



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA – UFRA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

LUIZ ANTONIO SOARES CARDOSO

**USO DE VEÍCULO AÉREO NÃO TRIPULADO PARA ANÁLISE ESPECTRAL
E ESPACIAL DA FITOSSANIDADE EM PLANTIOS DE CANA-DE-AÇÚCAR
NA AMAZÔNIA ORIENTAL**

BELÉM
2024

LUIZ ANTONIO SOARES CARDOSO

**USO DE VEÍCULO AÉREO NÃO TRIPULADO PARA ANÁLISE ESPECTRAL
E ESPACIAL DA FITOSSANIDADE EM PLANTIOS DE CANA-DE-AÇÚCAR
NA AMAZÔNIA ORIENTAL**

Tese apresentada como requisito para a
obtenção do grau de Doutor em
Agronomia pelo Programa de Pós-
graduação em Agronomia da
Universidade Federal Rural da
Amazônia.

Orientador: Prof. Dr. Paulo Roberto
Silva Farias

**BELÉM
2024**

Dados Internacionais de Catalogação na Publicação (CIP)
Bibliotecas da Universidade Federal Rural da Amazônia
Gerada automaticamente mediante os dados fornecidos pelo(a) autor(a)

- C268u Cardoso, Luiz Antonio Soares
Uso de Veículo Aéreo Não Tripulado para análise espectral e espacial da fitossanidade em plantios de cana-de-açúcar na Amazônia Oriental / Luiz Antonio Soares Cardoso. - 2024.
215 f. : il. color.
- Tese (Doutorado) - , Campus Universitário de Belém, Universidade Federal Rural Da Amazônia, Belém, 2024.
Orientador: Prof. Dr. Paulo Roberto Silva Farias
1. Saccharum ssp.; Índices de vegetação; Geoestatística; Machine learning; Mucuna pruriens; Agricultura de precisão. I. Farias, Paulo Roberto Silva , *orient.* II. Título

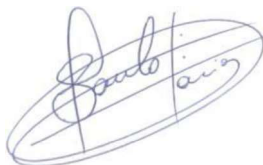
CDD 016.63

LUIZ ANTONIO SOARES CARDOSO

**USO DE VEÍCULO AÉREO NÃO TRIPULADO PARA ANÁLISE ESPECTRAL E
ESPACIAL DA FITOSSANIDADE EM PLANTIOS DE CANA-DE-AÇÚCAR NA
AMAZÔNIA ORIENTAL**

Tese apresentada ao Programa de Pós-graduação em Agronomia, como parte das exigências do Curso de Doutorado em Agronomia, área de concentração Agronomia, para obtenção do título de Doutor.

BANCA EXAMINADORA



Prof. Dr.º Paulo Roberto Silva Farias
Orientador

Universidade Federal Rural da Amazônia - UFRA

gov.br

Documento assinado digitalmente

FABIANO LUIS BELEM

Data: 03/05/2024 17:09:08-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr.º Fabiano Luís Belém
Universidade Federal do Amapá - UNIFAP

Prof. Dr.ª Francimary da Silva Carneiro
Universidade Federal Rural da Amazônia - UFRA

Javier Dias Pita Assinado de forma digital por Javier Dias Pita
Dados: 2024.05.02 21:11:33 -03'00'

Prof. Dr.º Javier Dias Pita
Instituto Federal de Educação, Ciência e Tecnologia do Pará - IFPA

gov.br

Documento assinado digitalmente

MARIANA MARTINS MEDEIROS DE SANTANA

Data: 06/05/2024 09:26:48-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr.ª Mariana Martins Medeiros de Santana
Universidade do Estado do Amapá - UEAP

Ao meu primo e irmão de leite:
Bruno Soares Gomes (*in memoriam*).

AGRADECIMENTOS

Agradeço a Deus pelo dom da vida.

Ao meu avô, Antonio Soares Neto, pelo grande incentivo à minha carreira acadêmica e pelo exemplo de integridade e perseverança ao qual busquei me inspirar ao longo de minha existência.

À minha avó, Maria Celina Alcântara Soares, por nunca ter soltado minha mão.

Aos meus pais, Sandro Souza Cardoso e Roselli Alcântara Soares, pelo amor e sacrifício que me dedicaram.

À minha namorada, Sabrina Sayd Guimarães Coutinho, por todo o apoio prestado durante os momentos mais difíceis do doutorado, demonstrando ser uma verdadeira companheira.

Aos meus irmãos, Lucas Soares Cardoso e Sandra Celina Soares Cardoso, e ao meu sobrinho Joaquim Pedro de Oliveira de Souza Filho, por tudo que representam em minha vida.

A todos os demais familiares e amigos que, de forma direta ou indireta, contribuíram para que eu alcançasse este objetivo em minha vida.

Ao meu orientador, Prof. Dr. Paulo Roberto Silva Farias, pela orientação acadêmica e pela parceria e amizade que construímos durante esse período.

Ao Prof. Dr. João Almiro Correa Soares pelo apoio desde a submissão da minha proposta de pesquisa até a cessão de dados importantes para a confecção desta tese de doutorado.

Ao Prof. Me. Carlos Rodrigo Tanajura Caldeira e à empresa Pará Pastoril e Agrícola S.A. (PAGRISA), principalmente ao Sr. Luís Ricardo Souza dos Santos, Líder em Automação Agrícola Pleno da empresa, por me confiarem dados e informações importantes utilizadas nesta pesquisa.

Ao Prof. Dr. Fábio Junior de Oliveira por ter me recebido no Campus da Universidade Federal Rural da Amazônia (UFRA), no município de Capitão Poço, estado do Pará, no início do ano de 2023, disponibilizando estrutura e suporte para continuidade e conclusão da minha tese.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Pará (IFPA), onde sou Professor do Ensino Básico, Técnico e Tecnológico (EBTT) no Campus Bragança desde maio/2017, por ter me concedido afastamento para pós-graduação strictu sensu no Brasil, no período de abril/2021 a abril/2024, o que permitiu que me dedicasse exclusivamente às atividades do doutorado.

À UFRA, ao Programa de Pós-graduação em Agronomia (PGAGRO) e aos demais docentes que me ofereceram as ferramentas necessárias para que eu realizasse o tão almejado objetivo de me tornar Doutor (PhD) em Agronomia.

“O saber é saber que nada se sabe. Esse é o preceito básico daqueles que investigam a natureza das coisas”.

Sócrates

RESUMO

Os Veículos Aéreos Não Tripulados (VANTs) tornaram-se uma importante ferramenta de inovação em diversas áreas da sociedade e da ciência, podendo ser utilizados nas mais diversas situações, melhorando e otimizando resultados. O amplo campo da Agricultura de Precisão (AP) aparece como um dos setores que melhor integra esta tecnologia, sendo utilizada nas mais diferentes espécies agrícolas, como, por exemplo, no cultivo da cana-de-açúcar, que será estudada neste trabalho. De acordo com o relatado, o objetivo desta pesquisa foi utilizar plataformas de VANT para análise espectral e espacial de plantações de cana-de-açúcar em áreas localizadas na Amazônia Oriental brasileira, região carente de pesquisas utilizando a ferramenta proposta e em relação à cultura estudada. A pesquisa foi subdividida em quatro capítulos. No primeiro capítulo foi realizada uma contextualização do cultivo da cana-de-açúcar e da Amazônia Oriental brasileira, bem como uma análise estatística em relação às áreas plantadas, produtividade e produção da cultura, ao longo de dez safras subsequentes, buscando compreender as dificuldades e o potencial da região. O segundo capítulo consistiu em uma revisão bibliográfica sobre a utilização de VANTs nos canaviais no Brasil, buscando demonstrar onde, quanto e como essa inovação tem sido utilizada nos canaviais nacionais. No terceiro capítulo iniciou-se o processamento das imagens obtidas pelo VANT, possibilitando a realização de análises estatístico-espectrais dos índices de vegetação NDVI (*Normalized Difference Vegetation Index*), SAVI (*Soil-Adjusted Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*) e GNDVI (*Green Normalized Difference Vegetation Index*), nas áreas canavieiras estudadas, permitindo a definição do índice que obteve o melhor ajuste aos dados, por meio de análises de correlação e regressão. Por fim, o quarto capítulo foi o último a ser discutido nesta pesquisa, possibilitando avaliar diferentes interpoladores espaciais para definir zonas de manejo fitossanitário em áreas com plantações de cana-de-açúcar, a fim de orientar o manejo de potenciais infestações da leguminosa mucuna-preta, considerada uma erva daninha para a cana-de-açúcar. Os interpoladores utilizados foram a *krigagem* ordinária (KO) e a *support vector machine* (SVM), provenientes, respectivamente, da geoestatística e do *machine learning*. Ao final deste capítulo foram inseridos dois anexos, um para cada interpolador utilizado, referentes aos resultados da realização de uma revisão de literatura para compreender o estado atual das pesquisas com ambos os interpoladores nas plantações de cana-de-açúcar no Brasil.

Palavras-chave: *Saccharum* ssp.; Índices de vegetação; Geoestatística; *Machine learning*; *Mucuna pruriens*; Agricultura de precisão.

ABSTRACT

Unmanned Aerial Vehicles (UAVs) have become an important innovation tool in different areas of society and science, and can be used in the most diverse situations, improving and optimizing results. The broad field of Precision Agriculture (PA) appears as one of the sectors that best integrates this technology, being used in the most different agricultural species, such as, for example, in the cultivation of sugar cane, which will be studied in this work. According to what was reported, the objective of this research was to use UAV platforms for spectral and spatial analysis of sugarcane plantations in areas located in the Brazilian Eastern Amazon, a region lacking in research using the proposed tool and in relation to the culture studied. The research was subdivided into four chapters. In the first chapter, a contextualization of sugarcane cultivation and the Brazilian Eastern Amazon was carried out, as well as a statistical analysis in relation to planted areas, productivity and production of the crop, over ten subsequent harvests, seeking to understand the difficulties and the potential of the region. The second chapter consisted of a bibliographical review on the use of UAVs in sugarcane fields in Brazil, seeking to demonstrate where, how much and how this innovation has been used in national sugarcane fields. In the third chapter, the processing of the images obtained by the UAV began, enabling the carrying out of statistical-spectral analyzes of the vegetation indices NDVI (Normalized Difference Vegetation Index), SAVI (Soil-Adjusted Vegetation Index), NDRE (Normalized Difference Red Edge Index) e GNDVI (Green Normalized Difference Vegetation Index), in the sugarcane areas studied, allowing the definition of the index that obtained the best adjustment to the data, through correlation and regression analyses. Finally, the fourth chapter was the last to be discussed in this research, making it possible to evaluate different spatial interpolators to define phytosanitary management zones in areas with sugarcane plantations, in order to guide the management of potential infestations of the legume velvet bean weed, considered a weed for sugar cane. The interpolators used were ordinary kriging (OK) and the support vector machine (SVM), coming, respectively, from geostatistics and machine learning. At the end of this chapter, two annexes were inserted, one for each interpolator used, referring to the results of carrying out a literature review to understand the current state of research with both interpolators on sugarcane plantations in Brazil.

Keywords: *Saccharum* ssp.; Vegetation indices; Geostatistics; Machine learning; *Mucuna pruriens*; Precision agriculture.

SUMÁRIO

1 ÁREA PLANTADA, PRODUTIVIDADE E PRODUÇÃO DE CANA-DE-AÇÚCAR NA AMAZÔNIA ORIENTAL BRASILEIRA.....	14
RESUMO	14
ABSTRACT	15
1.1 Introdução.....	16
1.2 Fenologia da Cana-de-Açúcar.....	17
1.3 Materiais e Métodos	18
1.3.1 Área de Estudo	18
1.3.2 Testes Estatísticos.....	21
1.4 Resultados e Discussão.....	23
1.4.1 Breve Descrição da Área Plantada, Produtividade e Produção de Cana-de-Açúcar nos estados da Amazônia Oriental (Safrá 2012/2013 a Safrá 2021/2022).....	23
1.4.1.1 Estado do Amapá (AP)	24
1.4.1.2 Estado do Maranhão (MA).....	25
1.4.1.3 Estado do Mato Grosso (MT).....	27
1.4.1.4 Estado do Pará (PA).....	29
1.4.1.5 Estado do Tocantins (TO).....	31
1.4.2 Análise da Normalidade dos Dados de Área Plantada, Produtividade e Produção de Cana-de-Açúcar nos Estados da Amazônia Oriental (Safrá 2012/2013 à Safrá 2021/2022).....	33
1.4.2.1 Estado do Amapá (AP)	33
1.4.2.2 Estado do Maranhão (MA).....	34
1.4.2.3 Estado do Mato Grosso (MT).....	34
1.4.2.4 Estado do Pará (PA).....	34
1.4.2.5 Estado do Tocantins (TO).....	34
1.4.3 Correlação e Regressão entre Dados de Área Plantada, Produtividade e Produção de Cana-de-Açúcar nos estados da Amazônia Oriental (Safrá 2012/2013 à Safrá 2021/2022).....	39
1.4.3.1 Estado do Amapá (AP)	39
1.4.3.2 Estado do Maranhão (MA).....	39

1.4.3.3 Estado do Mato Grosso (MT).....	40
1.4.3.4 Estado do Pará (PA).....	40
1.4.3.5 Estado do Tocantins (TO).....	41
1.4.4 Discussão.....	42
1.5 Conclusões.....	46
REFERÊNCIAS	47
2. USO DE VEÍCULO AÉREO NÃO TRIPULADO NO CULTIVO DA CANA-DE-AÇÚCAR NO BRASIL: UMA REVISÃO	51
RESUMO	51
ABSTRACT	52
2.1 Introdução.....	53
2.2 Uso de VANT em Plantações de Cana-de-açúcar no Brasil.....	54
2.3 Região Sudeste.....	56
2.3.1 Estado de São Paulo (SP).....	56
2.3.1.1 Detecção de Ervas Daninhas ou Pragas.....	56
2.3.1.2 Falhas de Plantio.....	58
2.3.1.3 Previsão de Maturidade	59
2.3.1.4 Melhoria de Sistema de Sensoriamento Remoto	60
2.3.1.5 Monitoramento do Estado Hídrico	61
2.3.2 Estado de Minas Gerais (MG).....	61
2.3.2.1 Falhas de Plantio.....	61
2.4 Região Centro-Oeste	62
2.4.1 Estado do Goiás (GO).....	62
2.4.1.1 Previsão de Maturidade	62
2.5 Região Sul	62
2.5.1 Estado do Paraná (PR).....	62
2.5.1.1 Mudanças nas Respostas Espectrais após Fertilização	62
2.6 Região Nordeste.....	63
2.6.1 Sem Localização Atribuída	63

2.6.1.1 Falhas de Plantio.....	63
2.7 Região Norte	63
2.7.1 Estado do Pará (PA)	63
2.7.1.1 Detecção de ervas daninhas ou pragas	63
2.8 Discussão	63
2.9 Conclusões.....	70
REFERÊNCIAS	72
3. USO DE VANT PARA ANÁLISE ESTATÍSTICA-ESPECTRAL DE ÍNDICES DE VEGETAÇÃO EM PLANTIOS DE CANA-DE-AÇÚCAR NA AMAZÔNIA ORIENTAL	78
RESUMO	78
ABSTRACT	79
3.1 Introdução.....	80
3.2 Materiais e Métodos.....	81
3.2.1 Área de Estudo	81
3.2.2 Levantamento de Imagens com VANT por meio Câmera Multiespectral de Alta Resolução.....	84
3.2.3 Plano de Voo, Parâmetros de Voo e Pré-processamento.....	86
3.2.4 Processamento de Dados e os Índices de Vegetação (IVs).....	86
3.2.5 Estatística dos Dados.....	87
3.2.6 Classificação da Imagem a partir do Índice de Vegetação	88
3.2.7 Validação da Classificação da Imagem	89
3.3 Resultados e Discussão.....	89
3.3.1 Distribuição Espacial das Composições Coloridas	89
3.3.2 Distribuição Espacial dos Índices de Vegetação	89
3.3.4 Testes de Normalidade	96
3.3.5 Testes de Correlação e Regressão.....	96
3.3.6 Classificação da Área de Estudo	97
3.3.7 Validação da Classificação	100
3.3.8 Discussão.....	102
3.4 Conclusões.....	105

REFERÊNCIAS	107
4. AVALIAÇÃO DE INTERPOLADORES ESPACIAIS PARA DEFINIÇÃO DE ZONAS DE MANEJO FITOSSANITÁRIO EM ÁREAS DE PLANTIO DE CANA-DE-AÇÚCAR NA AMAZÔNIA ORIENTAL	112
RESUMO	112
ABSTRACT	113
4.1 Introdução.....	114
4.2 Materiais e Métodos	116
4.2.1 Área de Estudo	116
4.2.2 Dados Utilizados	117
4.2.3 Definição das Malhas Regulares e Aleatórias	117
4.2.4 Extração dos Valores de GNDVI.....	118
4.2.5 Estatísticas Descritivas.....	119
4.2.6 Interpolação Espacial por Geoestatística.....	119
4.2.7 Interpolação Espacial por Aprendizado de Máquina.....	121
4.2.8 Correlação entre as Validações Cruzadas	122
4.2.9 Mapas de Zonas de Manejo Fitossanitário.....	123
4.3 Resultados e Discussão.....	123
4.3.1 Estatísticas Descritivas.....	123
4.3.2 Análise Semivariográfica	126
4.3.2.1 Malha Regular.....	126
4.3.2.2 Malha Aleatória.....	129
4.3.3 Mapas Interpolados	132
4.3.3.1 Mapas de <i>Krigagem</i> (Geoestatística).....	132
4.3.3.2 Mapas de <i>Support Vector Machine</i> (<i>Machine Learning</i>).....	132
4.3.3.3 Relação entre os Interpoladores aplicados ao Caso Concreto	137
4.3.4 Validação Cruzada.....	139
4.3.4.1 <i>Krigagem</i> Ordinária.....	139
4.3.4.2 <i>Support Vector Machine</i>	139

4.3.5 Mapas de Zonas de Manejo Fitossanitário.....	146
4.3.5.1 Relação entre FPI e NCE.....	146
4.3.5.2 Zonas de Manejo Fitossanitário.....	148
4.4 Conclusões.....	151
REFERÊNCIAS	152
APÊNDICE I - Fluxo entre semivariogramas, mapas de <i>krigagem</i> ordinária e validações cruzadas para cada zona de estudo com malha de amostragem regular.....	156
APÊNDICE II - Fluxo entre semivariogramas, mapas de <i>krigagem</i> ordinária e validações cruzadas para cada zona de estudo com malha de amostragem aleatória.....	157
APÊNDICE III - Fluxo entre mapas de <i>support vector machine</i> e as validações cruzadas para cada zona de estudo com malha de amostragem regular.....	158
APÊNDICE IV - Fluxo entre mapas de <i>support vector machine</i> e as validações cruzadas para cada zona de estudo com malha de amostragem aleatória.....	159
APÊNDICE V - Fluxo entre as relações de FPI e NCE e os mapas de zonas de manejo fitossanitário para cada zona de estudo.....	160
ANEXO I - Uso da Geoestatística no contexto da cana-de-açúcar no Brasil.....	161
REFERÊNCIAS	184
ANEXO II – Uso de Aprendizado de Máquinas no contexto da cana-de-açúcar no Brasil.....	195
REFERÊNCIAS	209

1 ÁREA PLANTADA, PRODUTIVIDADE E PRODUÇÃO DE CANA-DE-AÇÚCAR NA AMAZÔNIA ORIENTAL BRASILEIRA¹

RESUMO

Este capítulo teve como objetivo realizar uma análise para mensurar a importância do cultivo da cana-de-açúcar para a Amazônia Oriental brasileira, que compreende os estados do Amapá, Mato Grosso, Pará, Tocantins e parte do estado do Maranhão. Para isso, foram utilizados dados de Área Plantada, Produtividade e Produção, fornecidos pela Companhia Nacional de Abastecimento (CONAB), referentes às safras 2012/2013 a 2021/2022 nos estados da região em questão. Os dados foram normalizados e submetidos a análises de correlação e regressão entre as variáveis consideradas (área plantada, produtividade e produção), para melhor compreender como essas variáveis se comportaram e se relacionaram entre si nestas últimas 10 safras de cana-de-açúcar na região. Como resultado, percebeu-se que os dados apresentavam distribuição normal, com algumas correlações fortes e moderadas, sejam elas positivas ou negativas, o que coincidiu com os resultados também obtidos nos testes de regressão. Porém, as correlações e regressões identificadas ocorrem de forma diferente em cada estado, com destaque para o estado do Pará, que apresentou fortes correlações positivas para todos os testes realizados (área plantada, produtividade e produção), bem como regressões consideradas significativas. As avaliações realizadas demonstraram a qualidade dos dados utilizados e proporcionaram maior robustez na análise das variáveis consideradas, permitindo uma melhor compreensão da importância da cana-de-açúcar para a Amazônia Oriental.

Palavras-chave: *Saccharum* spp.; Análise estatística; Normalidade dos dados; Correlação e regressão entre variáveis

¹ Este capítulo foi base para artigo aceito na revista “*Bulgarian Journal of Agricultural Science*” intitulado: **Planted area, productivity and sugarcane production in the Eastern Brazilian Amazon**. O artigo tem previsão para publicação na edição nº 4/2024.

ABSTRACT

This work aimed to carry out an analysis to measure the importance of sugarcane culture for the Brazilian Eastern Amazon, which comprises the States of Amapá, Mato Grosso, Pará, Tocantins and part of the State of Maranhão. For this, data on Planted Area, Productivity and Production, provided by the National Supply Company (CONAB), referring to the 2012/2013 to 2021/2022 harvests in the states of the region in question were used. Data were normalized and submitted to correlation and regression analysis between the considered variables (planted area, productivity and production), to better understand how these variables behaved and related to each other in these last 10 sugarcane harvests in the region. As a result, it was noticed that the data had a normal distribution, with some strong and moderate correlations, whether positive or positive, which coincided with the results also obtained in the regression tests. However, the identified correlations and regressions occur differently in each State, with emphasis on the State of Pará, which presented strong positive correlations for all tests carried out (planted area, productivity and production), as well as regressions considered significant. The evaluations carried out demonstrated the quality of the data used and provided greater robustness in the analysis of the variables considered, allowing a better understanding of the importance of sugarcane for the Eastern Amazon.

Keywords: *Saccharum* spp.; Statistical analysis; Data normality; Correlation and regression between variables

1.1 Introdução

A cana-de-açúcar é uma espécie vegetal semiperene, pertencente à família *Poaceae* (Pereira et al., 2020), provavelmente tendo como país de origem a Índia, chegando ao Brasil no período recém-colonizado no século XVI. No território brasileiro, a cana-de-açúcar encontrou fatores muito favoráveis ao seu pleno desenvolvimento, como: solos férteis, água abundante, temperaturas amenas, relevos planos e grande quantidade de mão de obra (Rodrigues; Ross, 2020).

É uma gramínea tipicamente cultivada em países tropicais e/ou subtropicais, como o Brasil, constituída por um híbrido complexo de diversas espécies, derivadas principalmente da espécie *Saccharum officinarum*. A propagação da cultura é feita vegetativamente por meio do plantio de pedaços de colmo de cana, permitindo que novos brotos surjam das gemas nos nós da própria cana, garantindo assim um perfilhamento uniforme. A produtividade, por sua vez, tende a oscilar de acordo com a variedade plantada, fatores climáticos, disponibilidade de água, práticas de cultivo e duração do seu ciclo (Rein, 2013).

Alguns subprodutos podem ser produzidos a partir do processamento da cana-de-açúcar, como é o caso, principalmente, do etanol, seja anidro – usado na mistura com a gasolina – ou hidratado, além, é claro, do próprio açúcar (CONAB, 2020). Aproximadamente 70% do açúcar mundial é produzido a partir da cana-de-açúcar (Kumar et al., 2017).

Nesse contexto, o Brasil tem papel de destaque no cenário mundial da produção de cana-de-açúcar, consolidando-se como o maior produtor mundial da cultura (Cheavegatti-Gianotto et al., 2018; Dias; Sentelhas 2018). Sua produção mais que dobrou nas últimas décadas (Bordonal et al., 2018), principalmente devido às crescentes demandas mundiais pela redução da dependência do petróleo bruto e pela fabricação de combustíveis sustentáveis como o etanol, que hoje tem apelo ainda maior, colocando o Brasil como o segundo maior produtor de combustíveis do mundo (Yusuf; Caldarelli, 2018; Müller et al., 2019).

Segundo dados do IBGE (2022), Instituto Brasileiro de Geografia e Estatística, o Brasil produziu cerca de 724.428.135 toneladas de cana-de-açúcar em 2022, sendo o estado de São Paulo o maior produtor, com aproximadamente 420.724.619 toneladas no mesmo ano, o que representou mais da metade de toda a produção do país. Por sua vez, os estados que compõem a Amazônia Oriental produziram um total de cerca de 23.924.281 toneladas, representando cerca de 3,3% da produção nacional. Dentre esses estados, o que mais se destaca é Mato Grosso, com produção de 17.345.179 toneladas por ano, representando aproximadamente de 72,5% de tudo o que é produzido na Amazônia Oriental.

Ressalta-se também que a agroindústria canavieira continua em expansão no território

nacional, demonstrando grande capacidade de agregar valor também aos derivados do açúcar e do etanol, como vinhaça (fertilizante), torta de filtro (fertilizante), bagaço (matéria-prima para indústrias, alimentação animal e geração de energia elétrica) e palha vegetal (geração de eletricidade) (Carbonari et al., 2020). Nesse sentido, como prognóstico para o futuro, estima-se uma produção total de 26,7 bilhões de litros de etanol e 35 milhões de toneladas de açúcar na safra 2021/2022 para o país (CONAB, 2022).

Por tudo o que foi relatado, percebe-se o tamanho da representatividade da cultura canavieira para a economia brasileira, o que justifica a necessidade de pesquisas constantes sobre o assunto, para melhor compreender a dinâmica presente em seu sistema produtivo, ainda mais quando trata-se de áreas e regiões consideradas fronteiras agrícolas, como é o caso da Amazônia Oriental brasileira.

Diante do exposto, este capítulo tem o objetivo de realizar uma análise da Área Plantada, Produtividade e Produção de cana-de-açúcar nesta região do Brasil, através do estudo de possíveis correlações entre essas variáveis, em cada estado, nas últimas 10 safras (2012/2013 a 2021/2022). A intenção é permitir uma melhor visualização do atual momento da produção canavieira nos estados brasileiros que compõem a Amazônia Oriental, bem como traçar perspectivas futuras em meio aos desafios da cultura na região.


1.2 Fenologia da Cana-de-Açúcar

Seguindo a sequência lógica deste capítulo, é importante começar entendendo como a cana-de-açúcar se desenvolve de maneira geral. Assim, segundo a EMBRAPA (2022), Empresa Brasileira de Pesquisa Agropecuária, a cana-de-açúcar possui quatro fases, ilustradas na Figura 1 e explicadas a seguir.

A primeira fase é a fase de Estabelecimento, que corresponde ao momento em que o broto, também conhecido como colmo primário, rompe as folhas e se desenvolve em direção à superfície do solo, ao mesmo tempo que aparecem as raízes do tolete. A emergência dos brotos ocorre de 20 a 30 dias após o plantio, o que dependerá de fatores como qualidade da muda, ambiente, época e manejo de plantio. Nesta fase ocorre também o enraizamento inicial e o surgimento das primeiras folhas.

A segunda fase é denominada Vegetativa, subdividida em dois momentos. O primeiro é caracterizado pelo processo de emissão de colmos pela mesma planta, resultando no crescimento de brotos em direção à superfície, aproximadamente 20 a 40 dias após a emergência do colmo primário. O segundo momento representa o ápice do perfilhamento, constituído pela cobertura total do solo pela folhagem das plantas.

Figura 1 - Estágios de crescimento da cana-de-açúcar.



Fonte: adaptado de Cheavegatti-Gianotto et al. (2011).

A terceira fase, por sua vez, é a fase de Grande Crescimento, onde ocorre o crescimento vigoroso das raízes das plantas e a definição da população final de colmos. Os colmos sobreviventes continuam o seu desenvolvimento e crescimento, estimulados pela luz, umidade e calor. Neste momento, o açúcar se acumula em sua base e a planta ganha altura, chegando a até três metros de altura, variando de acordo com o clima e o solo.

A quarta e última fase é chamada de Amadurecimento. Inicia-se com o intenso crescimento dos colmos sobreviventes da fase de perfilhamento e o armazenamento contínuo de açúcar na base de cada colmo. Porém, ao atingir uma altura igual ou superior a dois metros, é possível notar o amarelecimento e ressecamento das folhas, o que indica o início da deposição de açúcar naquela região. Por fim, na parte final desta fase, ocorre maior atividade de maturação, menor atividade de crescimento e intenso armazenamento de açúcares, que culminará no momento da colheita, que deve ocorrer dependendo da variedade da planta e da época de plantio, levando em conta a duração do ciclo, o manejo da maturação e as condições climáticas do ambiente.

1.3 Materiais e Métodos

1.3.1 Área de Estudo

A Amazônia Oriental brasileira é atualmente composta por todo o território dos estados do Pará, Amapá, Tocantins e Mato Grosso, além de parte do estado do Maranhão (oeste do meridiano de 44°) (IBGE, 2020). Não existe uma legislação específica que estabeleça a Amazônia Oriental como é conhecida hoje, mas existe um marco legal que nos leva, por exclusão, a delimitar sua área total.

A região faz parte da Amazônia Legal, instituída inicialmente pela Lei 1.806/1953, que tratou do Plano de Valorização Econômica da Amazônia e criou a SPVEA (Superintendência do Plano de Valorização Econômica da Amazônia). Posteriormente, a Lei 1.806/1953 foi revogada pela Lei 5.173/1966, que, por sua vez, previu um novo Plano de Valorização Econômica da Amazônia, extinguindo a SPVEA e criando a Superintendência de Desenvolvimento da Amazônia (SUDAM).

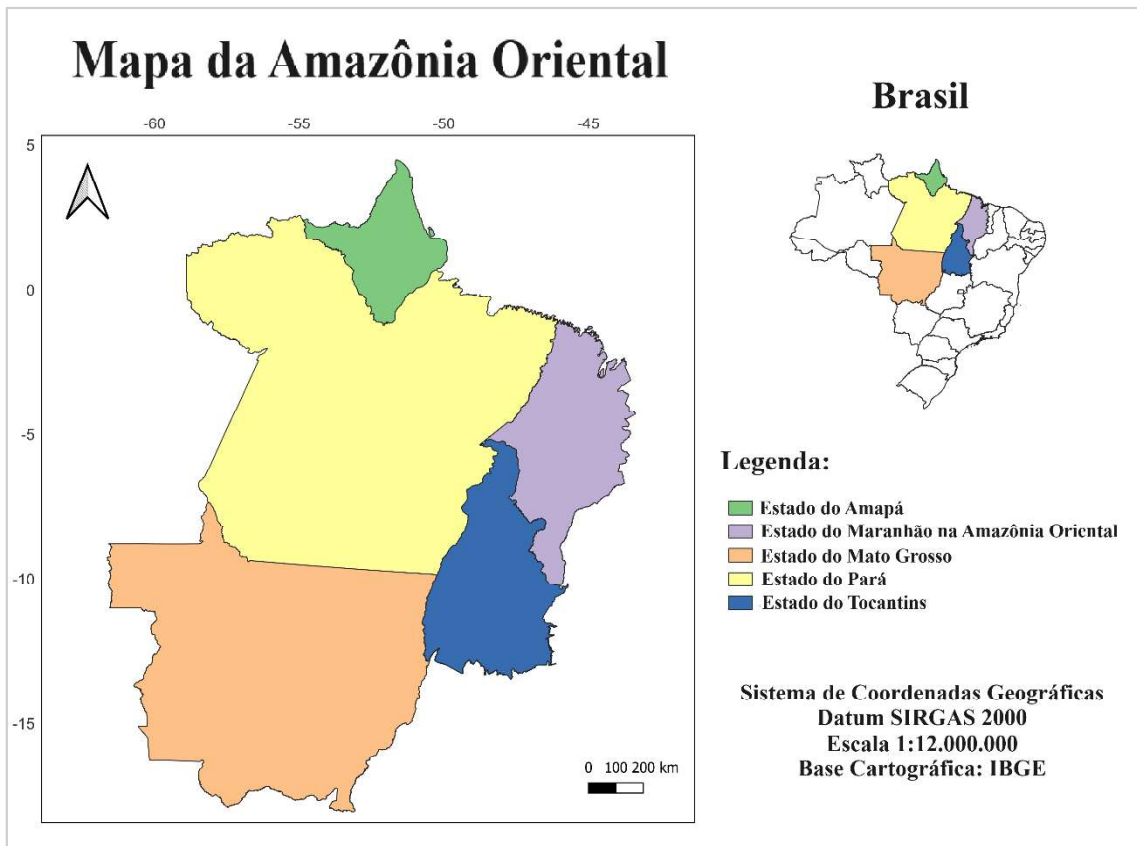
Atualmente, a Amazônia Legal corresponde exatamente à área de atuação da SUDAM, atualizada pela Lei Complementar 124/2007. Ao todo, é composta por 772 municípios, numa área total de 5.015.067,86 km², correspondendo a aproximadamente 58,93% do território brasileiro. Dos 772 municípios, 751 estão totalmente localizados na Amazônia Legal, enquanto 21 estão parcialmente integrados, pois parte deles está localizada a leste do meridiano 44° no estado do Maranhão (IBGE, 2021).

Embora instituída pelas leis citadas, a nomenclatura “Amazônia Legal” só passou a ser utilizada em legislações mais recentes, como a Lei 11.962/2009 e a Lei 12.651/2012, não aparecendo expressamente, com esta nomenclatura, nas leis que definiram a Amazônia na legislação de décadas anteriores (IBGE, 2017).

Dessa forma, a Amazônia Legal é composta pela soma dos territórios da Amazônia Oriental, acima mencionados, e também da Amazônia Ocidental, que, por sua vez, possui base legal, sendo instituída pelo Decreto-Lei 291/1967 e atualizado através do Decreto-Lei 356/1968 e legislação posterior. Nesse sentido, a Amazônia Ocidental abrange atualmente os estados do Amazonas, Acre, Rondônia e Roraima (IBGE, 2020).

Como o foco desta pesquisa é a Amazônia Oriental, serão aqui destacados os estados que compõem esta região (Figura 2). A Tabela 1 apresenta uma sequência das principais leis que compõem a história do arcabouço jurídico que se refere à Amazônia Oriental e aos estados pertencentes à região.

Figura 2 - Mapa da Amazônia Oriental Brasileira.



Fonte: autor.

Tabela 1 - Marco jurídico dos estados brasileiros pertencentes à Amazônia Oriental.

ESTADOS	ARCABOUÇO LEGAL
Pará	Pertence à Amazônia Oriental em sua totalidade e da mesma forma desde a Lei 1.806/1953.
Amapá	Pertence à Amazônia Oriental em sua totalidade desde a Lei 1.806/1953, originalmente como Território Federal de mesmo nome, porém, com o advento da Constituição Federal de 1988, foi elevado à condição de estado pelo artigo 14 do Ato das Disposições Constitucionais Transitórias (ADCT).
Tocantins	Passou a fazer parte da Amazônia Oriental com o advento da Constituição Federal de 1988, através do artigo 13 do ADCT, que previa a criação do estado do Tocantins a partir do desmembramento de parte do território do estado de Goiás. Mais recentemente, a Medida Provisória 2.146-1/2001 confirmou a fronteira entre os estados do Tocantins e Goiás, como limite da Amazônia Legal, permanecendo o Tocantins na Amazônia Oriental e o estado de Goiás fora da Amazônia Legal como um todo.
Mato Grosso	Pertence à Amazônia Oriental desde a Lei 1.806/1953, mas a área do estado foi modificada pela Lei Complementar 31/1977, que criou o estado de Mato Grosso do Sul através do desmembramento de parte da área original do estado de Mato Grosso. O que restou como território do estado de Mato Grosso pertence integralmente à Amazônia Oriental.
Maranhão	Pertence à Amazônia Oriental da mesma forma desde a Lei 1.806/1953.

Fonte: autor, adaptado de IBGE (2017), IBGE (2020) e SUDAM (2021).

1.3.2 Testes Estatísticos

Primeiramente foi realizado um levantamento de dados fornecidos pela Companhia Nacional de Abastecimento (CONAB), órgão do governo federal brasileiro, referentes às safras de cana-de-açúcar de 2012/2013 a 2021/2022, totalizando 10 safras. Foram verificados dados de área plantada, produção e produtividade.

Com os dados em mãos, iniciou-se a sua organização em tabelas no *software* Microsoft Excel, o que permitiu a construção de gráficos para melhor visualização. Juntamente com os gráficos, também para melhor visualização, foram confeccionados mapas de localização com os limites territoriais de cada estado que compõe a Amazônia Oriental Brasileira, utilizando o *software* QGIS, versão 3.28.

O próximo passo foi a realização de testes estatísticos, iniciando-se pelos testes de normalidade. Para análise da normalidade dos dados de Área Plantada, Produtividade e Produção dos Estados da Amazônia Oriental, referentes às safras 2012/2013 a 2021/2022, foram utilizados os testes Kolmogorov-Smirnov (K-S) com probabilidade de 95% no *software* Minitab 14. Para isso foram consideradas duas hipóteses: H0 (hipótese nula) que considera que os dados seguem uma distribuição normal e Ha (hipótese alternativa) que considera que os dados não seguem uma distribuição normal.

Para tomada de decisão entre as hipóteses, foram considerados os valores de P-Valor para cada variável, em cada um dos estados, dentro do intervalo de tempo avaliado. Como resultado, foi obtido que todos os dados analisados apresentaram distribuição normal, sem necessidade de qualquer transformação dos dados. Assim, com os dados considerados normais, eles foram submetidos a testes de correlação e regressão utilizando o *software* Minitab 14.

Testes de correlação e regressão entre as variáveis Área Plantada, Produtividade e Produção, relativas aos estados que compõem a Amazônia Oriental, foram realizados como forma de associação dos resultados obtidos. Para verificar a magnitude da correlação foram considerados dois parâmetros: Cohen (1992) e Rumsey (2016), conforme mostram as Tabelas 2 e 3. Durante os testes de correlação, também verificamos os valores de significância de cada um desses testes, através dos valores de P-Valor. As correlações aceitas foram aquelas com P-Valor menor que 0,05.

Tabela 2 - Parâmetros de interpretação da magnitude da correlação proposta por Cohen (1992).

Cohen (1992)	
r Pearson	Magnitude da Correlação
0,10 — 0,30	Correlação Fraca
0,30 — 0,50	Correlação Moderada
0,50 — 1,00	Correlação Forte

Fonte: autor.

Tabela 3 - Parâmetros para interpretação da magnitude da correlação proposta por Rumsey (2016).

Rumsey (2016)	
r Pearson	Magnitude da Correlação
0,30 — 0,50	Correlação Fraca
0,50 — 0,70	Correlação Moderada
0,70 — 1,00	Correlação Forte

Fonte: autor.

No caso dos testes de regressão, para validar as relações, foram considerados os valores dos coeficientes de determinação, também conhecidos como R^2 . Os valores de R^2 variam de 0 (0%) a 1 (100%), onde, quanto mais próximo de 0 a tendência é que o modelo não explique significativamente a variabilidade dos dados e, quanto mais próximo de 1, a tendência é que o modelo explique significativamente a variabilidade dos dados (Minitab, 2019). Em resumo, consideramos aqui que quanto maior o R^2 , melhor será o ajuste dos dados.

Nos testes de regressão, assim como nos testes de correlação, também foram verificados os valores de significância de cada um dos testes, através dos valores P-Valor. As regressões aceitas foram aquelas que apresentaram P-Valor inferior a 0,05.

1.4 Resultados e Discussão

1.4.1 Breve Descrição da Área Plantada, Produtividade e Produção de Cana-de-Açúcar nos estados da Amazônia Oriental (Safrá 2012/2013 a Safrá 2021/2022)

As informações referentes à área plantada, produtividade e produção de cana-de-açúcar no Brasil e, mais especificamente, na Amazônia Oriental, que serão consideradas neste tópico, foram disponibilizadas gratuitamente por meio de levantamentos realizados pela Companhia Nacional de Abastecimento (CONAB), empresa pública vinculada ao governo federal do país, e refletem informações das últimas 10 safras da região, referentes às safras de 2012/2013 a 2021/2022.

Como o foco desta pesquisa é a Amazônia Oriental, destacaremos o cenário atual da produção nos estados que compõem a região: Amapá, Maranhão, Mato Grosso, Pará e Tocantins. Vale ressaltar que o estado do Maranhão não pertence inteiramente à Amazônia Oriental, mas os dados aqui considerados levarão em conta o estado como um todo.

Dentre as 26 unidades federativas do Brasil mais o Distrito Federal, o estado de Mato Grosso é o maior produtor de cana-de-açúcar da Amazônia Oriental, ocupando a posição de 7º maior produtor nacional, seguido pelo Maranhão (11º maior produtor do país), Tocantins (14º

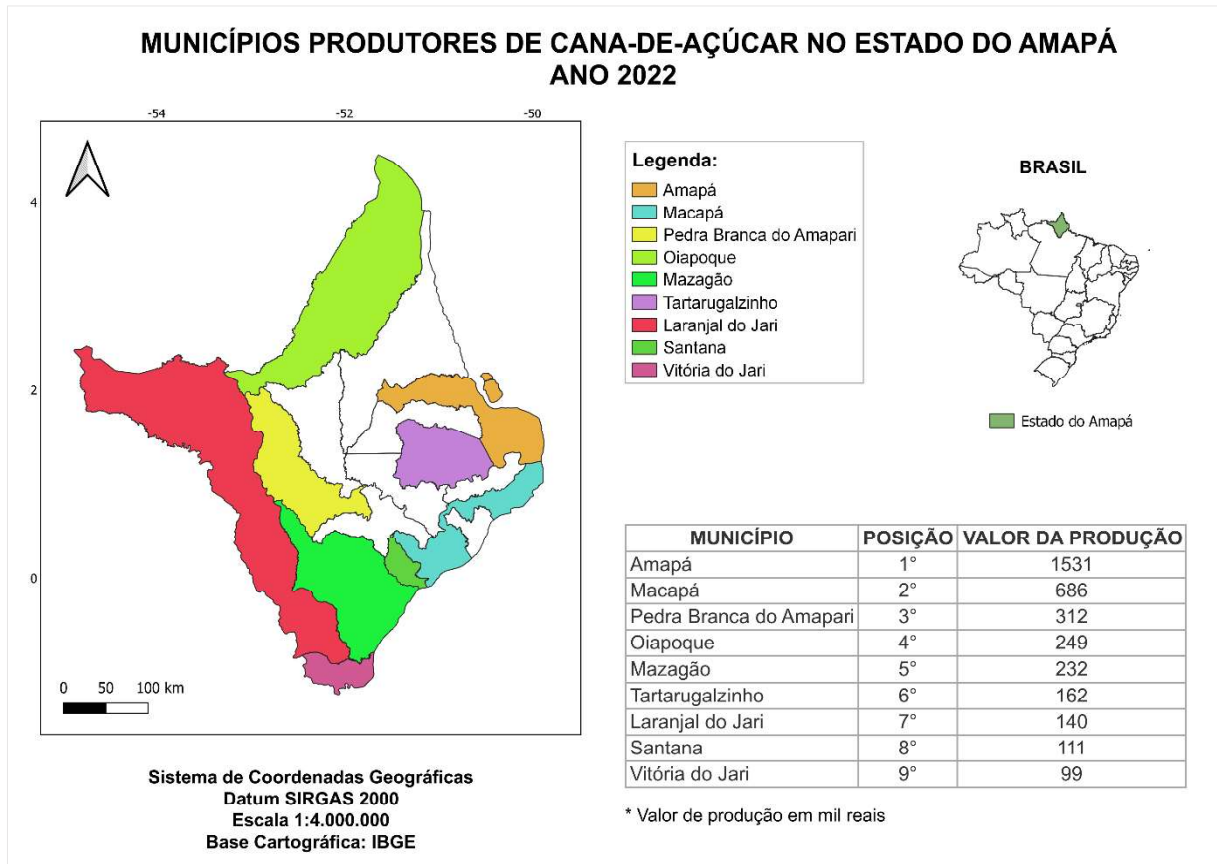
maior produtor), Pará (18º maior produtor) e por fim o estado do Amapá (24º maior produtor). (IBGE, 2022).

1.4.1.1 Estado do Amapá (AP)

Dentre os estados que compõem a Amazônia Oriental, o Amapá é o menos relevante no cultivo de cana-de-açúcar no país, o que também reflete a falta de dados nos levantamentos disponibilizados pela CONAB em relação às safras analisadas neste trabalho (2012/ 2013 a 2021/2022).

Por meio do IBGE, instituto do governo federal do Brasil, foi possível identificar que o estado produziu apenas cerca de 6.997 toneladas de cana-de-açúcar em 2022, em uma área colhida de apenas 280 hectares, com rendimento médio de 24.989 kg por hectare. O estado possui apenas 16 municípios, com pequena produção de cana-de-açúcar em 9 deles, com destaque para o município do Amapá, que teve 1.531 mil reais como valor de produção em 2022, cerca de 21,8% do valor total da produção do estado em 2022 (IBGE, 2022). A Figura 3 ilustra a localização e a lista dos municípios produtores, suas posições no rank estadual e seus valores de produção.

Figura 3 - Municípios produtores, posição no rank estadual e valor de produção de cana-de-açúcar no estado do Amapá.

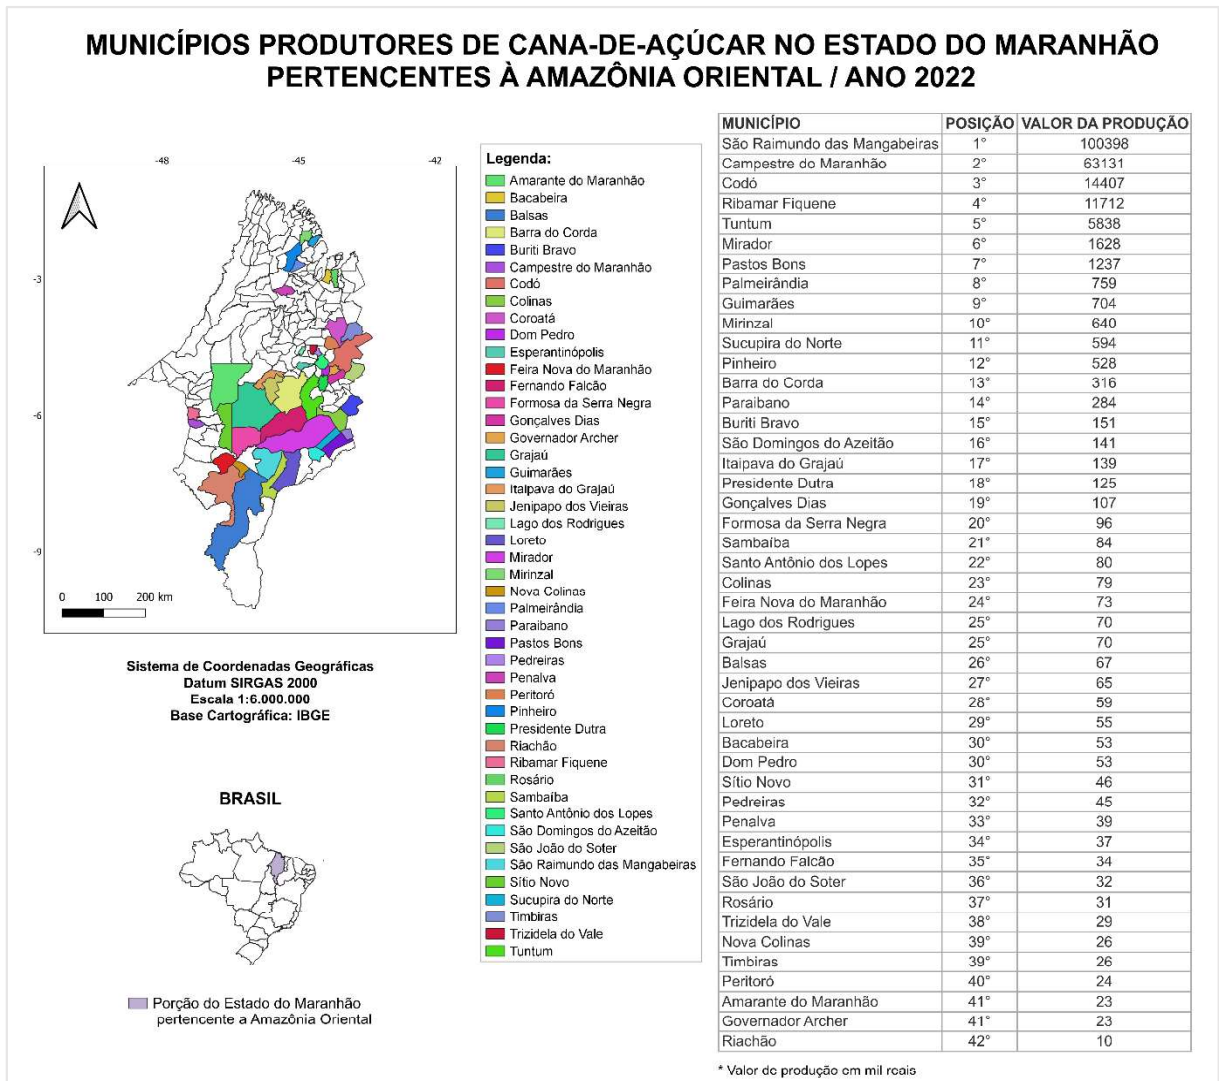


Fonte: autor, com dados de IBGE (2022).

