreas de estudos, com características diferentes. A utilização de processos automatizados permite que futuros trabalhos possam implementar melhorias e atualizações na metodologia utilizada.

7. REFERÊNCIAS

ABADI, F. R.; TASTRA, I. K.; KOENTJORO, B. S. Preliminary Study of WOFOST Crop Simulation in Its Prospect for Soybean (Glycine max L.) Optimum Harvest Time and Yield Gap Analysis in East Java. **Agrivita Journal of Agricultural Science**, [S.L.], v. 40, n. 3, p. 544-555, 2018. http://dx.doi.org/10.17503/agrivita.v40i3.1832.

ABEDINPOUR, M.; SARANGI, A.; RAJPUT, T.B.S.; SINGH, M.; PATHAK, H.; AHMAD, T. Performance evaluation of AquaCrop model for maize crop in a semi-arid environment. **Agricultural Water Management**, [S.L.], v. 110, p. 55-66, 2012. http://dx.doi.org/10.1016/j.agwat.2012.04.001.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. de M. Modeling monthly mean air temperature for Brazil. **Theoretical And Applied Climatology**, [S.L.], v. 113, n. 3-4, p. 407-427, 2012. http://dx.doi.org/10.1007/s00704-012-0796-6.

ARAUJO, G. P.; SILVA, M. A. V.; OLIVEIRA, E. C.; SALES, R. A.; SOUZA, S. A. Simulação e calibração do modelo Aquacrop para a estimativa da produtividade da cultura da soja. **Ciências Agrárias: Campo Promissor em Pesquisa 5,** [S.L.], p. 172-181, 2019. http://dx.doi.org/10.22533/at.ed.19119200619.

BAI, T.; WANG, T.; ZHANG, N.; CHEN, Y.; MERCATORIS, B. Growth simulation and yield prediction for perennial jujube fruit tree by integrating age into the WOFOST model. **Journal of Integrative Agriculture**, [S.L.], v. 19, n. 3, p. 721-734, 2020. http://dx.doi.org/10.1016/s2095-3119(19)62753-x.

BAYMA, A. P.; SANO, E. E. Séries temporais de índices de vegetação (NDVI e EVI) do sensor Modis para detecção de desmatamentos no bioma Cerrado. **Boletim de Ciências Geodésicas**, [S.L.], v. 21, n. 4, p. 797-813, 2015. http://dx.doi.org/10.1590/s1982-21702015000400047.

BECKER, W. R. Sensoriamento remoto associado a técnicas de mineração de dados para estimativas de produção agrícola. 2021. 159 f. Tese (Doutorado) - Curso de Programa de Pós-Graduação em Engenharia Agrícola, Universidade Estadual do Oeste do Paraná, Cascavel, 2021.

BENEDETTI, A. C. P.; LIPPERT, D. P.; PEREIRA, R. S.; ALMEIDA, C. M.; CARDOSO, C. D. V.; HENDGES, E. R. Uso do produto MOD13Q1 do sensor Modis para análise temporal e mapeamento das florestas nas Serras do Sudeste e Campanha Meridional do Rio Grande do Sul. **Revista Árvore**, [S.L.], v. 37, n. 3, p. 459-467, 2013. http://dx.doi.org/10.1590/s0100-67622013000300009.

BETTA, M. M. D.; TRABAQUINI, K.; ELIAS, H. T.; SILVA, M. S. Mapeamento da soja por meio de imagens Landsat e Sentinel-2 nos municípios de Lages e Capão Alto em Santa Catarina. **Agropecuária Catarinense**, [S.L.], v. 35, n. 2, p. 68-73, 2022. http://dx.doi.org/10.52945/rac.v35i2.1347.

BEZERRA, A. R. G.; SEDIYAMA, T.; BORÉM, A.; SOARES, M. M. Importância Econômica. In: SILVA, F.; BORÉM, A.; SEDIYAMA, T.; CÂMARA, G. (Org.). **Soja:** do plantio à colheita. São Paulo: Oficina de Textos, 2022. p. 9-20.

BEZERRA, U.A.; OLIVEIRA, L.M.M.; CANDEIAS, A.L.B.; SILVA, B.B.; LEITE, A.C.L.S.; SILVA, L.T.M.S. Comparison of the Normalized Difference Vegetation Index (NDVI) Between the Sensors OLI-Landsat Satellite-8 and MSI-Sentinel-2 Satellite in Semi-Arid Region. **Anuário do Instituto de Geociências - UFRJ**, [S.L.], v. 41, n. 3, p. 167-177, 2018. http://dx.doi.org/10.11137/2018_3_167_177.

BOEGH, E.; SOEGAARD, H.; BROGE, N.; HASAGER, C.B.; JENSEN, N.O.; SCHELDE, K.; THOMSEN, A. Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. **Remote Sensing of Environment**, [S.L.], v. 81, n. 2-3, p. 179-193, 2002. http://dx.doi.org/10.1016/s0034-4257(01)00342-x.

BORGES, K. M. R.; OROZCO FILHO, J. C.; COAN, G. P. de O.; VASCONCELOS, T. M. M. Sensoriamento Remoto e Geoprocessamento como Subsídio ao Manejo do Fogo e ao Combate aos Incêndios Florestais em Unidades de Conservação Federais. **Biodiversidade Brasileira - Biobrasil**, [S.L.], v. 11, n. 2, p. 168-178, 2021. http://dx.doi.org/10.37002/biobrasil.v11i2.1685.

BRAZ, A.M.; BARROS, M.H.S.; GARCIA, P.H.M. Validação das classificações das imagens dos satélites Landsat 8 e Sentinel-2 na bacia hidrográfica do Córrego Ribeirãozinho/MS. **Revista Eletrônica da Associação dos Geógrafos Brasileiros**, [S/L], v. 26, n. 14, p. 14-58, 2017.

CÂMARA, G. M. de S. Fenologia é ferramenta auxiliar de técnicas de produção. **Visão Agrícola**, v. 3, n. ja/ju, p. 63-66, 2006.

CAMARGO, A.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de agrometeorologia**, Campina Grande, v. 5, n. 1, p. 89-97, 1997.

CAMPBELL, J.B.; WYNNE, R.H. Introduction to Remote Sensing. 5th ed. New York: The Guilford Press, 2011.

CONAB. Acompanhamento da safra brasileira de grãos. [s.l:] 2022.

CONAB. **Portal de Informações Agropecuárias**. Disponível em: https://portaldeinformacoes.conab.gov.br/downloads/arquivos/SerieHistoricaGraos.txt. Acesso em: 24 out. 2022.

COPERNICUS SENTINEL. **Missão S2**. Disponível em: https://sentiwiki.copernicus.eu/web/s2-mission. Acesso em: 06 jul. 2024.

CURNEL, Y.; WIT, A.J.W. de; DUVEILLER, G.; DEFOURNY, P. Potential performances of remotely sensed LAI assimilation in WOFOST model based on an OSS Experiment. **Agricultural and Forest Meteorology**, [S.L.], v. 151, n. 12, p. 1843-1855, 2011. http://dx.doi.org/10.1016/j.agrformet.2011.08.002.

DERAL. **Boletim Semanal – 39/2022 – 20 de outubro de 2022**. Disponível em: https://www.agricultura.pr.gov.br/sites/default/arquivos_restritos/files/documento/2022-10/boletim_semanal_39_deral_20_outubro_2022.pdf. Acesso em: 24 out. 2022.

DERAL. **Prognóstico Cultura SOJA – Dezembro de 2020**. Disponível em: https://www.agricultura.pr.gov.br/sites/default/arquivos_restritos/files/documento/2021-09/prognostico_soja_-_2020_21.pdf. Acesso em: 22 out. 2022.

DEV ACHARYA, T.; YANG, I.; STUDENT, G. Exploring Landsat 8 Satellite precipitation dataset integration using machine learning View project Landslide Susceptibility Mapping of Sindhupalchowk, Nepal View project Exploring Landsat 8. International Journal of IT, Engineering and Applied Sciences Research. [s.l:s.n.]. Disponível em: http://earthobservatory.nasa.gov/IOTD/.

DORRANCE, A. E. The soybean crop. **Agrios' Plant Pathology**, [S.L.], p. 773-779, 2024. http://dx.doi.org/10.1016/b978-0-12-822429-8.00035-2. DUARTE, Y. C. N.; SENTELHAS, P. C. NASA/POWER and DailyGridded weather datasets how good they are for estimating maize yields in Brazil? **International Journal of Biometeorology**, [S.L.], v. 64, n. 3, p. 319-329, 2019. http://dx.doi.org/10.1007/s00484-019-01810-1.

ECMWF. **ERA5**. Disponível em: https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5. Acesso em: 26 out. 2022.

EMBRAPA SOJA. **Cultivares de soja**: Centro-Sul do Brasil: macrorregiões 1, 2, 3 e REC 401. Londrina/PR, 2019.