1.4.1.2 Estado do Maranhão (MA)

O estado do Maranhão possui ao todo 217 municípios, mas apenas 181 deles fazem parte da Amazônia Oriental, localizada a oeste do meridiano 44°. Ressalta-se ainda, que dos 181 municípios maranhenses que estão localizados na Amazônia Oriental, 21 deles não estão inteiramente na região em questão, pois parte de seu território está a leste do meridiano 44°. Dos 217 municípios do estado como um todo, 46 municípios localizados na Amazônia Oriental são produtores de cana-de-açúcar, com destaque para o município de São Raimundo das Mangabeiras, que gerou um valor de produção de 100.398 mil reais em 2022, o que representou aproximadamente 22,2% do valor do estado como um todo, que foi de 452.135 mil reais (IBGE, 2021b; 2022). A Figura 4 ilustra a localização de relação dos municípios produtores do estado, suas respectivas posições e o valor de produção de cada um deles.

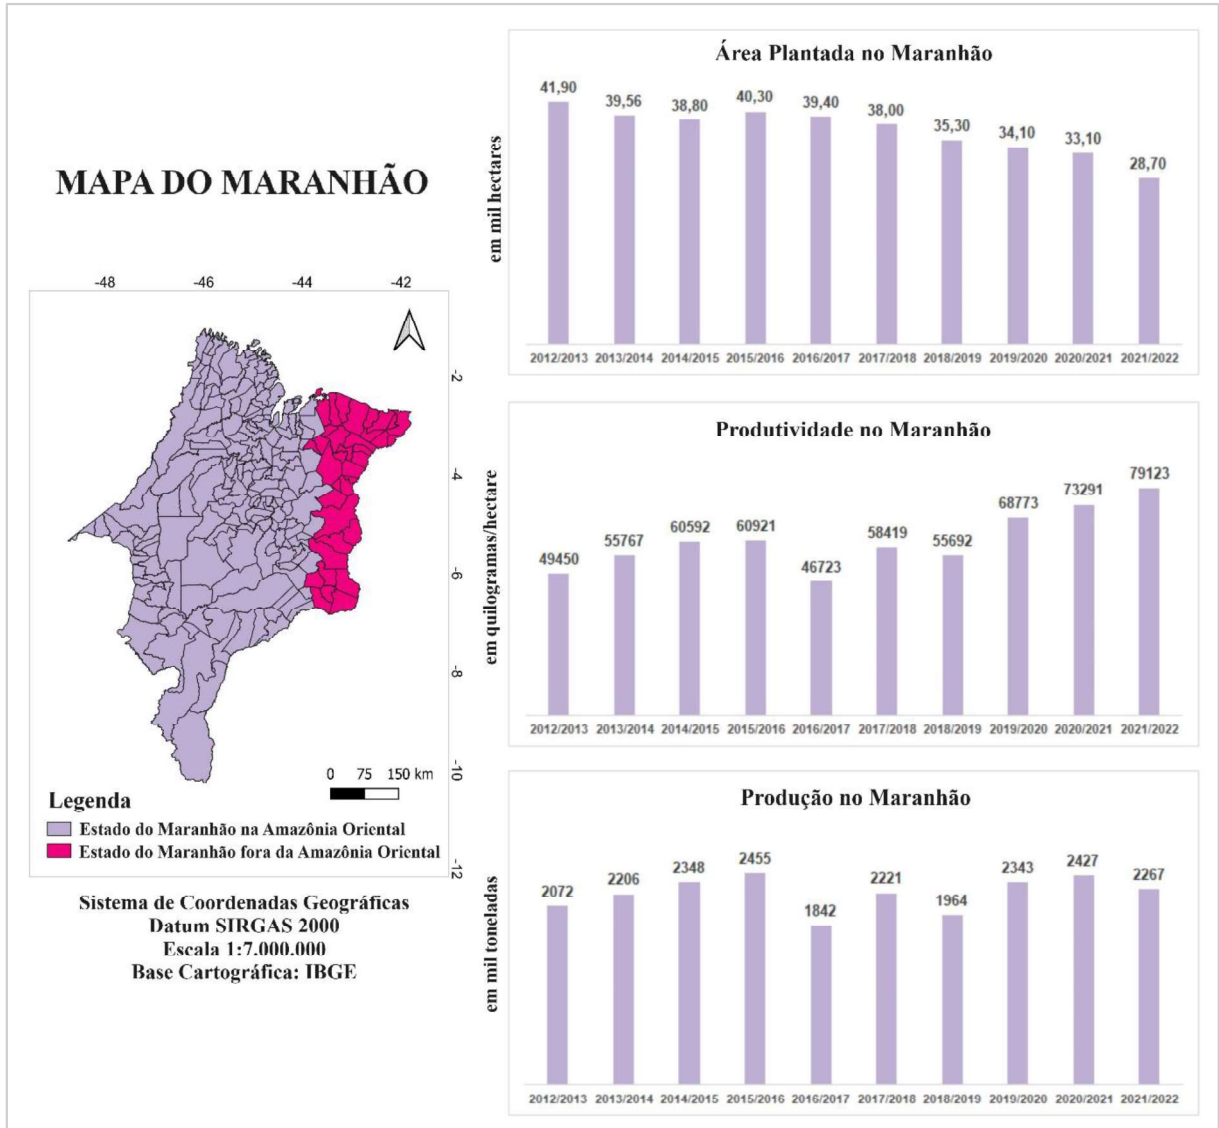
Figura 4 - Municípios produtores do estado do Maranhão que fazem parte da Amazônia Oriental, posição no rank estadual e valor de produção de cana-de-açúcar para cada um deles.



Fonte: autor, com dados de IBGE (2022).

Para esta análise serão consideradas informações do estado como um todo, disponibilizadas pela CONAB. A partir da análise preliminar dos dados, foi possível perceber que a área plantada diminuiu entre as safras 2012/2013 e 2021/2022, mas houve aumento na produtividade e na produção de cana-de-açúcar no estado (Figura 5).

Figura 5 - Mapa do estado do Maranhão com dados de Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) dos anos 2012/2013 a 2021/2022.

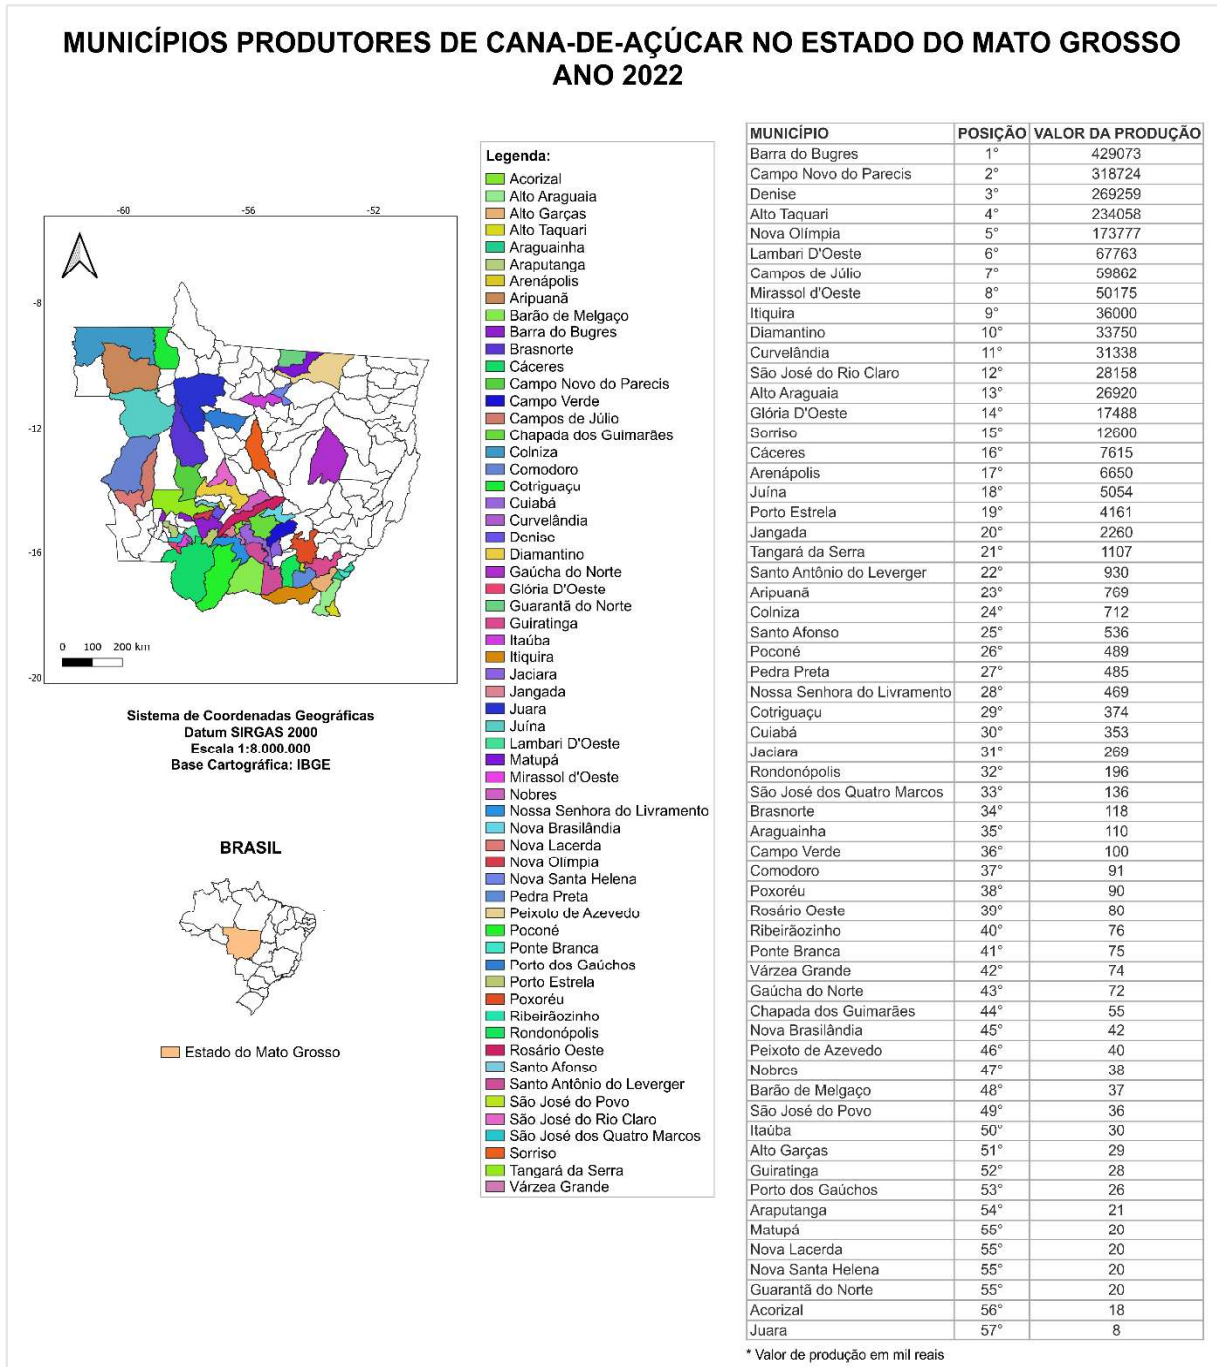


Fonte: autor, com base em dados da CONAB (2013); CONAB (2014); CONAB (2015); CONAB (2016); CONAB (2017); CONAB (2018); CONAB (2019); CONAB (2020); CONAB (2021) e CONAB (2022).

1.4.1.3 Estado do Mato Grosso (MT)

O estado do Mato Grosso é o que mais se destaca na Amazônia Oriental. Ao todo, possui 141 municípios, dos quais 60 produzem cana-de-açúcar, com destaque para o município de Barra de Bugres, que gerou um valor de produção de 429.073 mil reais, o que representou cerca de 23,5% para o montante de 2022, que foi de 1.822.884 mil reais (IBGE, 2022). A Figura 6 ilustra a relação dos municípios do estado e seus respectivos valores de produção para o ano de 2022.

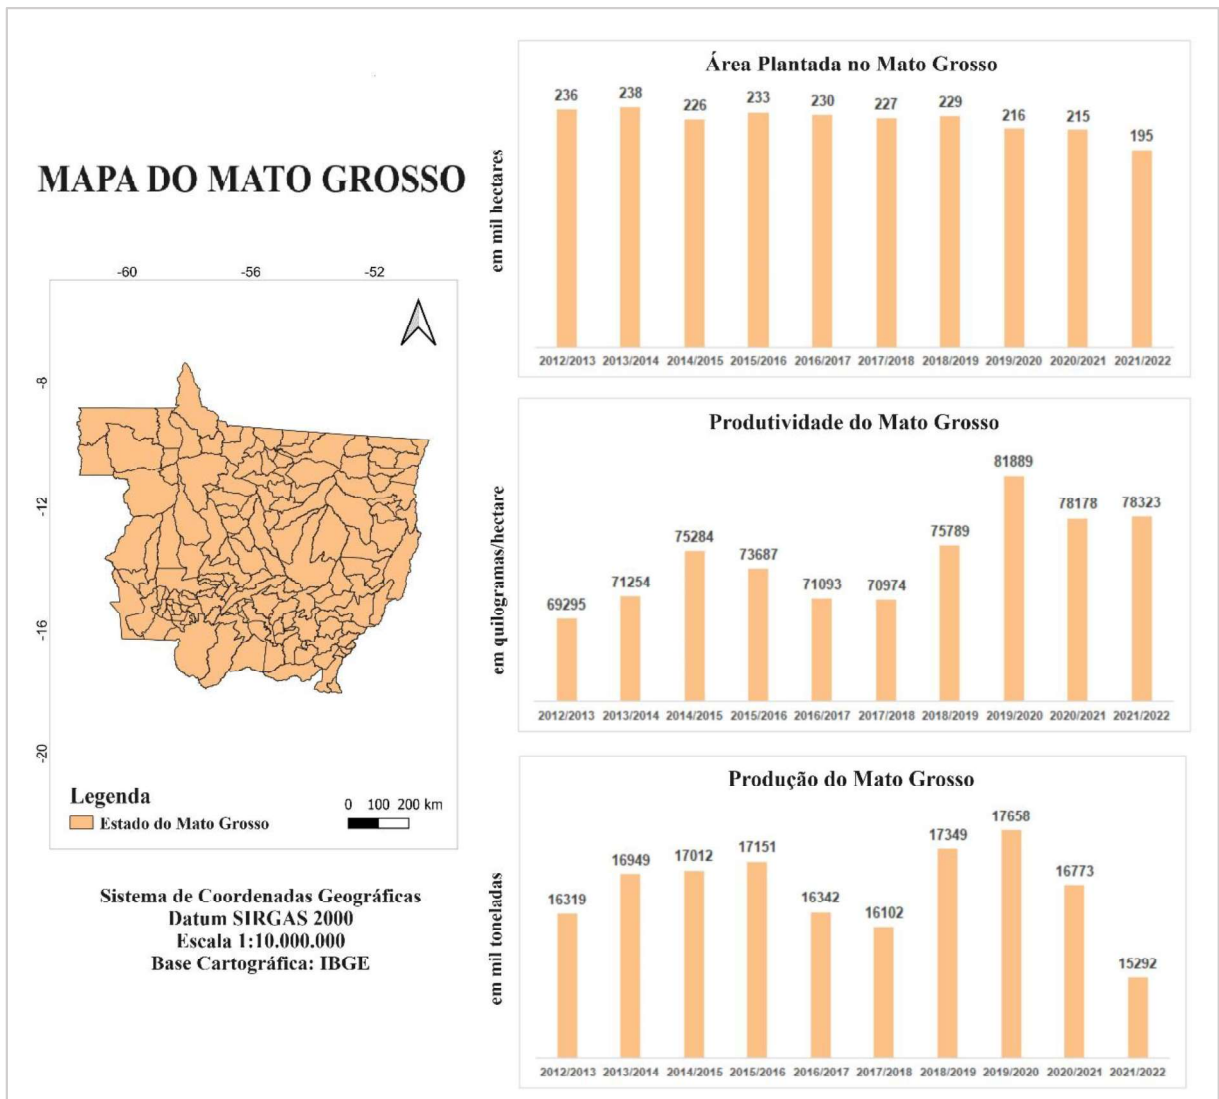
Figura 6 - Municípios produtores, posição no rank estadual e valor de produção de cana-de-açúcar no estado do Mato Grosso.



Fonte: autor, com dados de IBGE (2022).

Em relação aos dados oriundos da CONAB, em relação as safras 2012/2013 a 2021/2022, foi possível perceber que houve uma diminuição na área plantada e na produção de cana-de-açúcar, porém, mesmo com essa diminuição, houve aumento na produtividade (Figura 7).

Figura 7 - Mapa do estado do Mato Grosso com dados de Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) dos anos 2012/2013 a 2021/2022.

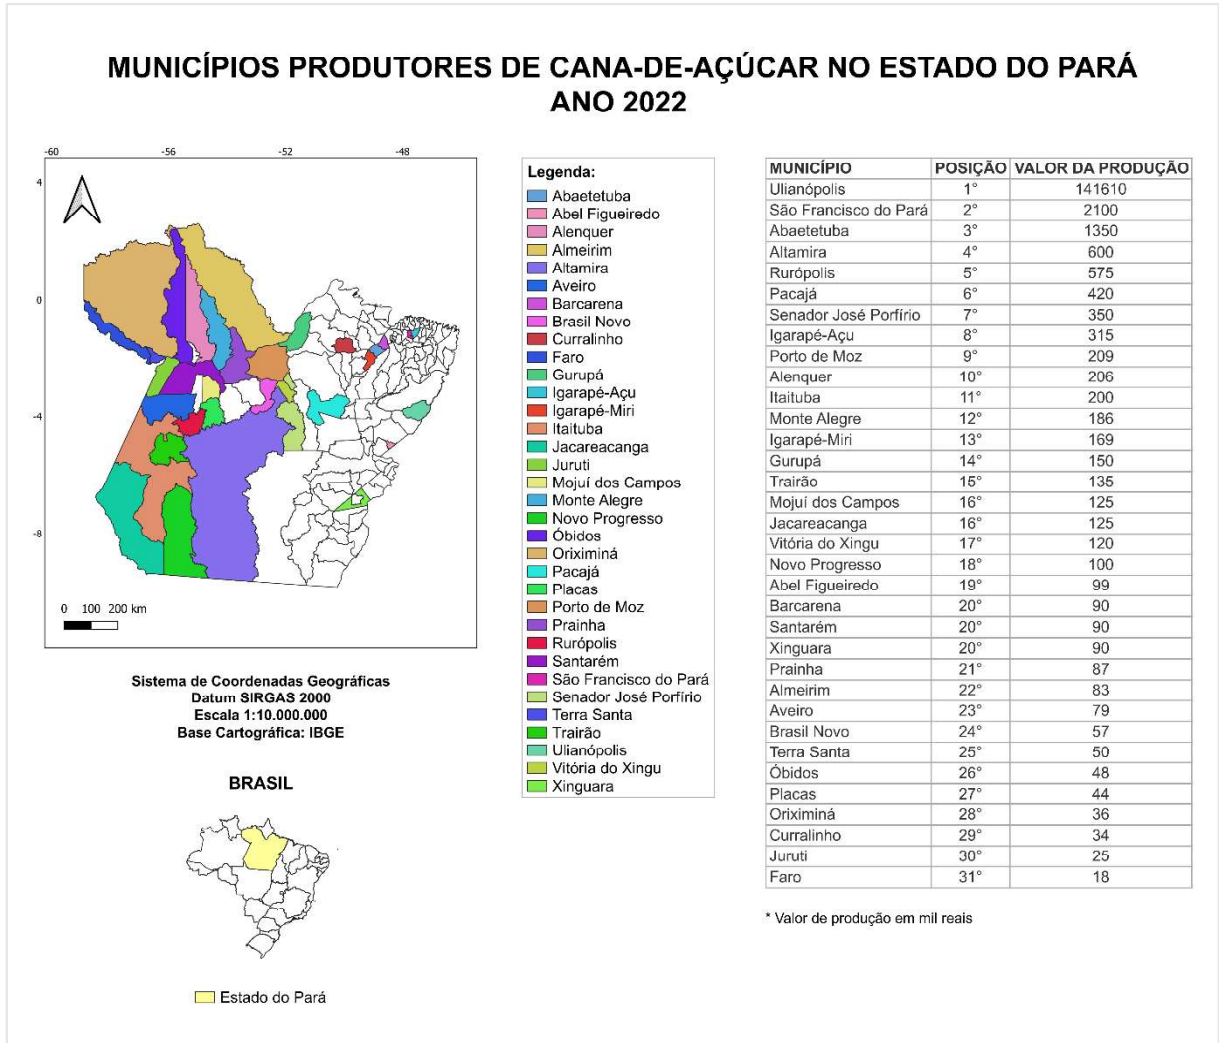


Fonte: autor, com base em dados da CONAB (2013); CONAB (2014); CONAB (2015); CONAB (2016); CONAB (2017); CONAB (2018); CONAB (2019); CONAB (2020); CONAB (2021) e CONAB (2022).

1.4.1.4 Estado do Pará (PA)

O estado do Pará é formado por 144 municípios, dos quais apenas 34 produzem cana-de-açúcar, com destaque para o município de Ulianópolis, que atingiu um valor de produção de 141.610 mil reais em 2022, praticamente 95% de tudo o que foi gerado no estado, que foi de 149.969 mil reais (IBGE, 2022). A Figura 8 ilustra os municípios produtores do estado e seus respectivos valores de produção.

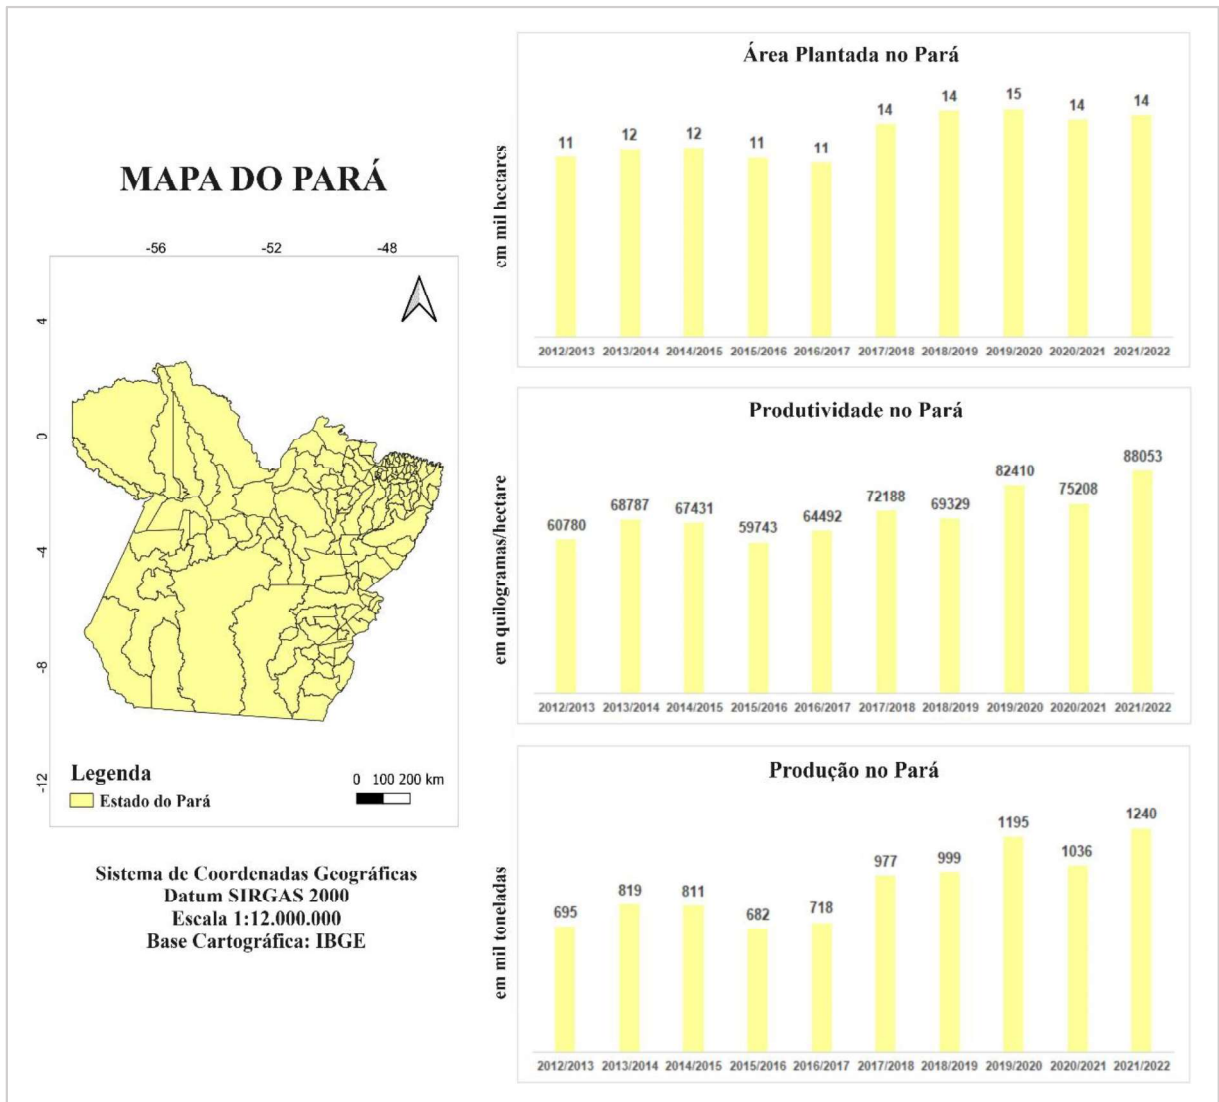
Figura 8 - Municípios produtores, posição no rank estadual e valor de produção de cana-de-açúcar no estado do Pará.



Fonte: autor, com dados de IBGE (2022).

Em aos dados da CONAB, foi possível observar que a variável área plantada aumentou durante as safras 2012/2013 a 2021/2022, o que refletiu no aumento da produtividade e da produção no estado (Figura 9).

Figura 9 - Mapa do estado do Pará com dados de Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) dos anos 2012/2013 a 2021/2022.

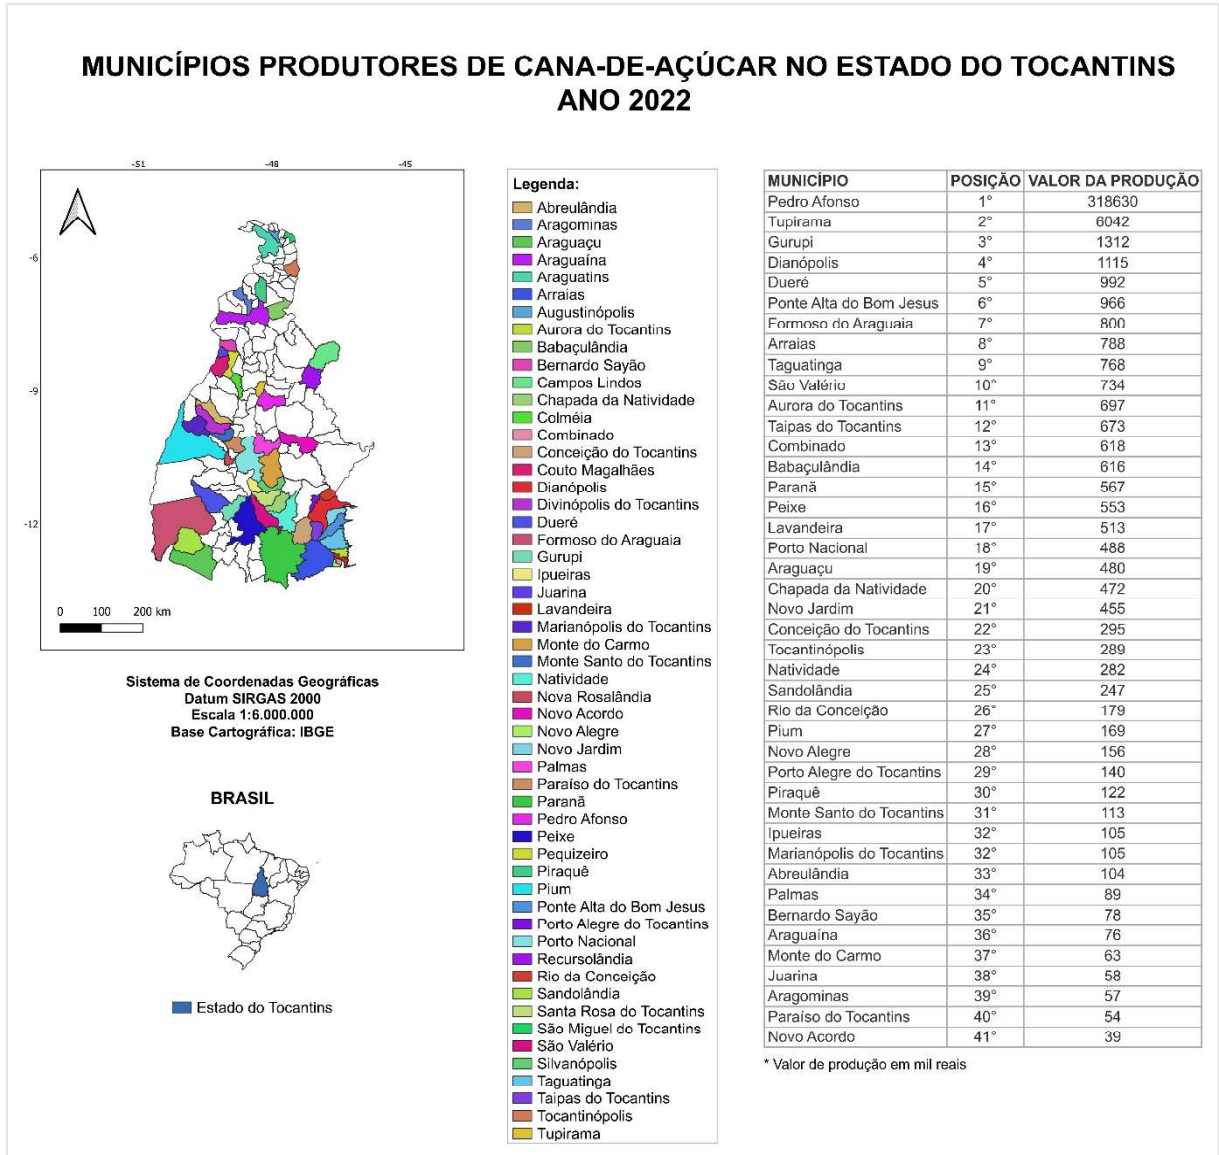


Fonte: autor, com base em dados da CONAB (2013); CONAB (2014); CONAB (2015); CONAB (2016); CONAB (2017); CONAB (2018); CONAB (2019); CONAB (2020); CONAB (2021) e CONAB (2022).

1.4.1.5 Estado do Tocantins (TO)

O estado do Tocantins possui um total de 139 municípios, sendo 54 produtores de cana-de-açúcar, com destaque para o município de Pedro Afonso, que obteve um valor de produção de 318.630 mil reais, equivalente a quase 95% do valor de produção do estado em 2022, que foi de 341.630 mil reais (IBGE, 2022). A Figura 10 ilustra os municípios produtores do estado e seus valores de produção.

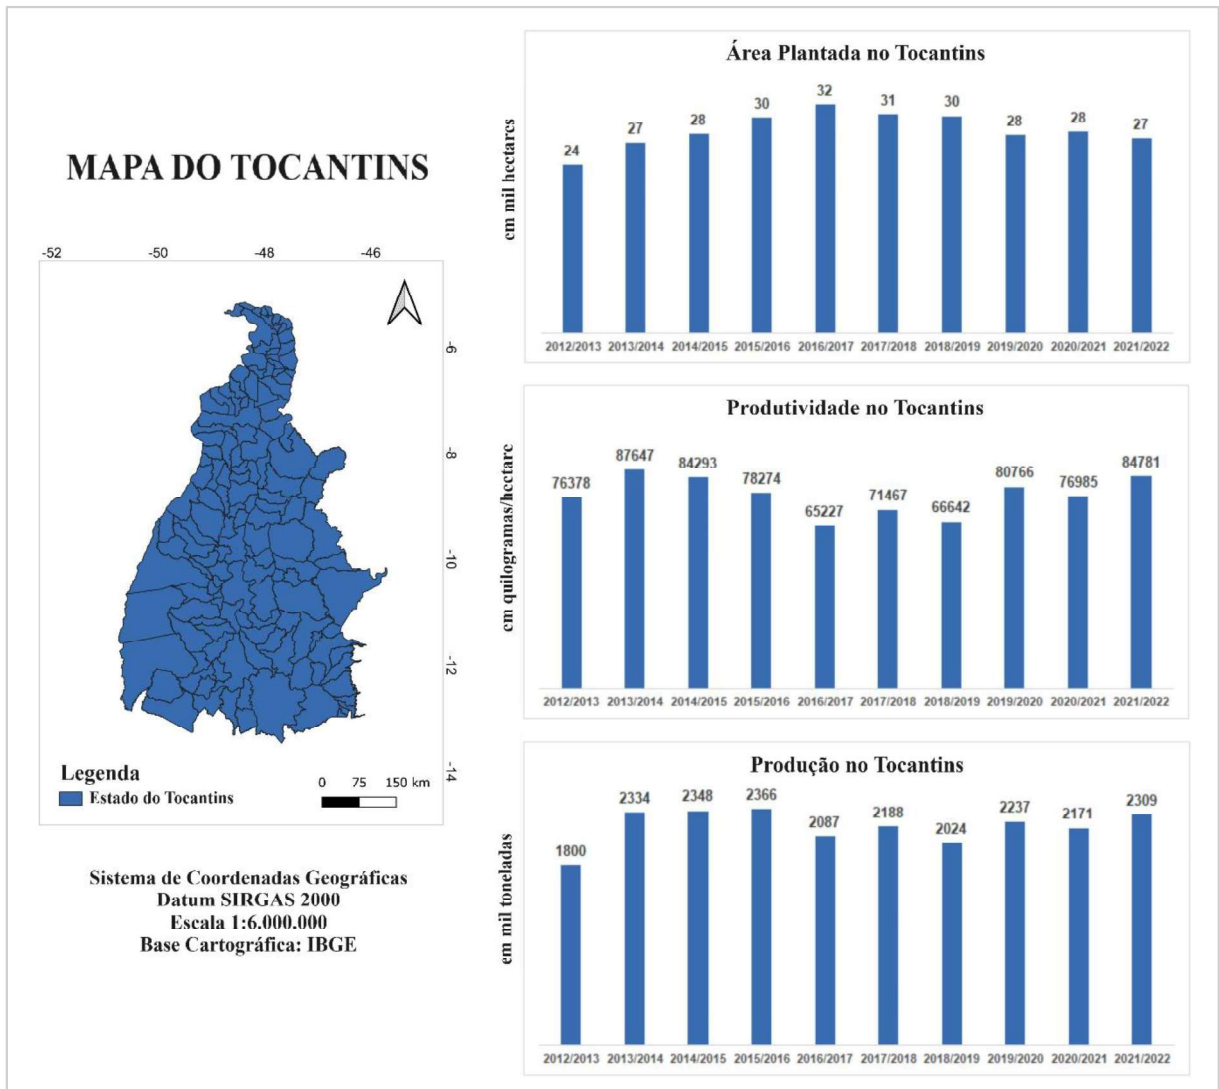
Figura 10 - Municípios produtores, posição no rank estadual e valor de produção de cana-de-açúcar no estado do Tocantins.



Fonte: autor, com dados de IBGE (2022).

Segundo os dados da CONAB, durante as safras 2012/2013 a 2021/2022, houve aumento na área plantada, na produtividade e na produção de cana-de-açúcar no estado (Figura 11).

Figura 11 - Mapa do estado do Tocantins com dados de Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) dos anos 2012/2013 a 2021/2022.



Fonte: autor, com base em dados da CONAB (2013); CONAB (2014); CONAB (2015); CONAB (2016); CONAB (2017); CONAB (2018); CONAB (2019); CONAB (2020); CONAB (2021) e CONAB (2022).

1.4.2 Análise da Normalidade dos Dados de Área Plantada, Produtividade e Produção de Cana-de-Açúcar nos Estados da Amazônia Oriental (Safrá 2012/2013 à Safrá 2021/2022)

Os valores de cada estado serão apresentados a seguir, através da apresentação de gráficos de normalidade e seus respectivos histogramas.

1.4.2.1 Estado do Amapá (AP)

Conforme mencionado anteriormente, o estado do Amapá não possui uma Área Plantada relevante para o contexto do país e, conseqüentemente, não apresenta uma Produtividade e

Produção em quantidade significativa. Assim, este estado não foi considerado para monitoramento da CONAB.

1.4.2.2 Estado do Maranhão (MA)

Os dados de Área Plantada, Produtividade e Produção aceitaram H_0 por unanimidade, apresentando distribuição normal para os dados das variáveis consideradas para as safras 2012/2013 a 2021/2022 no estado. As três variáveis tiveram o mesmo P-Valor de $>0,150$ (Figura 12).

1.4.2.3 Estado do Mato Grosso (MT)

Os dados referentes ao estado de Mato Grosso também apresentaram distribuição normal. As variáveis Produtividade e Produção apresentaram P-Valor de $>0,150$, enquanto a Área Plantada obteve P-Valor de 0,071 (Figura 13).

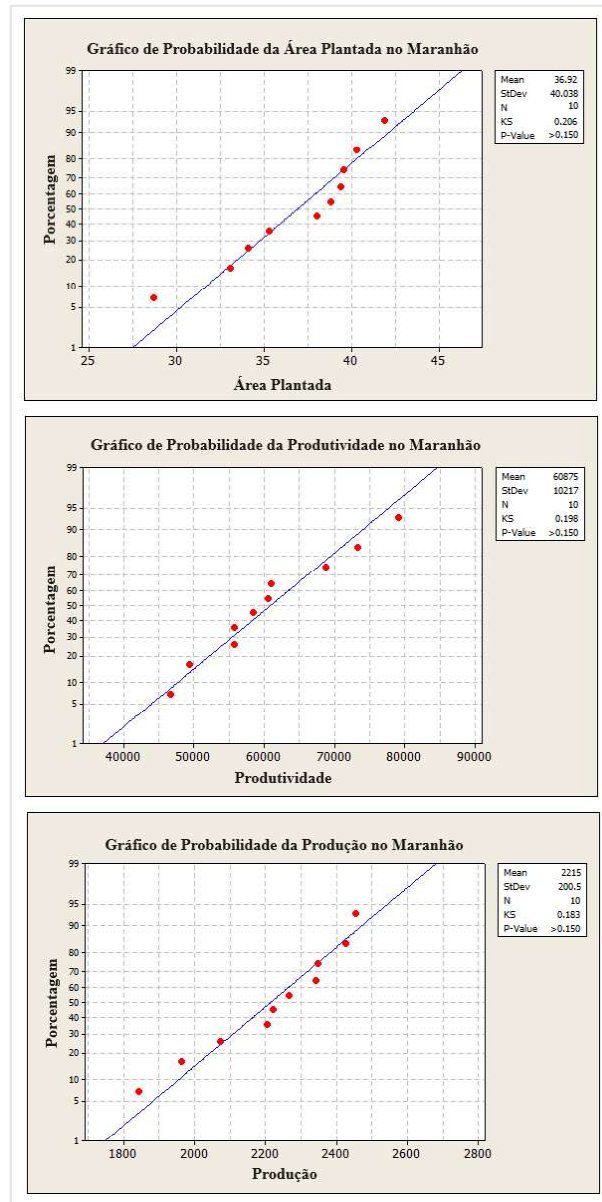
1.4.2.4 Estado do Pará (PA)

O estado do Pará também apresentou distribuição normal para os dados considerados. As três variáveis tiveram P-Valor de $>0,150$ (Figura 14).

1.4.2.5 Estado do Tocantins (TO)

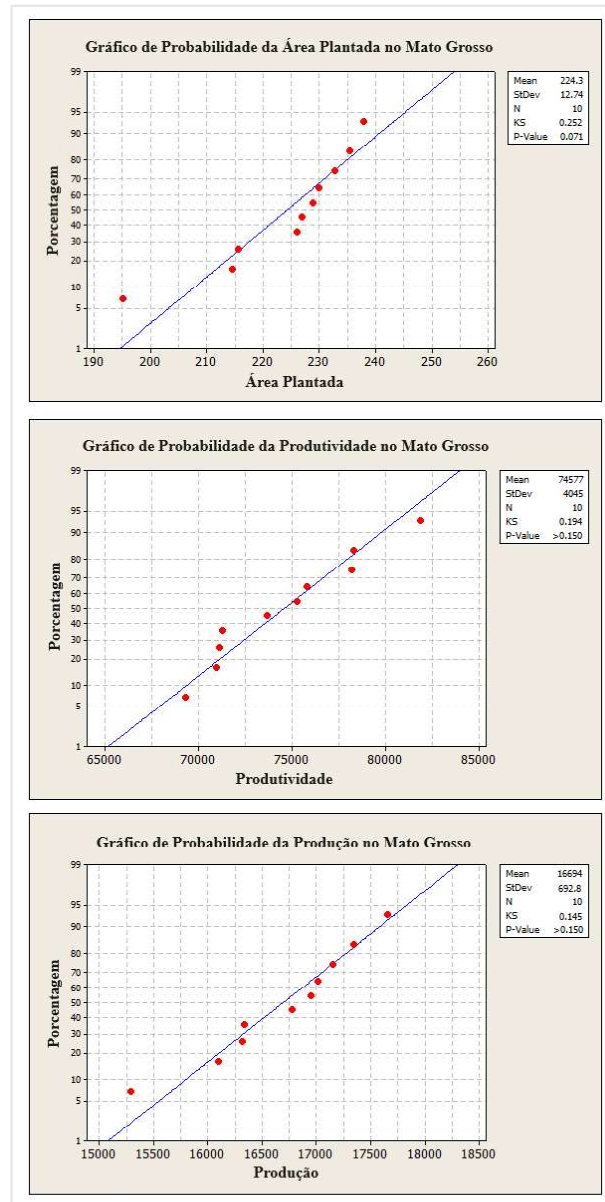
No estado do Tocantins, as estimativas do P-Valor foram idênticas às apresentadas também nos estados do Maranhão e Pará, ou seja, $>0,150$, apresentando também distribuição normal para os dados considerados (Figura 15).

Figura 12 - Gráficos de probabilidade das variáveis Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) de cana-de-açúcar no estado do Maranhão, Brasil, nos anos de 2012/2013 a 2021/2022.



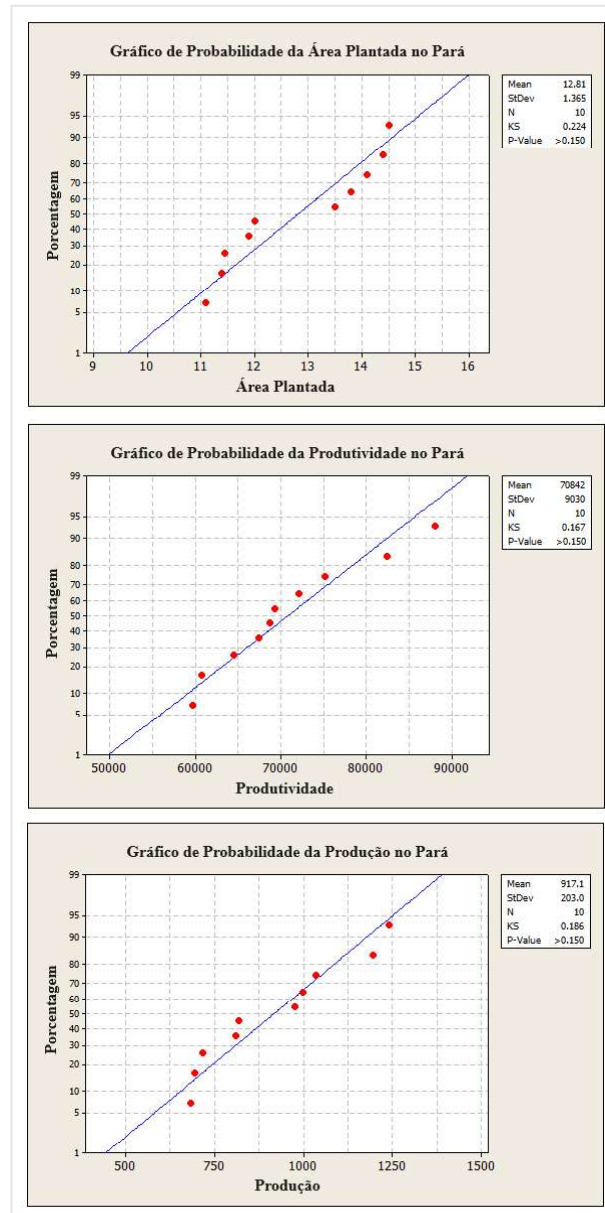
Fonte: autor.

Figura 13 - Gráficos de probabilidade das variáveis Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) de cana-de-açúcar no estado do Mato Grosso, Brasil, nos anos de 2012/2013 a 2021/2022.



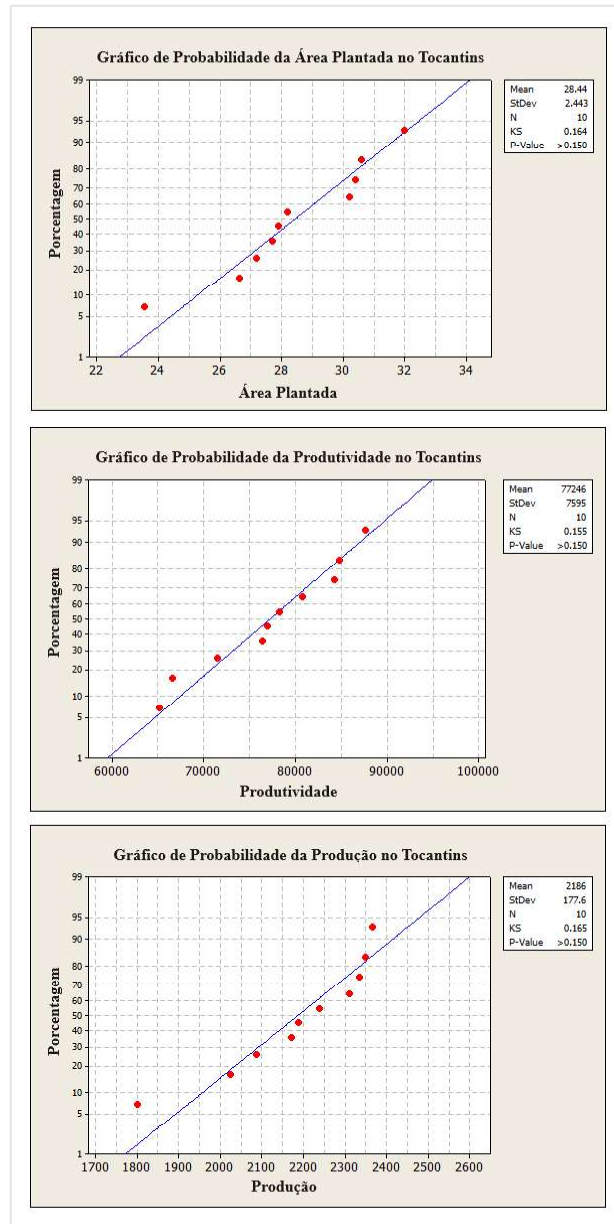
Fonte: autor.

Figura 14 - Gráficos de probabilidade das variáveis Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) de cana-de-açúcar no estado do Pará, Brasil, nos anos de 2012/2013 a 2021/2022.



Fonte: autor.

Figura 15 - Gráficos de probabilidade das variáveis Área Plantada (em mil hectares), Produtividade (em quilogramas/hectare) e Produção (em mil toneladas) de cana-de-açúcar no estado do Tocantins, Brasil, nos anos de 2012/2013 a 2021/2022.



Fonte: autor.

1.4.3 Correlação e Regressão entre Dados de Área Plantada, Produtividade e Produção de Cana-de-Açúcar nos estados da Amazônia Oriental (Safrá 2012/2013 à Safrá 2021/2022)

Os resultados obtidos para cada estado serão apresentados a seguir, através da apresentação de gráficos e da respectiva equação de regressão.

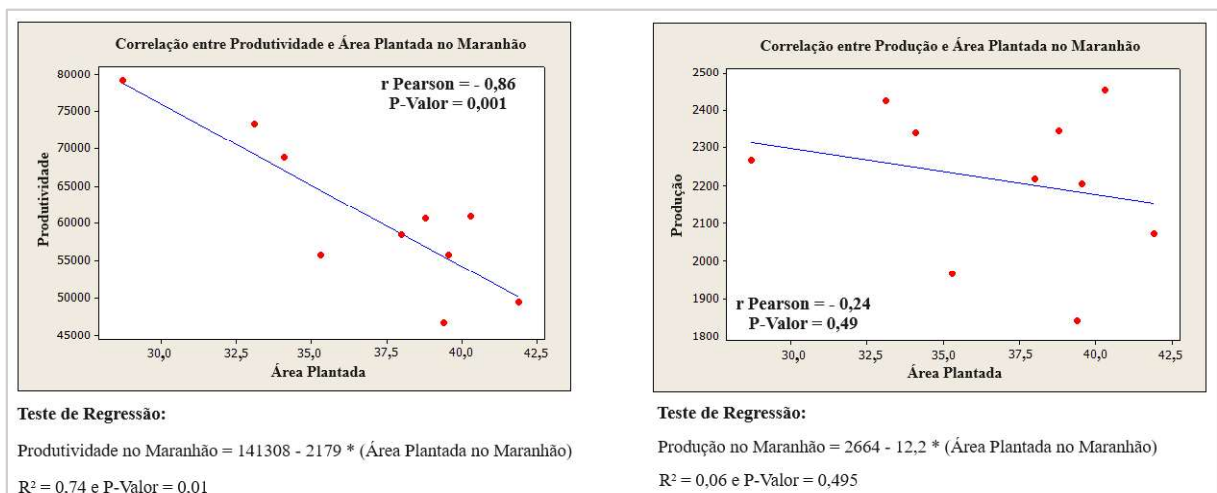
1.4.3.1 Estado do Amapá (AP)

O Estado do Amapá não foi considerado neste tópico pelos mesmos motivos expostos nos tópicos anteriores.

1.4.3.2 Estado do Maranhão (MA)

No estado do Maranhão foi possível perceber que existe uma forte correlação negativa entre as variáveis Área Plantada e Produtividade, para ambos os parâmetros de magnitude de correlação considerados, onde, ao longo das safras, houve diminuição da Área Plantada e consequente aumento da Produtividade. Em relação às variáveis Área Plantada e Produção, não foi possível observar significância entre a correlação das variáveis, uma vez que o P-Valor gerado foi superior a 0,05, além disso, os dados não apresentaram correlações relevantes, de acordo com os parâmetros de magnitude considerados (Figura 16).

Figura 16 - Correlações e Regressão entre Área Plantada x Produtividade e Área Plantada x Produção para o estado do Maranhão.



Fonte: autor.

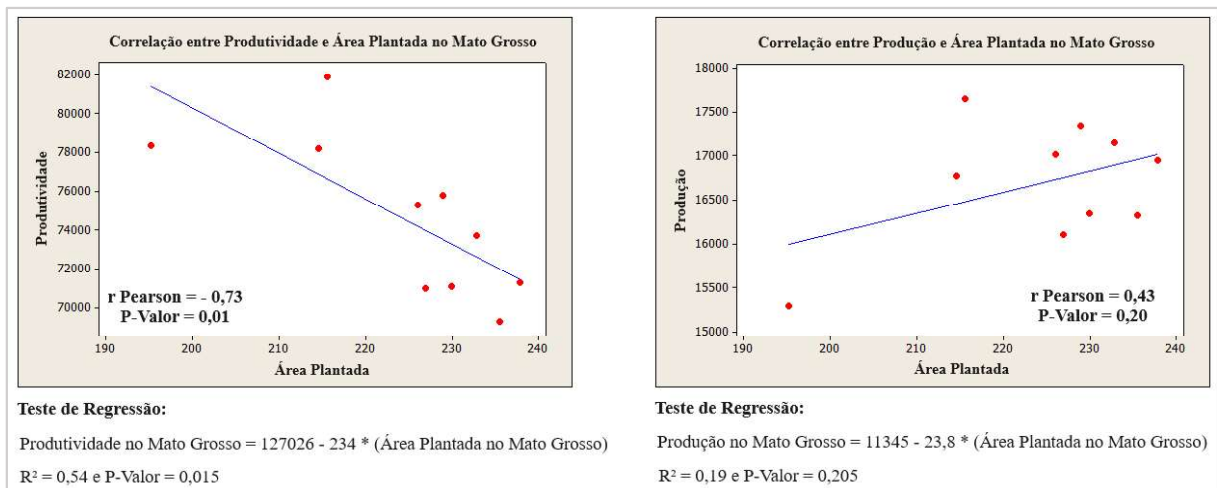
Os testes de regressão confirmaram o que já havia sido observado nos testes de correlação, pois o R² foi maior na regressão entre Área Plantada e Produtividade (R² = 0,74), com P-Valor de 0,01, enquanto os valores de regressão entre Área e Produção foi considerado

insignificante ($R^2 = 0,06$), com P-Valor de 0,495, ou seja, um valor estatisticamente insignificante.

1.4.3.3 Estado do Mato Grosso (MT)

No estado de Mato Grosso também foi possível verificar uma forte correlação negativa entre as variáveis Produtividade e Área Plantada, refletindo em um comportamento inversamente proporcional entre as variáveis em questão. A correlação entre Área Plantada e Produção não foi considerada significativa, de acordo com os valores de P-Valor resultantes (Figura 17).

Figura 17 - Correlações e Regressão entre Área Plantada x Produtividade e Área Plantada x Produção para o estado do Mato Grosso.



Fonte: autor.

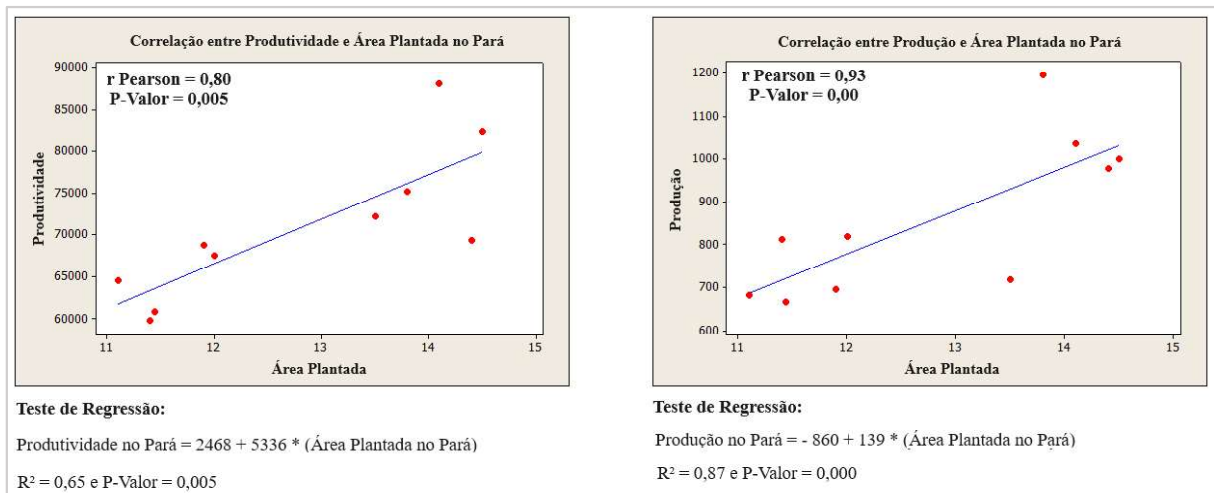
Nos testes de regressão foram identificados valores de R^2 de 0,54 para a regressão entre Área Plantada e Produtividade com P-Valor de 0,015, bem como R^2 de 0,19 para a regressão entre Área Plantada e Produção com P-Valor de 0,205. Esses valores confirmam o que foi observado na correlação de Pearson, pois apenas a regressão entre Área Plantada e Produtividade apresentou R^2 e P-Valor estatisticamente significativos.

1.4.3.4 Estado do Pará (PA)

O estado do Pará foi o único que apresentou correlação nos dois testes realizados. Em ambos foi possível identificar fortes correlações positivas, com P-Valores significativos, o que demonstra que as variáveis consideradas apresentam relação diretamente proporcional no estado (Figura 18). Em relação aos testes de regressão, obteve-se um R^2 de 0,65 para a regressão

entre Área Plantada e Produtividade, com P-Valor de 0,005, e um R^2 de 0,87 para a regressão entre Área Plantada e Produção, com P-Valor de 0,000, o que confirmou o que foi observado durante os testes de correlação, pois foram identificados valores estatisticamente significativos para ambas as regressões, assim como ocorreu nas duas correlações realizadas anteriormente para os dados do estado em questão.

Figura 18 - Correlações e Regressão entre Área Plantada x Produtividade e Área Plantada x Produção para o estado do Pará.



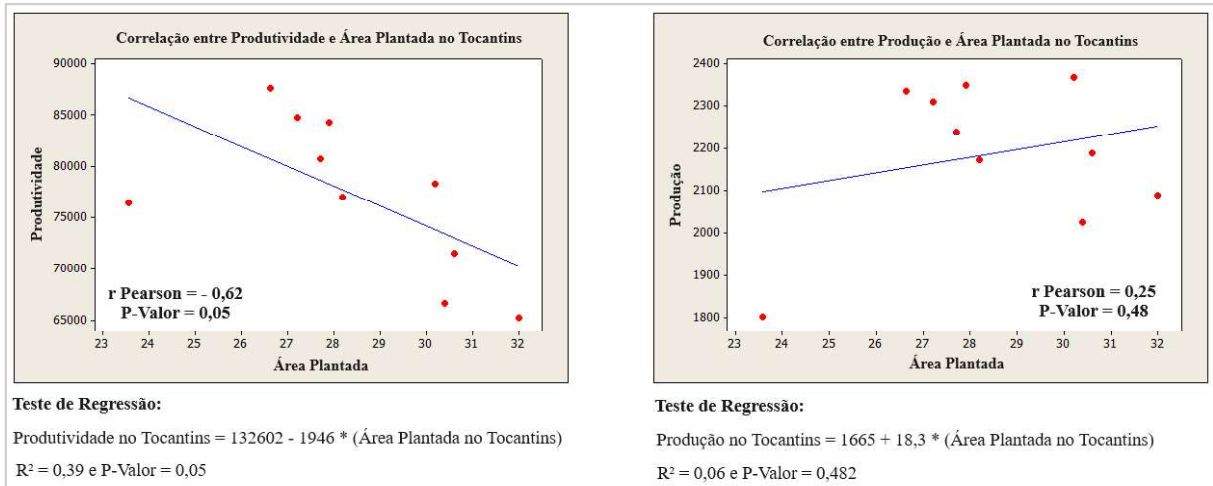
Fonte: autor.

1.4.3.5 Estado do Tocantins (TO)

No estado do Tocantins foi possível identificar correlação negativa entre as variáveis Área Plantada e Produtividade, com magnitude forte para os parâmetros de Cohen (1992) e moderada para os de Rumsey (2016), com P-Valor de 0,05 de significância. Já para as variáveis Área Plantada e Produção, o P-Valor acabou ultrapassando 0,05, gerando um P-Valor de 0,48. Além disso, os dados apresentaram correlações sem significância adequada, segundo os parâmetros de magnitude considerados (Figura 19).

Os testes de regressão para o estado também confirmaram o observado nos testes de correlação. A regressão entre Área Plantada e Produtividade obteve R^2 de 0,39, ficando dentro da margem moderada, conforme sugerido pelos parâmetros de correlação de Rumsey (2016), além de P-Valor de 0,05, bem no limite para ser considerado estatisticamente significativo. A regressão entre Área Plantada e Produção, apresentou R^2 de 0,06, com P-Valor de 0,482, ambos considerados estatisticamente não significativos, como ocorreu na correlação realizada anteriormente entre Área Plantada e Produção para o estado do Tocantins.

Figura 19 - Correlações e Regressão entre Área Plantada x Produtividade e Área Plantada x Produção para o estado do Tocantins.



Fonte: autor.

1.4.4 Discussão

Segundo Silva et al. (2021b), o Brasil possui mais de 10 milhões de hectares cultivados com cana-de-açúcar. Com isso, a cana-de-açúcar ocupa posição de destaque no Brasil, representando uma das principais culturas produzidas no território nacional e de grande relevância para a economia do país. Esses fatores justificam a soma de esforços entre produtores, pesquisadores e o próprio governo, para melhorias em relação à sua produtividade e consequente produção, a fim de antecipar e evitar possíveis problemas que possam afetar as culturas durante o ciclo vegetativo da planta, bem como no período de processamento.

Nesse sentido, uma das principais preocupações, que pode interferir na produtividade e na expansão da cana-de-açúcar em todo o território nacional e na Amazônia Oriental, é a possibilidade do surgimento de novas pragas que possam afetar a cultura, causando prejuízos aos produtores e comprometendo diretamente a qualidade da cana produzida, refletindo negativamente no desempenho do setor (Cezar, 2021). Para exemplificar, Narayan et al. (2020) apontam que as perdas de produtividade da cana-de-açúcar variam de 10 a 30% devido a insetos-praga que atacam a cultura.

Nas últimas décadas, com a constante expansão dos canaviais e a proibição da queima durante a colheita, houve um aumento significativo na população de pragas no Brasil (Bezerra et al., 2021), pois a colheita da cana sem queima foi adotada em cerca de 84% dos canaviais do país, tornando ainda mais complexo o manejo de insetos-praga, devido à presença de resíduos no solo, o que acaba afetando diretamente a ação dos herbicidas, aumentando a incidência de determinadas pragas (Castro et al., 2019; Carbonari et al., 2020).

Nesse sentido, sabe-se que a cultura da cana-de-açúcar pode ser atacada pelas mais diversas pragas, cada uma variando de acordo com sua manifestação e capacidade de proliferação, associadas às condições do canavial e à variedade afetada (Nocelli et al., 2017). Como forma de exemplificar essas possíveis pragas, Pinto et al. (2016) subdividiram as principais pragas da cana-de-açúcar em: pragas-chave, pragas importantes, regionais ou esporádicas, pragas secundárias e nematóides, conforme mostra a Tabela 4.

Tabela 4 - Pragas presentes na cultura da cana-de-açúcar brasileira.

	NOME CIENTÍFICO	NOME COMUM
PRAGAS-CHAVE	<i>Diatraea saccharalis</i> (Lepidoptera: Crambidae)	Broca-da-cana-de-açúcar
	<i>Mahanarva fimbriolata</i> (Hemiptera: Cercopidae)	Cigarrinha-das-raízes
PRAGAS IMPORTANTES, REGIONAIS OU ESPORÁDICAS	<i>Sphenophorus levis</i> (Coleoptera: Curculionidae)	Gorgulho-da-cana-de-açúcar
	<i>Heterotermes tenuis</i> (Isoptera: Rhinotermitidae)	Cupim
	<i>Atta</i> spp.	Formigas cortadeiras saúvas
	<i>Acromyrmex</i> spp. (Hymenoptera: Formicidae)	Quenquéns
	<i>Migdolus fryanus</i> (Coleoptera: Cerambycidae)	Migdolus
	<i>Telchin licus</i> (Lepidoptera: Castniidae)	Broca-gigante
	<i>Mahanarva posticata</i> (Hemiptera: Cercopidae)	Cigarrinha-das-folhas
PRAGAS SECUNDÁRIAS	<i>Metamasius hemipterus</i> (Coleoptera: Curculionidae)	Besouro-rajado
	Besouros de várias espécies (Coleoptera: Scarabaeidae)	Corós, pão-de-galinha ou bicho-bolo
	<i>Elasmopalpus lignosellus</i> (Lepidoptera: Pyralidae)	Lagarta-elasma
	<i>Hyponeuma taltula</i>	Broca-peluda ou iponeuma

	(Lepidoptera: Noctuidae)	Lagartas desfolhadoras
	<i>Spodoptera frugiperda</i> (Lepidoptera: Noctuidae)	
	<i>Mocis latipes</i> (Lepidoptera: Noctuidae)	
NEMATÓIDES	<i>Pratylenchus zeae</i> (Nematoda: Pratylenchidae)	Nematóides
	<i>Meloidogyne incognita</i> (Nematoda: Heteroderidae)	
	<i>Meloidogyne javanica</i> (Nematoda: Heteroderidae)	

Fonte: autor, com base em Pinto et al. (2016).

Além das pragas citadas, outra problemática importante para a cultura da cana-de-açúcar são as plantas daninhas, podendo ocasionar diversos prejuízos às lavouras, segundo Procópio et al. (2016), como, por exemplo: redução da produtividade de colmos e de açúcar, decréscimo na longevidade do canavial, dificuldade e aumento no custo da colheita, queda na qualidade industrial da matéria-prima, abrigo para pragas e doenças da cana-de-açúcar e depreciação do valor da terra. No capítulo 4 desta pesquisa, será dada uma especial ênfase à planta daninha mucuna-preta (*Mucuna pruriens*), principal problemática presente na área de estudo desta tese de doutorado.

Outro desafio para a cana-de-açúcar brasileira em geral são os efeitos climáticos adversos da seca e das baixas temperaturas durante o ciclo produtivo das culturas nacionais, oscilando entre altas e baixas temperaturas nas regiões do país ao longo do ano. Porém, neste contexto negativo, a Amazônia Oriental tem se destacado positivamente nos últimos anos, obtendo rendimentos superiores às safras passadas, ao contrário do que se observa no restante do país. Isso acontece, segundo a CONAB (2022), pelas melhores condições climáticas da região e pela agregação de melhores práticas de manejo em suas culturas.

Mais um desafio, segundo a CONAB (2022), é a enorme pressão econômica que o setor de grãos vem exercendo sobre as regiões produtoras em geral, acabando com a hegemonia do cultivo da cana-de-açúcar em áreas que antes só produziam esta cultura. Isso também vem acontecendo na Amazônia Oriental, com o aumento da produção de milho e soja na região, por exemplo, já que esses grãos passaram a ter retorno econômico mais vantajoso e maior liquidez. O milho inclusive tem tido participação crescente na produção de etanol, principalmente no

estado de Mato Grosso, onde tem havido maiores investimentos na cultura, gerando boas expectativas para as próximas safras no estado.

Outra limitação da produção na Amazônia Oriental foram questões legais que impediram a expansão da cultura nos últimos anos. Cardoso et al. (2022) expôs essas questões, destacando o zoneamento agroecológico da cana-de-açúcar, imposto pelo Decreto nº 6.961/2009, que limitou a produção de cana-de-açúcar na Amazônia Oriental, por estar localizada nos biomas Amazônia e Pantanal, pois a produção de cana-de-açúcar poderia representar um potencial risco ao meio ambiente. Contudo, o Decreto nº 6.961/2009 foi revogado pelo Decreto 10.084/2019, o que poderá facilitar a expansão da cultura na região como um todo, mesmo em áreas de matas nativas e indígenas que antes também eram limitadas pelo decreto do ano de 2009.

Obviamente, é importante que o setor sucroalcooleiro desenvolva suas atividades no âmbito de uma atividade agrícola sustentável, buscando aumentar sua rentabilidade por meio de ferramentas que otimizem a produção sem causar impactos significativos ao meio ambiente. A CONAB (2022) destaca essa boa relação entre o setor sucroenergético e o meio ambiente, enfatizando que, diferentemente do que acontece em outros países, a produção nacional opera em um contexto positivo e sustentável, em harmonia com a legislação vigente.

Mas como aumentar a Produtividade e a Produção sem aumentar o desmatamento no país, possibilitando assim maior produtividade e rentabilidade das culturas nacionais? Uma solução que tem surgido no contexto nacional ao longo dos últimos anos e décadas é a utilização das diversas ferramentas disponíveis na Agricultura de Precisão (AP), que permitem otimizar a produção nas culturas, procurando minimizar os problemas identificados e possibilitando, por exemplo: detecção rápida de pragas, análise de vegetação para mensurar possíveis falhas de plantio e estresse hídrico, monitoramento das taxas de crescimento durante o ciclo vegetativo da planta, análise de possível erosão do solo nas áreas de plantio, entre outras possibilidades.

Outra opção é o aproveitamento de áreas já degradadas. Na pesquisa realizada por Marin et al. (2016), os autores demonstraram, por exemplo, que o país tem possibilidade de aumentar sua produtividade sem ampliar as áreas de plantio, mas o ritmo histórico de ganhos de produtividade deve ser aumentado, o que minimizaria a pressão e a demanda futura por terras. As ferramentas de AP também são importantes para atingir esse objetivo.

A CNA (2021), Confederação da Agricultura e Pecuária do Brasil, também alerta para problemas recentes em relação aos altos preços dos insumos agrícolas utilizados no plantio, como fertilizantes importados, por exemplo, ainda refletindo os impactos decorrentes da pandemia da COVID-19, que teve impacto direto nos custos de produção. Todo esse cenário

aponta para a necessidade de implementação de medidas governamentais para exploração desses fertilizantes, em quantidade suficiente, no próprio país, para atender a demanda nacional pela cultura e outras culturas produzidas no Brasil.

1.5 Conclusões

Através da análise dos dados durante a construção deste capítulo, foi possível perceber a dimensão da importância da cultura canavieira para a Amazônia Oriental. Um fato que merece destaque é que, de forma geral, os estados analisados naquela região apresentaram aumento significativo na produtividade da cana-de-açúcar nas safras 2012/2013 a 2021/2022.

O estado do Pará foi o que mais ampliou sua Área Plantada no período, enquanto os estados do Maranhão e Mato Grosso tiveram suas áreas de plantio reduzidas. Por outro lado, o estado do Tocantins aumentou sua Área Plantada, ao comparar diretamente as safras 2012/2013 com a safra 2021/2022, mas teve seu ápice de Área Plantada na safra 2016/2017 e desde então vem apresentando queda em suas Áreas Plantadas.

No que diz respeito à Produção, houve maior variação entre os estados. Mato Grosso foi o único que apresentou queda na produção na comparação entre o início e o final da série, atingindo o pico de produção na safra 2019/2020. Os demais estados tiveram aumento de produção nesta mesma comparação, mas com picos de produção diferentes. Os estados do Maranhão e Tocantins tiveram produção máxima na safra 2015/2016, enquanto o Pará apresentou aumento na última das safras avaliadas, a safra 2021/2022, mais um indicador da tendência positiva de crescimento deste estado, pois foi o único entre os estados analisados que apresentou crescimento nas três variáveis consideradas: Área Plantada, Produtividade e Produção.

Foi possível perceber uma tendência positiva em relação ao crescimento da produção de cana-de-açúcar nos estados que compõem a Amazônia Oriental, ao analisar os dados de Área Plantada, Produtividade e Produção das últimas 10 safras. Resta à região superar os desafios que ainda existem para esta expansão, pois, na verdade, este território representa uma das últimas fronteiras agrícolas presentes no Brasil, necessitando de mais pesquisas e investimentos para o seu amplo desenvolvimento sustentável.

REFERÊNCIAS

- BEZERRA, J. I. M.; MOLTER, A.; RAFIKOV, M.; FRIGHETTO, D. F. (2021). Biological control of the chaotic sugarcane borer-parasitoid agroecosystem. **Ecological Modelling**, v. 450, 2021. <https://doi.org/10.1016/j.ecolmodel.2021.109564>.
- BORDONAL, R. O.; CARVALHO, J. L. N.; LAL, R.; FIGUEIREDO, E. B.; OLIVEIRA, B.G.; SCALA JÚNIOR, N. L. Sustainability of sugarcane production in Brazil. A review. **Agronomy for Sustainable Development**, v. 38, n. 13, 2018. <https://doi.org/10.1007/s13593-018-0490-x>.
- BRASILa. Decreto nº 6961, de 17 de setembro de 2009. Aprova o zoneamento agroecológico da cana-de-açúcar e determina ao Conselho Monetário Nacional o estabelecimento de normas para as operações de financiamento ao setor sucroalcooleiro, nos termos do zoneamento. **Presidência da República Federativa do Brasil**, 2009. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/decreto/d6961.htm. Acesso em: 3 jan. 2023.
- BRASILb. Decreto nº 10.084, de 5 de novembro de 2019. Revoga o Decreto nº 6.961, de setembro de 2009, que aprova o zoneamento agroecológico da cana-de-açúcar e determina ao Conselho Monetário Nacional o estabelecimento de normas para as operações de financiamento ao setor sucroalcooleiro, nos termos do zoneamento. **Presidência da República Federativa do Brasil**, 2019. Disponível em: https://www.planalto.gov.br/ccivil_03/_Ato2019-2022/2019/Decreto/D10084.htm. Acesso em: 3 jan. 2023.
- CARBONARI, C. A.; MATOS A. K. A.; BRITO, I. P. F. S.; VELINI, E. D.; DAYAN, F. E. Impact of green cane harvesting on pest management in sugarcane. **Outlooks on Pest Management**, v. 31, n. 2, p. 64-73, 2020. https://doi.org/10.1564/v30_apr_04.
- CARDOSO, L. A. S., FARIAS, P. R. S.; SOARES, J. A. C. Use of Unmanned Aerial Vehicle in sugarcane cultivation in Brazil: a review. **Sugar Tech**, v. 24, n. 6, p. 1636-1648, 2022. <https://doi.org/10.1007/s12355-022-01149-9>.
- CASTRO, S. G. Q.; DINARDO-MIRANDA, L. L.; FRACASSO, J. V.; BORDONAL, R. O.; MENANDRO, L. M. S.; FRANCO, H. C. J.; CARVALHO, J. L. N. Changes in Soil Pest Populations Caused by Sugarcane Straw Removal in Brazil. **BioEnergy Research**, v. 12, p. 878-887, 2019. <https://doi.org/10.1007/s12155-019-10019-4>.
- CEZAR, M. A. Avanços e perspectivas no manejo de podridões da cana-de-açúcar. *In*: CARVALHO-GONÇALVES, L. C. T. **Introdução à tecnologia sucroalcooleira**. João Pessoa: UFPB, 2021. p. 7-30.
- CHEAVEGATTI-GIANOTTO, A.; ABREU, H.M.C.; ARRUDA, P.; BESPALHOK FILHO, J. C.; BURNQUIST, W. L.; CRESTE, S.; CIERO, L.; FERRO, J. A.; FIGUEIRA, A. V. O.; FILGUEIRAS, T. S.; GROSSI-DE-SÁ, M. F.; GUZZO, E. C.; HOFFMANN, H. P.; LANDELL, M. G. A.; MACEDO, N.; MATSUOKA, S.; REINACH, F. C.; ROMANO, E.; SILVA, W. J.; SILVA FILHO, M. C.; ULIAN, E. C. Sugarcane (*Saccharum X officinarum*): a reference study for the regulation of genetically modified cultivars in Brazil. **Tropical Plant Biology**, v. 4, p. 62-89, 2011. <https://doi.org/10.1007/s12042-011-9068-3>.

CHEAVEGATTI-GIANOTTO, A.; GENTILE, A.; OLDEMBURGO, D. A.; MERHEB, G. A.; SERENO, M. L.; LIRETTE, R. P.; FERREIRA, T. H. S.; OLIVEIRA, W. S. Lack of detection of Bt sugarcane Cry1Ab and NptII DNA and proteins in sugarcane processing products including raw sugar. **Frontiers in Bioengineering and Biotechnology**, v. 6, n. 24, 2018. <https://doi.org/10.3389/fbioe.2018.00024>.

CNA. Safra 2021/2022 de cana-de-açúcar iniciará com expectativas de alta nos custos de produção. **Confederação da Agricultura e Pecuária do Brasil**, 2021. Disponível em: <https://cnabrazil.org.br/publicacoes/safra-2021-2022-de-cana-de-acucar-iniciara-com-expectativas-de-alta-nos-custos-de-producao-o>. Acesso em: 10 jan. 2023.

COHEN, J. Statistical power analysis. **Current Directions in Psychological Science**, v. 1, n. 3, p. 98-101, 1992. <https://doi.org/10.1111/1467-8721.ep10768783>.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2012/2013, quarto levantamento, abril/2013. **Companhia Nacional de Abastecimento**, 2013.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2013/2014, quarto levantamento, abril/2014. **Companhia Nacional de Abastecimento**, v. 1, 2014.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2014/2015, quarto levantamento, abril/2015. **Companhia Nacional de Abastecimento**, v. 1, n. 4, 2015.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2015/2016, quarto levantamento, abril/2016. **Companhia Nacional de Abastecimento**, v. 2, n. 4, 2016.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2016/2017, quarto levantamento, abril/2017. **Companhia Nacional de Abastecimento**, v. 3, n. 4, 2017.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2017/2018, quarto levantamento, abril/2018. **Companhia Nacional de Abastecimento**, v. 4, n. 4, 2018.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2018/2019, quarto levantamento, abril/2019. **Companhia Nacional de Abastecimento**, v. 5, n. 4, 2019.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2019/2020, quarto levantamento, abril/2020. **Companhia Nacional de Abastecimento**, v. 6, n. 4, 2020.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2020/2021, quarto levantamento, maio/2021. **Companhia Nacional de Abastecimento**, v. 7, n. 4, 2021.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2021/2022, quarto levantamento, abril/2022. **Companhia Nacional de Abastecimento**, v. 8, n. 4, 2022.

DIAS, H. B.; SENTELHAS, P. C. Sugarcane yield gap analysis in Brazil—A multi-model approach fordetermining magnitudes and causes. **Science of the Total Environment**, v. 637-638, p. 1127-1136, 2018. <https://doi.org/10.1016/j.scitotenv.2018.05.017>.

EMBRAPA. Fenologia. **Empresa Brasileira de Pesquisa Agropecuária**, 2022. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/pre-producao/caracteristicas/fenologia>. Acesso em: 12 out. 2023.

IBGE. Amazônia Legal. **Instituto Brasileiro de Geografia e Estatística**, 2021. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=o-que-e/>. Acesso em: 3 jan. 2023.

IBGE. Censo Agro 2017. **Instituto Brasileiro de Geografia e Estatística**, 2017. Disponível em: <https://censoagro2017.ibge.gov.br/1992-novo-portal/edicao/16194-amazonia-legal-amazonialegal-2.html>. Acesso em: 3 jan. 2023.

IBGE. IBGE atualiza Mapa da Amazônia Legal. **Instituto Brasileiro de Geografia e Estatística**, 2020. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/28089-ibge-atualiza-mapa-da-amazonia-legal>. Acesso em: 3 jan. 2023.

IBGE. Produção de Cana-de-açúcar. **Instituto Brasileiro de Geografia e Estatística**, 2022. Disponível em: <https://www.ibge.gov.br/explica/producao-agropecuaria/cana-de-acucar/br>. Acesso em: 15 mar. 2024.

KUMAR, P.; CHANDRA, S.; SINGH, B.; CHAUHAN, V. S.; SRIVASTAVA, S. PCR based RGAs strategy for identification of putative disease resistance genes analogues in sugarcane. **Trends in Biosciences**, v. 10, n. 33, p. 7029-7034, 2017.

MARIN, F. R.; MARTHA, G. B.; CASSMAN, K. G.; GRASSINI, P. Prospects for increasing sugarcane and bioethanol production on existing crop area in Brazil. **BioScience**, v. 66, n. 4, p. 307-316, 2016. <https://doi.org/10.1093/biosci/biw009>.

MINITAB. Análise da regressão: como interpretar o R-quadrado e avaliar a qualidade de ajuste. **Minitab**, 2019. Disponível em: <https://blog.minitab.com/pt/analise-de-regressao-como-interpretar-o-r-quadrado-e-avaliar-a-qualidade-de-ajuste>. Acesso em: 21 mar. 2023.

MÜLLER, C.; MILANI, L. M.; GIEHL, A.; BARRILLI, E. T.; DEOTI, L.; LUCARONI, A. C.; TADIOTO, V.; TREICHEL, H. Resíduos de cana-de-açúcar e milho como matéria prima do etanol 2G: atualidades e perspectivas. *In*: VOIGT, C. L. **Impactos das Tecnologias na Engenharia Química** 3. Ponta Grossa: Atena, 2019. p. 8-22 <https://doi.org/10.22533/at.ed.3191901042>.

NARAYAN, J. A.; MOHAN, C.; ESTERLING, M.; YAU, Y.-Y. Development of transgenic sugarcane for insect resistance. *In*: KUMAR, A.; YAU, Y.-Y.; OGITA, S.; SCHEIBE, R. **Climate Change, Photosynthesis and Advanced Biofuels**. Singapura: Springer, 2020. p. 389-406. https://doi.org/10.1007/978-981-15-5228-1_16.

NOCELLI, R. C. F.; ROAT, T. C.; SOCOLOWSKI, P. C.; MALASPINA, O. Controle de pragas na cana-de-açúcar e seu impacto sobre organismos voadores não alvos. *In*: FONTANETTI, C. S.; BUENO, O. C. **Cana-de-açúcar e seus impactos: uma visão acadêmica**. Bauru: Canal 6, 2017. p. 89-101.

PEREIRA, I. A.; FERREIRA, M.; OLIVEIRA, B. K. S.; MENEZES, F. G.; PEIXOTO, J. V. M.; MAGESTE, J. G.; LANA, R. Q. M.; MORAES, E. R. *Diatraea saccharalis*, (Fabr.) (Lepidoptera: Crambidae) em cana-de-açúcar de segundo corte fertilizada com organomineral de lodo de esgoto e bioestimulante. **Brazilian Journal of Development**, v. 6, n. 1, p. 2265-2271, 2020. <https://doi.org/10.34117/bjdv6n1-165>.

PINTO, A. S.; LOPES, V. L.; LIMA, A. A. Manejo de pragas. *In*: SANTOS, F.; BORÉM, A. **Cana-de-açúcar do plantio a colheita**. Viçosa: UFV, 2016. p. 94-107.

PROCÓPIO, S. O.; SILVA, A. A.; FERREIRA, E. A.; SILVA, A. F.; GALON, L. Plantas daninhas. *In*: SANTOS, F.; BORÉM, A. **Cana-de-açúcar do plantio a colheita**. Viçosa: UFV, 2016. p. 139-176.

REIN, P. **Engenharia do açúcar de cana**. Alemanha: Bartens, 2013. 872 p.

RODRIGUES, G. S. S. C.; ROSS, J. L. S. **A trajetória da cana-de-açúcar no Brasil: perspectivas geográfica, histórica e ambiental**. Uberlândia: EDUFU, 2020. 272 p.

RUMSEY, D. J. **Statistics for Dummies**. Estados Unidos: For Dummies, 2016. 416 p.

SILVA, M. S. O.; CARDOSO, J. F. M.; FERREIRA, M. E. P.; BALDO, F. B.; SILVA, R. S. A.; CHACON-OROZCO, J. G.; SHAPIRO-ILAN, D. I.; HAZIR, S.; BUENO, C. J.; LEITE, L. G. An assessment of *Steinernema rarum* as a biocontrol agent in sugarcane with focus on *Sphenophorus levis*, host-finding ability, compatibility with vinasse and field efficacy. **Agriculture**, v. 11, n. 6, 2021. <https://doi.org/10.3390/agriculture11060500>.

SUDAM. Legislação da Amazônia. **Superintendência do Desenvolvimento da Amazônia**, 2021. Disponível em: <https://www.gov.br/sudam/pt-br/acesso-a-informacoes/institucional/legislacao-da-amazonia>. Acesso em: 3 jan. 2023.

YUSUF, K. A.; CALDARELLI, C. E. Novos desafios para a agroindústria canavieira no Brasil. **Revista de Política Agrícola**, v. 27, n. 2, 2018.

2. USO DE VEÍCULO AÉREO NÃO TRIPULADO NO CULTIVO DA CANA-DE-AÇÚCAR NO BRASIL: UMA REVISÃO²

RESUMO

A utilização de Veículos Aéreos Não Tripulados (VANTs) está se tornando cada vez mais popular e presente em diversas atividades ao redor do mundo, como uma importante ferramenta de inovação para otimizar trabalhos e pesquisas em geral. Dentre as diversas áreas em que os VANTs estão presentes, neste capítulo destacaremos sua utilização como ferramenta de Agricultura de Precisão, com destaque para sua utilização no cultivo de cana-de-açúcar no Brasil, cultura com a terceira maior área plantada do país. O objetivo foi realizar uma revisão sistemática dos trabalhos já realizados sobre a utilização de VANTs nas lavouras brasileiras, buscando elucidar: onde, quanto e como essa inovação tem sido utilizada nas lavouras nacionais. Para atingir esse objetivo, utilizamos importantes bases de indexação de artigos científicos (*Scopus*, *Web of Science*, *Scielo* e *Google Scholar*), onde identificamos artigos publicados em periódicos e anais de eventos importantes dentro e fora do país. Com isso, foi possível visualizar o cenário da distribuição das pesquisas identificadas em todo o território nacional, constatando que há regiões do país onde os estudos se concentram mais do que outras. Ao final, concluímos que o país possui uma distribuição heterogênea quanto ao uso desta tecnologia, o que pode ser explicado por restrições legais impostas no passado ou pela ausência de obras e/ou publicidade nas pesquisas realizadas até o momento. Nesse sentido, o presente capítulo contribui para elucidar o estado atual das pesquisas e dimensionar perspectivas para o futuro.

Palavras-chave: VANT; Sensoriamento remoto; Agricultura de precisão.

² Este capítulo foi base para o artigo: **Use of Unmanned Aerial Vehicle in Sugarcane Cultivation in Brazil: A Review**, publicado na revista “*Sugar Tech*”. DOI: <https://doi.org/10.1007/s12355-022-01149-9>.

ABSTRACT

The use of Unmanned Aerial Vehicles (UAVs) is becoming increasingly popular and present in various activities around the world, as an important innovation tool to optimize work and research in general. Among the various areas in which UAVs are present, in this article we will highlight their use as a Precision Agriculture tool, with emphasis on their use in the cultivation of sugarcane in Brazil, a crop with the third largest planted area in the country. The objective was to carry out a systematic review of the work already carried out on the use of UAVs in Brazilian crops, seeking to elucidate: where, how much and how this innovation has been used in national crops. To achieve this goal, we use important scientific articles indexing databases (Scopus, Web of Science, Scielo and Google Scholar), where we identify articles published in journals and annals of important events inside and outside the country. With this, it was possible to visualize the scenario of the distribution of researches identified throughout the national territory, noting that there are regions of the country where studies are concentrated more than others. In the end, we conclude that the country has a heterogeneous distribution regarding the use of this technology, which can be explained by legal restrictions imposed in the past or by the absence of works and/or advertising in the research carried out so far. In this sense, the present article contributes to elucidate the current state of research and dimension perspectives for the future.

Keywords: UAV; Remote sensing; Precision agriculture.

2.1 Introdução

Um Veículo Aéreo Não Tripulado (VANT), popularmente conhecido como “drone”, é definido como qualquer aeronave projetada para operar sem piloto a bordo, com carga útil a bordo e de caráter não recreativo (DECEA, 2010). Portanto, ao contrário do que observamos no senso comum, nem todo “drone” é um VANT, pois se a aeronave for utilizada apenas para fins recreativos, pela definição legal no Brasil, não é um VANT.

Além da aeronave, o VANT também é composto por uma estação de controle em solo, responsável pelo planejamento e monitoramento remoto da missão executada. O VANT também possui um sistema de posicionamento acoplado, bem como uma unidade de navegação inercial, garantindo melhor precisão de posicionamento e determinação de coordenadas (Jorge; Inamasu, 2014).

A IMU, do inglês *Inertial Measurement Unit* e do português Unidade de Medida de Inércia, é essencial para realização de tarefas com precisão e para minimizar possíveis distúrbios durante o voo. É utilizada principalmente para medir a velocidade, orientação e força gravitacional dos dispositivos, consistindo, inicialmente, em giroscópios e acelerômetros para rastreamento de movimentos rotacionais e translacionais. Posteriormente, a tecnologia avançou, e foi incluído mais um sensor, o magnetômetro. O acelerômetro é utilizado para medir a aceleração inercial, o giroscópio para medir a rotação angular e o magnetômetro permite a melhoria da leitura do giroscópio (Madgwick et al., 2011; Ahmad et al., 2013; Petrenko et al. 2023).

Esta tecnologia tem se tornado cada vez mais popular ao longo dos anos, muito pela sua versatilidade, o que permite a sua aplicação em diversas áreas, como a Agricultura de Precisão (Silva et al., 2021). Um dos principais motivos dessa popularização é que os VANTs estão cada vez mais fáceis de operar, possibilitando sua utilização em campo e possibilitando o aprimoramento das técnicas de sensoriamento remoto, com base nas imagens geradas pelos sensores a eles acoplados (Jorge; Inamasu, 2014). Nesse sentido, o Brasil vem buscando acompanhar toda essa evolução.

Quando falamos do Brasil e de todo esse avanço que a Agricultura de Precisão representa para a produção rural - como é o caso dos VANTs como forma de inovar o processo produtivo, trazendo melhorias nos indicadores de produtividade -, é praticamente impossível ignorar a cana-de-açúcar, que representa a terceira maior área plantada do país, atrás apenas da soja e do milho, segundo a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA).

Segundo o IBGE (2019), Instituto Brasileiro de Geografia e Estatística, o Brasil produziu cerca de 752.895.389 toneladas de cana-de-açúcar em 2019, sendo o estado de São

Paulo o maior produtor, com aproximadamente 425.617.093 toneladas no mesmo ano, ou seja, mais de metade de tudo o que foi produzido no país.

Tamanha produção nacional, coloca o país em posição de destaque no cenário mundial, o consolidando como o maior produtor da cultura no mundo (Cheavegatti-Gianotto et al., 2018; Dias; Sentelhas, 2018). Assim, é fundamental que o setor sucroenergético brasileiro esteja atento às inovações tecnológicas que surgem na perspectiva da Agricultura de Precisão, como o uso de VANTs, buscando manter o país no auge de sua produtividade e em posição de referência.

Em geral, os VANTs são utilizados em pequenas áreas, mostrando-se eficazes para monitorar a cana-de-açúcar e estimar sua produtividade. Uma desvantagem é que a tecnologia pode não ser eficaz num sistema de monitoramento global, devido ao seu elevado custo em relação às plataformas orbitais. Contudo, os UAV também podem ser úteis para esta escala de monitoramento, fornecendo informações detalhadas do terreno (Som-ard et al., 2021).

Nesse sentido, este capítulo teve como objetivo realizar uma revisão sistemática dos trabalhos já realizados sobre a utilização de VANTs nas plantações de cana-de-açúcar no Brasil, buscando elucidar: onde, quanto e como essa inovação tem sido utilizada nas plantações nacionais. Para tanto, utilizamos importantes bases de dados de trabalhos científicos nacionais e internacionais (*Scielo, Scopus, Web of Science e Google Scholar*), onde foi possível identificar artigos publicados em alguns periódicos, bem como em anais de eventos importantes dentro e fora do país.

Com isso, foi possível visualizar o cenário da distribuição das pesquisas identificadas em todo o território nacional, constatando que existem regiões do país onde os estudos estão mais concentrados quando comparados a outros, o que pode demonstrar heterogeneidade no uso da tecnologia nas plantações. Em alguns casos, autores se repetem ou se alternam entre primeiro autor ou coautores, o que demonstra que a tecnologia proposta e as publicações ao seu respeito, ainda se restringem a poucos pesquisadores, em determinada região do país.

2.2 Uso de VANT em Plantações de Cana-de-açúcar no Brasil

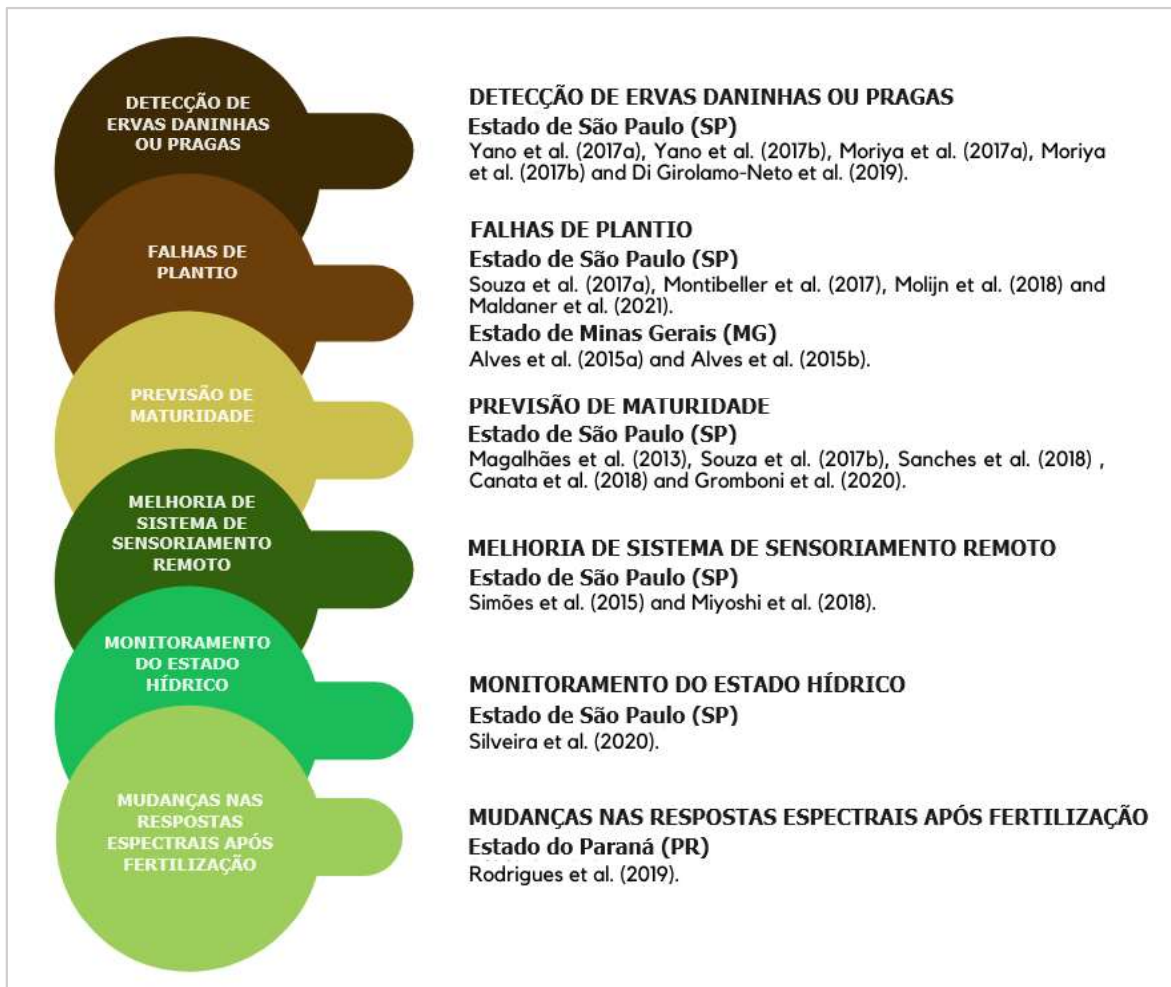
Para a construção deste tópico, optou-se por apresentar os trabalhos identificados, de acordo com a Divisão Regional do Brasil, conforme estabelecido pelo IBGE: Sudeste, Centro-Oeste, Sul, Nordeste e Norte. Pela ordem de apresentação, priorizamos as regiões do país com maior número de trabalhos identificados, em detrimento às regiões com menor número de estudos identificados.

Para a pesquisa bibliográfica e redação deste capítulo de revisão foram consultadas as bases de trabalhos científicos: Scopus, Web of Science, Scielo e Google Scholar. As palavras-chave utilizadas para a pesquisa foram: “sensoriamento remoto” e “veículo aéreo não tripulado” e “cana-de-açúcar” e “Brasil”.

Ao todo, identificamos 11 artigos publicados em revistas científicas nacionais e internacionais, além de mais 11 publicados em anais de eventos científicos dentro e fora do país, totalizando 22 estudos identificados.

As pesquisas estão distribuídas nas regiões Sudeste (19 artigos), Centro-Oeste (1 artigo), Sul (1 artigo) e Nordeste (1 artigo, mas sem a identificação do município onde a pesquisa foi realizada). O destaque ficou com a região Sudeste, onde foi identificada a maior parte das publicações. Na região Norte não foram identificadas pesquisas sobre o tema, enfatizando o grau de novidade desta pesquisa de doutorado para a região. A Figura 1 mostra os estados brasileiros onde as obras foram identificadas e a finalidade do uso dos VANTs.

Figura 1 - Fluxo de pesquisas realizadas com VANTs no cultivo de cana-de-açúcar no Brasil.



2.3 Região Sudeste

2.3.1 Estado de São Paulo (SP)

2.3.1.1 Detecção de Ervas Daninhas ou Pragas

Na cidade de Campinas-SP, em plantio experimental de cana-de-açúcar na Universidade Estadual de Campinas (UNICAMP), Yano et al. (2017a) desenvolveram estudos baseados no controle de plantas daninhas, enfatizando o uso do VANT como alternativa tecnológica sustentável ao controle químico, ainda predominante na cana-de-açúcar, por ser considerado mais prático e barato, quando comparado ao controle mecânico. Segundo os autores, essa tecnologia pode representar uma importante ferramenta no combate ao desperdício e má aplicação de produtos químicos, uma vez que o tipo de herbicida e sua respectiva dosagem podem variar nas parcelas de plantio, assim como o tipo de erva daninha.

Nesse sentido, esta pesquisa propôs um sistema de identificação de plantas daninhas utilizando VANT, capaz de identificar plantas invasoras mesmo em baixos níveis de infestação. Como resultado inicial, o sistema obteve uma precisão global de 83,1% e um coeficiente kappa de 0,775, utilizando o classificador KNN (K-Nearest Neighbours). As plantas utilizadas foram: erva daninha de folhas estreitas (*Cyperus Rotundus* comumente conhecida como tiririca), erva daninha de folhas grandes (*Ipomonea* sp conhecida como corda de viola) e a própria cana-de-açúcar (*Saccharum* spp).