EMBRAPA SOJA. **Soja em números (safra 2020/21)**. 2021. Disponível em: https://www.embrapa.br/web/portal/soja/cultivos/soja1/dados-economicos. Acesso em: 22 out. 2022.

EMBRAPA. **CULTIVARES SOJA – PARANÁ**. Disponível em: https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/soja/preproducao/caracteristicas-da-especie-e-relacoes-com-o-ambiente/cultivares/parana. Acesso em: 27 out. 2022

EMBRAPA. **Dados econômicos – Portal Embrapa**. Disponível em: https://www.embrapa.br/web/portal/soja/cultivos/soja1/dados-economicos. Acesso em: 22 out. 2022.

ESTEVAM, V. da S.; REGES, N.P.R.; SANTOS, M.P. dos. Uso do índice NDVI para deteminação fenológica da cultura da soja. **Revista Uniaraguaia**, [S.I.], v. 18, n. 1, p. 106-115, 2023.

FARIAS, J. R. B.; NEUMAIER, N.; NEPOMUCENO, A. L. SOJA. In: MONTEIRO, José Eduardo B. A. (Org.). **Agrometeorologia dos Cultivos**: o fator meteorológico na produção agrícola. Brasília: Instituto Nacional de Meteorologia – Inmet, 2009. p. 263-277.

FASOLO, P. J. CARVALHO, A. P.; POTTER, R. O.; BOGNOLA, I. A.; BHERING, S. B.; MARTORANO, L. G. **Caracterização dos solos do Município de Castro, PR**. Rio de Janeiro: Embrapa Solos, 2002. 88p.

FEHR, W. R.; CAVINESS, C. E. Stages of Soybean Development. **Special Report 80**. v. 80, p. 1-12, 1977.

FEIO, S.V.M. Análise multitemporal de imagens do satélite Sentinel-2 como suporte à elegibilidade das ajudas comunitárias agrícolas. 2017. 66 f. Dissertação (Mestrado) - Curso de Engenharia Geográfica, Universidade de Lisboa, Lisboa, 2017.

FUNDAÇÃO ABC. **Climatologia – Classificação Climática – Paraná**. Disponível em: https://sma.fundacaoabc.org/climatologia/classificacao_climatica/parana. Acesso em: 22 out. 2022.

GAIDA, W.; BREUNIG, F.; GALVÃO, L.; TELES, T.; BALBINOT, R. Variações da reflectância e dos índices de vegetação em função dos parâmetros da modelagem topográfica no Parque Estadual do Turvo, Rio Grande do Sul, Brasil. **Investigaciones Geográficas**, n. 91, 2016.

GASO, D.V.; WIT, A.; BRUIN, S.; PUNTEL, L.A.; BERGER, A.G.; KOOISTRA, L. Efficiency of assimilating leaf area index into a soybean model to assess within-field yield variability. **European Journal of Agronomy**, [S.L.], v. 143, p. 126718, 2023. http://dx.doi.org/10.1016/j.eja.2022.126718.

GOMES, A. C. S.; ROBAINA, A. D.; PEITER, M. X.; SOARES, F. C.; PARIZI, A. R. C. Modelo para estimativa da produtividade para a cultura da soja. **Ciência Rural**, [S.L.], v. 44, n. 1, p. 43-49, 2013. http://dx.doi.org/10.1590/s0103-84782013005000145.

GOOGLE LLC. **Google Earth Engine**. Disponível em: https://earthengine.google.com/. Acesso em: 10 ago. 2023.

GREGO, C.R.; TEIXEIRA, A.H. de C.; LEIVAS, J.F.; BAYMA-SILVA, G.; MANJOLIN, R.C. Interpolação de dados agromeorológicos em duas densidades amostrais no norte de Minas Gerais. **Agrometeoros**, [S.L.], v. 25, n. 1, p. 81-88, 2018. http://dx.doi.org/10.31062/agrom.v25i1.26269.

HIRAKURI, M. H. Perdas econômicas geradas por estresses bióticos e abióticos na produção brasileira de soja no período 2016-2020. Londrina, Pr: Embrapa, 2021. 8 p.

HU, S.; SHI, L.; HUANG, K.; ZHA, Y.; HU, X.; YE, H.; YANG, Q. Improvement of sugarcane crop simulation by SWAP-WOFOST model via data assimilation. **Field Crops Research**, [S.L.], v. 232, p. 49-61, 2019. http://dx.doi.org/10.1016/j.fcr.2018.12.009.