No mesmo campo experimental da UNICAMP, Yano et al. (2017b) propuseram e testaram um processo de levantamento também focado no combate a plantas daninhas, baseado no reconhecimento de padrões de imagens obtidas por VANT, após o crescimento espontâneo de plantas invasoras. As plantas daninhas utilizadas na pesquisa foram: mastruço (*Lepidium virginicum*), joá de capote (*Nicandra physalodes*) e capim-braquiária (*Brachiaria decumbens*); além da própria cana-de-açúcar (*Saccharum* spp). Como conclusão dos testes preliminares, três classificadores foram experimentados, o melhor consistiu em uma Rede Neural Artificial (RNA), que obteve precisão global de 91,67% e coeficiente kappa de 0,8958.

Segundo os autores, o VANT reconhece o padrão de ervas daninhas no início da infestação, o que o torna mais eficaz quando comparado aos satélites. Este reconhecimento precoce é importante, porque o controle das ervas daninhas no início da sua infestação pode evitar perdas de rendimento de até 90% na produção, devido à competição por luz, água e nutrientes entre a cultura e as ervas daninhas. Outra vantagem do VANT é que ele permite a aquisição de imagens não afetadas pela presença de nuvens.

Outro trabalho com utilização de VANT em plantações de cana-de-açúcar, foi realizado por Moriya et al. (2017a) em Euclides da Cunha-SP. A pesquisa teve como objetivo identificar o vírus do mosaico da cana-de-açúcar (SCMV – “*Sugar Cane Mosaic Virus*”) em canaviais, avaliando o potencial dos índices de vegetação para detecção do vírus em questão. Para isso, utilizaram imagens hiperespectrais obtidas pelo VANT. Através do estudo, perceberam que os índices que mais contribuíram para a detecção do vírus foram o *Normalized Difference Vegetation Index* (NDVI), *Normalized Difference Vegetation Index Red Edge* (NDVI705), *New Vegetation Index* (NVI) e *Anthocyanin Reflectance Index 2* (ARI2).

Em outro estudo no mesmo município, desta vez em uma área de 4,045 hectares pertencente à Fundação Ênio Pipino, Moriya et al. (2017b) realizaram pesquisa com o objetivo de desenvolver uma metodologia utilizando uma câmera hiperespectral acoplada a um VANT, que permitisse o posterior processamento e análise das imagens obtidas. O estudo partiu da hipótese de que os resultados permitiriam a discriminação e o reconhecimento de plantas de cana-de-açúcar infectadas pelo vírus do mosaico da cana-de-açúcar.

Para isso foi necessária a caracterização espectral de plantas saudáveis e infectadas, a fim de definir a forma mais correta de operar a câmera hiperespectral, uma vez que a câmera utilizada possuía diversas opções de bandas espectrais para geração de imagens, mas limitava cada imagem a 25 bandas espectrais. Nesse sentido, os pesquisadores utilizaram um espectrorradiômetro para realizar medições espectrais de folhas de cana infectadas e saudáveis, o que permitiu a criação de uma biblioteca espectral. Após a escolha das bandas espectrais mais adequadas, a câmera foi configurada e realizado o levantamento aéreo. Ao final, as imagens hiperespectrais, adquiridas pelo VANT, permitiram a identificação completa das áreas infectadas, demonstrando alto grau de precisão.

Em Iracemápolis-SP, foi realizado um levantamento na Usina Iracema por Di Girolamo-Neto et al. (2019). O objetivo do trabalho foi detectar a planta daninha *Cynodon dactylon*, popularmente conhecida como capim de bermuda, que pode reduzir a produtividade nas plantações de cana-de-açúcar. Sua detecção, por sensoriamento remoto, não é das tarefas mais fáceis, devido à semelhança espectral entre a planta daninha e a cultura da cana-de-açúcar. No entanto, o estudo não só demonstrou a capacidade do UAV de superar a limitação conhecida desta detecção, mas também destacou a importância da textura para a quantificação de alta precisão da invasão do capim de bermuda. Para isso foi utilizado o GRVI (*Green-Red Vegetation Index*), somado a algumas métricas de textura, que acabaram melhorando a precisão geral de 83% para 92,54%.

2.3.1.2 Falhas de Plantio

No município de Euclides da Cunha-SP, Souza et al. (2017a) utilizaram imagens de VANT para análise de imagens baseadas em objetos, também conhecida como OBIA (*Object-Based Image Analysis*), em plantações de cana-de-açúcar. A intenção foi mapear e extrair informações sobre possíveis falhas presentes nas linhas de plantio da cultura. Com resultado, alcançaram alto nível de automação e adaptabilidade, além de obter informações relevantes para melhorar decisões, monitoramento agrícola e reduzir custos operacionais.

Em Iracemópolis-SP, Montibeller et al. (2017) apresentaram resultados preliminares de uma metodologia para detecção de lacunas na cultura da cana-de-açúcar, com base em imagens adquiridas por VANT. Como resultado, conseguiram detectar com eficiência as lacunas presentes no plantio, identificando cerca de 20,9% do solo exposto na área de estudo, decorrentes de falhas de plantio e/ou cultivo. Este tipo de informação é importante para que os produtores possam intervir no plantio, através de novo plantio ou mesmo adubação da área, como forma de intensificar e aumentar a produtividade das culturas, confirmando que os VANTs podem representar excelentes ferramentas para coleta dessas informações e aperfeiçoamento das estimativas de produção.

Em Piracicaba-SP, Maldaner et al. (2021) realizaram trabalho com VANTs para identificação de lacunas nas linhas de cana-de-açúcar. A intenção foi comparar esta técnica com outras que também utilizam sensores. Desta forma, foram comparadas três possibilidades com sensores montados em trator (VIS – *Vegetative Index Sensor*, ultrassônico e fotoelétrico) e uma utilizando VANT com câmera RGB (*Red, Green and Blue*); sendo este último o método comercial atual. Os testes de campo foram realizados em quatro fases de desenvolvimento da cultura: 19, 31, 47 e 59 dias após a colheita, utilizando o RMSE (*Root Mean Squared Error*) para avaliar sensores na medição do comprimento das clareiras.

Como conclusão, percebeu-se que tanto o VANT quanto o VIS tiveram seus resultados afetados negativamente entre os dias 47 e 59 após a colheita, permitindo inferir que quanto maior a copa da planta, menor a capacidade de identificação e medição de clareiras. Dentre os métodos utilizados, o que apresentou melhor desempenho foi o sensor fotoelétrico, com menor variação no RMSE ao longo da fase de desenvolvimento da cana ($RMSE \leq 0,18$ m). Por sua vez, tanto o VANT quanto o VIS tiveram desempenhos semelhantes, com o RMSE variando entre 0,11 e 0,40 m.

Outro trabalho recente foi realizado em Jaboticabal-SP por Barbosa Júnior et al. (2021). Os autores usaram VANTs para analisar como o tamanho do pixel (3,5, 6,0 e 8,2 cm) e a altura das plantas (3,5, 0,9, 1,0, 1,2 e 1,7 m) podem afetar o mapeamento de lacunas em imagens

RGB. Como resultado, perceberam que ambos os fatores influenciaram significativamente o mapeamento. Os autores concluíram que quanto maior o pixel ou planta, menos precisa é a previsão. Essa metodologia é capaz de permitir que os produtores otimizem suas decisões, principalmente no que diz respeito ao replantio.

2.3.1.3 Previsão de Maturidade

Em outro estudo, no município de Euclides da Cunha-SP, Souza et al. (2017b) destacam a altura como um importante indicador de produtividade da cana-de-açúcar, pois, segundo os autores, a altura é altamente influenciada pelo solo, teor de açúcar total, teor de nitrogênio foliar, temperatura e intensidade de luz. Nesse sentido, a pesquisa gerou um Modelo de Superfície de Cultura (MSC), através da utilização de um VANT com câmera RGB acoplada. O MSC foi extraído do Modelo Digital de Superfície (MDS) e do Modelo Digital de Terreno (MDT) produzidos anteriormente, permitindo a elaboração de mapas de altura de cana-de-açúcar, posteriormente confirmados em medições de campo, o que demonstra o potencial do método para estimar a altura média de colheita.

No município de Itirapina-SP, Sanches et al. (2018) avaliaram o potencial de imagens geradas por VANT para medir o grau de fechamento do dossel em diferentes plantações de cana-de-açúcar. As avaliações incluíram o IAF (Índice de Área Foliar) e o GRVI, obtidos por sensor de campo e VANT, respectivamente. O objetivo foi avaliar o potencial das ferramentas em questão para prever a produtividade das culturas. Os resultados revelaram que o GRVI se mostrou melhor para refletir toda a condição de produtividade da cultura no campo, quando comparado ao IAF. Por outro lado, quando integrados, os dois índices conseguiram melhorar ainda mais as estimativas de produtividade.

Como conclusão do trabalho acima, notou-se que as imagens obtidas com o VANT podem representar uma ferramenta de baixo custo para obtenção de dados remotos de alta precisão, possibilitando sua utilização para estimar a produtividade agrícola nos canaviais a serem estudados, representando uma ferramenta eficaz para auxiliar nas decisões do produtor.

Em Piracicaba-SP, numa área de 0,77 ha, Canata et al. (2018) utilizaram sensores a laser baseados na tecnologia LiDAR (*Light Detection and Ranging*) juntamente com VANT, com o objetivo de detectar a copa das plantas de cana-de-açúcar. O sistema LiDAR foi instalado em um trator agrícola a 4 metros do solo, enquanto as imagens aéreas foram obtidas por VANT acoplado de uma câmera com resolução espectral na faixa do visível. Ao final da pesquisa, o resultado foi alcançado, com a identificação da copa das plantas de cana-de-açúcar, viabilizada pela utilização de ambas as técnicas.

Outro trabalho com foco na cana-de-açúcar foi realizado por Gromboni et al. (2020), em Ribeirão Preto-SP. O objetivo deste trabalho foi realizar uma análise exploratória dos componentes presentes na copa da cana-de-açúcar em cada um de seus estádios fenológicos. Em busca desse objetivo, foi proposta uma amostragem de dados de campo, utilizando um sensor óptico ativo para obtenção de valores de NDVI. O VANT proporcionou a classificação supervisionada das imagens, possibilitando a mensuração da porcentagem de cada componente em cada uma das fases fenológicas. Como resultado, observou-se que a metodologia proporcionou um desempenho satisfatório, demonstrando a heterogeneidade temporal presente na copa da cana-de-açúcar.

No município de Serra Azul-SP, Magalhães et al. (2013) realizaram um experimento em uma área de 30 hectares de cana-de-açúcar plantada pela primeira vez. O objetivo foi avaliar a predição da biomassa da cana-de-açúcar a partir de dados de IV (Índice de Vegetação), obtidos através de sensor de campo e VANT também em escala de campo, possibilitando a correlação dos resultados. Os atributos do solo foram medidos após a colheita e a biomassa entre 90 e 180 dias após a emergência da cultura.

Com base nesta metodologia, os autores acima conseguiram demonstrar que o IV, obtido por sensores terrestres e não orbitais, está correlacionado apenas com a produção de biomassa, não se relacionando com os atributos químicos do solo. Isso significa, segundo os autores, que a variabilidade espacial do campo depende mais de outros fatores do que dos atributos químicos do solo. Esses resultados podem justificar a utilização de sensores de colheita e VANT pelos produtores, como forma de adquirirem sua independência em relação à obtenção de imagens de alta resolução com baixo custo, sempre avaliando as condições de campo para intervir caso necessário.

2.3.1.4 Melhoria de Sistema de Sensoriamento Remoto

Em outro trabalho em Serra Azul-SP, Simões et al. (2015) tiveram como objetivo avaliar e comparar o desempenho de seis classificadores de imagens em um canavial pertencente à Usina da Pedra. Os métodos de classificação supervisionada utilizados foram: *Minimum distance*, *Mahalanobis distance*, *Maximum likelihood classifier*, *Parallelepiped*, *Spectral angle mapper* e *K-means*; para determinar quatro classes: cana-de-açúcar, palha, solo e outros elementos. A intenção foi criar uma metodologia para uso cotidiano a partir de imagens obtidas por VANT. Como resultado, os autores percebem que os métodos *Minimum distance* e *Mahalanobis distance* apresentaram o menor erro para as quatro classes definidas, com índice kappa de 0,73 e 0,66, respectivamente.

Procurando melhorias para otimizar um sistema de sensoriamento remoto baseado em VANT com sensor hiperespectral, Miyoshi et al. (2018) testaram uma nova câmera hiperespectral baseada em um interferômetro Fabry-Pérot a bordo de um VANT, devido à sua flexibilidade e capacidade de adquirir dados com alta resolução temporal e espacial. A área de estudo está localizada no município de Euclides da Cunha-SP, em área protegida pelo Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio), mais especificamente no fragmento Ponte Branca pertencente à Reserva Federal Mico-Leão-Preto. No total, a área de teste foi de cerca de 11 hectares, sendo principalmente floresta e plantação de cana-de-açúcar.

Para os testes foram adotadas cinco abordagens para produzir mosaicos de imagens hiperespectrais, considerando a variação da irradiância durante a aquisição da imagem e os efeitos da função de distribuição da refletância bidirecional. O objetivo principal foi alcançado comparando as respostas espectrais de alvos radiométricos de referência adquiridos com um espectrorradiômetro em campo, com aqueles produzidos pelas cinco diferentes abordagens. Os melhores resultados foram obtidos corrigindo os efeitos da função de refletância bidirecional e aplicando o método dos mínimos quadrados para um ajuste de bloco radiométrico utilizando apenas os dados da imagem, obtendo assim um RMSE de 11,35%.

2.3.1.5 Monitoramento do Estado Hídrico

Em Ribeirão Preto-SP também há registro recente do uso de VANT no cultivo de cana-de-açúcar, desenvolvido por Silveira et al. (2020) na área experimental do Instituto Agrônomo de Campinas. O objetivo do estudo foi avaliar alternativas de monitoramento do estado hídrico da cana-de-açúcar, através da utilização de câmeras termográficas e multiespectrais embarcadas em VANT. Como resultado, tanto a câmara térmica quanto a multiespectral apresentaram diferenças entre os tratamentos com e sem irrigação. Valendo ressaltar, que as imagens termográficas apresentaram velocidade e eficiência adequadas para expressar alterações no estado hídrico da planta, revelando potencial para demonstrar essas alterações mais precocemente que os dados de NDVI obtidos por imagens multiespectrais.

2.3.2 Estado de Minas Gerais (MG)

2.3.2.1 Falhas de Plantio

Ainda na região sudeste do Brasil, mas agora no estado de Minas Gerais, mais precisamente na Fazenda Santa Fé, localizada no município de Sacramento-MG, Alves et al. (2015a) realizaram trabalho com o objetivo de estimar o percentual de falhas de plantio através de técnicas de DIP (*Digital Image Processing*), utilizando imagens obtidas por VANT, para

posteriormente fazerem uma comparação entre o método proposto e o tradicionalmente utilizado pelo proprietário da fazenda. Para classificação da imagem foi utilizado o método de máxima verossimilhança em duas categorias de uso: cana-de-açúcar e solo. Como conclusão, os autores sugeriram que o uso da metodologia pode ser eficaz quando aplicado para fins de amostragem dentro da área total, sendo necessárias ainda mais pesquisas para sua melhor validação.

Em outro trabalho de Alves et al. (2015b) na mesma área de estudo, os autores desenvolveram pesquisa com o objetivo de avaliar a aplicação de imagens de sensoriamento remoto, provenientes de VANT, para identificar falhas de plantio em canaviais. Como resultado, os autores concluíram que a metodologia utilizada é promissora, mas sugerem que, com o uso de tecnologias mais sofisticadas, essas ferramentas podem se tornar ainda mais eficientes. Como, por exemplo, a utilização de tecnologias que permitam melhores planos de voo, a utilização de pontos de controle e o georreferenciamento automático das imagens.

2.4 Região Centro-Oeste

2.4.1 Estado do Goiás (GO)

2.4.1.1 Previsão de Maturidade

O único trabalho identificado foi realizado no município de Quirinópolis, estado de Goiás, por Rocha et al. (2020). Os pesquisadores testaram um método automático de detecção e medição de linhas de plantio em canaviais, por meio de técnicas DIP, acompanhadas de alguns algoritmos. A proposta consistiu em avaliar um banco de dados de imagens reais classificadas por KNN e preparadas com apoio de VANT. Os testes apontaram um erro relativo de 1,65%, considerado baixo quando comparado ao mapeamento manual nas regiões de plantio, demonstrando que a proposta tem potencial para identificar e medir linhas de plantio com alta precisão, possibilitando inspeções automatizadas.

2.5 Região Sul

2.5.1 Estado do Paraná (PR)

2.5.1.1 Mudanças nas Respostas Espectrais após Fertilização

Em Paranavaí-PR, Rodrigues et al. (2019) realizaram um estudo com o objetivo de verificar se a aplicação de Ca, Mg, S e K provocaria alterações nos valores de NDVI em uma área experimental de cana-de-açúcar. Para isso, realizaram a aplicação 36 dias antes do plantio da cana e durante todo o experimento (57, 150, 254 e 409 dias após o plantio), coletando imagens por sensores multiespectrais para preparação do NDVI até a colheita da cana, 425 dias

após plantio. Como resultado, puderam ver que houve um aumento nos valores médios de NDVI ao longo do experimento. Nesse sentido, o NDVI mostrou-se uma ferramenta eficaz para diferenciar tratamentos em determinadas condições de desenvolvimento da cana-de-açúcar.

2.6 Região Nordeste

2.6.1 Sem Localização Atribuída

2.6.1.1 Falhas de Plantio

Na região Nordeste do Brasil foi possível identificar apenas um trabalho sobre o tema, levantamento realizado por Melo et al. (2017), mas os autores não identificaram em qual município ou mesmo estado as atividades ocorreram. De qualquer forma, a pesquisa consistiu em testar um sistema de VANT para analisar imagens e reconhecer, em tempo real, possíveis deformidades nas plantações da área de estudo.

2.7 Região Norte

2.7.1 Estado do Pará (PA)

2.7.1.1 Detecção de ervas daninhas ou pragas

Em relação à região Norte do Brasil, não foram identificadas pesquisas publicadas sobre o tema, porém, vale ressaltar, a execução desta pesquisa à nível de doutorado e os resultados que serão apresentados nos próximos capítulos desta tese, que devem representar os primeiros estudos publicados sobre a temática na região. As atividades foram desenvolvidas em canaviais do município de Ulianópolis-PA, pertencentes à empresa Pará Pastoril e Agrícola S/A (PAGRISA), com foco, primeiramente, na resolução de problemas relacionados a presença de ervas daninhas.

2.8 Discussão

A partir dos trabalhos identificados na fase de revisão sistemática, foi possível traçar um panorama do uso de VANTs em plantios de cana-de-açúcar no Brasil, permitindo verificar quais foram os principais problemas que motivaram os pesquisadores a testar a ferramenta, além de demonstrar os locais onde a tecnologia é mais utilizada no território nacional (Tabela 1).

Através das pesquisas identificadas na revisão sistemática, podemos perceber a utilização de diferentes modelos de VANTs, tanto multirotores quanto de asa fixa, bem como a utilização de diferentes câmeras, desde aquelas com sensores passivos capazes de gerar imagens apenas no campo visível, até sensores mais sofisticados, com tecnologia multiespectral e hiperespectral, além da utilização de sensores ativos como radar.

Tabela 1 - Compilação de municípios, utilização e autoria dos levantamentos identificados com uso de VANTs no cultivo de cana-de-açúcar no Brasil.

MUNICÍPIO/UF	OBJETIVO DO USO DO VANT	RESULTADOS	AUTORIA
Campinas/SP	propor um sistema de identificação de plantas daninhas capaz de identificar plantas invasoras mesmo com baixos níveis de infestação.	Como resultado inicial, o sistema obteve uma precisão global de 83,1% e um coeficiente kappa de 0,775, utilizando o classificador KNN (<i>K-Nearest Neighbours</i>).	Yano et al. (2017a)
	propor e testar um processo de levantamento de ervas daninhas baseado no reconhecimento de padrões de imagem.	Como conclusão dos testes preliminares, foram testados três classificadores, sendo o melhor deles uma Rede Neural Artificial (RNA), que obteve precisão global de 91,67% e coeficiente kappa de 0,8958.	Yano et al. (2017b)
Euclides da Cunha/SP	avaliar o potencial dos índices de vegetação na detecção do vírus do mosaico da cana-de-açúcar.	Através do estudo, perceberam que os índices que mais contribuíram para a detecção do vírus foram o <i>Normalized Difference Vegetation Index</i> (NDVI), <i>Red Edge Normalized Difference Vegetation Index</i> (NDVI705), <i>New Vegetation Index</i> (NVI) e <i>Anthocyanin Reflectance Index 2</i> (ARI2).	Moriya et al. (2017a)
	desenvolver metodologia através do uso de câmera hiperespectral para discriminar e reconhecer plantas infectadas pelo vírus do mosaico da cana-de-açúcar	Ao final, as imagens hiperespectrais, adquiridas pelo VANT, permitiram a identificação completa das áreas infectadas, demonstrando alto grau de precisão.	Moriya et al. (2017b)
	mapear e extrair informações sobre possíveis falhas presentes nas linhas de plantio.	Como resultados, alcançaram alto nível de automação e adaptabilidade, além de obter informações relevantes para melhorar decisões, monitoramento agrícola e reduzir custos operacionais.	Souza et al. (2017a)

	estimar a altura média de colheita da planta.	A pesquisa gerou um Modelo de Superfície de Cultura (MSC), através da utilização de um VANT com câmera RGB (Vermelho, Verde e Azul) acoplada.	Souza et al. (2017b)
	estudar e otimizar um sistema de sensoriamento remoto usando um sensor hiperespectral	Os melhores resultados foram obtidos corrigindo os efeitos da função de refletância bidirecional e aplicando o método dos mínimos quadrados para um ajuste de bloco radiométrico utilizando apenas os dados da imagem, obtendo assim um RMSE (Root Mean Squared Error) de 11,35%.	Miyoshi et al. (2018)
	apresentar uma metodologia para detectar e quantificar lacunas formadas durante o plantio ou cultivo da planta.	Com isso, conseguiram detectar com eficiência as lacunas presentes no plantio, identificando cerca de 20,9% do solo exposto na área de estudo, decorrentes de falhas de plantio e/ou cultivo.	Montibeller et al. (2017)
Itacemópolis/SP	detectar a erva daninha <i>Cynodon dactylon</i> .	O estudo não só demonstrou a capacidade do VANT de superar a limitação conhecida desta detecção, mas também destacou a importância da textura para a quantificação de alta precisão da invasão do capim de bermuda.	Di Girolamo-Neto et al. (2019)
Itirapina/SP	medir o grau de fechamento da copa em diferentes plantações.	Os resultados revelaram que o GRVI mostrou-se o melhor para refletir toda a condição de produtividade da cultura no campo, quando comparado ao IAF. Por outro lado, quando integrados, os dois índices conseguiram melhorar ainda mais as estimativas de produtividade.	Sanches et al. (2018)
Jaboticabal/SP	analisar como o tamanho do pixel e a altura da planta podem afetar o mapeamento de lacunas em imagens RGB.	Como resultado, perceberam que ambos os fatores influenciaram significativamente o mapeamento. Os autores concluíram que quanto maior o pixel ou planta, menos precisa é a previsão.	Barbosa Júnior et al. (2021)

Piracicaba/SP	detectar o dossel das plantas. identificar lacunas nas linhas de plantio.	Ao final da pesquisa, o resultado foi alcançado com a identificação da copa das plantas de cana-de-açúcar, possibilitada pela utilização de ambas as técnicas. Na conclusão, percebeu-se que tanto o VANT quanto o VIS tiveram seus resultados afetados negativamente entre os dias 47 e 59 após a colheita, permitindo inferir que quanto maior a copa da planta, menor a capacidade de identificação e medição de clareiras.	Canata et al. (2018)
Ribeirão Preto/SP	realizar uma análise exploratória dos componentes presentes na copa da planta em cada uma de suas fases fenológicas. avaliar alternativas de monitoramento do estado hídrico da planta através do uso de câmeras termográficas e multiespectrais.	Como resultado, observou-se que a metodologia proporcionou um desempenho satisfatório, demonstrando uma heterogeneidade temporal presente na copa da cana-de-açúcar. Como resultado, tanto a câmara térmica quanto a multiespectral apresentaram diferenças entre os tratamentos com e sem irrigação.	Gromboni et al. (2020)
Serra Azul/SP	avaliar a previsão da biomassa vegetal a partir de dados de IV. avaliar e comparar o desempenho de classificadores de imagens.	Os autores conseguiram demonstrar que o IV, obtido por sensores terrestres e não orbitais, está correlacionado apenas com a produção de biomassa, não se relacionando com os atributos químicos do solo. Como resultado, os autores percebem que os métodos <i>Minimum distance</i> e <i>Mahalanobis distance</i> apresentaram o menor erro para as quatro classes definidas, com índice kappa de 0,73 e 0,66, respectivamente.	Silveira et al. (2020)
Sacramento/MG	estimar o percentual de falhas de plantio utilizando técnicas de DIP para posterior comparação com o método tradicionalmente utilizado na área.	Na conclusão, os autores sugeriram que o uso da metodologia pode ser eficaz quando aplicada para fins	Magalhães et al. (2013)
			Simões et al. (2015)
			Alves et al. (2015a)

		de amostragem dentro da área total, sendo necessárias ainda mais pesquisas para sua melhor validação.	
	avaliar a aplicação de imagens de sensoriamento remoto para identificar falhas de plantio.	Ao final, os autores concluíram que a metodologia utilizada é promissora, mas sugerem que, com a utilização de tecnologias mais sofisticadas, essas ferramentas podem se tornar ainda mais eficientes, como, por exemplo, a utilização de tecnologias que permitam a realização de melhores planos de voo, utilização de pontos de controle e que permitem o georreferenciamento automático de imagens.	Alves et al. (2015b)
Quirinópolis/GO	testar método automático de detecção e medição de linhas de plantio utilizando técnicas DIP, acompanhado de alguns algoritmos.	Os testes apontaram um erro relativo de 1,65%, considerado baixo quando comparado ao mapeamento manual nas regiões de plantio, demonstrando que a proposta tem potencial para identificar e medir linhas de plantio com alta precisão, possibilitando inspeções automatizadas.	Rocha et al. (2020)
Paranavaí/PR	verificar se a aplicação de Ca, Mg, S e K causaria alterações nos valores de NDVI.	Como resultado, os autores notaram que houve um aumento nos valores médios de NDVI ao longo do experimento. Nesse sentido, o NDVI mostrou-se uma ferramenta eficaz para diferenciar tratamentos em determinadas condições de desenvolvimento da cana-de-açúcar.	Rodrigues et al. (2019)

Fonte: autor.

Uma das questões mais citadas em pesquisas relacionadas ao uso de VANT no cultivo de cana-de-açúcar no país diz respeito à detecção de falhas nas linhas de plantio (Alves et al., 2015a; Alves et al., 2015b; Souza et al., 2017a; Montibeller et al., 2017; Rocha et al., 2020; Maldaner et al., 2021), que muitas vezes é um problema comum na cultura e precisa ser monitorado precocemente para ser corrigido.

Outro uso importante é no combate a pragas que podem atacar as lavouras, como ervas daninhas (Yano et al., 2017a; Yano et al., 2017b; Di Girolamo-Neto et al., 2019) e vírus do mosaico da cana-de-açúcar (Moriya et al., 2017a; Moriya et al., 2017b).

Além disso, foi possível perceber a utilização do VANT em diversos estudos que visam a percepção de outros fatores que influenciam e refletem diretamente na produtividade das lavouras brasileiras.

Por exemplo, época ideal de colheita, previsão de biomassa, grau de fechamento da copa, avaliação dos estágios fenológicos da planta, monitoramento do estado hídrico e resposta espectral da planta após aplicação de fertilizantes químicos (Magalhães et al., 2013; Souza et al., 2017b; Canata et al., 2018; Sanches et al., 2018; Gromboni et al., 2020; Silveira et al., 2020; Rodrigues et al., 2019).

Além do Brasil, outros países como Austrália, China, Estados Unidos, Nicarágua, Sri Lanka e Tailândia, por exemplo, também realizaram pesquisas recentes sobre o uso de VANTs no cultivo de cana-de-açúcar. Os objetivos são muito próximos, conforme explanado na Tabela 2.

Ratificando o exposto na Tabela 2, Som-ard et al. (2021) também identificaram esta tendência relacionada à quantidade de trabalhos realizados nos países, enfatizando que a distribuição regional das publicações em periódicos está intimamente ligada à importância da cultura para os países. Brasil, Austrália, China, Estados Unidos e Tailândia também foram destaque em suas pesquisas, assim como Índia e França. Como esses países são grandes produtores de cana-de-açúcar, é normal o incentivo a publicações sobre a cultura, como forma de desenvolver pesquisas que melhorem ainda mais a produtividade da cultura.

Voltando ao Brasil, os resultados da pesquisa estão concentrados na região Sudeste, principalmente no estado de São Paulo, o que era esperado, já que o estado de São Paulo é de longe o maior produtor de cana-de-açúcar do país, respondendo por mais da metade da produção nacional, em torno de 425.617.093 toneladas (56,53%). Relembrando que o Brasil como um todo produz cerca de 752.895.389 toneladas de cana-de-açúcar por ano, quantidade que o consolida como o maior produtor mundial de cana-de-açúcar, segundo o IBGE (2019).

Tabela 2 - Pesquisas realizadas em outros países além do Brasil.

PAÍS	PESQUISAS REALIZADAS	OBJETIVO DO USO DO VANT
Austrália	Basnayake et al. (2016)	Controle de herdabilidade
	Natarajan et al. (2019)	Controle de herdabilidade
	Sofonia et al. (2019)	Previsão de maturidade
	Akbarian et al. 2020	Previsão de maturidade
	Shendryk et al. (2020)	Previsão de maturidade e controle de doenças
China	Yang et al. (2017)	Previsão de maturidade
	Ma et al. (2018)	Controle de inundação
	Shi et al. (2018)	Monitoramento do estado da água
	Zhang et al. (2019)	Controle de pragas
	Yu et al. (2020)	Previsão de maturidade e monitoramento do estado da água
	Xu et al. (2020)	Previsão de maturidade
	Li et al. (2021a)	Previsão de maturidade
	Li et al. (2021b)	Monitoramento de plantio
Estados Unidos	Cholula et al. (2020)	Monitoramento de plantio
	Costa et al. (2020)	Melhoria de um sistema de sensoriamento remoto
	Todd; Johnson (2021)	Previsão de maturidade
Nicarágua	Luna; Lobo (2016)	Falhas de plantio
Sri Lanka	Madushanka et al. (2019)	Previsão de maturidade
Tailândia	Som-Ard et al. (2018)	Previsão de maturidade
	Chea et al. (2019)	Comparação entre índices de vegetação
	Chea et al. (2020)	Comparação entre índices de vegetação
	Tanut; Riyamongkol (2020)	Falhas de plantio
	Bunruang; Kaewplang (2021)	Previsão de maturidade
	Sumesh et al. (2021)	Previsão de maturidade

Fonte: autor.

Os estados de Goiás (2º maior produtor), Minas Gerais (3º maior produtor) e Paraná (5º maior produtor) também desenvolveram pesquisas nesse sentido, sendo responsáveis por cerca de 75.315.239 toneladas (10%), 72.968.836 toneladas (9,69%) e 41.658.888 toneladas (5,53%), do que se é produzido no país, respectivamente.

Em relação à região Norte, onde não foram identificadas pesquisas publicadas sobre o tema, a falta de trabalhos pode ser justificada pelo zoneamento agroecológico da cana-de-açúcar, adotado até recentemente pelo país (Decreto nº 6.961/2009), que limitava a região Norte na produção da cultura, por estar situada no contexto do bioma Amazônia, uma vez que o cultivo da cana-de-açúcar pode representar um risco potencial ao meio ambiente. Porém, conforme relatado anteriormente, há trabalhos preliminares sendo realizados pelo grupo de pesquisa Agricultura de Precisão em Fitossanidade, da UFRA, no município de Ulianópolis-PA.

Na região Centro-Oeste também houve limitação devido ao decreto citado acima, pois o bioma Pantanal está localizado na região e não poderia ser explorado para a produção da cultura, além do próprio bioma Amazônia, que também possui uma porção no Centro-Oeste do Brasil, limitando a exploração nessas localidades.

Porém, essa tendência deverá mudar nos próximos anos, em decorrência da revogação do Decreto nº 6.961/2009 (BRASILa, 2009), citado anteriormente, pelo Decreto nº 10.084/2019 (BRASILb, 2019), que passou a permitir o plantio nesses biomas mencionados, estendendo esse entendimento para florestas nativas e áreas indígenas em todo o Brasil, por exemplo, o que poderia causar um aumento significativo na produção de cana-de-açúcar nessas regiões e no país como um todo nos próximos anos, possivelmente refletindo em um aumento nas pesquisas sobre o uso de VANTs nas plantações de cana-de-açúcar no país.

2.9 Conclusões

Com base no levantamento bibliográfico sobre o estado atual das pesquisas relacionadas ao uso de VANTs em áreas de plantio de cana-de-açúcar no Brasil, chega-se a algumas conclusões. Uma delas é que os VANTs são utilizados nas lavouras brasileiras principalmente para detectar ervas daninhas ou pragas, falhas nos plantios e previsão de maturidade. Outros usos estão relacionados ao aprimoramento de sistemas de sensoriamento remoto, monitoramento do estado hídrico dos plantios e verificação de mudanças nas respostas espectrais das plantas após a fertilização.

As pesquisas sobre o tema concentram-se principalmente na região Sudeste, com destaque para o estado de São Paulo, confirmando a tendência esperada, já que o estado de São Paulo é o maior produtor nacional. Por outro lado, foi identificado apenas um levantamento nas regiões Centro-Oeste, segundo maior produtor de cana-de-açúcar do país, e nas regiões Sul e Nordeste. Em relação a esse baixo número, infere-se que as pesquisas com VANTs ainda são incipientes ou, caso ocorram com maior frequência, não estão sendo devidamente divulgadas

pelos mais diversos meios de divulgação, como, por exemplo, periódicos ou anais de importantes eventos.

Em relação à região Norte, a falta de publicações sobre o tema ao longo dos anos pode ser justificada pelo Decreto nº 6.961/2009, que limitou seu cultivo na região devido ao bioma Amazônia. Porém, pesquisas preliminares estão sendo realizadas por grupo de pesquisa da Universidade Federal Rural da Amazônia (UFRA). O Decreto nº 6.961/2009 também limitou o cultivo no bioma Pantanal, na região Centro-Oeste, e em áreas de florestas nativas e indígenas em todo o Brasil, por exemplo. Com a sua revogação, o plantio e, conseqüentemente, a pesquisa, nas regiões Centro-Oeste e Norte, bem como em outras áreas do país, devem aumentar.

Como podemos perceber no decorrer deste capítulo, os estudos sobre o tema estão longe de se esgotarem. A tendência observada é que a produção no Brasil aumente nos próximos anos, acompanhando as novas ferramentas da agricultura de precisão. Desta forma, fica como sugestão e recomendação aos futuros pesquisadores da área, que se dediquem ao assunto, principalmente relacionado ao uso de VANTs nas culturas nacionais, pois inovações como esta podem refletir em uma maior competitividade para o país em relação aos mercados concorrentes, representando um importante diferencial positivo.

REFERÊNCIAS

- AHMAD, N.; GHAZILLA, R. A. R.; KHAIRI, N. M. Reviews on various Inertial Measurement Unit (IMU) sensor applications. **International Journal of Signal Processing Systems**, v. 1, n. 2, p. 256-262, 2013. <https://doi.org/10.12720/ijsp.1.2.256-262>.
- AKBARIAN, S.; XU, C.-Y.; LIM, S. Analysis on the effect of spatial and spectral resolution of different remote sensing data in sugarcane crop yield study. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 5, n. 3, p. 655-661, 2020. <https://doi.org/10.5194/isprs-annals-V-3-2020-655-2020>.
- ALVES, M. O.; FERREIRA, R. V.; GALLIS, R. B. A. Optimization of identification of planting failures in sugarcane using geoprocessing. **X Brazilian Congress of Geoinformatics**, 2015a.
- ALVES, M. O.; FERREIRA, R. V.; GALLIS, R. B. A.; OLIVEIRA, J. V. M. The use of “agricultural drone” images to identify sugarcane planting failures. **VII Sugarcane Production Technology Symposium**, 2015b.
- BARBOSA JÚNIOR, M. R.; TEDESCO, D.; CORRÊA, R. G.; MOREIRA, B. R. A.; SILVA, R. P.; ZERBATO, C. Mapping gaps in sugarcane by UAV RGB imagery: the lower and earlier the flight, the more accurate. **Agronomy**, v. 11, 2021. <https://doi.org/10.3390/agronomy11122578>.
- BASNAYAKE, J.; LAKSHMANAN, P.; JACKSON, P.; CHAPMAN, S.; NATARAJAN, S. Canopy temperature: a predictor of sugarcane yield for irrigated and rainfed conditions. **Proceedings of the International Society of Sugar Cane Technologists**, v. 29, p. 1-9, 2016.
- BRASILa. Decreto nº 6961, de 17 de setembro de 2009. Aprova o zoneamento agroecológico da cana-de-açúcar e determina ao Conselho Monetário Nacional o estabelecimento de normas para as operações de financiamento ao setor sucroalcooleiro, nos termos do zoneamento. **Presidência da República Federativa do Brasil**, 2009. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/decreto/d6961.htm. Acesso em: 3 jan. 2023.
- BRASILb. Decreto nº 10.084, de 5 de novembro de 2019. Revoga o Decreto nº 6.961, de setembro de 2009, que aprova o zoneamento agroecológico da cana-de-açúcar e determina ao Conselho Monetário Nacional o estabelecimento de normas para as operações de financiamento ao setor sucroalcooleiro, nos termos do zoneamento. **Presidência da República Federativa do Brasil**, 2019. Disponível em: https://www.planalto.gov.br/ccivil_03/_Ato2019-2022/2019/Decreto/D10084.htm. Acesso em: 3 jan. 2023.
- BUNRUANG, P.; KAEWPLANG, S. Evaluation of sugarcane plant height using UAV remote sensing. **Engineering Access**, v. 7, p. 98-102, 2021. <https://doi.org/10.14456/mijet.2021.15>.
- CANATA, T. F.; MARTELLO, M.; TAVARES, T. R.; FIORI, P. R.; MOLIN, J. P. Monitoring sugarcane crops by aerial imagery and laser sensors. **Brazilian Precision Agriculture Congress**, 2018.
- CHEA, C.; SAENGPRACHATANARUG, K.; POSOM, J.; WONGPHATI, M.; TAIRA, E. Sugar yield parameters and fiber prediction in sugarcane fields using a multispectral camera

mounted on a small Unmanned Aerial System (UAS). **Sugar Tech**, v. 22, p. 605-621, 2020. <https://doi.org/10.1007/s12355-020-00802-5>.

CHEA, C.; SAENGPRACHATANARUG, K.; POSOM, J.; WONGPHATI, M.; TAIRA, E. Sugarcane canopy detection using high spatial resolution UAS images and digital surface model. **Engineering and Applied Science Research**, v. 46, p. 312-317, 2019. <https://doi.org/10.14456/easr.2019.35>.

CHEAVEGATTI-GIANOTTO, A.; GENTILE, A.; OLDEMBURGO, D. A.; MERHEB, G. A., SERENO, M. L.; LIRETTE, R. P.; FERREIRA, T. H. S.; OLIVEIRA, W. S. Lack of detection of Bt sugarcane Cry1Ab and NptII DNA and proteins in sugarcane processing products including raw sugar. **Frontiers in Bioengineering and Biotechnology**, v. 6, p. 1-14, 2018. <https://doi.org/10.3389/fbioe.2018.00024>.

CHOLULA, U.; SILVA, J. A.; MARCONI, T.; THOMASSON, J. A.; SOLORZANO, J.; ENCINO, J. Forecasting yield and lignocellulosic composition of energy cane using unmanned aerial systems. **Agronomy**, v. 10, 2020. <https://doi.org/10.3390/agronomy10050718>.

COSTA, L.; NUNES, L.; AMPATZIDIS, Y. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. **Computers and Electronics in Agriculture**, v. 172, p. 1-13, 2020. <https://doi.org/10.1016/j.compag.2020.105334>.

DECEA. Aeronautical Information Circular (AIC) nº 21/2010. **Departamento de Controle do Espaço Aéreo**, 2010. Disponível em: https://jarus-rpas.org/sites/jarus-rpas.org/files/regulations_por.pdf. Acesso em: 10 nov. 2021.

DI GIROLAMO-NETO, C.; SANCHES, I. D.; NEVES, A. K.; PRUDENTE, V. H. R.; KÖRTING, T. S.; PICOLI, M. C. A.; ARAGÃO, L. E. O. C. Assessment of texture features for bermudagrass (*Cynodon dactylon*) detection in sugarcane plantations. **Drones**, v. 3, 2019. <https://doi.org/10.3390/drones3020036>.

DIAS, H. B.; SENTELHAS, P. C. Sugarcane yield gap analysis in Brazil—A multi-model approach for determining magnitudes and causes. **Science of the Total Environment**, v. 637-638, p. 1127-1136, 2018. <https://doi.org/10.1016/j.scitotenv.2018.05.017>.

EMBRAPA. Estatísticas. **Empresa Brasileira de Pesquisa Agropecuária**. Disponível em: https://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_66_711200516719.html. Acesso em: 10 nov. 2021.

GROMBONI, J. F.; PEREIRA, L. H.; PULIDO, J.; TORO, A. P. S. G. D.; FERREIRA, M. V. Sugarcane canopy structure temporal analysis considering phenological stages and the temporal dynamics of NDVI values. **Proceedings XXI GEOINFO**, 2020.

IBGE. Produção Agrícola Municipal (PAM). **Instituto Brasileiro de Geografia e Estatística**, 2019. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pam/tabelas/>. Acesso em: 1 jun. 2021.

JORGE, L. A. C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão: resultados de um novo olhar**, Brasília: EMBRAPA, 2014. p. 109-134.

LI, X.; BA, Y.; ZHANG, S.; NONG, M.; ZHANG, M.; WANG, C. Sugarcane nitrogen and irrigation level prediction based on UAV-captured multispectral images at the elongation. **BioRxiv**, 2021a. <https://doi.org/10.1101/2020.12.18.423409>.

LI, X.; LI, X.; LIU, W.; WEI, H.; XU, X. A UAV-based framework for crop lodging assessment. **European Journal of Agronomy**, v. 123, p. 1-10, 2021b. <https://doi.org/10.1016/j.eja.2020.126201>.

LUNA, I.; LOBO, A. Mapping crop planting quality in sugarcane from UAV imagery: A pilot study in Nicaragua. **Remote Sensing**, v. 8, 2016. <https://doi.org/10.3390/rs8060500>.

MA, R.; LI, X.; SUN, M.; KUANG, Z. Experiment of Meteorological Disaster Monitoring on Unmanned Aerial Vehicle. **7th International Conference on Agro-geoinformatics (Agro-geoinformatics)**, 2018. <https://doi.org/10.1109/Agro-Geoinformatics.2018.8476134>.

MADGWICK, S. O. H.; HARRISON, A. J. L.; VAIDYANATHAN, R. Estimation of IMU and MARG orientation using a gradient descent algorithm. **International Conference on Rehabilitation Robotics**, 2011. <https://doi.org/10.1109/ICORR.2011.5975346>.

MADUSHANKA, P. L. A.; PERERA, T. A. N. T.; PERERA, M. M. D. S.; WIJEKOON, W. M. C. J.; KAZUHITHO, S.; JAYASINGHE, G. Y. Unmanned Aerial Vehicle (UAV) based images for the assessment of sugarcane vegetation and growth parameters. **Conference on Sri Lanka - Japan Collaborative Research**, 2019.

MAGALHÃES, P. S. G.; SANCHES, G. M.; MOLIN, J. P.; PORTZ, G.; AMARAL, L. R.; KOLLN, O. T.; DUFT, D. G. Potential solution to contribute for sugar cane spatial variability management. **EFITA-WCCA-CIGR Conference “Sustainable Agriculture through ICT Innovation”**, 2013.

MALDANER, L. F.; MOLIN, J. P.; MARTELLO, M.; TAVARES, T. R.; DIAS, F. L. F. Identification and measurement of gaps within sugarcane rows for site-specific management: comparing different sensor-based approaches. **Biosystems Engineering**, v. 209, p. 64-73, 2021. <https://doi.org/10.1016/j.biosystemseng.2021.06.016>.

MELO, J. C.; CONSTANTINO, R. G.; SANTOS, S. G.; NASCIMENTO, T. P.; BRITO, A. V. A system embedded in small unmanned aerial vehicle for vigor analysis of vegetation. **Proceedings XVIII GEOINFO**, 2017.

MIYOSHI, G. T.; IMAI, N. N.; TOMMASSELLI, A. M. G.; HONKAVAARA, E.; NÄSI, R.; MORIYA, E. A. S. Radiometric block adjustment of hyperspectral image blocks in the Brazilian environment. **International Journal of Remote Sensing**, v. 39, p. 4910-4930, 2018. <https://doi.org/10.1080/01431161.2018.1425570>.

MONTIBELLER, B.; SILVEIRA, H. L. F.; SANCHES, I. D.; KÖRTING, T. S.; FONSECA, L. M. G.; ARAGÃO, L. E. O. C.; PICOLI, M. C. A.; DUFT, D. G. Identification of gaps in sugarcane plantations using UAV images. **Proceedings of the XVIII Brazilian Symposium on Remote Sensing**, 2017.

MORIYA, E. A. S.; IMAI, N. N.; TOMMASELLI, A. M. G. Evaluation of the potential of vegetation indices for detection of sugarcane disease in hyperspectral images acquired by UAV. **Proceedings of the XVIII Brazilian Symposium on Remote Sensing**, 2017a.

MORIYA, E. A. S.; IMAI, N. N.; TOMMASELLI, A. M. G.; MIYOSHI, G. T. Mapping mosaic virus in sugarcane based on hyperspectral images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10. p. 740-748, 2017b. <https://doi.org/10.1109/JSTARS.2016.2635482>.

NATARAJAN, S.; BASNAYAKE, J.; WEI, X.; LAKSHMANAN, P. High-throughput phenotyping of indirect traits for early-stage selection in sugarcane breeding. **Remote sensing** 11, 2019. <https://doi.org/10.3390/rs11242952>.

PETRENKO, D.; KRYVENCHUK, Y.; YAKOVYNA, V. Enhancing data discretization for smoother drone input using GAN-based IMU data augmentation. **Drones**, v. 7, n. 7, p. 463. <https://doi.org/10.3390/drones7070463>.

ROCHA, B. M.; VIEIRA, G. S.; FONSECA, A. U.; PEDRINI, H.; SOUSA, N. M.; SOARES, F. Evaluation and detection of gaps in curved sugarcane planting lines in aerial images. **IEEE Canadian Conference on Electrical and Computer Engineering (CCEC)**, 2020. <https://doi.org/10.1109/CCECE47787.2020.9255701>.

RODRIGUES, M.; NANNI, M. R.; SANTOS, G. L. A. A.; REIS, A. S.; FURLANETTO, R. H.; OLIVEIRA, K. M. Effect of the application of Ca, Mg, S, and K sources on sugarcane productivity and on the NDVI prepared by multispectral sensors. **XI International Scientific Production Meeting**, 2019.

SANCHES, G. M.; DUFT, D. G.; KÖLLN, O. T.; LUCIANO, A. C. S.; CASTRO, S. G. Q.; OKUNO, F. M.; FRANCO, H. C. J. The potential for RGB images obtained using unmanned aerial vehicle to assess and predict yield in sugarcane fields. **International Journal of Remote Sensing**, v. 39, p. 5402-5414, 2018. <https://doi.org/10.1080/01431161.2018.1448484>.

SHENDRYK, Y.; SOFONIA, J.; GARRARD, R.; RIST, Y.; SKOCAJ, D.; THORBURN, P. Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging. **International Journal of Applied Earth Observation and Geoinformation**, v. 92, p. 1-14, 2020. <https://doi.org/10.1016/j.jag.2020.102177>.

SHI, L.; HU, S.; ZHA, Y. Estimation of sugarcane yield by assimilating UAV and ground measurements via ensemble Kalman filter. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, 2018. <https://doi.org/10.1109/IGARSS.2018.8518883>.

SILVA, R. R.; ESCARPINATI, M. C.; BACKES, A. R. Sugarcane crop line detection from UAV images using genetic algorithm and Radon transform. **Signal, Image and Video Processing**, v. 15, p. 1723–1730, 2021. <https://doi.org/10.1007/s11760-021-01908-3>.

SILVEIRA, J. M. C.; CÂNDIDO, B. M.; SILVA, A. L. B. O.; PAVÃO, G. C.; XAVIER, M. A.; PIRES, R. C. M. Multispectral and thermographic images for monitoring the water conditions of sugarcane. **Irriga**, v. 25, p. 689-696, 2020. <https://doi.org/10.15809/irriga.2020v25n4p689-696>.

SIMÕES, I.; DUFT, D. G.; MIRANDA, C. G.; SOUZA, C. H. W., SANCHES, G. M.; PICOLI, M. C. A. Evaluation of the performance of classifiers in Unmanned Aerial Vehicle (UAV) images. **Proceedings XVII Brazilian Symposium on Remote Sensing**, v. 7, p. 611-618, 2015.

SOFONIA, J.; SHENDRYK, Y.; PHINN, S.; ROELFSEMA, C.; KENDOUL, F.; SKOCAJ, D. Monitoring sugarcane growth response to varying nitrogen application rates: A comparison of UAV SLAM LiDAR and photogrammetry. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, p. 1-15, 2019. <https://doi.org/10.1016/j.jag.2019.05.011>.

SOM-ARD, J.; ATZBERGER, C.; IZQUIERDO-VELDIGUIER, E.; VUOLO, F.; IMMITZER, M. Remote sensing applications in sugarcane cultivation: a review. **Remote Sensing**, v. 13, p. 1-46, 2021. <https://doi.org/10.3390/rs13204040>.

SOM-ARD, J.; HOSSAIN, M. D.; NINSAWAT, S.; VEERACHITT, V. Pre-harvest sugarcane yield estimation using UAV-based RGB images and ground observation. **Sugar Tech**, v. 20, p. 645-657, 2018. <https://doi.org/10.1007/s12355-018-0601-7>.

SOUZA, C. H. W.; LAMPARELLI, R. A. C.; ROCHA, J. V.; MAGALHÃES, P. S. G. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) imagens. **Computers and Electronics in Agriculture**, v. 143, p. 49-56, 2017a. <https://doi.org/10.1016/j.compag.2017.10.006>.

SOUZA, C. H. W.; LAMPARELLI, R. A. C.; ROCHA, J. V.; MAGALHÃES, P. S. G. Height estimation of sugarcane using an unmanned aerial system (UAS) based on structure from motion (SfM) point clouds. **International Journal of Remote Sensing**, v. 38, p. 2218-2230, 2017b. <https://doi.org/10.1080/01431161.2017.1285082>.

SUMESH, K. C.; NINSAWAT, S.; SOM-ARD, J. Integration of RGB-based vegetation index, crop surface model and object-based image analysis approach for sugarcane yield estimation using unmanned aerial vehicle. **Computers and Electronics in Agriculture**, v. 180, p. 1-19, 2021. <https://doi.org/10.1016/j.compag.2020.105903>.

TANUT, B.; RIYAMONGKOL, P. The development of a defect detection model from the high-resolution images of a sugarcane plantation using an unmanned aerial vehicle. **Information**, v. 11, 2020. <https://doi.org/10.3390/info11030136>.

TODD, J.; JOHNSON, R. Prediction of ratoon sugarcane family yield and selection using remote imagery. **Agronomy**, v. 11, 2021. <https://doi.org/10.3390/agronomy11071273>.

XU, J.-X.; MA, J.; TANG, Y.-N.; WU, W.-X.; SHAO, J.-H.; WU, W.-B.; WEI, S.-Y.; LIU, Y.-F.; WANG, Y.-C.; GUO, H.-Q. Estimation of sugarcane yield using a machine learning approach based on UAV-LiDAR data. **Remote Sensing**, v. 12, p. 1-13, 2020. <https://doi.org/10.3390/rs12172823>.

YANG, Q.; YE, H.; HUANG, K.; ZHA, Y.; SHI, L. Estimation of leaf area index of sugarcane using crop surface model based on UAV image. **Transactions of the Chinese Society of Agricultural Engineering**, v. 33, p. 104-111, 2017. <https://doi.org/10.11975/j.issn.1002-6819.2017.08.014>.

YANO, I. H.; MESA, N. F. O.; SANTIAGO, W. E.; AGUIAR, R. H.; TERUEL, B. Weed identification in sugarcane plantation through images taken from remotely piloted aircraft (RPA) and KNN classifier. **Journal of Food and Nutrition Sciences**, v. 5, p. 211-216, 2017a. <https://doi.org/10.11648/j.jfns.20170506.11>.

YANO, I. H.; SANTIAGO, W. E.; ALVES, J. R.; MOTA, L. T. M.; TERUEL, B. Choosing classifier for weed identification in sugarcane fields through images take by UAV. **Bulgarian Journal of Agricultural Science**, v. 23, p. 491-497, 2017b.

YU, D.; ZHA, Y.; SHI, L.; JIN, X.; HU, S.; YANG, Q.; HUANG, K.; ZENG, W. Improvement of sugarcane yield estimation by assimilating UAV-derived plant height observations. **European Journal of Agronomy**, v. 121, p. 1-16, 2020. <https://doi.org/10.1016/j.eja.2020.126159>.

ZHANG, X.-Q.; LIANG, Y.-J.; QIN, Z.-Q.; LI, D.-W.; WEI, C.-Y.; WEI, J.-J.; LI, Y.-R.; SONG, X.-P. Application of multi-rotor unmanned aerial vehicle application in management of stem borer (*Lepidoptera*) in sugarcane. **Sugar Tech**, v. 21, 2019. <https://doi.org/10.1007/s12355-018-0695-y>.

3. USO DE VANT PARA ANÁLISE ESTATÍSTICA-ESPECTRAL DE ÍNDICES DE VEGETAÇÃO EM PLANTIOS DE CANA-DE-AÇÚCAR NA AMAZÔNIA ORIENTAL³

RESUMO

A utilização de Veículos Aéreos Não Tripulados (VANTs) está cada vez mais presente nas atividades agrícolas no Brasil e no mundo, podendo representar uma importante ferramenta de inovação. A cultura da cana-de-açúcar tem acompanhado esse processo de expansão, como mostram pesquisas realizadas sobre o tema. Nesse sentido, o presente capítulo teve o objetivo de utilizar uma aeronave remotamente pilotada para realizar uma análise estatístico-espectral de índices de vegetação em plantios de cana-de-açúcar na Amazônia Oriental brasileira. Para atingir esse objetivo foi utilizada uma aeronave modelo EbeeSQ, que possui uma câmera multiespectral com sensor Sequoia, que permitiu a obtenção de fotografias aéreas em quatro bandas espectrais distintas: verde, vermelho, borda vermelha e infravermelho próximo. Para as análises espectrais foram consideradas treze zonas de estudo, onde foram calculados quatro índices de vegetação: NDVI (*Normalized Difference Vegetation Index*), SAVI (*Soil-Adjusted Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*) e GNDVI (*Green Normalized Difference Vegetation Index*). Após a geração dos índices, foi possível realizar uma estatística descritiva para cada um deles, bem como para os números digitais da fotografia original, em cada uma das treze zonas previamente definidas. Também foram realizados testes para verificar a normalidade dos dados, bem como testes de correlação e regressão entre os índices de vegetação e os números digitais da fotografia aérea. Através das análises, percebeu-se que o GNDVI foi o índice que melhor se ajustou aos dados, apresentando maior média, amplitude, magnitude de correlação e r-quadrado. Enquanto o NDVI e o SAVI apresentaram os resultados menos satisfatórios. Por fim, a partir do GNDVI, foi possível realizar uma classificação de imagens e cálculo de área das porções de baixo, médio e alto GNDVI.

Palavras-chave: *Saccharum* ssp.; NDVI; SAVI; GNDVI; NDRE; Classificação de imagens.

³ Este capítulo foi base para o artigo: **Use of a UAV for statistical-spectral analysis of vegetation indices in sugarcane plants in the Eastern Amazon**, publicado na revista “*International Journal of Environmental Science and Technology*”. DOI: <https://doi.org/10.1007/s13762-024-05477-z>.

ABSTRACT

The use of Unmanned Aerial Vehicles (UAVs) are increasingly present in agricultural activities in Brazil and in the world, and may represent an important innovation tool. The sugarcane culture has accompanied this expansion process, as shown by research carried out on the subject. In this sense, the present work aimed to use a remotely piloted aircraft to carry out a statistical-spectral analysis of vegetation indices in sugarcane plantations in the Brazilian Eastern Amazon. To achieve this objective, an EbeeSQ model aircraft was used, which has a multispectral camera with a Sequoia sensor, which allowed aerial photographs to be obtained in four distinct spectral bands: green, red, red-edge and near-infrared. For the spectral analyses, thirteen study zones were considered, where four vegetation indices were calculated: NDVI (*Normalized Difference Vegetation Index*), SAVI (*Soil-Adjusted Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*) e GNDVI (*Green Normalized Difference Vegetation Index*). After generating the indices, it was possible to perform descriptive statistics for each one of them, as well as for the pixels of the original photograph. Tests were also carried out to verify the normality of the data, as well as correlation and regression tests between the vegetation indices and the digital numbers of the aerial photograph. Through the analyses, it was noticed that the GNDVI was the index that best adjusted to the data, presenting the highest mean, range, magnitude of correlation and r-square. While NDVI and SAVI presented the least satisfactory results. Finally, from the GNDVI, it was possible to perform an image classification and area calculation of the low, medium and high portions of the GNDVI.

Keywords: *Saccharum* ssp.; NDVI; SAVI; GNDVI; NDRE; Image classification.

3.1 Introdução

A utilização de Veículos Aéreos Não Tripulados (VANTs) em projetos agrícolas já é uma realidade no Brasil e no mundo. Lu et al. (2020), destacam alguns benefícios desta inovação para a agricultura, destacando vantagens relacionadas à obtenção de fotografias aéreas com alta resolução espacial, aquisição instantânea de informações, capacidade de realizar manobras e ausência de interferência de nuvens, isso tudo a um custo relativamente baixo.

As lavouras de cana-de-açúcar brasileiras são exemplos de atividades agrícolas que fazem uso dessa tecnologia, conforme demonstrado por Cardoso et al. (2022). Os autores visualizaram pesquisas em praticamente todas as regiões do Brasil, com única ausência de trabalhos na região Norte, que, por sua vez, possui estados que fazem parte da Amazônia Oriental, região a ser destacada neste trabalho. As atividades identificadas em território nacional, são sobre os mais diversos temas, tais como: detecção de plantas daninhas ou pragas, falhas de plantio, previsão de maturidade, proposição de melhorias no sistema de sensoriamento remoto, monitoramento do estado hídrico das plantas e alterações espectrais após a fertilização.

O avanço dessa ferramenta nas plantações de cana-de-açúcar no Brasil se justifica pela importância que a cultura tem para o país, fazendo-o despontar como o maior produtor mundial de cana-de-açúcar (Nachiluk, 2021). Segundo a Companhia Nacional de Abastecimento (CONAB), o Brasil produziu cerca de 578.768.100 toneladas de cana-de-açúcar na safra 2021/2022, em uma área plantada de 8.345 mil hectares, obtendo uma produtividade de 69.355 kg/hectare. Para a safra 2022/2023 projeta-se uma produção ainda maior, em torno de 598.345.400 toneladas (CONAB, 2022).

Para se ter ideia dessa importância, segundo a Secretaria de Política Econômica (SPE), vinculada ao governo federal, o Valor Bruto da Produção (VBP) da agricultura no Brasil foi estimado em R\$ 1,185 bilhão para o ano de 2022, onde aproximadamente, R\$ 813 bilhões referem-se à agricultura. Desse montante, a cana-de-açúcar representa cerca de R\$ 8,4 bilhões, perdendo apenas para a soja (R\$ 28,5 bilhões) e o milho (R\$ 12,5 bilhões). Para 2023, há projeção de aumento do VBP da agropecuária para R\$ 1,257 bilhão, onde cerca de R\$ 873 bilhões virão da agropecuária, permanecendo a cana-de-açúcar como a terceira maior cultura do VBP do país, com cerca de R\$ 7,9 bilhões, o que é uma pequena queda em relação ao PIB do ano anterior. Por outro lado, a soja deverá subir para R\$ 32,4 bilhões e o milho cair para R\$ 12 bilhões (SPE, 2022).

Nesse contexto da produção canavieira no Brasil, destacaremos nesta pesquisa o estado do Pará, que integra a região da Amazônia Oriental brasileira, constituída, além do próprio estado do Pará, pelos estados do Amapá, Mato Grosso, Tocantins e parte do estado do Maranhão

(IBGE, 2020). Em trabalhos iniciais, Cardoso et al. (2022) não identificaram pesquisas direcionadas ao uso de VANTs na cultura canavieira neste estado, o que corroborou como motivação e justificativa para a presente pesquisa no estado. O Pará ocupa a 17ª posição entre os 26 estados brasileiros e o Distrito Federal, com produção projetada em torno de 1.227 toneladas para a safra 2022/2023, segundo a Companhia Nacional de Abastecimento (CONAB, 2022).

A Confederação da Agricultura e Pecuária do Brasil (CNA), destaca a importância do agronegócio para a economia do Pará, enfatizando que o estado tem capacidade de desenvolver ainda mais as culturas existentes em seu território, assim como pode aumentar a importância de outras, como é o caso da cana-de-açúcar, que tem perspectivas de crescimento nos próximos anos, podendo contribuir para o desenvolvimento do estado, devido à previsão da possível instalação de um centro de excelência em cana-de-açúcar no sudeste do estado, com a presença de órgãos governamentais e instituições de pesquisa, que poderão refletir na geração de empregos e renda para o estado e para a população em geral (CNA, 2022).

Diante do exposto, o objetivo deste trabalho foi utilizar uma plataforma de VANT, com câmera multiespectral de alta resolução em baixa altitude, para realizar análises estatístico-espectrais em plantações de cana-de-açúcar no leste da Amazônia brasileira, mais especificamente em áreas cultivadas no estado do Pará, Brasil. Para isso, foram utilizados *softwares* e equipamentos inerentes à área de geotecnologia, que permitiram obter resultados importantes quanto ao estado vegetativo das plantações na área de estudo.

3.2 Materiais e Métodos

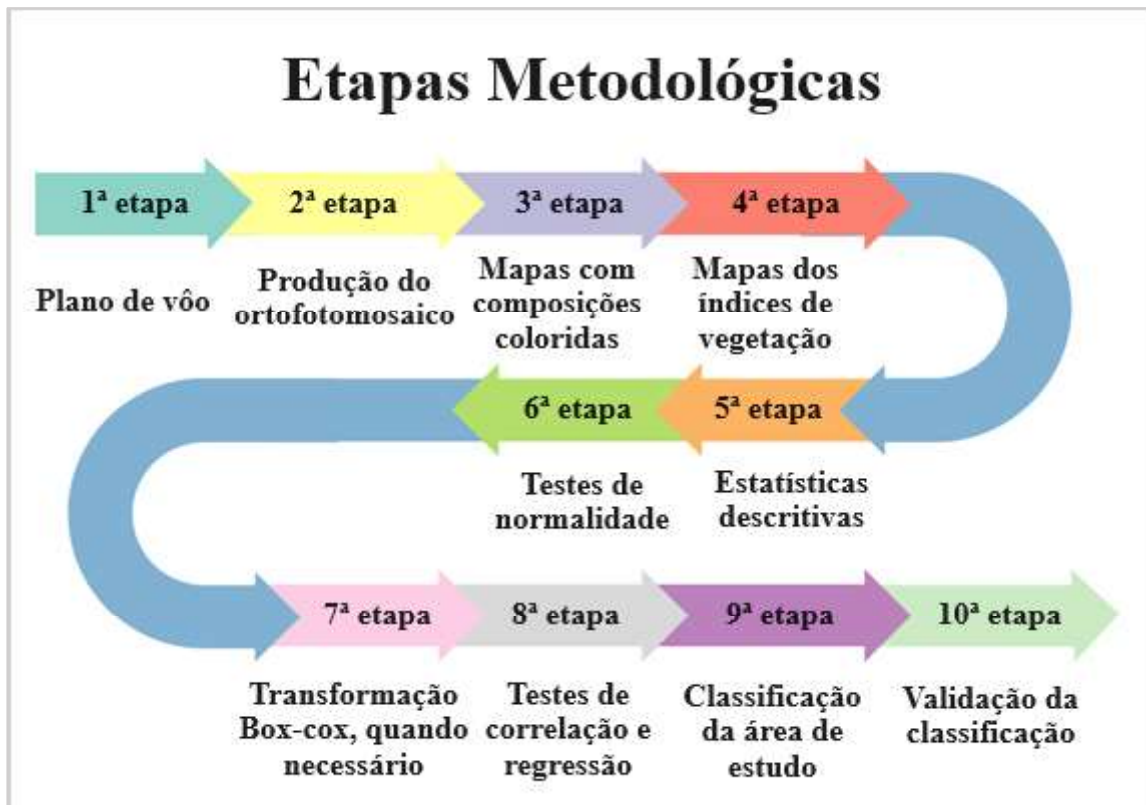
Neste tópico serão apresentadas as etapas metodológicas para obtenção dos resultados (Figura 1), bem como os equipamentos e softwares utilizados. As etapas metodológicas 1 e 2 estão contidas no tópico “3.2.3 Plano de Voo, Parâmetros de Voo e Pré-processamento”; as etapas 3 e 4 no tópico “3.2.4 Processamento de Dados e os Índices de Vegetação (IVs)”; as etapas de 5 a 8 estão no tópico “3.2.5 Estatística dos Dados”; a etapa 9 está no tópico “3.2.6 Classificação da Imagem a partir do Índice de Vegetação”; e, por último, a etapa 10 está descrita no tópico “3.2.7 Validação da Classificação da Imagem”.

3.2.1 Área de Estudo

A área de estudo está localizada no município de Ulianópolis, localizado no estado do Pará, que, por sua vez, faz parte da Amazônia Oriental brasileira. O município pertence à mesorregião Sudeste Paraense e à microrregião de Paragominas, com extensão territorial de

aproximadamente 5.000 km² e população de 62.286 pessoas. A sede do município está sob as coordenadas 03°45'32" de latitude sul e 47°29'26" de longitude oeste do meridiano de Greenwich (Sousa et al., 2017; IBGE, 2021a; IBGE, 2021b; IBGE, 2021c). O clima é classificado como tropical de monção (Am), segundo Köppen (1948), por fazer parte de um clima tropical chuvoso, com breve estação seca e chuvas intensas no restante do ano.

Figura 1 - Passos metodológicos para obtenção dos resultados.



Fonte: autor.

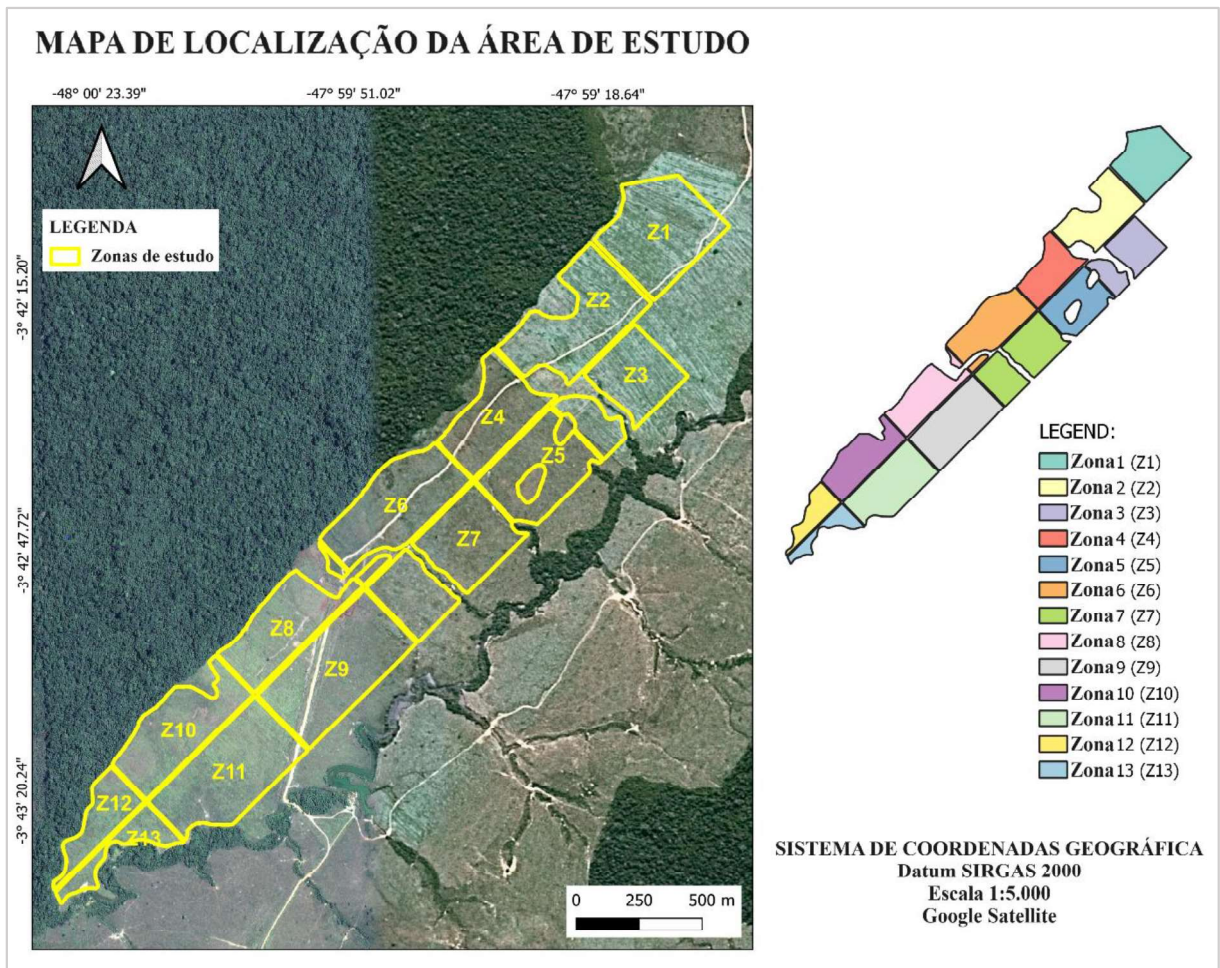
O município é de longe o maior produtor do estado, sendo responsável, segundo o IBGE, por cerca de 1.012.200 toneladas no ano de 2021, o que representa aproximadamente 98,37% de tudo o que foi produzido no Pará no ano, já que o estado produziu cerca de 1.028.940 toneladas em 2021 (IBGE, 2021d), o que também justificou a realização da pesquisa no município em questão. As parcelas estudadas continham a variedade RB08-464 e foram subdivididas em 13 zonas, totalizando cerca de 161ha, conforme Tabela 1 e Figura 2.

Tabela 1 - Zonas de estudo, par de coordenadas geográficas (longitude e latitude), área de cada uma destas zonas, data do plantio da cana-de-açúcar e quantidade de dias após o plantio quando foi realizada o levantamento aéreo.

Zone	Location		Area (ha)	Planting date	Days after planting
	Longitude	Latitude			
Z1	47°59'10,27" W	03°42'06,89" S	14,73	28/08/2020	106 dias
Z2	47°59'20,80" W	03°42'18,24" S	14,83	27/08/2020	107 dias
Z3	47°59'14,97" W	03°42'27,17" S	11,85	31/08/2020	103 dias
Z4	47°59'31,72" W	03°42'30,69" S	10,01	29/08/2020	105 dias
Z5	47°59'25,88" W	03°42'37,54" S	10,46	05/09/2020	98 dias
Z6	47°59'44,32" W	03°42'42,42" S	14,73	29/08/2020	105 dias
Z7	47°59'37,70" W	03°42'49,31" S	16,55	03/09/2020	100 dias
Z8	47°59'58,55" W	03°42'57,53" S	11,41	03/09/2020	100 dias
Z9	47°59'51,80" W	03°43'03,18" S	17,83	03/09/2020	100 dias
Z10	48°00'12,13" W	03°43'11,05" S	12,38	03/09/2020	100 dias
Z11	48°00'05,61" W	03°43'16,37" S	16,58	03/09/2020	100 dias
Z12	48°00'22,17" W	03°43'22,49" S	5,55	03/09/2020	100 dias
Z13	48°00'19,46" W	03°43'26,18" S	4,09	03/09/2020	100 dias

Fonte: autor.

Figura 2 - Área de estudo com delimitação das zonas de pesquisa.



Fonte: autor.


3.2.2 Levantamento de Imagens com VANT por meio Câmera Multiespectral de Alta Resolução

Para o levantamento aéreo da área de estudo foi utilizada uma aeronave de asa fixa modelo Ebee SQ, comercializada pela SenseFly (Figura. 3A e Figura. 3C). Essa aeronave foi especialmente projetada para monitoramento de culturas agrícolas, auxiliando o produtor a ter um melhor rendimento (Wang et al., 2019). Possui tempo máximo de voo de 55 min e a capacidade de, em apenas um voo, a uma altura de 80m e 70% de sobreposição frontal e lateral, por exemplo, realizar o mapeamento de uma área de 80ha, gerando imagens com GSD (*Ground Sample Distance*) de 8 cm, através de sua câmera multiespectral acoplada (Puri et al., 2017).

A câmera multiespectral presente no eBee SQ é a Parrot Sequoia, desenvolvida em parceria entre Parrot e MicaSense. Esta câmera foi projetada especificamente para agricultura de precisão, permitindo a aquisição de imagens de quatro sensores específicos, referentes às bandas verde, vermelho, borda vermelha (*Red-Edge - RE*) e infravermelho próximo (*Near-InfraRed - NIR*), respectivamente (Fig. 3B), o que possibilitou a geração dos índices de

vegetação analisados neste trabalho (Tabela 2). Além disso, a câmera também possui um sensor RGB (*Red, Green and Blue*) de 16 Mpx (Fig. 3B), além de um sensor de luz solar (*Sunshine*) (Fig. 3D). O sensor *Sunshine*, inclusive, é de suma importância para calibrar as imagens, de acordo com o brilho do sol, permitindo a comparação das fotos ao longo do tempo, apesar das variações de luz no momento de cada fotografia (Parrot Sequoia, 2017).

Figura 3 - Aeronave Ebee SQ, câmera Parrot Sequoia e seus sensores.



Fonte: adaptado de Wang et al. (2019).

Tabela 2 - Bandas espectrais, comprimentos de onda, larguras de banda e resoluções dos sensores Parrot Sequoia.

BANDAS	SENSORES ESPECTRAIS	COMPRIMENTO DE ONDA	LARGURA DA BANDA	RESOLUÇÃO
Banda 1 (B1)	Verde	550nm	40nm	1,2 Mpx
Banda 2 (B2)	Vermelho	660nm	40nm	1,2 Mpx
Banda 3 (B3)	Borda do vermelho (<i>RedEdge</i>)	735nm	10nm	1,2 Mpx
Banda 4 (B4)	Infravermelho Próximo (<i>NIR</i>)	790nm	40nm	1,2 Mpx

Fonte: autor, baseado em Parrot Sequoia (2017).

3.2.3 Plano de Voo, Parâmetros de Voo e Pré-processamento

O plano de voo foi todo realizado no *software* eMotion, fornecido pela empresa SenseFly, desenvolvedora da aeronave eBeeSQ. O voo ocorreu no dia 11 de dezembro de 2020, a uma altitude de 150m e 70% de sobreposição frontal/lateral, com início às 9h26 e término às 10h57, totalizando 1h31m de tempo de voo. Após a aquisição das imagens em campo, foi utilizado o *software* Pix4Dfields para gerar o ortofotomosaico a partir das imagens obtidas. O ortofotomosaico final teve resolução espacial de aproximadamente 22cm.

3.2.4 Processamento de Dados e os Índices de Vegetação (IVs)

Após a geração do ortofotomosaico, iniciou-se o processamento das bandas espectrais no *software* QGIS, versão 3.18. Primeiramente, foram gerados quatro mapas de composição de colorida, utilizando a ferramenta “Renderização da banda”, com as seguintes ordens de entrada: B1-B2-B3, B1-B2-B4, B3-B2-B1 e B4-B2-B1. A intenção foi visualizar a interação entre as bandas utilizadas e a respectiva distribuição espacial presente na área, principalmente em relação à borda do vermelha e ao infravermelho próximo.

Posteriormente, foram gerados mapas com os índices de vegetação NDVI (*Normalized Difference Vegetation Index*), SAVI (*Soil-Adjusted Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*) e GNDVI (*Green Normalized Difference Vegetation Index*), utilizando a ferramenta “Calculadora Raster”, também presente no *software* QGIS.

Os valores de cada um dos índices de vegetação considerados são unidimensionais e podem variar entre -1 e 1. Quanto mais próximo de 1, a tendência é para áreas cobertas por proporções substanciais de vegetação saudável; enquanto valores próximos de 0 tendem a áreas de grama ou solo seco (Kharuf-Gutierrez et al., 2018), com exceção do SAVI, que pode apresentar valores além deste intervalo. O valor de L adotado para o SAVI foi 0,5, que é o mais utilizado como ajuste para a maioria das coberturas do solo (Sergieieva, 2022). A lista de fórmulas e os pesquisadores que desenvolveram cada um dos índices de vegetação utilizados estão explanados na Tabela 3.

Tabela 3 - Índices de vegetação utilizados na pesquisa, suas fórmulas matemáticas e os pesquisadores que os desenvolveram.

ÍNDICE DE VEGETAÇÃO	FÓRMULA	APLICAÇÕES	AUTOR
NDVI	$NDVI = \frac{NIR - RED}{NIR + RED}$	Detecção de estresse da planta, sendo um bom indicador de saúde	Rouse Júnior et al. (1974)
SAVI	$SAVI = \frac{(1 + L)(NIR - RED)}{L + NIR + RED}$	Mesma utilização do NDVI, porém desenvolvido para melhorar a sensibilidade do NDVI em relação ao solo	Huete (1988)
GNDVI	$GNDVI = \frac{NIR - GREEN}{NIR + GREEN}$	Determinação do teor de umidade e nitrogênio das folhas da planta, sendo um bom indicador da sua atividade fotossintética	Gitelson et al. (1996)
NDRE	$NDRE = \frac{NIR - REDEEDGE}{NIR + REDEEDGE}$	Detecção do vigor vegetativo entre os estágios de médio à final do ciclo da planta, devido aos altos índices de clorofila nas suas folhas nesses estágios	Barnes et al. (2000)

Fonte: autor, adaptado de Panwar et al. (2020) e Amarasingam et al. (2022).

3.2.5 Estatística dos Dados

Após o cálculo dos índices de vegetação, foi utilizada a ferramenta “Estatísticas Zonais”, também presente no QGIS, para extrair os dados estatísticos. A ferramenta possibilitou extrair informações de Contagem, Média, Mediana, Variância, Desvio Padrão, Máximo, Mínimo e Amplitude. Foram obtidas informações para cada uma das treze zonas em relação a cada um dos quatro índices de vegetação gerados, bem como para os valores de pixel da imagem original.

Com os dados estatísticos em mãos foi possível realizar testes de normalidade no *software* Minitab 14. Para os testes de normalidade foram considerados os valores médios dos índices de vegetação em cada uma das treze zonas estudadas. Os dados com P-Valor acima de 5% (0,05), foram considerados normais, enquanto aqueles com valores abaixo deste parâmetro foram considerados não normais. Por sua vez, os dados que não apresentaram distribuição

normal foram submetidos à transformação Box-Cox, também no *software* Minitab, o que permitiu a normalização de todos os dados inicialmente considerados não normais.

Por fim, ainda no *software* Minitab, foram realizados testes de correlação e regressão entre o número digital da imagem original e os índices de vegetação considerados (NDVI, SAVI, GNDVI e NDRE). Para verificar a magnitude da correlação foram considerados os parâmetros de Cohen (1992) e Rumsey (2016), onde, o primeiro considera uma correlação forte quando o r de Pearson está na faixa de 0,50 — 1,00; moderada entre 0,30 — 0,50; e fraca entre 0,10 — 0,30. Já o segundo autor, considera a correlação fraca quando o r de Pearson apresenta valores entre 0,30 — 0,50; moderada entre 0,50 — 0,70; e forte entre 0,70 — 1,00.

Também foi utilizado o *software* Minitab para os testes de regressão, o que permitiu a geração de gráficos e equações de regressão, bem como a análise do coeficiente de determinação, também chamado de R^2 . Os valores de R^2 variam de 0 (0%) a 1 (100%). Quanto mais próximo de 0 a tendência é que o modelo não explique significativamente a variabilidade dos dados. Por outro lado, quanto mais próximo de 1, a tendência é que o modelo explique significativamente a variabilidade dos dados (Minitab, 2019). Tanto para os testes de correlação quanto para os testes de regressão, foram aceitos apenas resultados com P-Valor inferior a 5%, ou seja, abaixo de 0,05.

3.2.6 Classificação da Imagem a partir do Índice de Vegetação

A partir do conhecimento do índice de vegetação que melhor se ajustou aos dados, iniciou-se um processo de classificação da imagem com base no índice selecionado, que foi o GNDVI. Para isso, subdividimos os valores do índice em três classes de vigor vegetativo: baixo, médio e alto, cada uma com sua respectiva faixa de valores: 0,00 — 0,33 (sem vegetação ou baixa densidade vegetativa); 0,33 — 0,66 (densidade vegetativa moderada); e 0,66 — 1,00 (alta densidade vegetativa), conforme adaptado de USGS (2018), Cherlinka (2019) e Laksono et al. (2020).

A ferramenta utilizada para a definição dos intervalos das classes e a classificação foi “r. recode”, disponível no QGIS. Após a classificação, ainda foi possível calcular o tamanho de cada uma das classes geradas na imagem para o GNDVI, utilizando a ferramenta “r. report”, também no *software* QGIS, onde foi dimensionado o quanto cada classe representava nas treze zonas de pesquisa e, posteriormente, na área de pesquisa como um todo. Um gráfico de pizza foi construído e anexado ao mapa de classificação, como forma de melhorar a visualização dos resultados.

3.2.7 Validação da Classificação da Imagem

Para validar a classificação, optou-se por realizar uma correlação e regressão entre os valores médios do índice de vegetação GNDVI, de cada uma das treze zonas, com os valores médios da classificação, obtidos pela ferramenta “Estatísticas Zonais” no *software* QGIS. Em posse da estatística descritiva da classificação com o GNDVI, iniciou-se a verificação dos valores de correlação (r de Pearson) e regressão (R^2), conforme critérios adotados no tópico “3.2.5 Estatística de Dados”.

Antes dos testes descritos acima, também foram realizados testes iniciais para verificar a normalidade dos dados da imagem classificada, bem como a transformação Box-Cox, quando necessária, conforme também efetuado no tópico mencionado anteriormente. Todos os testes estatísticos que validaram a classificação realizada foram realizados no *software* Minitab 14.

3.3 Resultados e Discussão

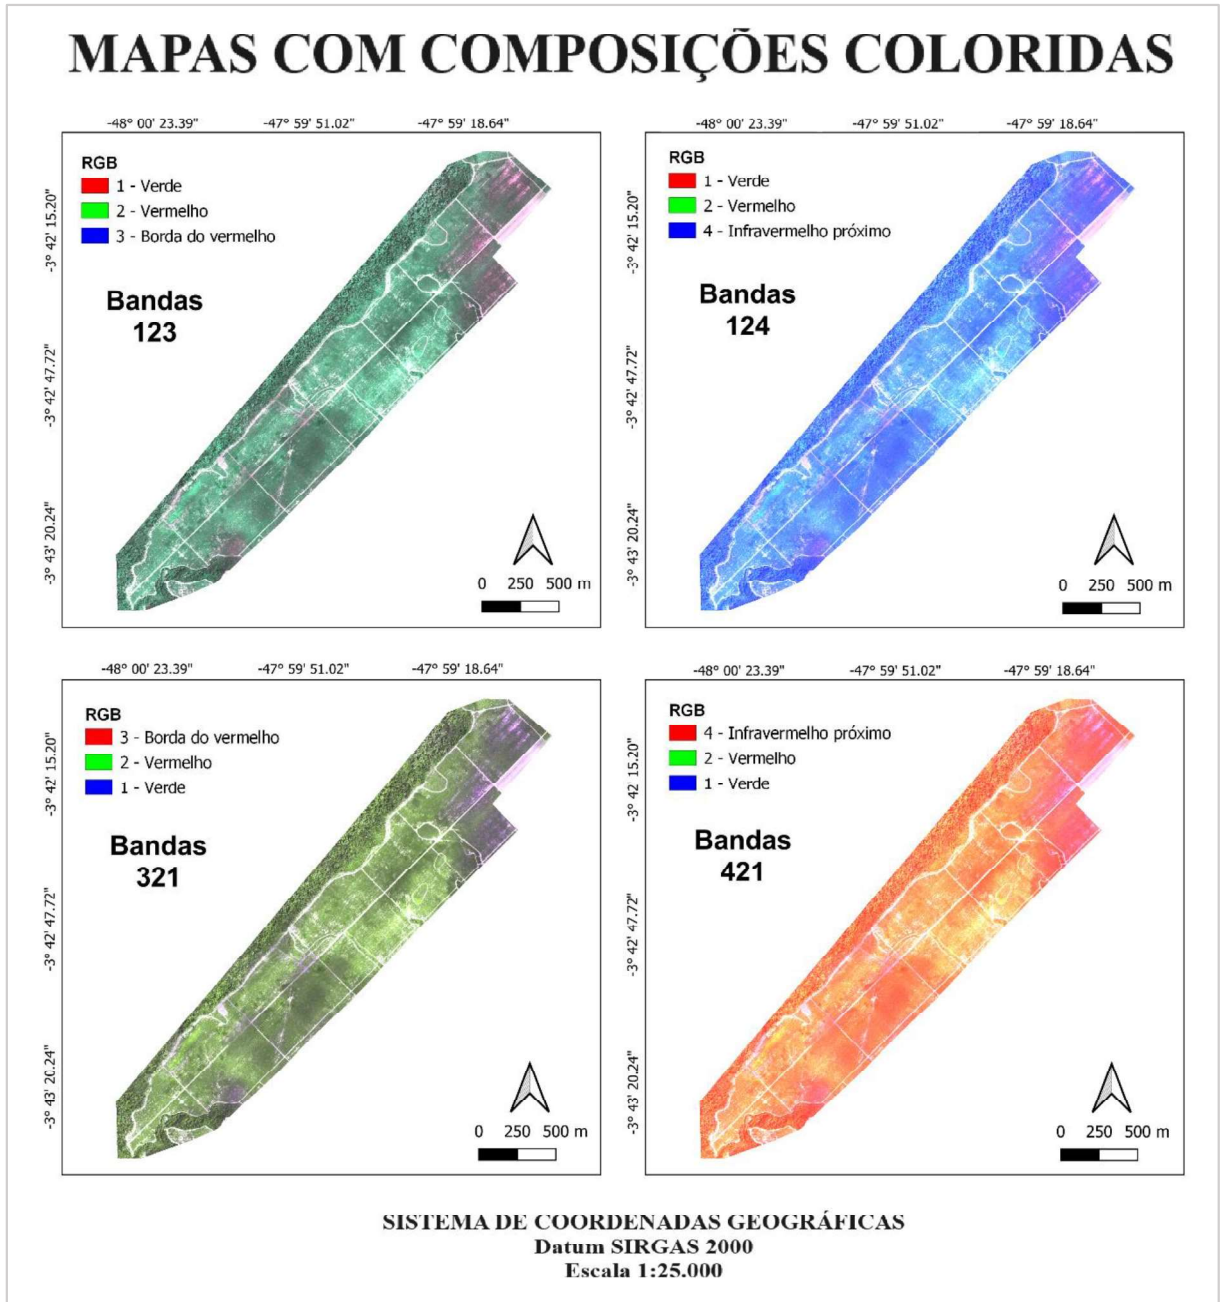
3.3.1 Distribuição Espacial das Composições Coloridas

A princípio, com os dados em mãos, foram feitas algumas composições entre as bandas do verde (B1), vermelha (B2), borda do vermelha (B3) e infravermelho próximo (B4), como forma de melhor compreensão da distribuição espacial, comportamento e relação entre as bandas espectrais adotadas (Figura 4).

3.3.2 Distribuição Espacial dos Índices de Vegetação

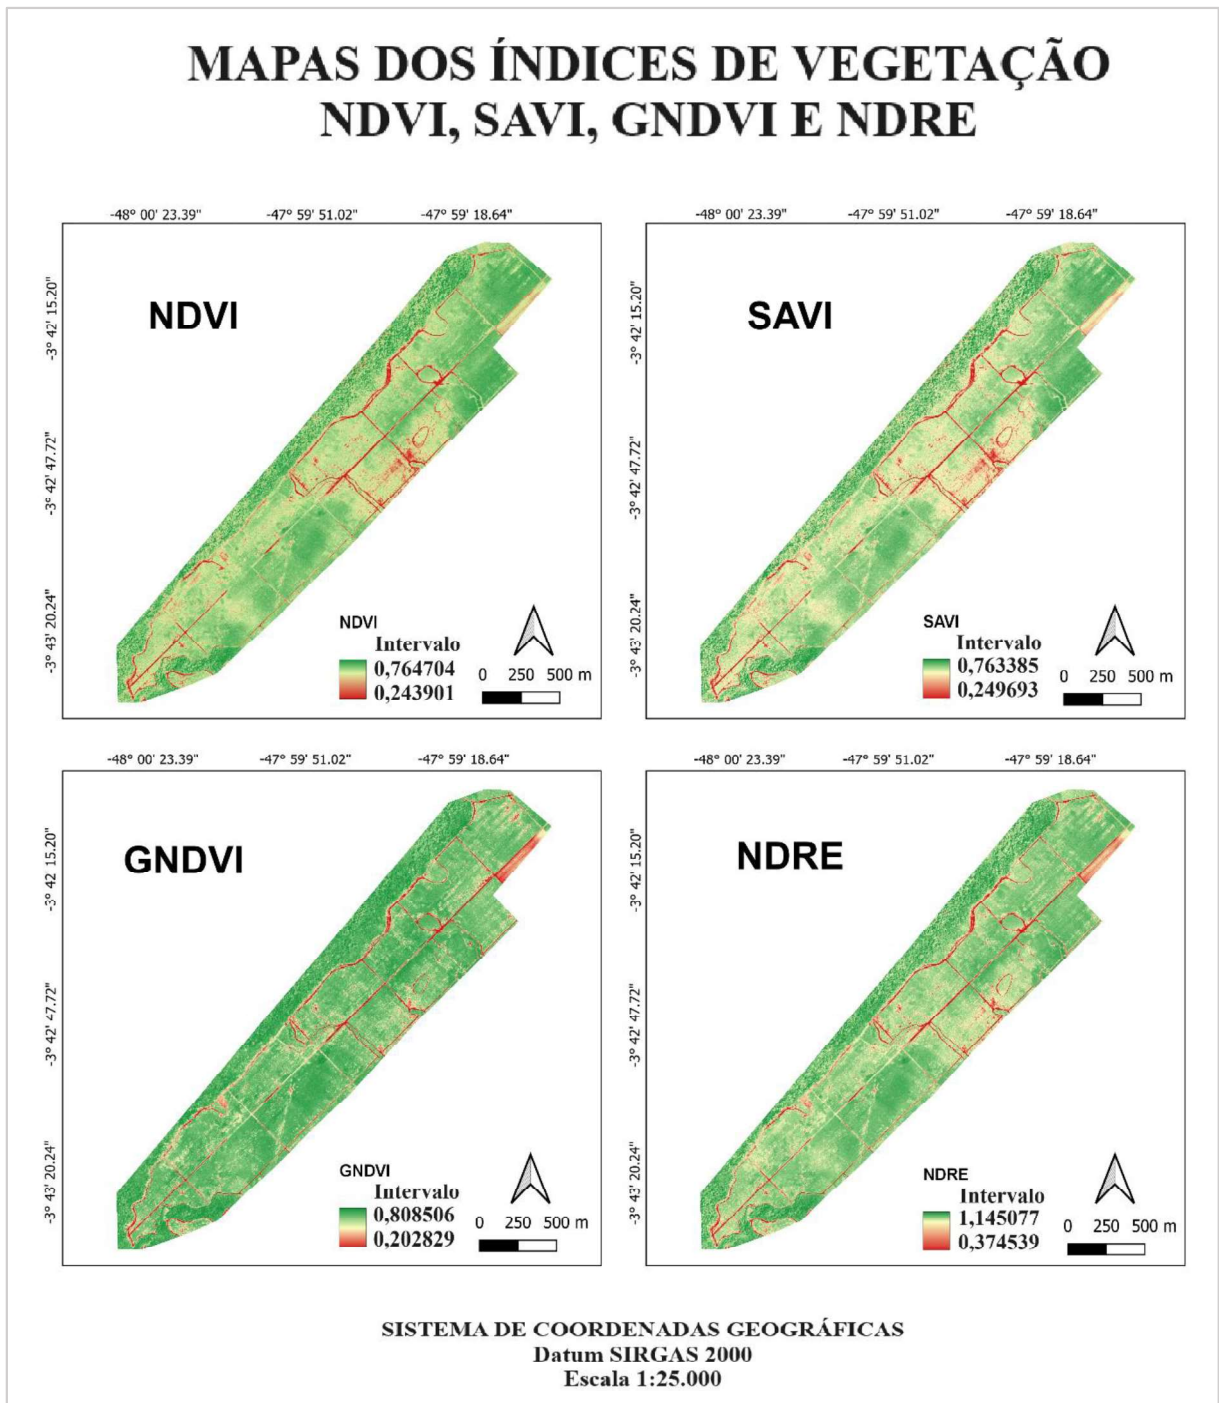
Os mapas dos índices de vegetação apresentaram diferenças entre si, em relação à distribuição e aos valores máximos e mínimos gerais. O NDVI, por exemplo, oscilou, em geral, de 0,2439 a 0,7647, enquanto o SAVI oscilou de 0,3745 a 1,1450. O NDRE obteve um comportamento intermediário entre os quatro índices, oscilando de 0,2318 a 0,7894, obtendo uma faixa de valores superior aos dois índices anteriores. Já o GNDVI variou de 0,2028 a 0,8085 (Figura 5).

Figura 4 - Mapa com as composições coloridas B1-B2-B3, B1-B2-B4, B3-B2-B1 e B4-B2-B1.



Fonte: autor

Figura 5 - Mapa dos índices de vegetação NDVI, SAVI, GNDVI e NDRE.



Fonte: autor

3.3.3 Estatísticas Descritivas

Após gerados os mapas, o nível de detalhamento foi aumentado, através de procedimento de geração de estatísticas descritivas para cada uma das treze zonas de trabalho, em cada um dos índices de vegetação calculados (NDVI, SAVI, GNDVI e NDRE), bem como dos números digitais da imagem utilizada para gerar os respectivos índices de vegetação. Foram considerados valores de contagem, média, mediana, variância, desvio padrão, máximo, mínimo e amplitude (Tabela 4, Tabela 5, Tabela 6, Tabela 7 e Tabela 8).

Tabela 4 - Estatísticas descritivas das treze zonas em relação aos valores dos números digitais da imagem original.

IMAGEM								
Zona	Contagem	Média	Mediana	Variância	Desvio Padrão	Máximo	Mínimo	Amplitude
Z1	2839977	53,8402	48	325,8696	18,0518	224	22	202
Z2	2859157	51,9356	47	364,6227	19,0950	251	21	230
Z3	2283573	49,0283	46	164,7706	12,8363	191	23	168
Z4	1930286	45,0596	41	204,2145	14,2903	232	21	211
Z5	2016705	50,0273	45	376,8279	19,4120	230	20	210
Z6	2838460	53,3306	47	340,8563	18,4622	240	26	214
Z7	3189293	51,8070	47	312,2462	17,6704	231	20	211
Z8	2199108	51,3996	47	262,3155	16,1961	234	22	212
Z9	3437504	41,9012	39	137,2622	11,7158	185	18	167
Z10	2385899	51,2416	46	266,4788	16,3241	223	21	202
Z11	3196214	46,7319	44	150,3888	12,2633	247	21	226
Z12	1070199	52,1642	46	356,4729	18,8804	218	23	195
Z13	787527	52,5623	46	397,3533	19,9337	221	23	198

Fonte: autor.

Tabela 5 - Estatísticas descritivas das treze zonas em relação aos valores do NDVI.

NDVI									
	Contagem	Média	Mediana	Variância	Desvio Padrão	Máximo	Mínimo	Amplitude	CV (%)
Z1	2839977	0,6473	0,6612	0,0029	0,0539	0,8149	0,1159	0,6989	8,3269
Z2	2859157	0,6020	0,6080	0,0034	0,0589	0,7647	0,0408	0,7238	9,7841
Z3	2283573	0,6607	0,6666	0,0021	0,0459	0,7894	0,1888	0,6006	6,9472
Z4	1930286	0,5773	0,5887	0,0041	0,0641	0,7586	0,0386	0,7199	11,1034
Z5	2016705	0,5419	0,5454	0,0084	0,0919	0,7647	0,0602	0,7044	16,9588
Z6	2838460	0,5301	0,5407	0,0042	0,0650	0,7465	0,0240	0,7224	12,2618
Z7	3189293	0,5230	0,5269	0,0064	0,0804	0,7832	0,0000	0,7832	15,3728
Z8	2199108	0,5610	0,5644	0,0039	0,0626	0,7894	0,0580	0,7313	11,1586
Z9	3437504	0,6285	0,6346	0,0024	0,0496	0,8279	0,1778	0,6501	7,8918
Z10	2385899	0,5449	0,5501	0,0040	0,0637	0,7586	0,0625	0,6961	11,6902
Z11	3196214	0,5972	0,6037	0,0032	0,0570	0,7832	0,1512	0,6319	9,5445
Z12	1070199	0,5393	0,5501	0,0045	0,0673	0,7465	0,0782	0,6683	12,4791
Z13	787527	0,5400	0,5501	0,0057	0,0759	0,7647	0,1086	0,6560	14,0556

Fonte: autor.

Tabela 6 - Estatísticas descritivas das treze zonas em relação aos valores do SAVI.