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, [S.L.], v. 25, n. 3, p. 295-309, 1988. http://dx.doi.org/10.1016/0034-4257(88)90106-x.

IBGE+ Produção Agrícola Municipal 2022. Rio de Janeiro: IBGE, 2023

IBGE. **Cidades e Estados do Brasil**. Disponível em: https://cidades.ibge.gov.br/. Acesso em: 25 jun. 2023.

INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONÔMICO E SOCIAL. Caderno estatístico município de Castro. Castro: Ipardes, 2024.

INSTITUTO PARANAENSE DE DESENVOLVIMENTO ECONÔMICO E SOCIAL. Caderno estatístico município de Piraí do Sul. Piraí do Sul: Ipardes, 2022.

JIN, X.; KUMAR, L.; LI, Z.; FENG, H.; XU, X.; YANG, G.; WANG, J. A review of data assimilation of remote sensing and crop models. **European Journal of Agronomy**, [S.L.], v. 92, p. 141-152, 2018. http://dx.doi.org/10.1016/j.eja.2017.11.002.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital Modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná – Brasil. **Engenharia Agrícola**, [S.L.], v. 36, n. 1, p. 126-142, 2016. http://dx.doi.org/10.1590/1809-4430-eng.agric.v36n1p126-142/2016.

JOHANN, J.A.; ROCHA, J.V.; ROLIM, G.S.; LAMPARELLI, R.A.C.; DUFT, D.G. Comparação entre dados de temperatura média de estações meteorológicas com dados do modelo ECMWF entre 2000 e 2009 no estado do Paraná. XV Simpósio Brasileiro de Sensoriamento Remoto - Sbsr, **Anais...** Curitiba, v. 1, n. 1, p. 5817-5824, maio 2011.

KANG, Y.; ÖZDOğAN, M. Field-level crop yield mapping with Landsat using a hierarchical data assimilation approach. **Remote Sensing of Environment**, [S.L.], v. 228, p. 144-163, 2019. http://dx.doi.org/10.1016/j.rse.2019.04.005.

KÖPPEN, W.; GEIGER, R. **Klimate der Erde.** Gotha: Verlag Justus Perthes. 1928. Wall-map 150cmx200cm.

LEASTRO, M.O.; KITAJIMA, E.W.; SÁNCHEZ-NAVARRO, J.Á. Soybean. Viral Diseases of Field and Horticultural Crops, [S.L.], p. 139-153, 2024. http://dx.doi.org/10.1016/b978-0-323-90899-3.00080-x.

LEE, C.; KUO, C.; YANG, C.; KAO, H.; TSENG, K.; LAN, W. Assessment of hydrological changes in inland water body using satellite altimetry and Landsat imagery: a case study on tsengwen reservoir. **Journal of Hydrology: Regional Studies**, [S.L.], v. 44, p. 101227, 2022. http://dx.doi.org/10.1016/j.ejrh.2022.101227.

LEIVAS, J. F.; TEIXEIRA, A. H. C.; ANDRADE, R. G. Agrometeorologia. In: TÔSTO, S. G.; RODRIGUES, C. A. G.; BOLFE, É. L.; BATISTELLA, M. (Eds.). **Geotecnologias e Geoinformação**: o produtor pergunta, a Embrapa responde. 2. ed. Brasília: Embrapa, 2014. Cap. 7. p. 119-134. (Coleção 500 Perguntas, 500 Respostas).

LI, X.; TAN, J.; WANG, X.; HAN, G.; QIAN, Z.; LI, H.; WANG, L.; NIU, G. Responses of spring wheat yield and growth period to different future climate change models in the yellow river irrigation area based on CMIP6 and WOFOST models. **Agricultural and Forest Meteorology**, [S.L.], v. 353, p. 110071-110072, 2024. http://dx.doi.org/10.1016/j.agrformet.2024.110071.

LIMA, A. A. S.; TEIXEIRA, J. S.; ARAUJO, F. A.; ALVES, G. A. R.; MELO, M. R. da S.; SOUZA, D. L.; SOUZA JÚNIOR, G. N. de; BRAGA, M. de B. Detecção e mapeamento de vegetação daninha em áreas de cultivo de soja por meio de Inteligência Artificial e Sensoriamento Remoto no Sudeste Paraense. **Observatório de La Economía Latinoamerican**a, [S.L.], v. 22, n. 3, p. 01-20, 2024. http://dx.doi.org/10.55905/oelv22n3-009.