SAVI									
	Contagem	Média	Mediana	Variância	Desvio Padrão	Máximo	Mínimo	Amplitude	CV (%)
Z1	2839977	0,9695	0,9902	0,0065	0,0807	1,2202	0,1737	1,0464	8,3239
Z2	2859157	0,9016	0,9118	0,0077	0,0882	1,1450	0,0611	1,0839	9,7826
Z3	2283573	0,9894	0,9983	0,0047	0,0687	1,1821	0,2828	0,8992	6,9436
Z4	1930286	0,8647	0,8818	0,0092	0,0960	1,1359	0,0579	1,0779	11,1021
Z5	2016705	0,8116	0,8169	0,0189	0,1375	1,1450	0,0903	1,0547	16,9418
Z6	2838460	0,7940	0,8099	0,0094	0,0973	1,1179	0,0361	1,0818	12,2544
Z7	3189292	0,7833	0,7892	0,0145	0,1204	1,1727	0,0148	1,1579	15,3709
Z8	2199108	0,8402	0,8453	0,0087	0,0937	1,1821	0,0870	1,0950	11,1521
Z9	3437504	0,9413	0,9503	0,0055	0,0743	1,2397	0,2664	0,9732	7,8933
Z10	2385899	0,8162	0,8239	0,0090	0,0953	1,1359	0,0936	1,0423	11,6761
Z11	3196214	0,8944	0,9042	0,0072	0,0853	1,1727	0,2266	0,9461	9,5371
Z12	1070199	0,8077	0,8239	0,0101	0,1008	1,1179	0,1172	1,0007	12,4799
Z13	787527	0,8088	0,8239	0,0129	0,1136	1,1450	0,1628	0,9822	14,0455

Fonte: autor.

Tabela 7 - Estatísticas descritivas das treze zonas em relação aos valores do GNDVI.

GNDVI									
	Contagem	Média	Mediana	Variância	Desvio Padrão	Máximo	Mínimo	Amplitude	CV (%)
Z1	2839977	0,6562	0,6831	0,0071	0,0845	0,8411	0,0647	0,7764	12,8772
Z2	2859157	0,6670	0,6887	0,0078	0,0886	0,8478	0,0079	0,8399	13,2834
Z3	2283573	0,6801	0,6943	0,0041	0,0646	0,8345	0,1434	0,6910	9,4986
Z4	1930286	0,7030	0,7229	0,0052	0,0724	0,8478	0,0472	0,8005	10,2987
Z5	2016705	0,6778	0,6999	0,0087	0,0933	0,8545	0,0515	0,8029	13,7651
Z6	2838460	0,6592	0,6887	0,0075	0,0867	0,8149	0,0303	0,7846	13,1523
Z7	3189293	0,6671	0,6887	0,0072	0,0851	0,8545	0,0493	0,8051	12,7567
Z8	2199108	0,6686	0,6887	0,0062	0,0788	0,8411	0,0429	0,7982	11,7858
Z9	3437504	0,7201	0,7346	0,0036	0,0605	0,8681	0,1590	0,7090	8,4016
Z10	2385899	0,6696	0,6943	0,0065	0,0807	0,8478	0,0669	0,7808	12,0520
Z11	3196214	0,6927	0,7056	0,0038	0,0619	0,8478	0,0159	0,8318	8,9360
Z12	1070199	0,6657	0,6943	0,0079	0,0889	0,8345	0,0782	0,7563	13,3544
Z13	787527	0,6641	0,6943	0,0085	0,0924	0,8345	0,0714	0,7631	13,9136

Fonte: autor.

Tabela 8 - Estatísticas descritivas das treze zonas em relação aos valores do NDRE.

NDRE									
	Contagem	Média	Mediana	Variância	Desvio Padrão	Máximo	Mínimo	Amplitude	CV (%)
Z1	2839977	0,6524	0,6666	0,0040	0,0634	0,7894	0,1135	0,6759	9,7180
Z2	2859157	0,6340	0,6504	0,0039	0,0625	0,7894	0,0240	0,7653	9,8580
Z3	2283573	0,6710	0,6776	0,0021	0,0461	0,8021	0,1670	0,6350	6,8703
Z4	1930286	0,6390	0,6558	0,0044	0,0665	0,7832	0,0602	0,7229	10,4069
Z5	2016705	0,6080	0,6190	0,0082	0,0906	0,8021	0,0669	0,7351	14,9013
Z6	2838460	0,5930	0,6139	0,0053	0,0730	0,7770	0,0386	0,7383	12,3103
Z7	3189293	0,5928	0,6037	0,0064	0,0803	0,8149	0,0240	0,7908	13,5459
Z8	2199108	0,6138	0,6242	0,0042	0,0653	0,8021	0,0669	0,7351	10,6386
Z9	3437504	0,6742	0,6831	0,0026	0,0515	0,8345	0,1751	0,6594	7,6387
Z10	2385899	0,6055	0,6190	0,0042	0,0653	0,8021	0,0736	0,7284	10,7845
Z11	3196214	0,6444	0,6558	0,0028	0,0531	0,8021	0,0669	0,7351	8,2402
Z12	1070199	0,6009	0,6190	0,0056	0,0749	0,7770	0,0851	0,6918	12,4646
Z13	787527	0,6006	0,6190	0,0066	0,0814	0,7832	0,1015	0,6817	13,5531

Fonte: autor.

A contagem dos *pixels* foi a mesma para todos os índices e para a imagem original, o que era esperado, variando da zona 13, com menor número de *pixels* (787.527), até a zona 9, com maior número de *pixels* (3.437.504), o que também era esperado, pois a zona 13 possui a menor área entre as treze estudadas, com 4,09 ha, enquanto a zona 9 possui a maior área, com 17,83 ha. Como valor médio, as zonas apresentaram 2.387.223 *pixels*, totalizando 31.033.899 *pixels* analisados em toda a área de estudo.

O valor médio máximo do pixel da imagem original foi 225,1540 e o mínimo médio foi 21,6154, resultando em uma amplitude média de 203,5380. Para o NDVI, o valor médio máximo foi 0,7763 e o valor médio mínimo foi 0,0849, resultando em uma amplitude média de 0,6913. Para o SAVI, os mesmos parâmetros analisados anteriormente foram 1,1624, 0,1284 e 1,0339, respectivamente; para o GNDVI foram 0,8437, 0,0637 e 0,7799, respectivamente; e para o NDRE foram 0,7968, 0,0817 e 0,7149, respectivamente.

O valor médio do pixel da imagem original foi 50,0791. Já para os índices de vegetação, foi de 0,5764 para o NDVI; 0,8632 para SAVI; 0,6762 para GNDVI; e 0,6253 para o NDRE. Em relação ao valor médio das medianas, os valores médios foram 45,3077 para os pixels da imagem original; 0,5838 para NDVI; 0,8745 para SAVI; 0,6983 para o GNDVI; e 0,6390 para o NDRE.

No que diz respeito à variância, a imagem original apresentou valor médio de 281,5140; o NDVI apresentou valor médio de 0,0042; o SAVI apresentou valor médio de 0,0095; o GNDVI apresentou valor médio de 0,0064; e o NDRE apresentou valor médio de 0,0046. Para os parâmetros de desvio padrão, a imagem original apresentou valor médio de 16,5486; o NDVI de 0,0643; o SAVI de 0,0962; o GNDVI de 0,0798; e o NDRE de 0,0672.

Por último, também foi avaliado o coeficiente de variação (CV%). O NDVI apresentou valor médio de 11,3519%; o SAVI de 11,3464%; o GNDVI de 11,8519%; e o NDRE de 10,8408%. Segundo Ferreira (2018), valores de CV inferiores a 10%, representam uma ótima precisão experimental; valores de CV entre 10 e 15%, denotam boa precisão experimental; valores de CV acima de 15% e menores ou iguais a 20%, indicam uma precisão experimental regular ou aceitável; valores de CV maiores que 20% e menores ou iguais a 30%, apresentam péssima precisão experimental; e valores de CV acima de 30%, representam uma precisão experimental muito péssima. Neste sentido, todos os índices de vegetação apresentaram valores médio entre 10 e 15%, o que denota boa precisão experimental no geral.

3.3.4 Testes de Normalidade

Através dos testes de normalidade verificou-se que os valores de NDVI, SAVI e NDRE apresentaram distribuição normal, enquanto os valores da imagem original e GNDVI não apresentaram normalidade. Com essas informações em mãos, iniciou-se o processo de normalização das variáveis consideradas não normais. O processo de normalização foi realizado utilizando a transformação Box-Cox no *software* Minitab 14. Após esse procedimento, os dados da imagem original e do GNDVI passaram a apresentar distribuição normal (Tabela 9).

Tabela 9 - Resultados dos testes de normalidade Kolmogorov-Smirnov (K-S) e Shapiro-Wilk (S-W), antes e após a transformação Box-Cox, quando foi o caso.

VARIÁVEL	P-VALOR	TESTE	H ₀	P-VALOR APÓS BOX-COX	TESTE	H ₀
IMAGEM	0,039 (Não Normal)	K-S	Rejeitado	>0,100 (Normal)	S-W	Aceito
NDVI	0,108 (Normal)	K-S	Aceito	-----	-----	-----
SAVI	0,109 (Normal)	K-S	Aceito	-----	-----	-----
GNDVI	0,030 (Não Normal)	K-S	Rejeitado	0,094 (Normal)	K-S	Aceito
NDRE	>0,150 (Normal)	K-S	Aceito	-----	-----	-----

Fonte: autor.

3.3.5 Testes de Correlação e Regressão

Com os dados normalizados, foram iniciados os testes de correlação e, posteriormente, os testes de regressão, relacionando os índices de vegetação com os valores normalizados dos *pixels* da imagem original (Y), conforme resumido na Tabela 10.

Tabela 10 - Resultados dos testes de correlação e regressão dos índices de vegetação.

ÍNDICE	r DE PEARSON	MAGNITUDE DA CORRELAÇÃO	R ²	P-VALOR	H ₀	EQUAÇÃO DE REGRESSÃO
NDVI	-0,351	Moderada para Cohen (1992) e Fraca para Rumsey (2016)	0,123	0,240	Rejeitado	$Y = 7,52E+08 - 7,35E+08 * NDVI$
SAVI	-0,376	Moderada para Cohen (1992) e Fraca para Rumsey (2016)	0,141	0,206	Rejeitado	$Y = 66,5 - 19,0 * SAVI$
GNDVI	0,996	Forte para Cohen (1992) e Forte para Rumsey (2016)	0,992	0,000	Aceito	$Y = -4,45E+08 + 1,08E+08 * GNDVI$
NDRE	-0,610	Forte para Cohen (1992) e Moderada para Rumsey (2016)	0,372	0,027	Aceito	$Y = 1,62E+09 - 2,06E+09 * NDRE$

Fonte: autor.

O NDVI e o SAVI retornaram valores próximos, apresentando r de Pearson de -0,351 e -0,376, respectivamente, o que demonstra uma correlação negativa moderada para Cohen (1992) e fraca para Rumsey (2016). Os dois índices também apresentaram valores de R² próximos, de 0,123 (12,3%) e 0,141 (14,1%), respectivamente, valores considerados baixos, por estarem distantes de 1 (100%). O P-Valor dos testes de correlação e regressão, também confirmaram para que o índice fosse rejeitado, pois ambos apresentaram valores acima de 0,05 (5%). O NDVI apresentou P-Valor de 0,240 e o SAVI de 0,206, para ambos os testes: correlação e regressão.

O GNDVI foi o índice de vegetação que melhor respondeu aos testes, apresentando valores considerados elevados para a correlação de Pearson, tanto para Cohen (1992) quanto para Rumsey (2016), refletindo em um r de Pearson de 0,996, o que representa uma forte correlação positiva. Em relação ao teste de regressão, obteve-se um R² de 0,992 (99,2%), o que é considerado alto, pois os valores são próximos de 1 (100%). O P-Valor abaixo de 0,05 (5%), também confirmou a qualidade do ajuste dos dados.

O NDRE foi o índice que apresentou dados mais medianos dentre os índices de vegetação estimados. Para a correlação de Pearson, por exemplo, o teste apresentou r de Pearson de -0,610, refletindo uma correlação negativa, que foi considerada forte para os parâmetros de Cohen (1992) e moderada para os de Rumsey (2016). Apesar de apresentar valores de P-Valor aceitáveis, os valores de R² são bem inferiores quando comparados ao GNDVI.

3.3.6 Classificação da Área de Estudo

Como o GNDVI foi o índice de vegetação que apresentou melhores ajustes aos dados obtidos na área de pesquisa, foi o índice utilizado para a realização da classificação da imagem.

Conforme já relatado na metodologia, foram considerados os seguintes parâmetros: Baixo GNDVI: 0,00 – 0,33 (sem vegetação ou baixa densidade de vegetação); Médio GNDVI: 0,33 |— 0,66 (moderada densidade de vegetação); e Alto GNDVI: 0,66 |— 1,00 (alta densidade de vegetação).

A área de Alto GNDVI apresentou a maior área, em torno de 118,60ha, seguida pela área de Médio GNDVI, com aproximadamente 41,46ha, e, por último, a área de Baixo GNDVI, com cerca de 1,07ha (Figura 6). A Tabela 11 apresenta a subdivisão das três classes GNDVI em relação às treze zonas trabalhadas, juntamente com o tamanho aproximado das respectivas áreas.

Figura 6 - Mapa com a classificação GNDVI nas classes de baixo, médio e alto vigor vegetativo.

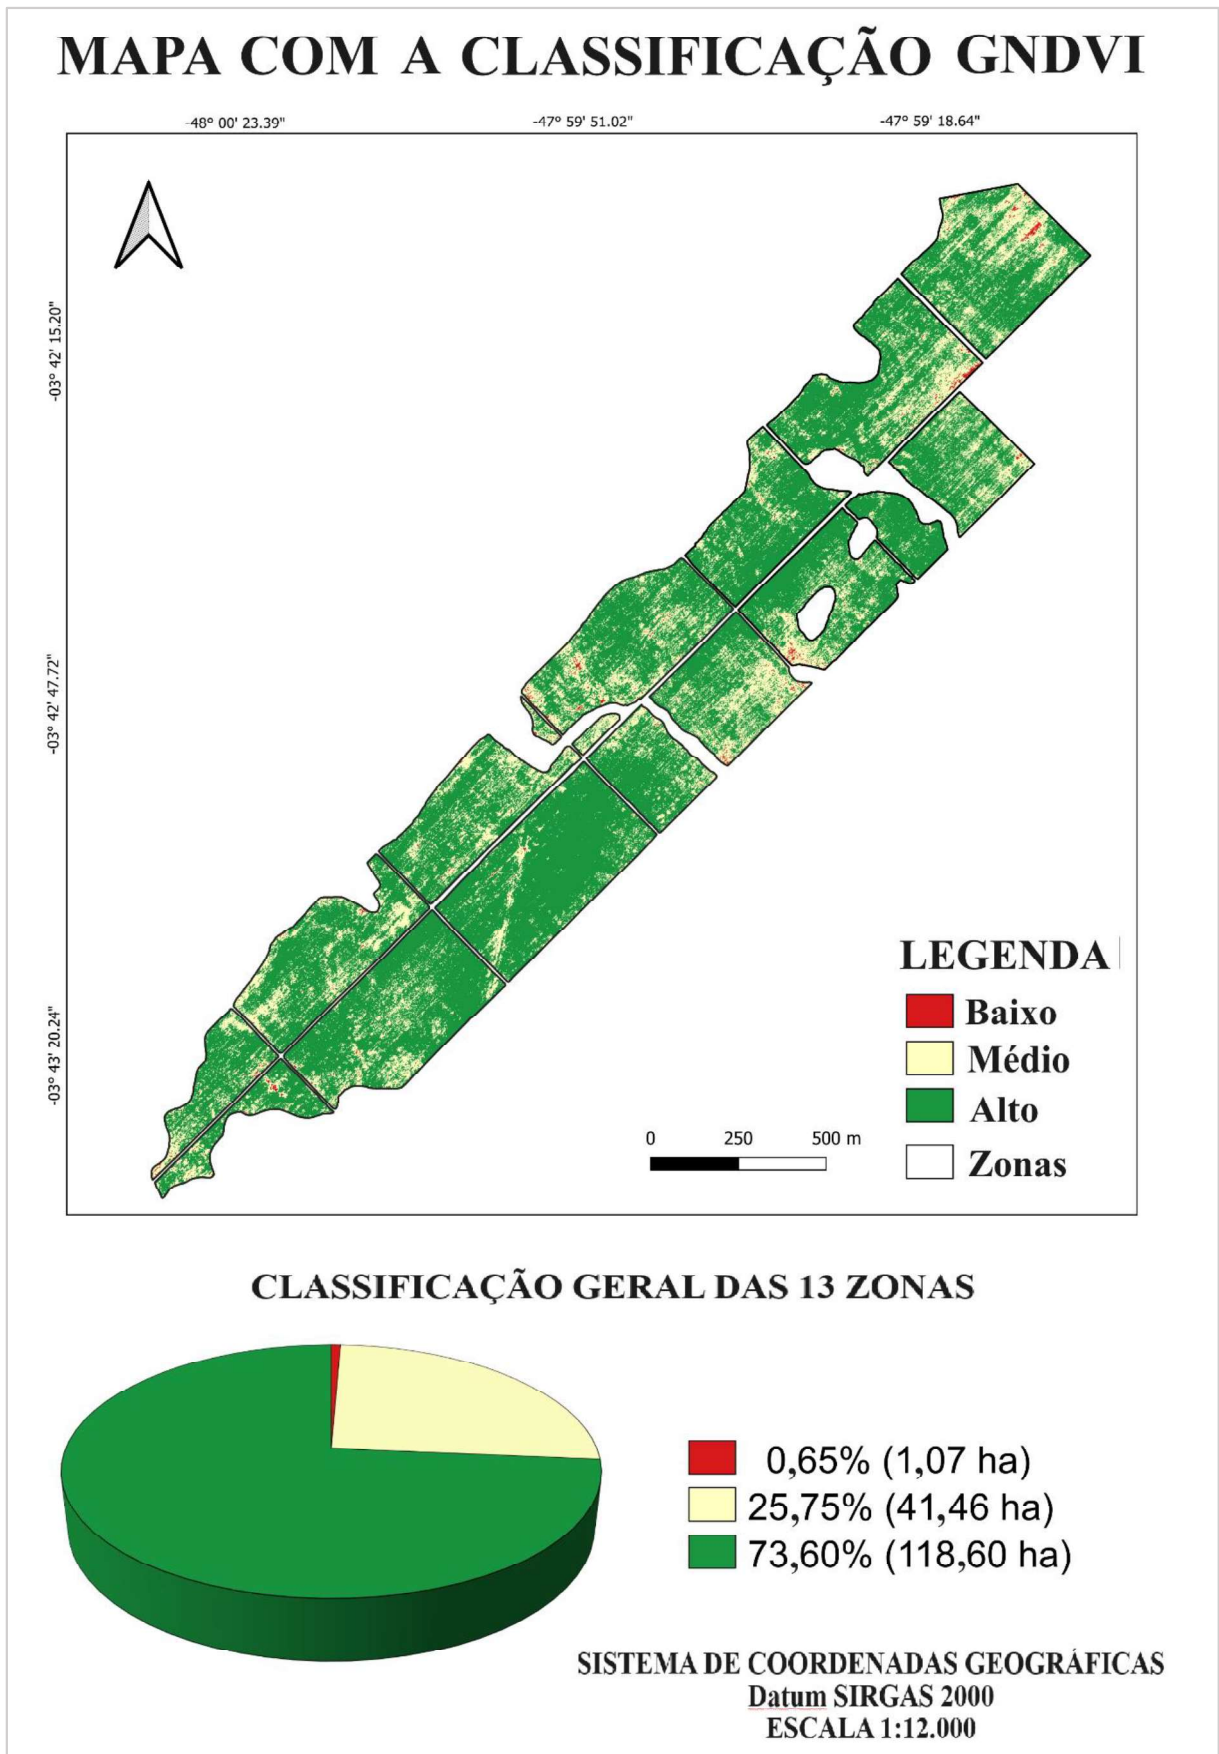


Tabela 11 – Classes de baixo, médio e alto GNDVI com suas respectivas áreas em hectare.

GNDVI				
ZONA	CLASSE 1 Baixo	CLASSE 2 Médio	CLASSE 3 Alto	TOTAL
Z1	0,17 ha (~1,15%)	5,03 ha (~34,10%)	9,55 ha (~64,75%)	14,75 ha
Z2	0,20 ha (~1,35%)	4,22 ha (~28,40%)	10,43 ha (~70,25%)	14,85 ha
Z3	0,02 ha (~0,15%)	2,96 ha (~25,00%)	8,87 ha (~74,85%)	11,85 ha
Z4	0,02 ha (~0,20%)	1,74 ha (~17,40%)	8,25 ha (~82,40%)	10,01 ha
Z5	0,11 ha (~1,05%)	2,86 ha (~27,30%)	7,50 ha (~71,65 %)	10,47 ha
Z6	0,16 ha (~1,10%)	4,75 ha (~32,20%)	9,84 ha (~66,70%)	14,75 ha
Z7	0,13 ha (~0,80%)	5,25 ha (~31,70%)	11,19 ha (~67,50%)	16,57 ha
Z8	0,05 ha (~0,45%)	3,46 ha (~30,30%)	7,90 ha (~69,25%)	11,41 ha
Z9	0,02 ha (~0,10%)	1,74 ha (~9,75%)	16,09 ha (~90,15%)	17,85 ha
Z10	0,04 ha (~0,30%)	3,68 ha (~29,70%)	8,67 ha (~70,00%)	12,39 ha
Z11	0,03 ha (~0,20%)	3,09 ha (~18,60%)	13,48 ha (~81,20%)	16,60 ha
Z12	0,06 ha (~1,10%)	1,58 ha (~28,50%)	3,91 ha (~70,40%)	5,55 ha
Z13	0,06 ha (~1,45%)	1,1 ha (~26,95%)	2,92 ha (~71,50%)	4,08 ha
TOTAL	1,07 ha (~0,65%)	41,46 ha (~25,75%)	118,60 ha (~73,60%)	161,13 ha

Fonte: autor.

3.3.7 Validação da Classificação

Para validação da classificação, primeiro foram calculadas as estatísticas descritivas dos dados da classificação, da mesma forma que foi feito anteriormente para os dados dos índices de vegetação e para a imagem original (Tabela 12). Como contagem de pixels, obteve-se uma média de 2.387.216 pixels, totalizando 31.033.808 pixels em toda a classificação. A média dos valores de classificação foi 2,7228; a mediana de 3; a variância média de 0,2105; o desvio padrão médio de 0,4555; o valor máximo de 3; o valor mínimo de 1; e amplitude de 2.

Os valores médios foram utilizados para realizar testes de correlação e regressão para validar a classificação. Porém, a princípio, não apresentaram distribuição normal, então foi realizada a transformação Box-Cox para normalizar os dados. Após a transformação, os dados foram novamente submetidos ao teste de normalidade Shapiro-Wilk (S-W), desta vez apresentando distribuição normal, com P-Valor de 0,085, acima de 0,05 (5%).

Tabela 12 - Estatísticas descritivas das treze zonas em relação aos valores da classificação GNDVI.

CLASSIFICAÇÃO GNDVI								
	Contagem	Média	Mediana	Variância	Desvio Padrão	Máximo	Mínimo	Amplitude
Z1	2839976	2,6360	3,0000	0,2545	0,5045	3,0000	1,0000	2,0000
Z2	2859156	2,6884	3,0000	0,2417	0,4917	3,0000	1,0000	2,0000
Z3	2283571	2,7455	3,0000	0,1942	0,4406	3,0000	1,0000	2,0000
Z4	1930284	2,8200	3,0000	0,1535	0,3917	3,0000	1,0000	2,0000
Z5	2016704	2,7051	3,0000	0,2292	0,4787	3,0000	1,0000	2,0000
Z6	2838438	2,6559	3,0000	0,2477	0,4977	3,0000	1,0000	2,0000
Z7	3189278	2,6672	3,0000	0,2380	0,4879	3,0000	1,0000	2,0000
Z8	2199107	2,6867	3,0000	0,2251	0,4744	3,0000	1,0000	2,0000
Z9	3437502	2,8994	3,0000	0,0931	0,3052	3,0000	1,0000	2,0000
Z10	2385897	2,6955	3,0000	0,2190	0,4680	3,0000	1,0000	2,0000
Z11	3196197	2,8091	3,0000	0,1591	0,3988	3,0000	1,0000	2,0000
Z12	1070166	2,6909	3,0000	0,2381	0,4880	3,0000	1,0000	2,0000
Z13	787526	2,6971	3,0000	0,2445	0,4945	3,0000	1,0000	2,0000

Fonte: autor.

Em posse dos dados da média da imagem classificada normalizados, foram realizados testes de correlação e regressão em relação à imagem original (Y). Nos testes de correlação foi possível verificar uma correlação positiva elevada, tanto para Cohen (1992) quanto para Rumsey (2016), com r de Pearson de 0,977 (97,7%). Para o teste de regressão foi identificado um R² de 0,955, considerado alto, muito próximo do máximo, que é 1. O P-Valor, tanto para o teste de correlação quanto para o teste de regressão, ficou abaixo de 0,05 (5%), validando assim ambos os testes. A fórmula da regressão foi: $Y = -4,19E+08 + 1,11E+11 * GNDVI_{classificado}$, conforme tabela 13.

Tabela 13 - Resultados dos testes de correlação e regressão entre o GNDVI classificado e a imagem original.

ÍNDICE	r DE PEARSON	MAGNITUDE DA CORRELAÇÃO	R ²	P-VALOR	H ₀	EQUAÇÃO DE REGRESSÃO
GNDVI	0,977	Forte para Cohen (1992) e Fraca para Rumsey (2016)	0,955	0,000	Aceito	$Y = -4,19E+08 + 1,11E+11 * GNDVI_{classificado}$

Fonte: autor.

3.3.8 Discussão

Os índices de vegetação são valores digitais que tendem a medir a biomassa e o vigor das plantas em um *pixel* (Kharuf-Gutierrez et al., 2018), sendo projetados para maximizar a sensibilidade das características da vegetação, otimizando resultados e minimizando fatores externos que possam influenciar negativamente os dados obtidos. Os índices de vegetação mais utilizados para esse fim, utilizam as bandas espectrais do vermelho e do infravermelho próximo, combinadas na forma de razões matemáticas (Fang; Liang, 2014). O NDVI, SAVI e GNDVI, são os índices derivados de sensores multiespectrais mais utilizados (Candiago et al., 2015). Para esta pesquisa, foram utilizados estes três mais comuns, somados ao NDRE; este último, diferentemente dos demais, utiliza a borda do vermelho em seu cálculo.

É importante salientar, inicialmente, que Cardoso et al. (2022) não identificaram pesquisas em cultivos de cana-de-açúcar utilizando plataformas VANT na Amazônia Oriental brasileira, o que também justifica a iniciativa de realização desta pesquisa, para que possa orientar a continuidade de trabalhos futuros com o uso desta inovação tecnológica, já utilizada em canaviais de outras regiões do Brasil.

Dentre os índices de vegetação utilizados nesta pesquisa, o que gerou os melhores resultados foi o GNDVI, apresentando valores satisfatórios em relação aos cálculos da estatística descritiva e aos testes de correlação e regressão, permitindo um excelente ajuste em relação à classificação, ilustrado na Figura 6. De acordo com Akbarian et al. (2022a), o GNDVI é o índice mais utilizado para a cultura da cana-de-açúcar, sendo ainda mais usado que o NDVI e o NDRE. O GNDVI fornece o mesmo tipo de informação que o NDVI como dados de entrada, sendo, este último, o mais conhecido e utilizado na grande área do sensoriamento remoto, servindo também de base para a criação de outros índices de vegetação, como o próprio GNDVI (Kharuf-Gutierrez et al., 2018; Basso et al., 2019).

O GDNVI é útil para medir a atividade fotossintética da cobertura vegetal, sendo frequentemente utilizado para determinar o teor de umidade e nitrogênio das plantas (Amarasingam et al., 2022). Os valores de GNDVI encontrados na área de estudo referem-se a uma média de 0,6762, que representam valores considerados elevados (USGS, 2018; Cherlinka, 2019; Laksono et al., 2020), refletindo, assim, bons parâmetros tanto de umidade quanto de nitrogênio vegetal.

No que diz respeito aos valores de desvio padrão e variância, os quatro índices apresentam valores próximos e baixos para esses parâmetros, demonstrando que os dados apresentam valores homogêneos e próximos à média (Minitab, 2023). Por sua vez, o GNDVI

apresentou os melhores valores para a mediana dentre os quatro índices testados (0,6983) e a segunda melhor amplitude (0,7799), ficando atrás apenas do SAVI (1,0339).

Os valores médios do GNDVI foram considerados elevados, o que já era esperado, pois as plantas encontravam-se entre a fase de vegetativa e de grande crescimento, conforme Cheavegatti-Gianotto et al. (2011) e Marin (2022), referindo-se à plantas em pleno desenvolvimento, entre 3 e 4 meses após o plantio, diferente dos achados de Fahmi (2019), que, em trabalho realizado com cana-de-açúcar na Indonésia, identificou valores próximos de 0, demonstrando que a cultura já havia passado por essa fase de desenvolvimento e provavelmente estaria em sua fase generativa, com idade provável entre 10 e 12 meses, entrando no período de colheita.

White (2020), por sua vez, identificou que o GNDVI se mostrou promissor após cerca de 160 dias após plantio da cana-de-açúcar, sendo útil para se estimar o conteúdo de nitrogênio foliar e possível rendimento do plantio, demonstrando que o índice pode ser útil no decorrer da fase de grande crescimento da cana-de-açúcar, podendo se mostrar eficiente além do intervalo de tempo investigado nesta pesquisa.

Em relação aos valores de baixo GNDVI, em entrevista às pessoas que trabalham no dia-a-dia da área de pesquisa, foi relatada uma problemática enfrentada há anos nos plantios de estudo, que consiste na presença da planta daninha mucuna-preta (*Mucuna pruriens*). A referida planta daninha, provavelmente, ocupa as porções do plantio em que o GNDVI apresentou valores mais baixos, após vencer a disputa por território com a cana-de-açúcar. Essa relação será melhor discutida no Capítulo 4 desta tese.

Como o GNDVI se destacou nesta pesquisa, cabe destacar, neste momento, outros estudos recentes que corroboram os resultados positivos identificados para este índice de vegetação através da utilização de plataformas VANT integradas a sensores multiespectrais. Chea et al. (2018), por exemplo, em investigação realizada na Tailândia, utilizaram um UAV modelo VESPA HEX 650 com seis rotores, equipado com uma câmara Micasense RedEdge, o que permitiu verificar que o referido índice era o que melhor se correlacionava com o valor brix, apresentando melhores ajustes quando comparado ao NDVI, em plantios com 10 meses de idade. Posteriormente, Chea et al. (2020) também encontraram altas correlações entre GNDVI e o valor brix.

McCollam et al. (2018) realizaram um projeto nos EUA, utilizando os quatro índices de vegetação testados nesta pesquisa (NDVI, SAVI, GNDVI e NDRE), bem como o mesmo sensor multiespectral (*Parrot Sequoia* com sensor *Sunshine*), mas utilizaram outra plataforma VANT, o modelo 3DR Solo. Como resultados, perceberam que no início do plantio o SAVI obteve

melhor ajuste, juntamente com o NDRE. Após cerca de 6 meses, o NDRE começou a se ajustar melhor aos dados. O GNDVI foi melhor no início da fase de grande crescimento, provavelmente devido ao fechamento do dossel. No entanto, no pico do crescimento, o NDVI teve um desempenho melhor. A pesquisa demonstrou as variações que podem ocorrer em relação à resposta espectral do índice utilizado e à fase em que se encontra o plantio.

Sanseechan et al. (2019) também destacaram a importância do uso do GNDVI por meio de imagens de VANT em plantações na Tailândia. Foi utilizado o mesmo modelo de VANT utilizado por Chea et al. (2018), com o mesmo sensor (*Micasense RedEdge*), para testar os índices de vegetação para detecção da doença da folha branca da cana-de-açúcar. O GNDVI se destacou em relação aos demais índices, perdendo apenas para o NDRE, que também apresentou bom potencial de detecção da doença, com valores muito próximos entre os dois. NDVI e SAVI também foram testados, com resultados inferiores. Saengprachatanarug et al. (2022) também realizaram pesquisas nesse sentido, corroborando os resultados de Sanseechan et al. (2019), pois, tanto o GNDVI quanto o NDRE, apresentaram maior potencial de detecção da doença.

Na Austrália, Shendryk et al. (2020), utilizaram imagens multiespectrais obtidas por VANT, modelo multirrotor DJI M600 Pro, com sensor *Micasense RedEdge* e Emesent Hovermap LiDAR, para prever biomassa e conteúdo foliar. O GNDVI obteve os melhores resultados para o modelo baseado em componentes principais dos índices de vegetação, derivados de imagens multiespectrais, em relação aos parâmetros: valor médio de todos os *pixels* e para os valores dos percentis 25 e 50, superando o NDVI. Wang et al. (2022), posteriormente, utilizaram os mesmos dados gerados por Shendryk et al. (2020) e confirmaram a existência de correlação positiva entre a variável percentil 50 do GNDVI e a biomassa da cana-de-açúcar.

Akbarian et al. (2022b) também obtiveram bons resultados com GNDVI. Os pesquisadores realizaram levantamentos multitemporais com auxílio de um VANT modelo *Phantom 3 Advanced*, integrado a um sensor multiespectral (*Micasense RedEdge*), em canaviais também na Austrália. Foi possível observar que o NDVI apresentou baixa correlação na fase final do ciclo vegetal, enquanto o GNDVI e o NDRE apresentaram maior resistência à senescência em condições de maior biomassa, quando comparados ao NDVI. A ausência da banda do vermelho, tanto no GNDVI quanto no NDRE, pode ter influenciado nessa diferença entre os índices no pico de crescimento da cultura.

No Sri Lanka, em pesquisa desenvolvida por Narmilan et al. (2022) com auxílio de uma plataforma VANT, modelo *DJI P4*, integrada a um sensor multiespectral de cinco bandas (azul,

verde, vermelho, borda do vermelho e infravermelho próximo), em uma área de plantio de cana-de-açúcar, observaram que o GNDVI gerou valores idênticos ao NDRE, apresentando correlações positivas com o teor de clorofila. O NDVI, por sua vez, apresentou valores próximos aos índices citados anteriormente, porém valores inferiores.

Na Índia, Dwivedi et al. (2022) realizaram uma análise em uma área com plantações de cana-de-açúcar, utilizando um VANT, modelo *DJI Matrix-100* com sensor *Micasense RedEdge* integrado. Os resultados mostraram melhores ajustes para valores médios de *pixel* para o GNDVI e o NDVI. Por outro lado, o SAVI apresentou valores médios mais baixos.

Mais próximo ao Brasil, na Colômbia, García et al. (2017) encontraram bons resultados para o GNDVI. Os pesquisadores usaram uma plataforma VANT modelo *Araknos V2* com uma câmera *ADC lite* acoplada. Ao testar o GNDVI, juntamente com o NDVI e o SAVI, observaram que, dentre eles, o GNDVI foi o único capaz de perceber diferenças significativas entre determinadas aplicações de nitrogênio e as variedades de cana-de-açúcar estudadas.

Em relação ao Brasil, ainda em 2013, Magalhães et al. (2013) realizaram pesquisa no município de Serra Azul, estado de São Paulo, identificando também valores significativos para o GNDVI. Para o levantamento aéreo foi utilizado um VANT modelo *Swinglet CAM*, com câmera *ELPH 300 NDVI*. O GNDVI foi o índice que apresentou melhor resultado após 180 dias do plantio, provavelmente pela proximidade da colheita.

3.4 Conclusões

Abaixo estão listadas as principais conclusões relevantes ao objetivo desta pesquisa:

1. Os únicos conjuntos de dados que não apresentaram distribuição normal foram aqueles relativos aos *pixels* da imagem original, aos do GNDVI e aos da classificação GNDVI, havendo necessidade de normalização. Justamente os que apresentaram melhores indicadores de correlação e regressão entre si.
2. O GNDVI foi o índice que melhor se ajustou aos *pixels* da imagem original, apresentando maiores valores em relação à média dos *pixels* (0,6762), mediana (0,6983), maior correlação (r de Pearson = 0,996) e maior coeficiente de determinação ($R^2 = 0,992$).
3. Os valores tanto da variância quanto do desvio padrão, dos quatro índices testados, são semelhantes, todos apresentando valores baixos, o que demonstra que os dados gerados pelos índices estão próximos da média, com homogeneidade no conjunto de dados. Assim como os valores de CV(%), que variam em média entre 10 e 15%, denotando boa precisão para os quatro índices utilizados.

4. Tanto o NDVI como o SAVI apresentaram as piores associações com os dados da área de investigação.
5. A classificação proposta entre a imagem original e o GNDVI apresentou valores satisfatórios (r de Pearson = 0,977 e $R^2 = 0,955$), se ajustando melhor ao momento entre fase vegetativa e de grande crescimento das zonas de plantio, com idade entre 3 e 4 meses.

REFERÊNCIAS

AKBARIAN, S.; XU, C.; WANG, W.; GINNS, S.; LIM, S. An investigation on the best-fit models for sugarcane biomass estimation by linear mixed-effect modelling on unmanned aerial vehicle-based multispectral images: A case of Australia. **Information Processing in Agriculture**, v. 10, n. 3, p. 361-376, 2022b. <https://doi.org/10.1016/j.inpa.2022.03.005>.

AKBARIAN, S.; XU, C.; WANG, W.; GINNS, S.; LIM, S. Sugarcane yields prediction at the row level using a novel cross-validation approach to multi-year multispectral images. **Computers and Electronics in Agriculture**, v. 198, p. 107024, 2022a. <https://doi.org/10.1016/j.compag.2022.107024>.

AMARASINGAM, N.; SALGADOE, A. S. A.; POWELL, K.; GONZALEZ, L. F.; NATARAJAN, S. A review of UAV platforms, sensors, and applications for monitoring of sugarcane crops. **Remote Sensing Applications: Society and Environment**, v. 26, p. 100712, 2022. <https://doi.org/10.1016/j.rsase.2022.100712>.

BARNES, E. M.; CLARKE, T. R.; RICHARDS, S. E.; COLAIZZI, P. D.; HABERLAND, J.; KOSTRZEWSKI, M.; WALLER, P.; CHOI, C.; RILEY, E.; THOMPSON, T.; LASCANO, R. J.; LI, H.; MORAN, M. S. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. **Proceedings of the 5th International Conference on Precision Agriculture and other resource management**, 2000.

BASSO, M.; STOCCHERO, D.; HENRIQUES, R. V. B.; VIAN, A. L.; BREDEMEIER, C.; KONZEN, A. A.; FREITAS, E. P. Proposal for an embedded system architecture using a GNDVI algorithm to support UAV-based agrochemical spraying. **Sensors**, v. 19, n. 24, p. 5397, 2019. <https://doi.org/10.3390/s19245397>.

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

CARDOSO, L. A. S.; FARIAS, P. R. S.; SOARES, J. A. C. Use of Unmanned Aerial Vehicle in sugarcane cultivation in Brazil: a review. **Sugar Tech**, v. 24, n. 6, p. 1636-1648, 2022. <https://doi.org/10.1007/s12355-022-01149-9>.

CHEA, C.; SAENGPRACHATHANARUG, K.; POSOM, J.; WONGPHATI, M.; TAIRA, E. Sugar yield parameters and fiber prediction in sugarcane fields using a multispectral camera mounted on a small Unmanned Aerial System (UAS). **Sugar Tech**, v. 22, n. 4, p. 605-621, 2020. <https://doi.org/10.1007/s12355-020-00802-5>.

CHEA, C.; SAENGPRACHATHANARUG, K.; WONGPHATI, M.; POSOM, J.; NODTHAISONG, C.; TAIRA, E. Feasibility study of evaluation brix of sugarcane using multispectral camera mounted on Unmanned Aerial Vehicle. **The 11th Thai Society of Agricultural Engineering International Conference**, 2018.

CHEAVEGATTI-GIANOTTO, A.; ABREU, H. M. C.; ARRUDA, P.; BESPALHOK FILHO, J. C.; BURNQUIST, W. L.; CRESTE, S.; CIERO, L.; FERRO, J. A.; FIGUEIRA, A. V. O.;

FILGUEIRAS, T. S.; GROSSI-DE-SÁ, M. F.; GUZZO, E. C.; HOFFMANN, H. P.; LANDELL, M. G. A.; MACEDO, N.; MATSUOKA, S.; REINACH, F. C.; ROMANO, E.; SILVA, W. J.; SILVA FILHO, M. C.; ULIAN, E. C. Sugarcane (*Saccharum X officinarum*): a reference study for the regulation of genetically modified cultivars in Brazil. **Tropical Plant Biology**, v. 4, p. 62-89, 2011. <https://doi.org/10.1007/s12042-011-9068-3>.

CHERLINKA, V. NDVI FAQ: All you need to know about index. **EOS Data Analytics**, 2019. Disponível em: <https://eos.com/blog/ndvi-faq-all-you-need-to-know-about-ndvi/>. Acesso em: 26 abr. 2023.

CNA. Conheça o projeto que fará o Pará despontar na produção de cana-de-açúcar. **Confederação da Agricultura e Pecuária do Brasil**, 2022. Disponível em: <https://cnabrazil.org.br/noticias/conheca-o-projeto-que-fara-o-para-despontar-na-producao-de-cana-de-acucar/>. Acesso em: 16 fev. 2023.

COHEN, J. Statistical power analysis. **Current Directions in Psychological Science**, v. 1, n° 3, 1992. <https://doi.org/10.1111/1467-8721.ep10768783>.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2022/2023, terceiro levantamento, dezembro/2022. **Companhia Nacional de Abastecimento**, v. 9, n. 3, 2022.

DWIVEDI, A. K.; SINGH, A. K.; SINGH, D. An object based image analysis of multispectral satellite and drone images for precision agriculture monitoring. **IEEE International Geoscience and Remote Sensing Symposium**, p. 4899-4092, 2022. <https://doi.org/10.1109/IGARSS46834.2022.9884674>.

FAHMI, L. P. Z. **Utilization of small format aerial photograhpy (SFAP) colored infrared for identification of plant ages and maturity level of sugarcane (*Saccharum officinarum*) in part of Gamping, Godean and Prambanan District**. Especialização em Ciência da Informação Geográfica - Universidade Gadjah Mada, Indonesia, 2019.

FANG, H.; LIANG, S. Leaf Area Index models. **Reference Module in Earth Systems and Environmental Sciences**, 2014. <https://doi.org/10.1016/B978-0-12-409548-9.09076-X>.

FERREIRA, P. V. **Estatística Experimental aplicada às ciências agrárias**. Viçosa: UFV, 2018. 588 p.

GARCÍA, C. E.; MONTERO, D.; CHICA, H. A. Evaluation of a NIR camera for monitoring yield and nitrogen effect in sugarcane. **Agronomía Colombiana**, v. 35, n. 1, p. 82-91, 2017. <https://doi.org/10.15446/agron.colomb.v35n1.60852>.

GITELSON, A. A.; MERZLYAK, M. N.; LICHTENTHALER, H. K. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. **Journal of Plant Physiology**, v. 148, n. 3-4, p. 501-508, 1996. [https://doi.org/10.1016/S0176-1617\(96\)80285-9](https://doi.org/10.1016/S0176-1617(96)80285-9).

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

IBGE. Áreas territoriais. **Instituto Brasileiro de Geografia e Estatística**, 2021a. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15761-areas-dos-municipios.html/>. Acesso em: 14 mar. 2023.

IBGE. Divisão Territorial Brasileira. **Instituto Brasileiro de Geografia e Estatística**, 2021b. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/23701-divisao-territorial-brasil-eira.html?edicao=33002/>. Acesso em: 14 mar. 2023.

IBGE. Estimativas da população. **Instituto Brasileiro de Geografia e Estatística**, 2021c. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html/>. Acesso em: 14 mar. 2023.

IBGE. IBGE atualiza mapa da Amazônia Legal. **Instituto Brasileiro de Geografia e Estatística**, 2020. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/28089-ibge-atualiza-mapa-da-amazonia-legal/>. Acesso em: 16 fev. 2023.

IBGE. PAM - Produção Agrícola Municipal. **Instituto Brasileiro de Geografia e Estatística**, 2021d. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html?=&t=resultados/>. Acesso em: 25 abr. 2023.

KHARUF-GUTIERREZ, S.; HERNÁNDEZ-SANTANA, L.; OROZCO-MORALES, R.; DÍAZ, O. C. A.; MORA, I. D. Análisis de imágenes multiespectrales adquiridas com vehículos aéreos no tripulados. **Revista de Ingeniería Electrónica, Automática y Comunicaciones**, v. 39, n. 2, p. 79-91, 2018.

KÖPPEN, W. **Climatología: con un estudio de los climas de la tierra**. México: Fondo de Cultura Económica, 1948. 478 p.

LAKSONO, A.; SAPUTRI, A. A.; IZUMI, B.; ARKAN, M. Z. 2020. Vegetation covers change and its impact on Barchan Dune morphology in Parangtritis Coast, Indonesia. **E3S Web Conferences**, v. 200, p. 020206. <https://doi.org/10.1051/e3sconf/202020002026>.

LU, H.; FAN, T.; GHIMIRE, P.; DENG, L. Experimental evaluation and consistency comparison of UAV multispectral minisensors. **Remote Sensing**, v. 12, n. 16, p. 2542, 2020. <https://doi.org/10.3390/rs12162542>.

MAGALHÃES, P. S. G.; SANCHES, G. M.; MOLIN, J. P.; PORTZ, G.; AMARAL, L. R.; KOLLN, O. T.; DUFT, D. G. Potential solution to contribute for sugar cane spatial variability management. **EFITA-WCCA-CIRG Conference “Sustainable Agriculture through ICT Innovation**, 2013.

MARIN, F. R. Fenologia. **Empresa Brasileira de Pesquisa Agropecuária**, 2022. Disponível: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/pre-producao/caracteristicas/fenologia/>. Acesso em: 4 mai. 2023.

MCCOLLAM, G.; MCCOLLAM, S.; JOHNSON, R.; FASTIE, C. Correlating nitrogen application rates in sugarcane with low-cost Normalized Difference Vegetation Index (NDVI).

Sustainable Agriculture Research and Education Projects, FS14-282, 2018. Disponível em: <https://projects.sare.org/project-reports/fs14-282/#study-goals/>. Acesso em: 4 mai. 2023.

MINITAB. Análise da regressão: como interpretar o R-quadrado e avaliar a qualidade de ajuste. **Minitab**, 2019. Disponível em: <https://blog.minitab.com/pt/analise-de-regressao-como-interpretar-o-r-quadrado-e-avaliar-a-qualidade-de-ajuste/>. Acesso em: 21 mar. 2023.

MINITAB. Interpretar todas as estatísticas para armazenamento de estatísticas descritivas. **Minitab**, 2023. Disponível em: <https://support.minitab.com/pt-br/minitab/21/help-and-how-to/statistics/basic-statistics/how-to/store-descriptive-statistics/interpret-the-statistics/all-statistics/#stdev/>. Acesso em: 05 mai. 2023.

NACHILUK, K. Alta na produção e exportações de açúcar marcam a safra 2020/2021 de cana. **Análises e Indicadores do Agronegócio**, v. 16, n. 6, p. 1-5, 2021.

NARMILAN, A.; GONZALEZ, F.; SALGADOE, A. S. A.; KUMARASIRI, U. W. L. M.; WEERASINGHE, H. A. S.; KULASEKARA, B. R. Predicting canopy chlorophyll content in sugarcane crops using machine learning algorithms and spectral vegetation indices derived from UAV multispectral imagery. **Remote Sensing**, v. 14, n. 5, p. 1140, 2022. <https://doi.org/10.3390/rs14051140>.

PANWAR, E.; SINGH, D.; SHARMA, A. K. Exploring the possibility of assessing biochemical variables in sugarcane crop with Sentinel-2 data. **IEEE International Geoscience and Remote Sensing Symposium**, p. 3712-3715, 2020. <https://doi.org/10.1109/IGARSS39084.2020.9323317>.

PARROT SEQUOIA. User guide. **Parrot Sequoia**, 2017.

PURI, V.; NAYYAR, A.; RAJA, L. Agriculture drones: a modern breakthrough in precision agriculture. **Journal of Statistics and Management Systems**, v. 20, n. 4, p. 507-518, 2017. <https://doi.org/10.1080/09720510.2017.1395171>.

ROUSE JÚNIOR, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite-1 Symposium**, v. 1, p. 309-317, 1974.

RUMSEY, D. J. **Statistics for Dummies**. Estados Unidos: For Dummies, 2016. 416 p.

SAENGPRACHATHANARUG, K.; CHEA, C.; POSOM, J.; SAIKAEW, K. A review on innovation of remote sensing technology based on Unmanned Aerial Vehicle for sugarcane production in Tropical region. *In*: AHAMED, T. **Remote Sensing Application. New Frontiers in Regional Science: Asian Perspectives**, v. 59. Singapura: Springer, 2022. 361 p. https://doi.org/10.1007/978-981-19-0213-0_12.

SANSECHAN, P.; SAENGPRACHATHANARUG, K.; POSOM, J.; WONGPICHET, S.; CHEA, C.; WONGPHATI, M. Use of vegetation indices in monitoring sugarcane white leaf disease symptoms in sugarcane field using multispectral UAV aerial imagery. **IOP Conference Series: Earth and Environmental Science**, v. 301, p. 012025, 2019. <https://doi.org/10.1088/1755-1315/301/1/012025>.

SERGIEIEVA, K. Vegetation indices to drive digital agri solutions. **EOS Data Analytics**, 2022. Disponível em: <https://eos.com/blog/vegetation-indices/>. Acesso em: 4 mai. 2023.

SHENDRYK, Y.; SOFONIA, J.; GARRARD, R.; RIST, Y., R.; SKOCAJ, D.; THORBURN, P. Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging. **International Journal of Applied Earth Observation and Geoinformation**, v. 92, p. 102177, 2020. <https://doi.org/10.1016/j.jag.2020.102177>.

SOUSA, L. M.; ADAMI, M.; LIMA, A. M. M.; RAMOS, W. F. Avaliação do uso e cobertura da terra em Paragominas e Ulianópolis-PA, utilizando dados do Projeto TerraClass. **Revista Brasileira de Cartografia**, v. 69, n. 3, p. 421-431, 2017. <https://doi.org/10.14393/rbcv69n3-44339>.

SPE. VBP – Valor Bruto de Produção. **Secretaria de Política Econômica**, 2022. Disponível em: https://www.gov.br/fazenda/pt-br/centrais-de-conteudos/publicacoes/conjuntura-economica/agricola/2022/2022-12-15-vbp-novembro_2022.pdf. Acesso em: 16 fev. 2023.

USGS. NDVI, the Foundation for Remote Sensing Phenology. **United States Geological Survey**, 2018. Disponível em: <https://www.usgs.gov/special-topics/remote-sensing-phenology/science/ndvi-foundation-remote-sensing-phenology/>. Acesso em: 18 mar. 2023.

WANG, Y.; ZHANG, K.; TANG, C.; CAO, Q.; TIAN, Y.; ZHU, Y.; CAO, W.; LIU, X. Estimation of rice growth parameters based on linear mixed-effect model using multispectral images from fixed-wing Unmanned Aerial Vehicles. **Remote Sensing**, v. 11, n. 11, p. 1371, 2019. <https://doi.org/10.3390/rs11111371>.

WANG, Z.; LU, Y.; ZHAO, G.; SUN, C.; ZHANG, F.; HE, S. Sugarcane biomass prediction with multi-mode remote sensing data using deep archetypal analysis and integrated learning. **Remote Sensing**, v. 14, n. 19, p. 4944, 2022. <https://doi.org/10.3390/rs14194944>.

WHITE, M. Research program targeting improved: nue in sugar industry. **Cane Connection**, 2020. Disponível em: https://elibrary.sugarresearch.com.au/bitstream/handle/11079/18087/CaneConnection%20Winter%202020_F_pg26-27.pdf?sequence=1/. Acesso em: 4 mai. 2023.

4. AVALIAÇÃO DE INTERPOLADORES ESPACIAIS PARA DEFINIÇÃO DE ZONAS DE MANEJO FITOSSANITÁRIO EM ÁREAS DE PLANTIO DE CANA-DE-AÇÚCAR NA AMAZÔNIA ORIENTAL

RESUMO

Os Veículos Aéreos Não Tripulados (VANTs) têm se mostrado uma importante ferramenta de inovação dentro da agricultura de precisão, fazendo uso de conceitos de aerofotogrametria para auxiliar os produtores nos mais diversos processos de tomada de decisão. O cultivo da cana-de-açúcar no Brasil representa um dos setores agrícolas onde esta tecnologia está sendo implementada. Nesse sentido, esta pesquisa tem como objetivo avaliar diferentes interpoladores espaciais para definição de zonas de manejo fitossanitário em áreas com plantações de cana-de-açúcar, a fim de orientar o manejo de potenciais infestações da erva daninha mucuna preta. Para tanto, foram coletadas imagens com um VANT modelo EbeeSQ, que permitiu o imageamento da área de estudo com sensor multiespectral. Com as imagens processadas foram realizados cálculos dos índices de vegetação NDVI (*Normalized Difference Vegetation Index*), SAVI (*Soil-Adjusted Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*) e GNDVI (*Green Normalized Difference Vegetation Index*). Após análise de estatística descritiva, correlação e regressão, para cada índice, percebeu-se que o GNDVI apresentou os melhores resultados. De posse dessas informações, iniciou-se o procedimento de extração dos valores do GNDVI, utilizando malhas amostrais regulares e aleatórias, o que permitiu a análise das áreas utilizando os interpoladores espaciais *Krigagem Ordinária* e *Máquina de Vetores de Suporte* (*Support Vector Machine - SVM*). A estatística descritiva demonstrou que os dados apresentaram homogeneidade, qualidade e confirmaram a precisão da metodologia de amostragem. Os interpoladores mostraram-se eficientes na demonstração da variabilidade espacial dos valores do GNDVI, confirmada pelo procedimento de validação cruzada. A relação entre *Índice de Performance Fuzzy* (*Fuzzy Performance Index - FPI*) e *Entropia de Classificação Normalizada* (*Normalized Classification Entropy - NCE*) permitiu a integração dos mapas gerados e a identificação de diferentes classes nas áreas de estudo, confirmando a eficácia da metodologia proposta nesta pesquisa.

Palavras-chave: Geoestatística; Aprendizado de máquina; Krigagem ordinária; Máquina de vetores de suporte; Mucuna preta.

ABSTRACT

Unmanned Aerial Vehicles (UAVs) have proven to be an important innovation tool within precision agriculture, making use of aerial photogrammetry concepts to assist producers in the most diverse decision-making processes. The cultivation of sugar cane in Brazil represents one of the agricultural sectors where this technology is being implemented. In this sense, this research aims to evaluate different spatial interpolators for defining phytosanitary management zones in areas with sugarcane plantations, in order to guide the management of potential infestations of the velvet bean weed. To this end, images were collected with a UAV model EbeeSQ, which allowed imaging of the study area with a multispectral sensor. With the processed images, calculations of the vegetation indices NDVI (Normalized Difference Vegetation Index), SAVI (Soil-Adjusted Vegetation Index), NDRE (Normalized Difference Red Edge Index) and GNDVI (Green Normalized Difference Vegetation Index) were carried out. After analyzing descriptive statistics, correlation and regression, for each index, it was noticed that the GNDVI presented the best results. With this information in hand, the procedure for extracting the GNDVI values began, using regular and random sampling meshes, which allowed the analysis of the areas using the Ordinary Kriging and Support Vector Machine (SVM) spatial interpolators. Descriptive statistics demonstrated that the data presented homogeneity, quality and confirmed the precision of the sampling methodology. The interpolators proved to be efficient in demonstrating the spatial variability of GNDVI values, confirmed by the cross-validation procedure. The relationship between FPI (Fuzzy Performance Index) and NCE (Normalized Classification Entropy) allowed the integration of the generated maps and the identification of different classes in the study areas, confirming the effectiveness of the methodology proposed in this research.

Keywords: Geostatistics; Machine learning; Ordinary Kriging; Support Vector Machine; Velvet bean.

4.1 Introdução

A cana-de-açúcar é uma das principais culturas agrícolas do Brasil, responsável por uma produção estimada de 610.804,8 mil hectares na safra 2022/2023 e com projeção de 652.947,2 toneladas para a safra 2023/2024, segundo a Companhia Nacional de Abastecimento (Conab, 2023). Porém, apesar desses excelentes números, existem alguns problemas que dificultam o alcance de uma produtividade ainda maior. Uma delas é a presença da mucuna-preta nas culturas nacionais.

A mucuna-preta (*Mucuna pruriens* var. *utilis* (Wall. ex Wight) Baker ex Burck) é uma leguminosa herbácea anual, da família *Fabaceae* e do gênero *Mucuna* Adans., que, nos últimos anos, tem assumido posição de destaque como importante planta daninha em diversas regiões do país (Wiriadinata et al. 2016; Dias et al., 2021). Possui como característica ramos trepadores e vigorosos, que se adaptam bem aos climas tropicais e subtropicais (Wutke, 1993). A presença dessa planta daninha pode afetar as plantações de cana-de-açúcar, principalmente no início do seu ciclo de desenvolvimento, competindo com a cana-de-açúcar por recursos vitais, como água e nutrientes do solo (Ferreira et al, 2020).

Nesse sentido, faz-se necessário o desenvolvimento e o uso de ferramentas de agricultura de precisão no controle dessa erva daninha, para enfrentamento da problemática e otimização do processo produtivo nas lavouras, reduzindo custos com o manejo necessário e, conseqüentemente, aumentando a produtividade. Dentre as diversas ferramentas da agricultura de precisão, esta pesquisa irá enfatizar dois mecanismos de interpolação espacial, para estabelecer uma comparação entre eles. Os interpoladores utilizados foram a *Krigagem Ordinária* (KO), proveniente da Geoestatística, e a *Máquina de Vetores de Suporte* (*Support Vector Machine* - SVM), oriunda de técnicas de *Aprendizado de Máquina* (*Machine Learning* - ML).

A geoestatística baseia-se no conceito de variáveis regionalizadas, buscando avaliar a variabilidade espacial dos atributos considerados, por meio da coleta e organização espacial dos dados, levando em consideração a semelhança entre pontos vizinhos georreferenciados, para analisar a possível dependência espacial entre eles, também sendo uma ferramenta importante para estimar valores em locais não amostrados (Grego et al., 2014). A teoria das variáveis regionalizadas é didaticamente resumida na famosa frase do pesquisador Waldo Tobler, proferida ainda na década de 1970, conhecida como 1ª Lei da Geografia: “Tudo está relacionado com tudo, mas as coisas mais próximas estão mais relacionadas entre si do que as mais distantes” (Abreu, 2018). Esta frase está intimamente ligada aos princípios que regem a Geoestatística.

Dentre os estimadores geoestatísticos, a KO foi a utilizado para esta pesquisa. A *krigagem* em si, consiste em um processo de estimação de valores de variáveis distribuídas no espaço e/ou tempo, tendo como principal diferença, em relação aos métodos tradicionais, o fato de somente ela ser capaz de apresentar estimativas não tendenciosas, além da mínima variância associada ao valor estimado. Existem alguns tipos de *krigagem*, contudo, a mais usual é a *Krigagem Ordinária* (Yamamoto; Landim, 2013). Em pesquisa recente, Cardoso et al. (2023) realizaram uma importante revisão bibliográfica sobre o uso da geoestatística nas plantações de cana-de-açúcar no Brasil, demonstrando a heterogeneidade existente sobre o tema nas diferentes regiões do país e o baixo número de publicações nos estados que compõem a Amazônia Oriental.

O outro interpolador utilizado está dentro do rol das técnicas de *Machine Learning* (ML), que se referem genericamente ao processo de adaptação de modelos preditivos ao conjunto de dados ou ao processo de identificação de agrupamentos que se referem a alguma informação existente nos dados, buscando, essencialmente, a aproximação ou imitação da capacidade humana de reconhecer padrões por meio da computação, ainda que de forma objetiva. Esta metodologia é particularmente útil quando o conjunto de dados é muito grande ou muito complexo para análise humana (Greener et al., 2022), como é o caso dos dados desta investigação.

As técnicas de ML são compostas por diversos algoritmos, porém, neste trabalho, foi utilizado especificamente o algoritmo *Support Vector Machine* (SVM), que representa um dos mais poderosos e robustos algoritmos de classificação e regressão. O SVM tem desempenhado um papel significativo no reconhecimento de padrões, ganhando reconhecimento em pesquisas e aplicações em diversas áreas científicas (Cervantes et al., 2020).

Diante do exposto, o objetivo deste trabalho foi o de utilizar imagens de Veículos Aéreos Não Tripulados (VANTs), após cálculo do índice de vegetação GNDVI (*Green Normalized Difference Vegetation Index*), para avaliação dos interpoladores espaciais *Krigagem Ordinária* e da Máquina de Vetores de Suporte e posterior definição de zonas de manejo fitossanitário, com o objetivo de otimizar o controle da incidência da mucuna-preta em áreas de plantio de cana-de-açúcar na Amazônia Oriental, por meio de amostragem em malha regular e aleatória.

Ao final deste Capítulo, constam dois Anexos referentes à levantamentos bibliográficos sobre o estado da arte das pesquisas em plantios de cana-de-açúcar do Brasil com ferramentas de Geoestatística (Anexo I) e de Aprendizagem de Máquina (Anexo II), para demonstrar o estado atual do uso destas inovações nas lavouras brasileiras. Os levantamentos bibliográficos foram realizadas nos moldes da revisão bibliográfica proposta no Capítulo 2.

4.2 Materiais e Métodos

Neste tópico serão apresentadas as etapas metodológicas para obtenção dos resultados (Figura 1), bem como os equipamentos e softwares utilizados. As etapas metodológicas 1 e 2 estão contidas resumidamente no tópico “4.2.2 Dados Utilizados” e de forma mais detalhada no Capítulo 3 dessa tese; a etapa 3 no tópico “4.2.3 Definição das Malhas Regulares e Aleatórias”; a etapas de 4 está no tópico “4.2.4 Extração dos Valores de GNDVI”; a etapa 5 está no tópico “4.2.5 Estatísticas Descritivas”; a etapa 6 no tópico “4.2.6 Interpolação Espacial por Geoestatística”; a etapa 7 no tópico “4.2.7 Interpolação Espacial por Aprendizado de Máquina”; a etapa 8 no tópico “4.2.8 Correlação entre as Validações Cruzadas”; e, por último, a etapa 9 está descrita no tópico “4.2.9 Mapas de Zonas de Manejo Fitossanitário”.

Figura 1 - Passos metodológicos para obtenção dos resultados.



Fonte: autor.

4.2.1 Área de Estudo

A área de pesquisa consiste nas mesmas 13 zonas estudadas no Capítulo 3, apresentados na sua Tabela 1, localizadas no município de Ulianópolis, estado do Pará, Brasil (Figura 2 do Capítulo 3), somando, ao todo, cerca de 161 ha.

4.2.2 Dados Utilizados

As imagens utilizadas para o desenvolvimento desta pesquisa, foram as mesmas usadas também no Capítulo 3, fruto do mesmo levantamento aéreo realizado com o Veículo Aéreo Não Tripulado (VANT), modelo *eBeeSQ*, que possui o sensor multiespectral *Parrot Sequoia* acoplado. Neste sentido, foram considerados o mesmo plano de voo, parâmetros de voo, pré-processamento e aritmética de bandas, citadas no referido Capítulo. Vale ressaltar que, para todos os procedimentos relatados, foram utilizados os mesmos *softwares* também mencionados no Capítulo 3 publicados por Cardoso et al. (2024).

Como, ao final da análise estatístico-espectral dos índices de vegetação, verificou-se que o GNDVI (*Green Normalized Difference Vegetation Index*), foi o que apresentou os melhores resultados para a metodologia proposta no Capítulo 3, decidiu-se, neste Capítulo, utilizá-lo como base para a avaliação das interpolações espaciais e para a definição das zonas de manejo fitossanitário. Lembrando que o GNDVI consiste na relação espectral: Infravermelho Próximo (NIR) – Verde / Infravermelho Próximo (NIR) + Verde (Gitelson et al., 1996).

4.2.3 Definição das Malhas Regulares e Aleatórias

Para amostrar os valores do GNDVI, foi definida uma grade regular que amostrasse amplamente cada uma das 13 áreas de pesquisa e otimizasse a extração dos valores. Portanto, após os testes, o espaçamento entre pontos selecionado foi o de 10m. Para a criação da malha, foi utilizada a ferramenta “Pontos regulares”, contida na opção “Criação de Vetor” do *software* QGIS, versão LTR 3.18.

Na criação da malha regular, alguns pontos ultrapassaram as áreas das zonas de estudo, precisando serem excluídos, pois poderiam representar possíveis *outliers*, restando, desta forma, apenas os pontos efetivamente contidos nos limites das áreas das respectivas zonas de pesquisa. O número de pontos amostrados em cada zona variou conforme Tabela 1, onde, quanto maior a área da zona, maior o número de pontos amostrados pela malha definida, e vice-versa. No total foram coletados 16.123 pontos, o que representou uma média de aproximadamente 100 pontos por hectare.

Tabela 1 - Zonas de pesquisa, número de pontos amostrais, tamanho da área de cada zona e número de pontos por hectare.

ZONA	NÚMERO DE PONTOS	ÁREA (ha)	Nº PONTOS/HA
Z1	1.483	14,73	100,68
Z2	1.491	14,83	100,54
Z3	1.190	11,85	100,42
Z4	992	10,01	99,10
Z5	1.042	10,46	99,62
Z6	1.465	14,73	99,46
Z7	1.669	16,55	100,85
Z8	1.144	11,41	100,26
Z9	1.788	17,83	100,28
Z10	1.231	12,38	99,43
Z11	1.678	16,58	101,21
Z12	551	5,55	99,28
Z13	399	4,09	97,56

Fonte: autor.

Após a definição da grade regular e da quantidade de pontos para extração dos valores de GNDVI em cada zona, iniciou-se a criação da grade de amostragem aleatória, utilizando a ferramenta “Pontos aleatórios nas bordas da camada”, que também se encontra dentro da opção “Criação de Vetor” no *software* QGIS. Para a grade aleatória, foi adotado o mesmo número de pontos para cada zona apresentada na Tabela 1, porém, desta vez, os pontos foram amostrados aleatoriamente pela ferramenta citada anteriormente.

4.2.4 Extração dos Valores de GNDVI

Com as malhas regulares e aleatórias definidas para cada zona, iniciou-se o procedimento de extração dos valores do índice de vegetação GNDVI. Para isso, foi utilizado o complemento “*Point Sampling Tool*”, que precisou ser instalado no *software* QGIS. Através do complemento, foi possível amostrar com precisão os valores que, posteriormente, foram utilizados para os cálculos de interpolação espacial e definição de zonas de manejo fitossanitário, ambos propostos por esta pesquisa.

4.2.5 Estatísticas Descritivas

Neste momento, foram tabulados os valores extraídos do GNDVI, tanto os com amostragem regular quanto os com amostragem aleatória, para posterior análise exploratória dos dados no *software* de planilha Microsoft Excel. Os testes estatísticos permitiram a determinação de medidas de posição (média e mediana), de dispersão (valores mínimo e máximo, variância, desvio padrão e coeficiente de variação) e de forma (simetria e curtose).


Durante a discussão dos resultados da estatística descritiva, também foram realizados testes de correlação por meio das medidas de posição, dispersão e forma, entre os valores obtidos por ambas as amostragens. Os testes foram realizados utilizando a versão gratuita do *software* estatístico Minitab 21. Para avaliar a magnitude das correlações, foram utilizados como referência Cohen (1992) e Rumsey (2016).

4.2.6 Interpolação Espacial por Geoestatística

As análises geoestatísticas foram realizadas utilizando o *software* QGIS, através do complemento “*Smart-Map*”, desenvolvido por Pereira et al. (2022). Primeiramente foram importados os arquivos vetoriais de pontos, referentes às malhas regulares e aleatórias de cada zona de pesquisa, uma por vez. A partir daí, iniciou-se um procedimento importante e crucial dentro da geoestatística, que se refere ao ajuste dos semivariogramas.

O semivariograma é comumente composto por Alcance (A), Patamar ($C_0 + C$), Contribuição (C) e Efeito Pepita (C_0) (Figura 1). O Alcance refere-se à distância até onde as amostras são correlacionadas espacialmente; o Patamar é o valor do semivariograma que corresponde ao seu Alcance, onde, a partir deste valor, considera-se que não há mais dependência espacial entre as amostras; a Contribuição corresponde à diferença entre Patamar e Efeito Pepita; e, por fim, temos o Efeito Pepita, que diz respeito ao salto vertical do valor 0 (zero) na origem, para o valor do semivariograma, em distâncias de separação extremamente pequenas, que pode ocorrer, dentre outros motivos, por erros de amostragem ou devido a uma variabilidade de curta escala, por exemplo, onde não é possível calcular (Isaaks; Srivastava, 1989; Camargo, 1997).

Figura 2 - Exemplo de semivariograma experimental.



Fonte: autor, adaptado de Camargo 1997.

Foram testados os três modelos mais utilizados: Esférico, Exponencial e Gaussiano (Obroślak; Dorozhynskyy, 2017). Quanto melhor o ajuste semivariográfico, a tendência é obter melhores resultados no momento da interpolação geoestatística, por isso é necessária a máxima atenção do pesquisador nesta etapa. A Tabela 2 apresenta as equações de cada um dos modelos de semivariograma testado:

Tabela 2 - Modelos semivariográficos mais utilizados e que serão testados nesta pesquisa, assim como suas respectivas fórmulas matemáticas e representação gráfica.

Modelo	Equação	REPRESENTAÇÃO GRÁFICA
Esférico	$y(h) = C_0 + C \left[1,5 \frac{h}{a} - 0,5 \left(\frac{h}{a} \right)^3 \right] \text{ para } h < a$ $y(h) = C_0 + C \text{ para } h \geq a$	
Exponencial	$y(h) = C_0 + C \left[1 - \text{Exp} \left(-\frac{h}{a} \right) \right]$	
Gaussiano	$y(h) = C_0 + C \left[1 - \text{Exp} \left(-\left(\frac{h}{a} \right)^2 \right) \right]$	

Legenda: C₀: efeito pepita; C: contribuição; C₀ + C: patamar; h: distância.

Fonte: autor, adaptado de Isaaks & Srivastava (1989), Olea (1999) e Yamamoto & Landim (2013).

Para a avaliação de possível dependência espacial presente nos dados analisados, considerou-se três diferentes parâmetros: o Grau de Dependência Espacial (GDE), proposto por Cambardella et al. (1994); o Índice de Dependência Espacial (IDE) ou parâmetro “k”, recomendado por Zimback (2001); e o Índice de Moran (IM), de acordo com o sugerido por Legendre & Fortin (1989), conforme Tabela 3.

Tabela 3 - Parâmetros de dependência espacial, suas fórmulas matemáticas e respectivas interpretações.

PARÂMETRO	FÓRMULA	INTERPRETAÇÃO
GDE	$GDE = \frac{C_0}{(C + C_0)} \times 100$	Onde: - GDE > 75%: dependência Fraca ; - 75% > GDE > 25%: dependência Moderada ; - GDE < 25%: dependência Forte .
IDE	$IDE = \frac{C}{(C_0 + C)}$	Onde: - IDE (k) < 0,25: dependência Fraca ; - 0,25 < IDE (k) < 0,75: dependência Moderada ; - IDE (k) > 0,75 dependência Forte .
IM	$IM = \left[\frac{n}{\sum_{i=1} \sum_{j=1} w_{ij}} \times \frac{\sum_{i=1} \sum_{j=1} w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_i (x_i - \bar{x})^2} \right]$	Onde: - IM > 0: Há agrupamento de valores similares ; - IM = 0: Sem autocorrelação ; - IM < 0: Há agrupamentos de valores diferentes .

Legenda: C₀: efeito pepita; C: contribuição; C₀+C: patamar; n: número de observações na área de estudo; x_i, x_j: representam os valores observados dos atributos a serem interpolados nos pontos i, j; \bar{x} : é a média de x; w_{ij}: são os elementos da matriz de pesos espaciais com valor 0 na diagonal (w_{ii} = 0).

Fonte: autor, adaptado de Cambardella et al. (1994), Zimback (2001) e Legendre & Fortin (1989).

Após o ajuste dos semivariogramas, iniciou-se o procedimento de interpolação, utilizando o método geoestatístico de *Krigagem Ordinária* (KO), para geração dos mapas de *Krigagem*. No momento da interpolação dos mapas, foi também realizado o procedimento de Validação Cruzada, em cada uma das áreas de investigação e em relação a cada método de amostragem (regular e aleatória), como forma de validar a interpolação realizada. O procedimento de validação cruzada também foi realizado no complemento “*Smart-Map*” no QGIS.

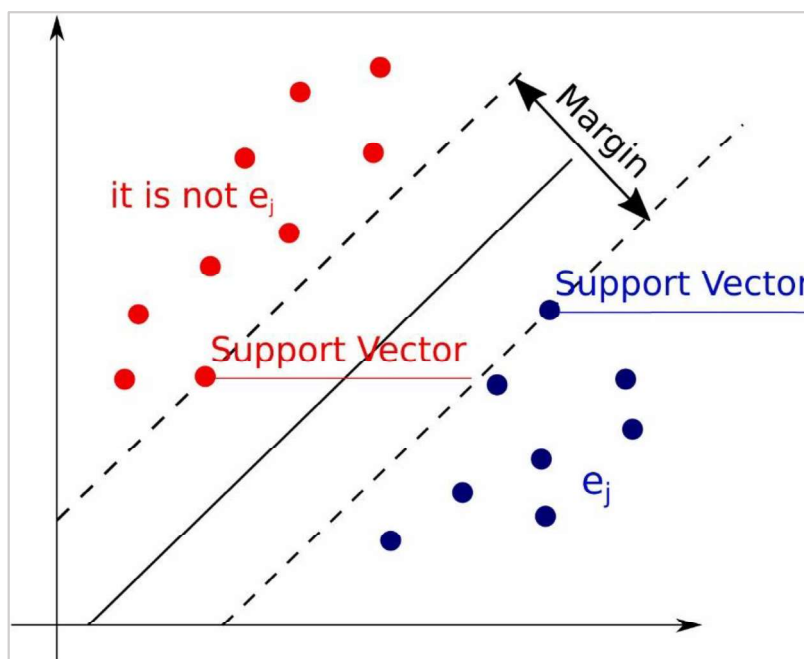
4.2.7 Interpolação Espacial por Aprendizado de Máquina

Os produtos de Aprendizado de Máquina também foram gerados no complemento “*Smart-Map*”, no QGIS. Para tanto, também foram importados arquivos vetoriais em geometria de pontos, referentes a malhas regulares e aleatórias. Em seguida, foi adicionada a covariável a

ser utilizada, neste caso os valores do GNDVI, de cada malha amostral e de cada zona de pesquisa, uma por vez. Após a adição dos valores de GNDVI, foi possível realizar o procedimento de interpolação espacial, utilizando o algoritmo de *Machine Learning* denominado *Support Vector Machine* (SVM).

O SVM consiste em um modelo de aprendizagem supervisionada amplamente utilizado em problemas que envolvem classificações de padrões. De acordo com Borg et al. (2021), um classificador baseado em SVM visa separar um conjunto de dados em duas classes diferentes usando um hiperplano, conforme Figura 2, onde os pontos mais próximos são denominados de Vetores de Suporte e o hiperplano de separação é chamado de Margem Rígida, sendo derivado da maximização das distâncias entre os vetores de suporte.

Figura 3 - Ilustração de vetores de suporte e margem rígida para classificação de e_j .



Fonte: Borg et al. (2021).

Durante a interpolação dos mapas, dentro do mesmo complemento no QGIS, também foi possível realizar o procedimento de Validação Cruzada, como forma de validar a interpolação realizada.

4.2.8 Correlação entre as Validações Cruzadas

Para a realização desta correlação, foi construído um correlograma para correlacionar os valores de r -quadrado e Raiz do Erro Quadrático Médio (*Root Mean Squared Error* - RMSE), entre os diferentes interpoladores e as malhas amostrais consideradas nesta pesquisa. O

procedimento foi realizado no *software* estatístico Minitab versão 21 e, para avaliar a magnitude das correlações, foram levados em consideração os parâmetros de Cohen (1992) e Rumsey (2016).

4.2.9 Mapas de Zonas de Manejo Fitossanitário

Ao final do trabalho foi possível construir mapas de zonas de manejo fitossanitário, a partir da combinação dos interpoladores propostos: *Krigagem Ordinária* e *Máquina de Vetores de Suporte*; ambos com amostragem regular e aleatória. Para a definição das zonas de manejo, foi também utilizado o complemento “*Smart-Map*”.

As classes de manejo, para cada zona de pesquisa, foram calculadas com base na relação entre o Índice de Performance Fuzzy (*Fuzzy Performance Index* - FPI) e Entropia de Classificação Normalizada (*Normalized Classification Entropy* - NCE), segundo McBratney & Moore (1985) e Bezdek (1981), respectivamente. O FPI mede o grau de imprecisão criado por um determinado número de classes e o NCE refere-se a uma estimativa da quantidade de desordem criada por um determinado número de classes (Moharana et al., 2020).

Tal procedimento permitiu a obtenção do número de classes consideradas ideais para cada zona. Os indicadores propostos são representados pelas seguintes equações:

$$FPI = 1 - \frac{c}{c-1} \left[1 - \frac{\sum_{i=1}^c \sum_{k=1}^n (\mu_{ik})^2}{n} \right] \quad (1)$$

$$NCE = \frac{n}{n-c} \left[-\frac{\sum_{k=1}^n \sum_{i=1}^c \mu_{ik} \log_a (\mu_{ik})}{n} \right] \quad (2)$$

onde, “c” consiste no número de clusters; “n” no número de observações; “ μ_{ik} ” na associação fuzzy; e o “ \log_a ” no logaritmo natural.

4.3 Resultados e Discussão

4.3.1 Estatísticas Descritivas

Em posse dos valores extraídos por cada malha de amostragem considerada, em cada uma das 13 zonas de pesquisa, foi possível a realização de análises estatísticas dos dados, apresentados nas Tabelas 4 e 5.

Tabela 4 - Estatística descritiva para as 13 zonas amostradas por malha regular.

ZONAS	MÉDIA	VARIÂNCIA	MEDIANA	DESVIO PADRÃO	CURTOSE	ASSIMETRIA	MÍN.	MÁX.	CV (%)
Z1	0,656	0,007	0,683	0,086	5,064	-2,057	0,200	0,802	13,102
Z2	0,664	0,008	0,689	0,090	5,442	-2,118	0,178	0,802	13,624
Z3	0,680	0,004	0,694	0,067	8,521	-2,183	0,192	0,802	9,797
Z4	0,701	0,006	0,723	0,075	5,981	-2,092	0,262	0,815	10,685
Z5	0,679	0,008	0,700	0,090	4,529	-1,789	0,181	0,821	13,242
Z6	0,659	0,007	0,689	0,085	6,514	-2,222	0,189	0,783	12,894
Z7	0,668	0,007	0,689	0,083	4,173	-1,761	0,164	0,809	12,469
Z8	0,665	0,007	0,689	0,085	5,226	-1,973	0,183	0,802	12,771
Z9	0,720	0,004	0,735	0,060	9,133	-2,524	0,291	0,835	8,312
Z10	0,672	0,006	0,694	0,079	3,253	-1,662	0,226	0,815	11,761
Z11	0,694	0,004	0,706	0,061	10,104	-2,339	0,116	0,802	8,763
Z12	0,666	0,008	0,694	0,092	5,751	-2,201	0,192	0,802	13,752
Z13	0,672	0,006	0,694	0,076	6,531	-2,266	0,235	0,789	11,379

Fonte: autor.

Tabela 5 - Estatística descritiva para as 13 zonas amostradas por malha aleatória.

ZONAS	MÉDIA	VARIÂNCIA	MEDIANA	DESVIO PADRÃO	CURTOSE	ASSIMETRIA	MÍN.	MÁX.	CV (%)
Z1	0,654	0,007	0,683	0,085	6,117	-2,240	0,170	0,815	12,984
Z2	0,668	0,008	0,689	0,090	8,908	-2,600	0,083	0,796	13,551
Z3	0,680	0,004	0,694	0,067	6,893	-2,108	0,256	0,796	9,852
Z4	0,707	0,005	0,723	0,067	7,580	-2,212	0,266	0,821	9,514
Z5	0,681	0,009	0,706	0,093	5,336	-1,997	0,126	0,815	13,731
Z6	0,658	0,008	0,689	0,089	5,239	-2,086	0,172	0,783	13,579
Z7	0,667	0,008	0,689	0,088	8,434	-2,317	0,060	0,828	13,242
Z8	0,667	0,006	0,689	0,075	4,453	-1,776	0,226	0,789	11,283
Z9	0,719	0,004	0,735	0,063	11,295	-2,778	0,262	0,828	8,714
Z10	0,669	0,007	0,694	0,082	3,992	-1,757	0,206	0,796	12,186
Z11	0,695	0,004	0,706	0,060	12,170	-2,575	0,203	0,809	8,672
Z12	0,670	0,007	0,694	0,082	5,397	-2,094	0,223	0,783	12,305
Z13	0,674	0,008	0,700	0,089	9,531	-2,086	0,220	0,771	13,267

Fonte: autor.

Os valores de média e mediana apresentaram uma correlação bem forte, tanto para Cohen (1992) quanto para Rumsey (2016), com estimativas de r de Pearson de 0,990 e 0,989, respectivamente, demonstrando valores próximos entre si. Os parâmetros mínimo e máximo, também se apresentaram correlacionáveis, com valores de r de Pearson de 0,531 e 0,746, respectivamente, o que representa uma magnitude de correlação forte para Cohen (1992) e moderada para Rumsey (2016) em relação ao parâmetro máximo; e forte para ambos os autores para o parâmetro mínimo.

Para aos valores desvio padrão e variância, as duas amostragens apresentaram valores próximos e baixos para os parâmetros em questão, remetendo a um conjunto de dados com valores homogêneos e próximos à média (Minitab, 2023). A variância apresentou correlação de 0,850 e o desvio padrão de 0,832, ambos considerados fortes para Cohen (1992) e Rumsey (2016).

Outro parâmetro avaliado, foi o Coeficiente de Variação (CV), que, na estatística clássica, é considerado importante para se avaliar a qualidade e precisão do experimento. Quanto menor o valor de CV, maior a precisão experimental. Desta forma, quanto maior a precisão do experimento, menor será o seu erro amostral e suas conclusões terão maior credibilidade. De modo geral, segundo Ferreira (2018), valores de CV inferiores a 10%, representam uma ótima precisão experimental; valores de CV entre 10 e 15%, denotam boa precisão experimental; valores de CV acima de 15% e menores ou iguais a 20%, indicam uma precisão experimental regular ou aceitável; valores de CV maiores que 20% e menores ou iguais a 30%, apresentam péssima precisão experimental; e valores de CV acima de 30%, representam uma precisão experimental muito péssima.

Os dados das zonas desta pesquisa, apresentaram CVs que variaram de 8,312% (Zona 9) a 13,752% (Zona 12), para a amostragem regular; e de 8,672% (Zona 11) a 13,731% (Zona 5), para a amostragem aleatória. O que demonstra que as amostragens variaram entre ótima (<10%) e boa (10 a 15%) precisão. Os valores de CV, para cada amostragem, apresentaram um r de Pearson de 0,872, o que demonstra uma forte correlação entre os CVs de cada amostragem, tanto para Cohen (1992) e para Rumsey (2016).

Os parâmetros de assimetria e curtose, foram utilizados para entender a forma de distribuição dos dados. Os valores de assimetria foram todos negativos para ambas as malhas, o que indica uma distribuição assimétrica negativa ou à esquerda. Em relação a curtose, todos os dados apresentaram curtose positiva, típico de dados não-normais, como os utilizados nesta pesquisa. Os valores de assimetria e curtose, entre as malhas utilizadas, apresentaram r de Pearson de 0,627 e 0,710, respectivamente, o que demonstra forte correlação da assimetria para

Cohen (1992) e moderada correlação da assimetria para Rumsey (2016). Já a curtose apresentou forte correlação para ambos os autores.

Com a ciência de que os dados não apresentaram distribuição normal, recorreu-se a métodos de normalização, mas sem sucesso, provavelmente pelo alto número de amostras, que variaram de 399 pontos (Zona 1) a 1.788 (Zona 9). Como os dados serão utilizados em análises geoestatísticas, é importante ressaltar o que já foi enfatizado por alguns pesquisadores, como Folegatti (1996), Silva et al. (2010) e Assumpção & Hadlich (2017), que afirmam que a normalidade dos dados, apesar de desejável, não é uma exigência para a geoestatística.

Todavia, é conveniente que a distribuição não apresente caudas muito alongadas, o que pode comprometer futuras análises. Nesta pesquisa, apesar dos dados não apresentarem distribuição normal, os semivariogramas foram bem ajustados, apresentando estacionaridade, o que demonstra que esse fator não comprometeu as análises.

4.3.2 Análise Semivariográfica

Ao todo foram construídos 26 semivariogramas, um para cada zona e para cada uma das malhas amostrais consideradas nesta pesquisa. Para a malha regular, o modelo semivariográfico que mais se ajustou aos dados da pesquisa foi o Gaussiano, presente em 6 zonas, seguido pelo Esférico em 4 zonas e o Exponencial em 3 zonas (Tabela 6 e Fig. 3). Em relação a malha aleatória, o modelo que mais se ajustou foi o Esférico, presente em 6 zonas, seguido pelo Exponencial em 5 zonas e o Gaussiano em 2 zonas (Tabela 7 e Fig. 4).

4.3.2.1 Malha Regular

Os semivariogramas produzidos da amostragem regular, apresentaram os seguintes valores para cada um dos seus principais parâmetros: efeito pepita (C_0) variando de 0,002 a 0,005, com um valor médio de 0,003; patamar ($C_0 + C$) variando de 0,003 a 0,007, com um valor médio de 0,005; e alcance (A) variando de 24,734 a 63,573, com um valor médio de 45,612.

Em todas as 13 zonas foi possível notar um excelente ajuste nos semivariogramas, que apresentaram valores bem altos de coeficiente de determinação (r^2), que variou de 0,897 a 0,999, com um valor médio de 0,977. Vale ressaltar, que os valores de r^2 variam de 0 (0%) a 1 (100%), onde, quanto mais próximo de 0, a tendência é a de que os dados não apresentem um bom ajuste ao modelo proposto. Em contrapartida, quanto mais próximo de 1, a tendência é a de que os dados se ajustem significativamente ao modelo (Minitab, 2019).

Outro fator avaliado foi a presença de dependência espacial no conjunto de dados. Para essa avaliação, levou-se em conta três índices bastante utilizados em outras pesquisas sobre a

temática, são eles: Grau de Dependência Espacial (GDE), proposto por Cambardella et al. (1994); Índice de Dependência Espacial (IDE), sugerido por Zimback (2001); e o Índice de Moran, levando em conta relação matemática proposta por Legendre & Fortin (1989).

O GDE variou 83,333% a 42,857%, apresentando valor médio de 61,978%, classificado como de moderado. Ao todo, realmente todas as zonas apresentaram GDE moderado, com exceção da Zona 12 que apresentou valores que se enquadraram como GDE fraco. O mesmo aconteceu com o IDE, que variou de 0,167 a 0,571, com valor médio de 0,380. Da mesma forma que o GDE, o IDE apresentou praticamente todas as zonas classificadas como moderadas, com exceção também da Zona 12, que também foi classificada como fraca. Por fim, verificou-se o IM, onde foi possível perceber que todos os dados apresentaram valores acima de 0, variando de 0,618 a 1,000, com valor médio de 0,699, demonstrando que há agrupamento de valores similares nos nossos dados, também validado pelo P-Valor de 0,001 em todas as 13 zonas.

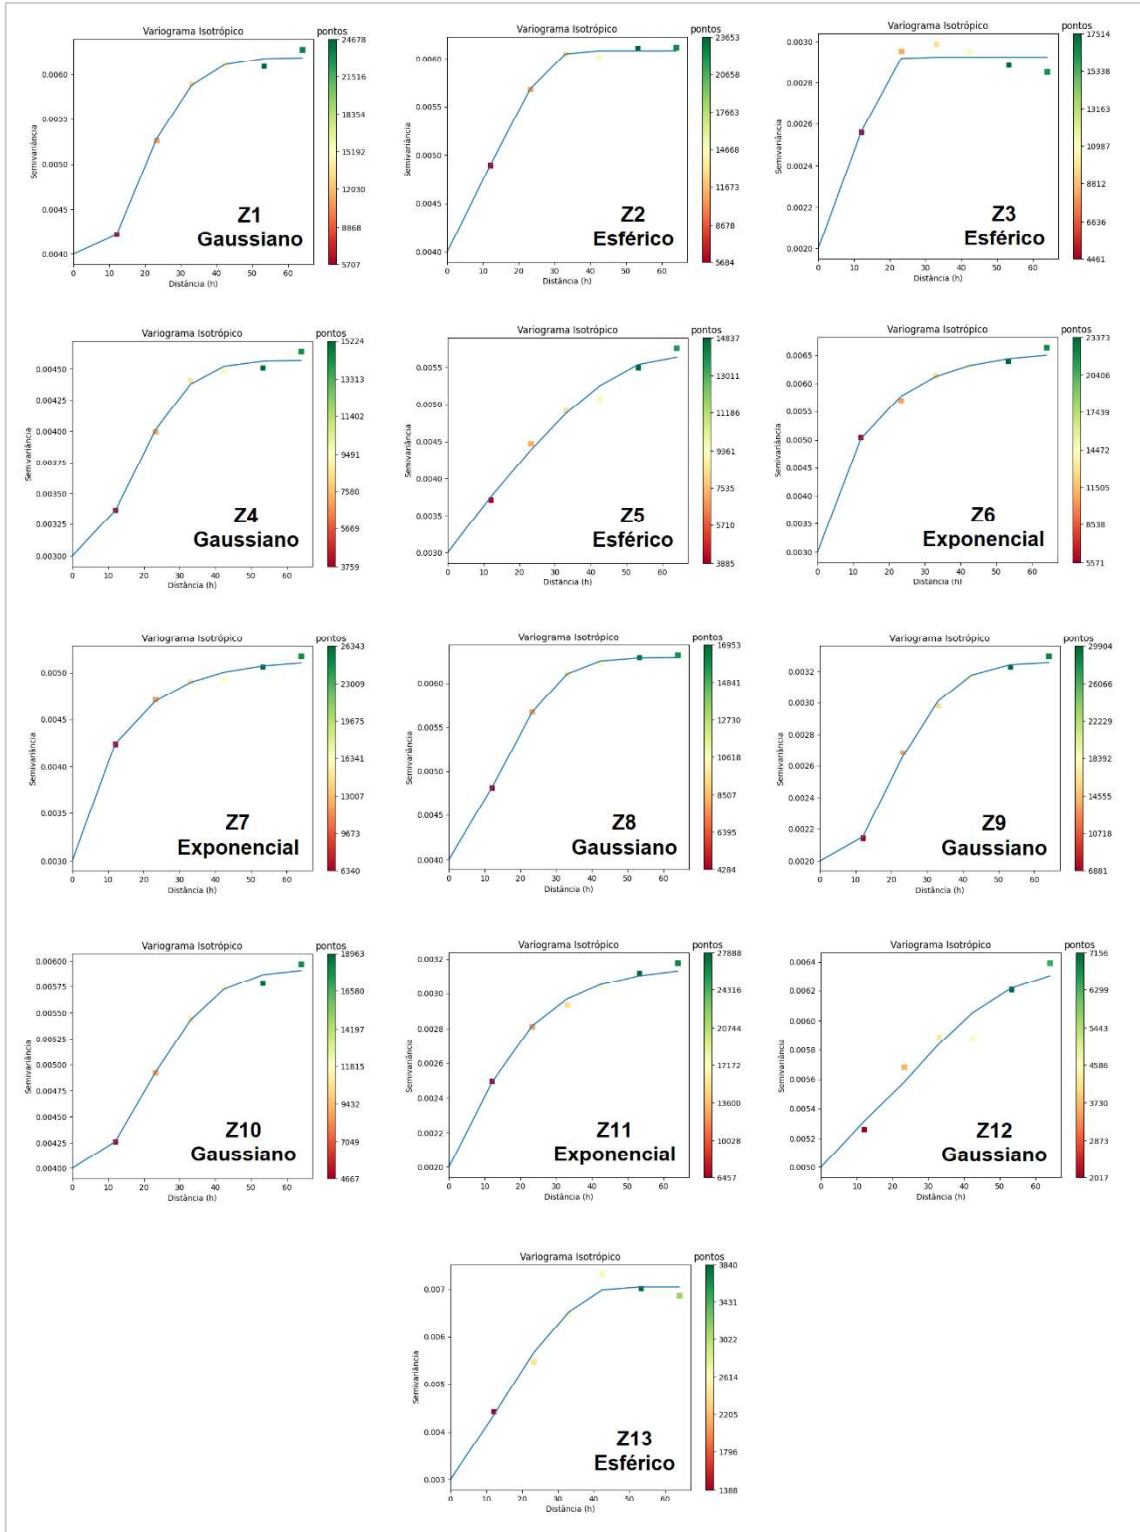
Tabela 6 - Modelos semivariográficos e testes de dependência espacial para a malha regular.

Semivariogramas					Teste de Dependência Espacial					
Zona	Modelo	C ₀	(C ₀ +C)	A	r ²	GDE (%)	IDE	Classe	Moran	P-Value
Z1	Gaussiano	0,004	0,006	39,230	0,995	66,667	0,333	Moderada	0,696	0,001
Z2	Esférico	0,004	0,006	36,666	0,994	66,667	0,333	Moderada	0,676	0,001
Z3	Esférico	0,002	0,003	24,734	0,897	66,667	0,333	Moderada	0,697	0,001
Z4	Gaussiano	0,003	0,005	39,284	0,991	60,000	0,400	Moderada	0,687	0,001
Z5	Esférico	0,003	0,006	63,537	0,979	50,000	0,500	Moderada	0,761	0,001
Z6	Exponencial	0,003	0,007	50,609	0,985	42,857	0,571	Moderada	0,618	0,001
Z7	Exponencial	0,003	0,005	48,624	0,982	60,000	0,400	Moderada	0,674	0,001
Z8	Gaussiano	0,004	0,006	37,103	0,999	66,667	0,333	Moderada	0,637	0,001
Z9	Gaussiano	0,002	0,003	43,668	0,997	66,667	0,333	Moderada	0,691	0,001
Z10	Gaussiano	0,004	0,006	48,178	0,995	66,667	0,333	Moderada	1,000	0,001
Z11	Exponencial	0,002	0,003	50,617	0,988	66,667	0,333	Moderada	0,655	0,001
Z12	Gaussiano	0,005	0,006	63,673	0,931	83,333	0,167	Fraca	0,657	0,001
Z13	Esférico	0,003	0,007	47,033	0,971	42,857	0,571	Moderada	0,635	0,001

Legenda: C₀: efeito pepita; C₀+C: patamar; A: Alcance.

Fonte: autor.

Figura 4 - Semivariogramas ajustados para as 13 zonas amostradas por malha regular.



Fonte: autor.

4.3.2.2 Malha Aleatória

Os semivariogramas provenientes da amostragem aleatória, apresentaram os seguintes valores: efeito pepita (C_0) variou de 0,001 a 0,005, com valor médio de 0,003; patamar ($C_0 + C$) variou de 0,003 a 0,010, com valor médio de 0,005; e alcance (A) variou de 24,762 a 46,911, com valor médio de 36,763.

Da mesma forma como ocorreu com os semivariogramas com amostragem regular, foi possível perceber um excelente ajuste nos semivariogramas com a amostragem aleatória, que apresentaram valores bem altos de coeficiente de determinação (r^2), variando de 0,807 a 0,998, com um valor médio de 0,963, reforçando que os dados se ajustam significativamente aos modelos semivariográficos propostos.

Em relação aos parâmetros de dependência espacial, o GDE variou 80,000% a 20,000%, apresentando valor médio de 52,418%, o que lhe permite classificar, no geral, como moderado. Neste sentido, foi possível perceber que praticamente todas as zonas apresentaram GDE moderado, com exceção da Zona 12 e Zona 13, que apresentaram valores que as enquadraram como GDE fraco e forte, respectivamente. Da mesma forma ocorreu com o IDE, que variou de 0,200 a 0,800, com valor médio de 0,476, que assim como GDE, refletiu na grande maioria das zonas com dependência espacial moderada, com exceção também da Zona 12 e Zona 13, que também foram classificadas como fraca e forte, respectivamente.

Por fim, também foi analisado o IM, o que possibilitou observar que todos os dados apresentaram valores acima de 0, variando de 0,388 a 0,639 e com um valor médio de 0,521, sinalizando que há agrupamento de valores similares nos dados desta pesquisa, também validado pelo P-Valor de 0,001 em todas as 13 zonas.