LIMA, E. P.; SEDIYAMA, G. C.; ANDRADE, R. G.; LOPES, V. D.; SILVA, B. B. Evapotranspiração real diária em sub-bacias do Paracatu, utilizando produtos do sensor Modis. **Revista Ceres**, [S.L.], v. 61, n. 1, p. 17-27, 2014. http://dx.doi.org/10.1590/s0034-737x2014000100003.

LÓPEZ-SERRANO, P. M.; DOMÍNGUEZ, J. L. C.; CORRAL-RIVAS, J. J.; JIMÉNEZ, E.; LÓPEZ-SÁNCHEZ, C. A.; VEGA-NIEVA, D. J. Modeling of Aboveground Biomass with Landsat 8 OLI and Machine Learning in Temperate Forests. **Forests**, [S.L.], v. 11, n. 1, p. 11, 2019. http://dx.doi.org/10.3390/f11010011.

LOPRESTI, M. F.; BELLA, C. M.; DEGIOANNI, A. J. Relationship between MODIS-NDVI data and wheat yield: a case study in northern Buenos Aires Province, Argentina. **Information Processing in Agriculture**, [S.L.], v. 2, n. 2, p. 73-84, 2015. http://dx.doi.org/10.1016/j.inpa.2015.06.001.

LUO, D.; SILVA, D. P.; MARCO JÚNIOR, P.; PIMENTA, M.; CALDAS, M. M. Model approaches to estimate spatial distribution of bee species richness and soybean production in the Brazilian Cerrado during 2000 to 2015. **Science of The Total Environment**, [S.L.], v. 737, p. 139674, 2020. http://dx.doi.org/10.1016/j.scitotenv.2020.139674.

MACHADO JÚNIOR, C. S.; SILVA, C. R.; SANCHES, M. C.; HAMAWAKI, O. T.; SOUSA, L. B. Physiologic parameters of soybean of determinate and indeterminate growth habit subjected to levels of soil moisture. **Pesquisa Agropecuária Brasileira**, [S.L.], v. 52, n. 6, p. 419-425, 2017. http://dx.doi.org/10.1590/s0100-204x2017000600005.

MEDEIROS, R. M. Método da classificação climática de Köppen e Thornthwaite aplicado ao município de Bom Jesus - PI, Brasil. **Brazilian Journal of Agroecology And Sustainability**, [S.L.], p. 1-19, 2020. http://dx.doi.org/10.52719/bjas.v1i2.2648.

MINISTÉRIO DA AGRICULTURA E PECUÁRIA. **Exportações do agronegócio fecham 2023 com US\$ 166,55 bilhões em vendas**. Disponível em: https://www.gov.br/agricultura/ptbr/assuntos/noticias/exportacoes-do-agronegocio-fecham-2023-com-us-166-55-bilhoes-emvendas. Acesso em: 10 maio 2024.

MINISTÉRIO DA AGRICULTURA E PECUÁRIA. Valor bruto da produção ultrapassa R\$ 1,14 trilhão em março. Disponível em: https://www.gov.br/agricultura/pt-

br/assuntos/noticias/valor-bruto-da-producao-ultrapassa-r-1-14-trilhao-em-marco-deste-ano. Acesso em: 15 maio 2024.

MUNICÍPIO DE CASTRO. **Portal do Cidadão – Município de Castro**. Disponível em: https://castro.atende.net/cidadao/pagina/dados-gerais. Acesso em: 22 out. 2022.

NASA. **Missão de satélite de observação da Terra Aqua | Ciência do Projeto Aqua**. Disponível em: https://aqua.nasa.gov/. Acesso em: 22 out. 2022b.

NASA. MODIS Web. Disponível em: https://modis.gsfc.nasa.gov/. Acesso em: 22 out. 2022a.

NASA. **The POWER Project**. Disponível em: https://power.larc.nasa.gov/. Acesso em: 11 out. 2022.

NGUY-ROBERTSON, A.; GITELSON, A.; PENG, Y.; VIÑA, A.; ARKEBAUER, T.; RUNDQUIST, D. Green Leaf Area Index Estimation in Maize and Soybean: combining vegetation indices to achieve maximal sensitivity. **Agronomy Journal**, [S.L.], v. 104, n. 5, p. 1336-1347, 2012. http://dx.doi.org/10.2134/agronj2012.0065.

PALUDO, A.; BECKER, W. R.; RICHETTI, J.; SILVA, L. C. de A.; JOHANN, J. A. Mapping summer soybean and corn with remote sensing on Google Earth Engine cloud computing in Parana state – Brazil. **International Journal of Digital Earth**, [S.L.], v. 13, n. 12, p. 1624-1636, 2020. http://dx.doi.org/10.1080/17538947.2020.1772893.

PAN, H.; CHEN, Z.; WIT, A.; REN, J. Joint Assimilation of Leaf Area Index and Soil Moisture from Sentinel-1 and Sentinel-2 Data into the WOFOST Model for Winter Wheat Yield Estimation. **Sensors**, [S.L.], v. 19, n. 14, p. 3161, 2019. http://dx.doi.org/10.3390/s19143161.

PAPON, J.; ABRAMOV, A.; SCHOELER, M.; WORGOTTER, F. Voxel Cloud Connectivity Segmentation – Supervoxels for Point Clouds. **2013 IEEE Conference on Computer Vision and Pattern Recognition**, [S.L.], v. 1, n. 1, p. 2027-2034, jun. 2013. IEEE. http://dx.doi.org/10.1109/cvpr.2013.264.

PATI, T. R.; SHEREKAR, S. S. Performance Analysis of Naive Bayes and J48 Classification Algorithm for Data Classification. **International Journal of Computer Science and Applications**, [S. L.], v. 6, n. 2, p. 256-261, 2013.

PINHEIRO, E. A. R.; VAN LIER, Q. J.; I·IMŏNEK, J. The role of soil hydraulic properties in crop water use efficiency: a process-based analysis for some Brazilian scenarios. **Agricultural Systems**, [S.L.], v. 173, p. 364-377, 2019. http://dx.doi.org/10.1016/j.agsy.2019.03.019

PORTAL DA INDÚSTRIA. **Comércio Exterior e Exportação no Brasil**. Disponível em: https://www.portaldaindustria.com.br/industria-de-a-z/exportacao-e-comercio-exterior/. Acesso em: 16 out. 2022.

PORTAL EMBRAPA. **Aqua**. Disponível em: https://www.embrapa.br/satelites-demonitoramento/missoes/aqua. Acesso em: 22 out. 2022b.

PORTAL EMBRAPA. **SENTINEL**. Disponível em: https://www.embrapa.br/satelites-de-monitoramento/missoes/sentinel. Acesso em: 22 out. 2022a.

POTTER, R. O.; CARVALHO, A. P.; FASOLO, P. J.; BOGNOLA, I. A.; BHERING, S. B.; MARTORANO, L. G. **Caracterização dos solos do Município de Piraí do Sul, PR**. Rio de Janeiro: Embrapa Solos, 2002. 61 p.

QUARTAROLI, C. F.; VICENTE, L. E.; ARAUJO, L. S. de. Sensoriamento remoto. In: TÔSTO, S. G.; RODRIGUES, C. A. G.; BOLFE, E. L.; BATISTELLA, M. (Eds.). **Geotecnologias e**

geoinformação. Brasília, DF: Embrapa, 2014. p. 61-79. (Coleção 500 Perguntas, 500 Respostas)

RAFIQUE, K.; AHMED, K.; SHERIN, K. K.; KHAN, S.; TARIQ, S.; GUL, A. Genome engineering in soybean. **Targeted Genome Engineering Via Crispr/ Cas9 in Plants**, [S.L.], p. 177-195, 2024. http://dx.doi.org/10.1016/b978-0-443-26614-0.00013-8.

REES, W. G. **Physical Principles of Remote Sensing**. Cambridge: Cambridge University Press, 2012.

RODIGHERI, G.; FONTANA, D. C.; SCHAPARINI, L. P.; MENDES, A. P. S. F.; DALMAGO, G. A. Análise espectro-temporal DE NDVI e área da soja cultivada frente ao La Niña de 2012. **Agrometeoros**, [S.L.], v. 27, n. 1, p. 63-71, 2020. http://dx.doi.org/10.31062/agrom.v27i1.26569.

RODRIGUES, S. S.; BARROS, M. M. O uso do Vant e do sensoriamento remoto como ferramenta de melhoria das técnicas de agricultura de precisão. **Revista Digital Simonsen**, n. 10, 2019.

RODRÍGUEZ, A. T.; DÁVILA, J. F. R.; SICLÁN, M. L. S.; VILDÓZOLA, Á. C.; ZAMORA, F. I. M.; DIAZA, A. V. L. Distribuição espacial da antracnose (*Colletotrichum gloeosporioides Penz*) em abacate no Estado do México, México. **Revista Argentina de Microbiologia**, Buenos Aires, v. 52, n. 1, p. 72-81, 2020.

ROUSE JUNIOR, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **NASA**, Texas, v. 1, n. 1, p. 309-317, jan. 1974.

SCHAPARINI, L. P.; FONTANA, D. C.; DALMAGO, G. A.; RODIGHERI, G.; FERNANDES, J. M. C.; SANTI, A.; VARGAS, P. R. Análise comparativa entre índices de vegetação e sua relação com o balanço hídrico em soja. **Agrometeoros**, [S.L.], v. 27, n. 1, p. 183-190, 2020. http://dx.doi.org/10.31062/agrom.v27i1.26574.

SCHAPARINI, L. P.; FONTANA, D. C.; DALMAGO, G. A.; RODIGHERI, G.; FERNANDES, J. M. C.; SANTI, A.; VARGAS, P. R. Análise comparativa entre índices de vegetação e sua relação com o balanço hídrico em soja. **Agrometeoros**, [S.L.], v. 27, n. 1, p. 183-190, 2020. http://dx.doi.org/10.31062/agrom.v27i1.26574.

SCHIRMBECK, L. W.; FONTANA, D. C.; DALMAGO, G. A.; SCHIRMBECK, J.; VARGAS, P. R.; FERNANDES, J. M. C. Condições hídricas de lavoura de soja usando sensoriamento remoto terrestre. **Agrometeoros**, [S.L.], v. 27, n. 1, p. 173-181, 2020. http://dx.doi.org/10.31062/agrom.v27i1.26565.

SENTINEL. **Sentinel-2 – Descrição do Satélite**. Disponível em: https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/satellite-description. Acesso em: 22 out. 2022.

SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICENTE, L. E.; VICTORIA, D. C.; DUCATI, J. R.; OLIVEIRA, R. P. de; VILELA, M. de F. Sensoriamento Remoto: conceitos básicos e aplicações na agricultura de precisão. In: BERNARDI, A. C. de C.; BERNARDI, A. C. de C.; NAIME, J. M.; RESENDE, A. V; BASSOI, L. H.; INAMASU, R. Y. (Eds.). Agricultura de precisão: resultados de um novo olhar. Brasília: Embrapa, 2014. Cap. 4. p. 58-73.

SILVA JUNIOR, C. A.; LEONEL-JUNIOR, A. H. S.; ROSSI, F. S.; CORREIA FILHO, W. L. F.; SANTIAGO, D. B.; OLIVEIRA-JUNIOR, J. F.; TEODORO, P. E.; LIMA, M.; CAPRISTO-SILVA, G. F. Mapping soybean planting area in Midwest Brazil with remotely sensed images and phenology-based algorithm using the Google Earth Engine platform. Computers and Electronics Agriculture, in [S.L.], ٧. 169. n. 1, p. 105194. 2020. http://dx.doi.org/10.1016/j.compag.2019.105194.

SILVA, A. F. da; SEDIYAMA, T.; BORÉM, A. Exigências Edafoclimáticas. In: SILVA, F.; BORÉM, A.; SEDIYAMA, T.; CAMARA, G. **Soja:** do plantio à colheita. São Paulo: Oficina de Textos, 2022. p. 55-65.

SUNNY, D.S.; ISLAM, K.M. A.; MULLICK, R. A.; ELLIS, J. T. Performance study of imageries from MODIS, Landsat 8 and Sentinel-2 on measuring shoreline change at a regional scale. **Remote Sensing Applications**: Society and Environment, [S.L.], v. 28, p. 100816, 2022. http://dx.doi.org/10.1016/j.rsase.2022.100816.

TODOROVIC, M.; ALBRIZIO, R.; ZIVOTIC, L.; SAAB, M. A.; STÖCKLE, C.; STEDUTO, P. Assessment of AquaCrop, CropSyst, and WOFOST Models in the Simulation of Sunflower Growth under Different Water Regimes. **Agronomy Journal**, [S.L.], v. 101, n. 3, p. 509-521, 2009. http://dx.doi.org/10.2134/agronj2008.0166s.

TOMAR, V.; MANDAL, V. P.; SRIVASTAVA, P.; PATAIRIYA, S.; SINGH, K.; RAVISANKAR, N.; SUBASH, N.; KUMAR, P. Rice Equivalent Crop Yield Assessment Using MODIS Sensors' Based MOD13A1-NDVI Data. **IEEE Sensors Journal**, [S.L.], v. 14, n. 10, p. 3599-3605, 2014. http://dx.doi.org/10.1109/jsen.2014.2329185.

TRINDADE, F. S.; ALVES, M. C.; NOETZOLD, R.; ANDRADE, I. C.; POZZA, A. A. A. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. **Revista de Ciências Agrárias**, [S.L.], v. 62, p. 1-11, 2019. http://dx.doi.org/10.22491/rca.2019.2928.

TRINDADE, J. P. P.; VOLK, L. B. S.; ROCHA, D. S. Aplicação do Índice Normalizado de Vegetação no Monitoramento de Sistema de Unidades de Manejo. **Embrapa Pecuária Sul**, Bagé, v. 1, n. 1, p. 1-31, 2021.

U.S. GEOLOGICAL SURVEY. Landsat 8. Disponível em: https://www.usgs.gov/landsat-missions/landsat-8. Acesso em: 07 jul. 2024.

VALENCIA, L. V. A. Comportamento espectral das culturas de milho, arroz e soja, usando imagens dos satélites SENTINEL-2, CBERS-4 e LANDSAT-8. 2020. 118 f. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Ciências e Aplicações Geoespaciais, Universidade Presbiteriana Mackenzie, São Paulo, 2020.

VANUYTRECHT, E.; RAES, D.; STEDUTO, P.; HSIAO, T. C.; FERERES, E.; HENG, L. K.; VILA, M. G.; MORENO, P. M. AquaCrop: FAO'S crop water productivity and yield response model. **Environmental Modelling & Software**, [S.L.], v. 62, n. 1, p. 351-360, 2014. http://dx.doi.org/10.1016/j.envsoft.2014.08.005.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, [S.L.], v. 32, n. 13, p. 2088-2094, 2011. http://dx.doi.org/10.1002/joc.2419.

WIT, A.; BOOGAARD, H.; FUMAGALLI, D.; JANSSEN, S.; KNAPEN, R.; VAN KRAALINGEN, D.; SUPIT, I.; WIJNGAART, R. V. D.; VAN DIEPEN, K. 25 years of the WOFOST cropping systems model. **Agricultural Systems**, [S.L.], v. 168, p. 154-167, 2019. http://dx.doi.org/10.1016/j.agsy.2018.06.018.

WIT, A.J.W de; BOOGAARD, H. L.; SUPIT, I.; BERG, M. van Den. **System description of the WOFOST 7.2 cropping systems model**. [S.I.]: Wageningen Environmental Research, 2020. 109 p.

WU, S.; YANG, P.; REN, J.; CHEN, Z.; LI, H. Regional winter wheat yield estimation based on the WOFOST model and a novel VW-4DEnSRF assimilation algorithm. **Remote Sensing of Environment**, [S.L.], v. 255, n. 1, p. 112276, 2021. http://dx.doi.org/10.1016/j.rse.2020.112276.

ZHU, X.; DUAN, S.; LI, Z.; WU, P.; WU, H.; ZHAO, W.; QIAN, Y. Reconstruction of land surface temperature under cloudy conditions from Landsat 8 data using annual temperature cycle model. **Remote Sensing of Environment**, [S.L.], v. 281, n. 1, p. 113261, 2022. http://dx.doi.org/10.1016/j.rse.2022.113261.

ZHU, Z.; WULDER, M. A.; ROY, D. P.; WOODCOCK, C. E.; HANSEN, M. C.; RADELOFF, V. C.; HEALEY, S. P.; SCHAAF, C.; HOSTERT, P; STROBL, P. Benefits of the free and open Landsat data policy. **Remote Sensing of Environment**, [S.L.], v. 224, p. 382-385, 2019. http://dx.doi.org/10.1016/j.rse.2019.02.016.

ZHUO, W.; FANG, S.; GAO, X.; WANG, L.; WU, D.; FU, S.; WU, Q.; HUANG, J. Crop yield prediction using MODIS LAI, TIGGE weather forecasts and WOFOST model: a case study for winter wheat in Hebei, China during 2009-2013. **International Journal of Applied Earth Observation and Geoinformation**, [S.L.], v. 106, p. 102668-102682, 2022. http://dx.doi.org/10.1016/j.jag.2021.102668.

ZHUO, W.; HUANG, J.; XIAO, X.; HUANG, H.; BAJGAIN, R.; WU, X.; GAO, X.; WANG, J.; LI, X.; WAGLE, P. Assimilating remote sensing-based VPM GPP into the WOFOST model for improving regional winter wheat yield estimation. **European Journal of Agronomy**, [S.L.], v. 139, p. 126556, 2022. http://dx.doi.org/10.1016/j.eja.2022.126556.