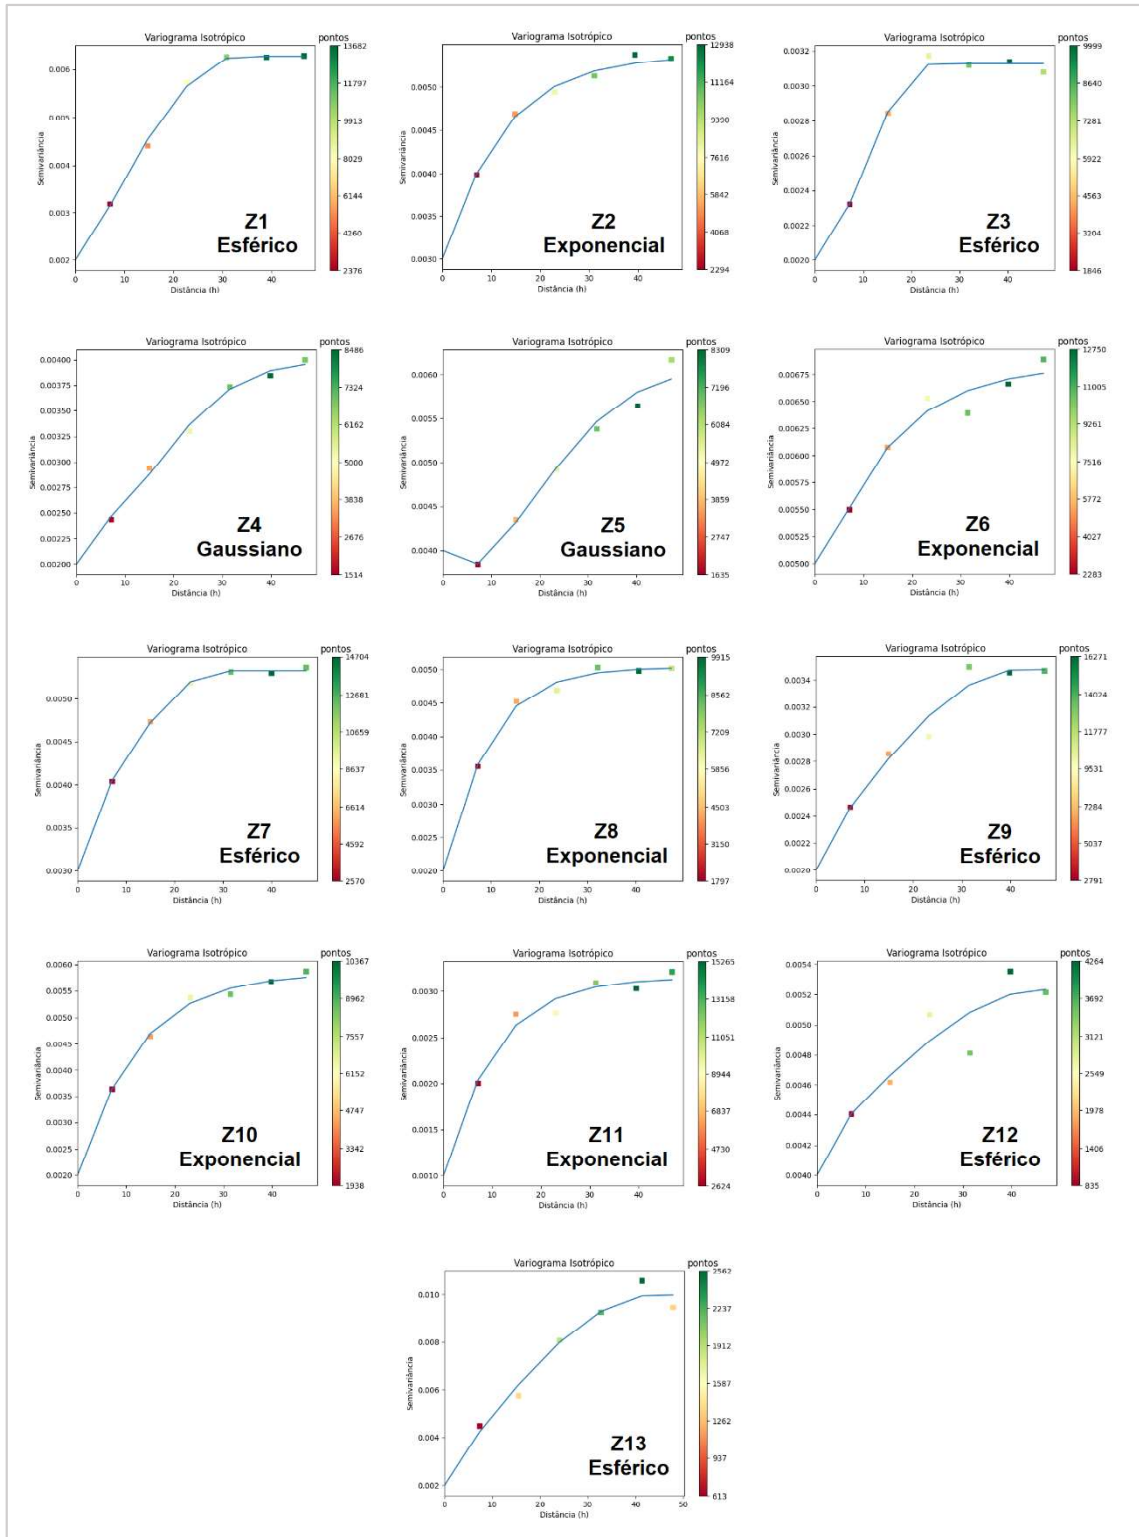
Tabela 7 - Modelos semivariográficos e testes de dependência espacial para a malha aleatória.

Semivariogramas						Teste de Dependência Espacial				
Zona	Modelo	C ₀	(C ₀ +C)	A	r ²	GDE (%)	IDE	Classe	Moran	P-Value
Z1	Esférico	0,002	0,006	33,467	0,997	33,333	0,667	Moderada	0,583	0,001
Z2	Exponencial	0,003	0,005	35,756	0,986	60,000	0,400	Moderada	0,542	0,001
Z3	Esférico	0,002	0,003	24,762	0,990	66,667	0,333	Moderada	0,558	0,001
Z4	Gaussiano	0,002	0,004	40,520	0,993	50,000	0,500	Moderada	0,551	0,001
Z5	Gaussiano	0,004	0,006	46,911	0,978	66,667	0,333	Moderada	0,639	0,001
Z6	Exponencial	0,005	0,007	42,911	0,937	71,429	0,286	Moderada	0,388	0,001
Z7	Esférico	0,003	0,005	29,578	0,998	60,000	0,400	Moderada	0,556	0,001
Z8	Exponencial	0,002	0,005	25,871	0,984	40,000	0,600	Moderada	0,402	0,001
Z9	Esférico	0,002	0,003	41,734	0,952	66,667	0,333	Moderada	0,527	0,001
Z10	Exponencial	0,002	0,006	35,813	0,988	33,333	0,667	Moderada	0,526	0,001
Z11	Exponencial	0,001	0,003	30,216	0,943	33,333	0,667	Moderada	0,511	0,001
Z12	Esférico	0,004	0,005	46,411	0,807	80,000	0,200	Fraca	0,523	0,001
Z13	Esférico	0,002	0,010	43,967	0,967	20,000	0,800	Forte	0,467	0,001

Legenda: C₀: efeito pepita; C₀+C: patamar; A: Alcance.

Fonte: autor.

Figura 5 - Semivariogramas ajustados para as 13 zonas amostradas por malha aleatória.



Fonte: autor.

4.3.3 Mapas Interpolados

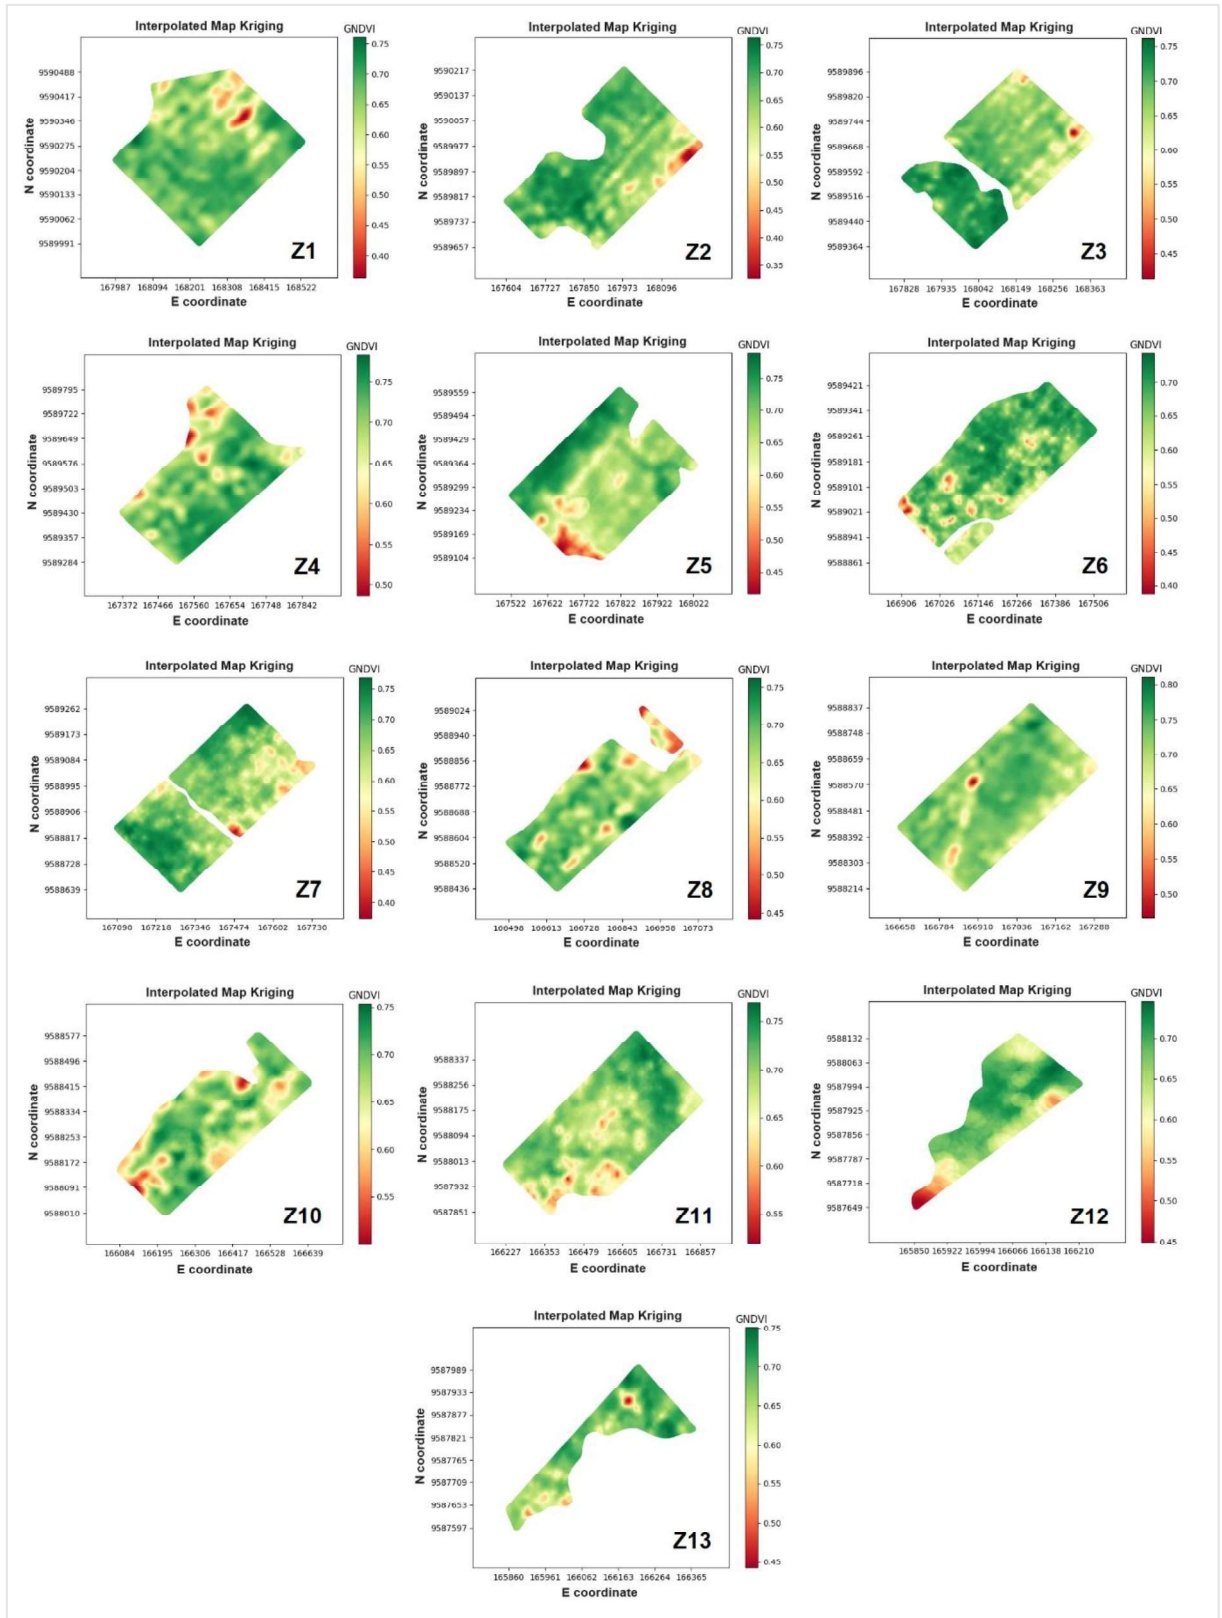
4.3.3.1 Mapas de *Krigagem* (Geoestatística)

Os mapas oriundos da interpolação por *Krigagem* Ordinária (KO), se mostraram eficientes para demonstrar a variabilidade espacial presente nas 13 zonas de estudo, correspondendo fielmente aos semivariogramas anteriormente ajustados, permitindo uma visualização prévia da área para possíveis recomendações de manejo localizado de problemáticas, aumentando a escala e otimizando as decisões a serem tomadas, conforme demonstrado nas Figuras 5 e 6, para malhas regular e aleatória, respectivamente.

4.3.3.2 Mapas de *Support Vector Machine* (*Machine Learning*)

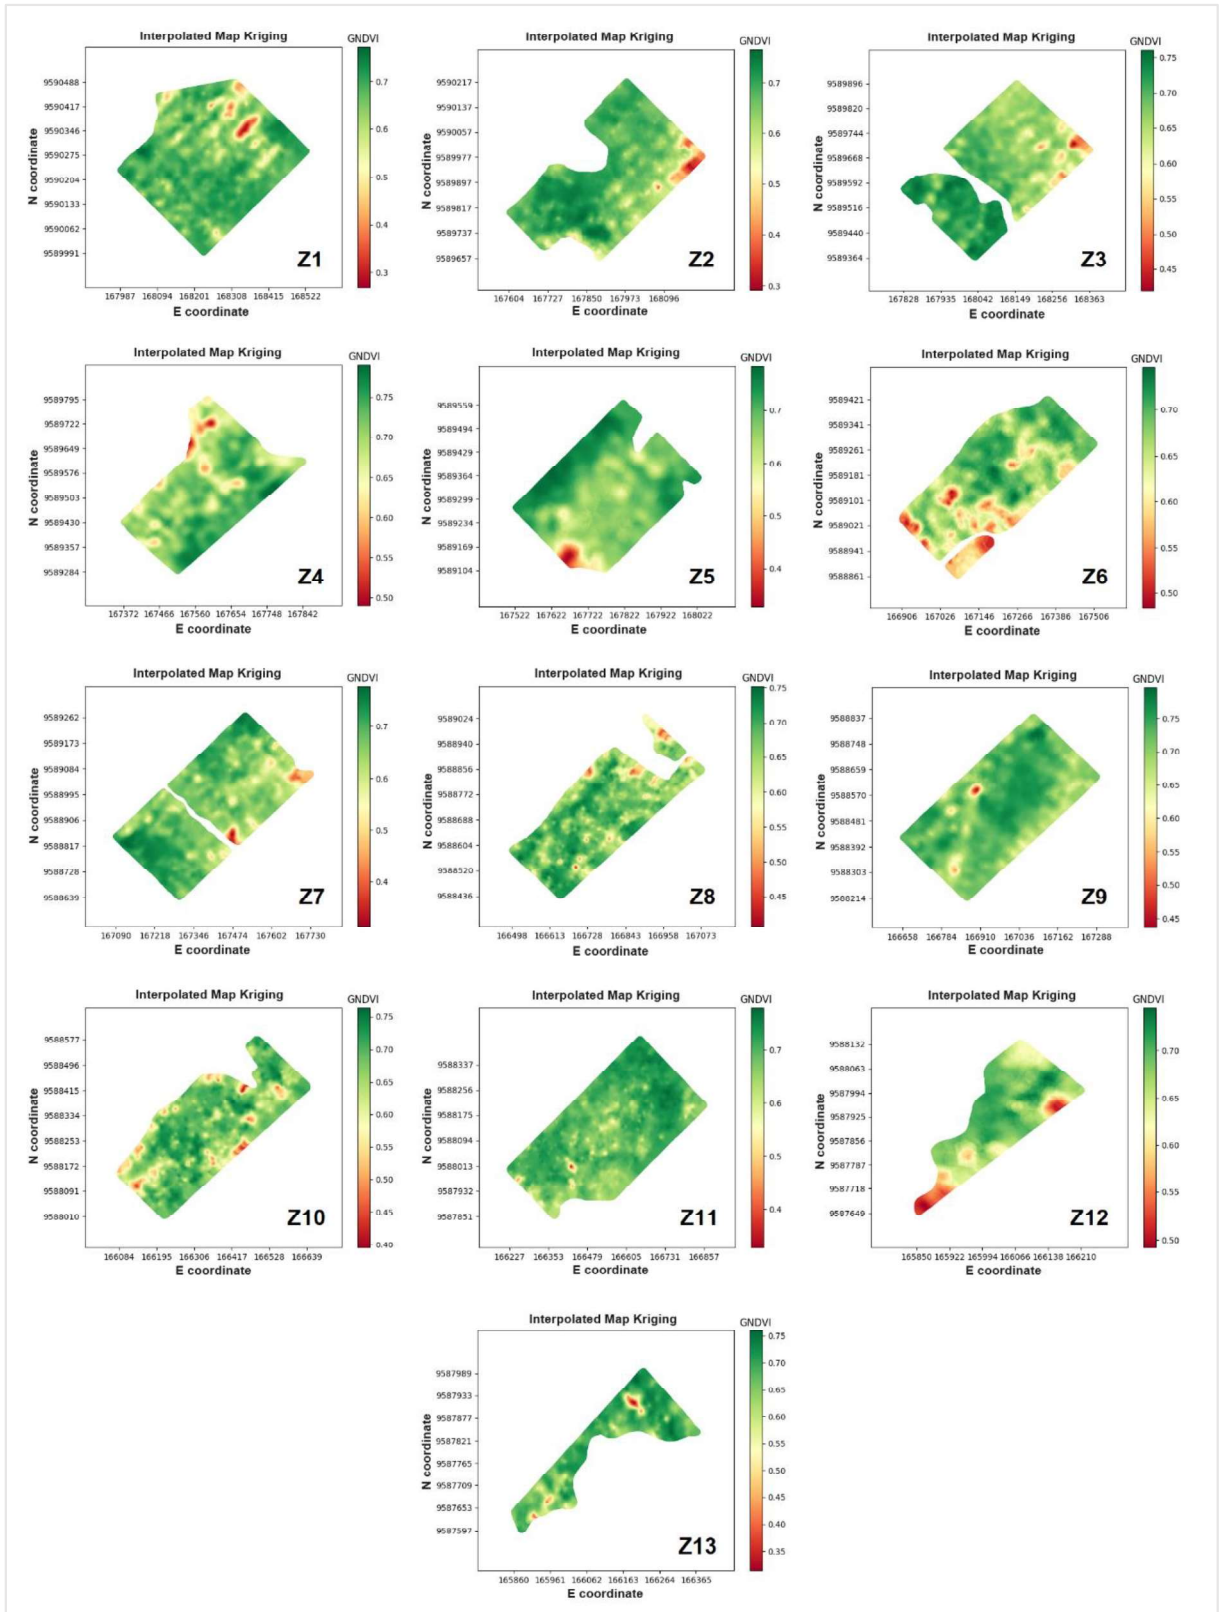
Da mesma forma que o interpolador anterior, o algoritmo *Support Vector Machine* também se mostrou eficiente para demonstrar as heterogeneidades presentes na área, por meio da interpolação dos pontos extraídos dos mapas de GNDVI, seja relacionada a amostragem regular ou aleatória, permitindo uma análise holística das 13 zonas e orientação para otimização de possível manejo a ser aplicado na área, conforme Figuras 7 e 8.

Figura 6 - Mapas de *Krigagem* das 13 zonas de pesquisa a partir da amostragem com malha regular.



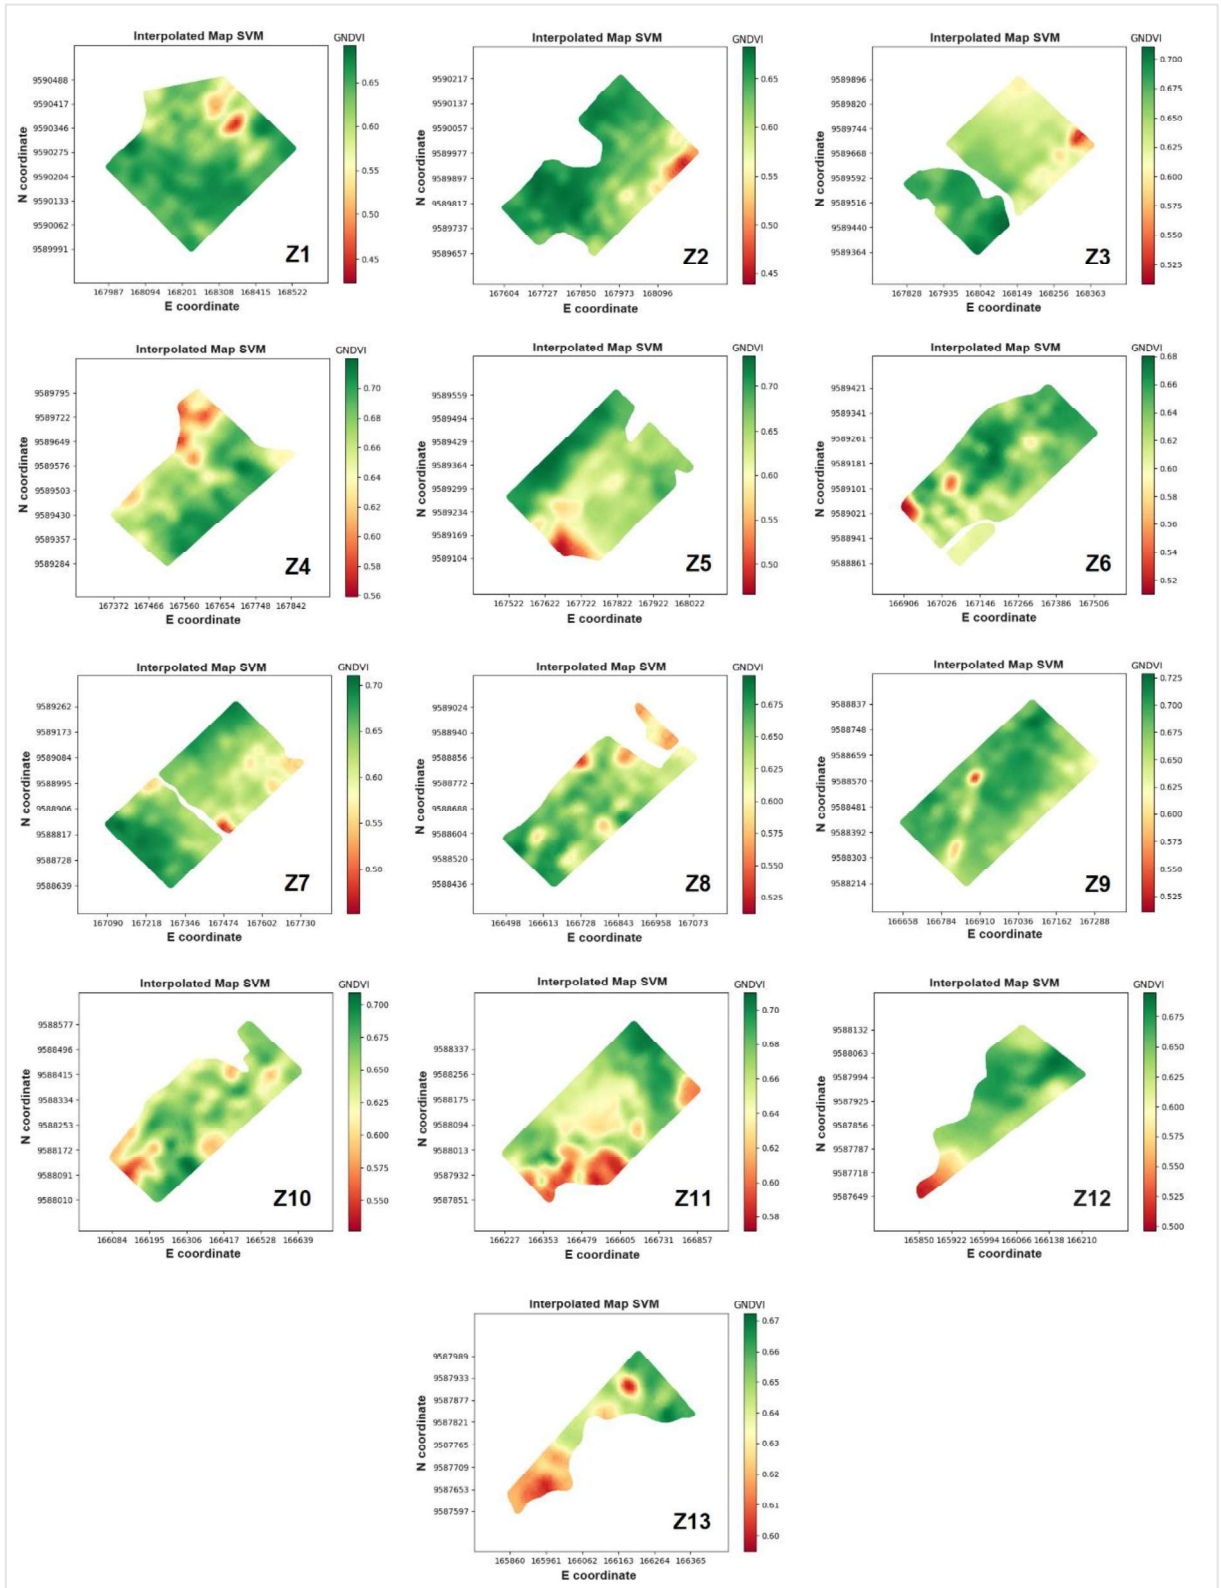
Fonte: autor.

Figura 7 - Mapas de *Krigagem* das 13 zonas de pesquisa a partir da amostragem com malha aleatória.



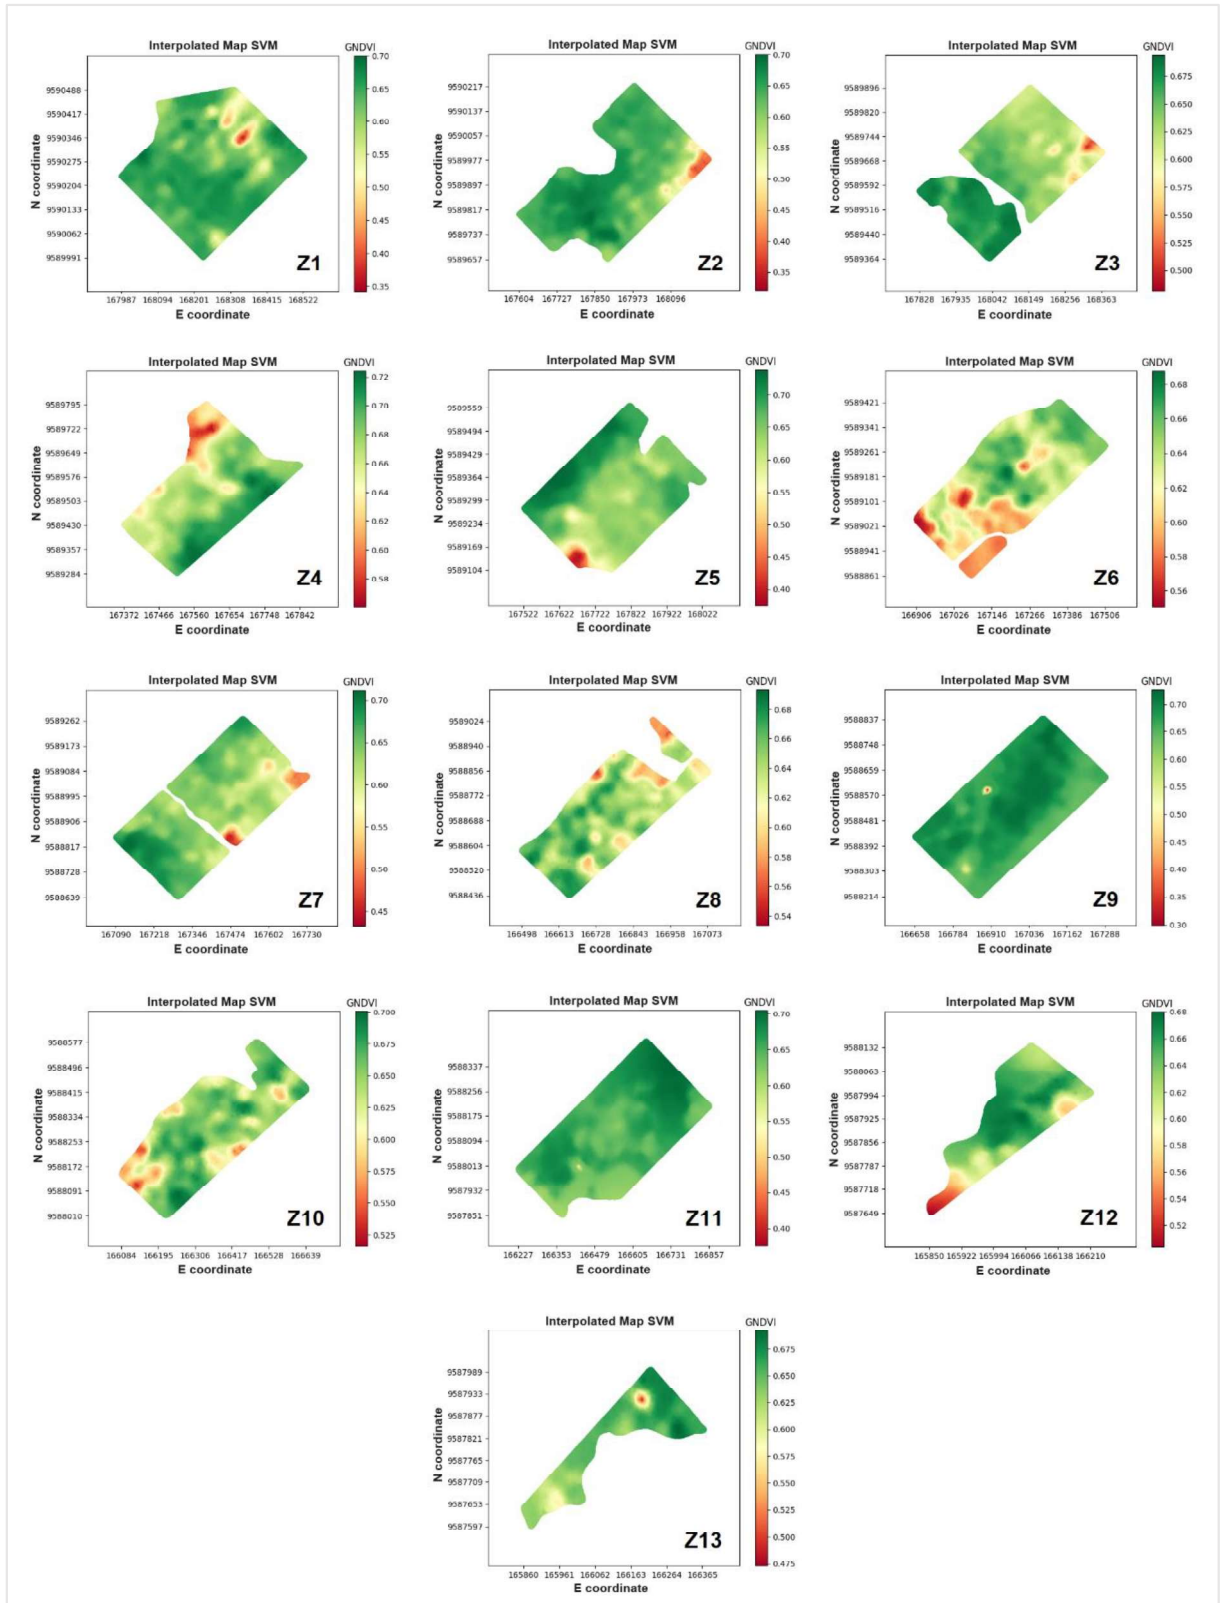
Fonte: autor.

Figura 8 - Mapas de *Support Vector Machine* das 13 zonas de pesquisa a partir da amostragem com malha regular.



Fonte: autor.

Figura 9 - Mapas de *Support Vector Machine* das 13 zonas de pesquisa a partir da amostragem com malha aleatória.



Fonte: autor.

4.3.3.3 Relação entre os Interpoladores aplicados ao Caso Concreto

Como relatado anteriormente, os dois interpoladores se mostraram competentes para demonstrar as diferenças presentes nas 13 zonas estudadas, seja pela amostragem regular ou aleatória, evidenciando a importância de ferramentas de agricultura de precisão, para a otimização de tomadas de decisão, permitindo o reconhecimento das heterogeneidades presentes nas zonas de estudo, diferente do que ocorre na agricultura convencional, onde, muitas das vezes, se trata uma área heterogênea como se fosse homogênea, conforme relatam Machado et al. (2018).

Para análise dos mapas interpolados, é importante perceber que, quanto mais próximo da coloração avermelhada, mais baixos serão os valores GNDVI, ou seja, as colorações próximas ao vermelho, representam regiões onde se necessita de um manejo mais localizado, no intuito de verificar e entender melhor o motivo para estas repostas espectrais, em níveis abaixo do que é considerado mais saudável para as culturas. Por outro lado, quanto mais próximo da coloração verde, melhor os resultados na área de plantio, refletindo em plantas com melhores indicadores fotossintéticos, segundo Gitelson et al. (1996).

Em visita ao local de pesquisa, foi possível perceber que a principal problemática na área de estudo é a presença da planta daninha *Mucuna pruriens*, também conhecida vulgarmente como mucuna-preta (Figura 9). A constatação desta problemática foi consensual entre todos os relatos colhidos de funcionários que desenvolvem suas atividades nas áreas de plantio, desde os níveis mais operacionais aos mais estratégicos dentro da empresa.

Bressanin et al. (2016) relatam que, no passado, algumas espécies de leguminosas, como a mucuna-preta, eram amplamente utilizadas para a renovação dos canaviais. Ambrosano et al. (2013), por exemplo, chegaram a recomendar o seu cultivo na fase prévia ao plantio da cana-de-açúcar, devido suas propriedades para adubação verde, podendo melhorar parâmetros físicos, químicos e/ou biológicos do solo, conforme relatado por Abranches et al., (2021).

Contudo, no decorrer dos anos, essa leguminosa acabou se tornando uma espécie problemática para a cultura da cana, devido a geminação escalonada das suas sementes (Sousa et al., 2023). Esse desafio tem sido agravado, conforme destacado por Ramos et al. (2018), devido a crescente adoção da colheita mecanizada nos canaviais. Além disso, o controle desta erva daninha é ainda mais complicado pela sua comprovada resistência aos herbicidas comumente empregados, conforme relatado por Silva et al. (2012), demonstrando sua tolerância a produtos tradicionalmente utilizados para seu manejo em ambientes agrícolas. Todo esse processo descrito, também ocorreu na área de estudo desta pesquisa, o que tornou a leguminosa um problema fitossanitário a ser considerado e tratado.

Figura 10 - Vista aérea de plantio de cana-de-açúcar na propriedade onde foi realizada esta pesquisa, permitindo a visualização do resultado negativo da ação da leguminosa.



Fonte: autor

Neste sentido, é importante conhecer o ciclo da planta daninha, para minimizar impactos negativos que possam ocorrer nas lavouras. Um importante estudo, foi desenvolvido por Bressanin et al. (2016), que possibilitou a determinação do período crítico para a prevenção da mucuna-preta nas áreas de plantio. Os autores perceberam que a intervenção deve ocorrer entre o intervalo de 50 a 188 dias após o plantio da cana-de-açúcar, representando, desta forma, uma janela de 138 dias para a realização de ações que combatam e previnam a disseminação da praga, evitando perda de produtividade e da qualidade do produto colhido. Segundo os autores, a mucuna-preta ocasionou a relevante diminuição de cerca de 50% da produtividade na área de pesquisa do respectivo estudo.

O levantamento aéreo desta pesquisa, foi realizado entre, no mínimo, 98 dias após o plantio (Zona 5) e, no máximo, 107 dias após o plantio (Zona 2), ou seja, dentro da janela de 138 dias para a possível tomada de ações para controle e enfrentamento da planta daninha, conforme sugerido por Bressanin et al. (2016). Desse modo, no decorrer deste trabalho, serão apresentados mapas com a definição de zonas de manejo fitossanitário, dentro do intervalo pré-

determinado, como forma de direcionar os esforços para tratamento e supervisão da incidência da mucuna-preta nos plantios de cana-de-açúcar estudados, já que a germinação das suas sementes ocorre de forma escalonada e a tendência é a continuidade da sua incidência, como problemática, nos plantios no decorrer dos anos seguintes.

4.3.4 Validação Cruzada

Os valores de validação cruzada, tanto para a *Krigagem* Ordinária (KO) quanto para o *Support Vector Machine* (SVM), nas duas amostragens testadas, apresentaram estimativas bem próximas e correlacionáveis, quando comparados os valores do coeficiente de determinação (r^2) e do erro quadrático médio (RMSE), como pode ser verificado nas Tabelas 8 e 9 e nas Figuras 10, 11, 12 e 13, que serão mais bem relatadas no decorrer dos próximos tópicos.

Apesar de valores bem próximos, por meio de uma análise mais detalhada na comparação entre os métodos de interpolação e as amostragens adotadas, percebe-se que os mapas de *Krigagem* Ordinária gerados a partir da amostragem aleatória, apresentaram, no geral, resultados levemente melhores que os demais.

Comparativos entre amostragem por malha regular e aleatória, por métodos geoestatísticos, também foram realizados por Arantes et al. (2019), porém para a extração de valores do índice de vegetação NDVI (*Normalized Difference Vegetation Index*), calculados a partir de imagens do projeto *Landsat*. Ambas as amostragens se mostraram consistentes e sem diferença significativa entre elas, assim como ocorreu nesta pesquisa.

4.3.4.1 *Krigagem* Ordinária

A validação cruzada se mostrou satisfatória para a interpolação pelo método geoestatístico, com valores de coeficiente angular (b) sempre próximos a 1, variando de 0,861 (Zona 6) a 1,044 (Zona 9) e coeficiente linear (a) baixos, próximos de 0, variando de -0,032 (Zona 9) a 0,091 (Zona 6 e Zona 13), apresentando valores baixos de RMSE, que variou de 0,048 (Zona 9) a 0,078 (Zona 12), conforme Tabela 8 e Figuras 10 e 11.

4.3.4.2 *Support Vector Machine*

A validação cruzada produto da análise dos dados pelo método de *machine learning* proposto, também comprovaram a confiabilidade dos dados, devido aos bons valores obtidos, com coeficientes angulares (b) relativamente próximos a 1, variando de 1,098 (Zona 11) a 1,435 (Zona 9) e coeficientes lineares (a) baixos, próximos de 0, variando de -0,025 (Zona 11) a -

0,252 (Zona 6), apresentando valores baixos de RMSE, variando de 0,064 (Zona 9) a 0,083 (Zona 12), de acordo com as Tabela 9 e Figuras 12 e 13.

Tabela 8 - Validação cruzada da interpolação por *Krigagem* para as malhas regular e aleatória.

Zona	<i>Krigagem</i> Malha Regular					<i>Krigagem</i> Malha Aleatória				
	a	b	r ²	RMSE	Regressão	a	b	r ²	RMSE	Regressão
Z1	-0,008	1,013	0,392	0,067	$Y = 1,013x - 0,008$	0,013	0,980	0,507	0,060	$Y = 0,980x + 0,013$
Z2	0,021	0,968	0,334	0,074	$Y = 0,968x + 0,021$	-0,019	1,026	0,428	0,068	$Y = 1,026x - 0,019$
Z3	0,022	0,968	0,356	0,053	$Y = 0,968x + 0,022$	-0,007	1,009	0,409	0,051	$Y = 1,009x - 0,007$
Z4	0,016	0,977	0,358	0,060	$Y = 0,977x + 0,016$	0,037	0,947	0,340	0,055	$Y = 0,947x + 0,037$
Z5	0,008	0,988	0,485	0,065	$Y = 0,988x + 0,008$	0,017	0,975	0,480	0,067	$Y = 0,975x + 0,017$
Z6	0,091	0,861	0,228	0,075	$Y = 0,861x + 0,091$	0,046	0,930	0,245	0,078	$Y = 0,930x + 0,046$
Z7	0,045	0,933	0,319	0,069	$Y = 0,933x + 0,045$	0,057	0,914	0,362	0,071	$Y = 0,914x + 0,057$
Z8	0,022	0,966	0,246	0,074	$Y = 0,966x + 0,022$	0,023	0,965	0,267	0,064	$Y = 0,965x + 0,023$
Z9	-0,032	1,044	0,364	0,048	$Y = 1,044x - 0,032$	-0,001	1,001	0,333	0,051	$Y = 1,001x - 0,001$
Z10	0,031	0,954	0,242	0,069	$Y = 0,954x + 0,031$	0,007	0,989	0,370	0,065	$Y = 0,989x + 0,007$
Z11	0,038	0,944	0,275	0,052	$Y = 0,944x + 0,038$	0,055	0,920	0,323	0,050	$Y = 0,921x + 0,055$
Z12	0,033	0,950	0,280	0,078	$Y = 0,950x + 0,033$	0,049	0,926	0,256	0,071	$Y = 0,926x + 0,049$
Z13	0,091	0,865	0,202	0,068	$Y = 0,865x + 0,091$	0,195	0,710	0,203	0,081	$Y = 0,710x + 0,195$

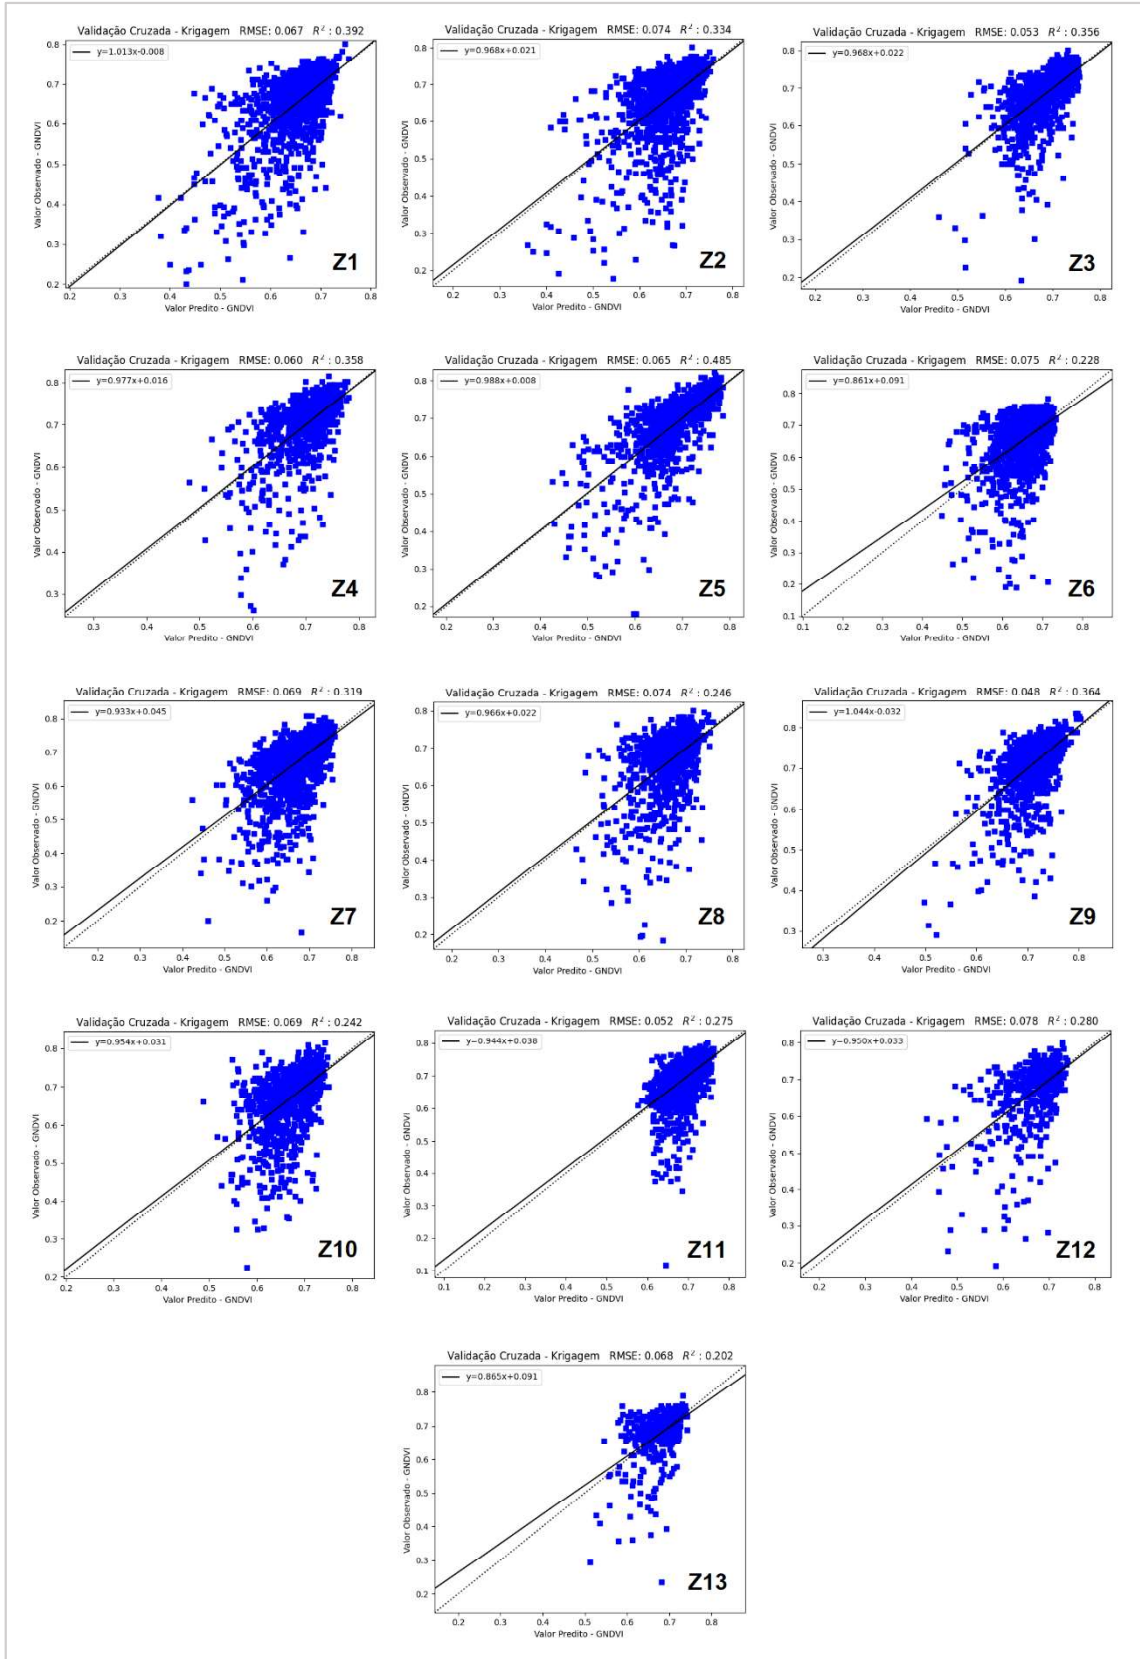
Fonte: autor.

Tabela 9 - Validação cruzada da interpolação por *Support Vector Machine* para as malhas regular e aleatória.

Zona	<i>Support Vector Machine</i> Malha Regular					<i>Support Vector Machine</i> Malha Aleatória				
	a	b	r ²	RMSE	Regressão	a	b	r ²	RMSE	Regressão
Z1	-0,133	1,251	0,360	0,074	$Y = 1,251x - 0,133$	-0,117	1,234	0,488	0,069	$Y = 1,234x - 0,117$
Z2	-0,187	1,339	0,311	0,081	$Y = 1,339x - 0,187$	-0,089	1,193	0,390	0,079	$Y = 1,193x - 0,089$
Z3	-0,083	1,176	0,288	0,065	$Y = 1,176x - 0,083$	-0,218	1,397	0,385	0,065	$Y = 1,397x - 0,218$
Z4	-0,232	1,398	0,330	0,071	$Y = 1,398x - 0,232$	-0,090	1,187	0,308	0,067	$Y = 1,187x - 0,090$
Z5	-0,130	1,245	0,473	0,072	$Y = 1,245x - 0,130$	-0,080	1,166	0,472	0,074	$Y = 1,166x - 0,080$
Z6	-0,252	1,435	0,220	0,080	$Y = 1,435x - 0,252$	-0,298	1,515	0,238	0,084	$Y = 1,515x - 0,298$
Z7	-0,106	1,209	0,300	0,076	$Y = 1,209x - 0,106$	-0,202	1,362	0,363	0,077	$Y = 1,362x - 0,363$
Z8	-0,185	1,327	0,221	0,079	$Y = 1,327x - 0,185$	-0,149	1,270	0,216	0,071	$Y = 1,270x - 0,149$
Z9	-0,190	1,340	0,345	0,064	$Y = 1,340x - 0,190$	-0,026	1,096	0,316	0,065	$Y = 1,096x - 0,026$
Z10	-0,109	1,210	0,223	0,075	$Y = 1,210x - 0,109$	-0,169	1,300	0,306	0,073	$Y = 1,300x - 0,169$
Z11	-0,025	1,098	0,252	0,065	$Y = 1,098x - 0,025$	-0,167	1,310	0,312	0,063	$Y = 1,310x - 0,167$
Z12	-0,177	1,311	0,247	0,083	$Y = 1,311x - 0,177$	-0,119	1,233	0,250	0,078	$Y = 1,233x - 0,119$
Z13	-0,205	1,378	0,120	0,080	$Y = 1,378x - 0,205$	-0,131	1,248	0,210	0,085	$Y = 1,248x - 0,131$

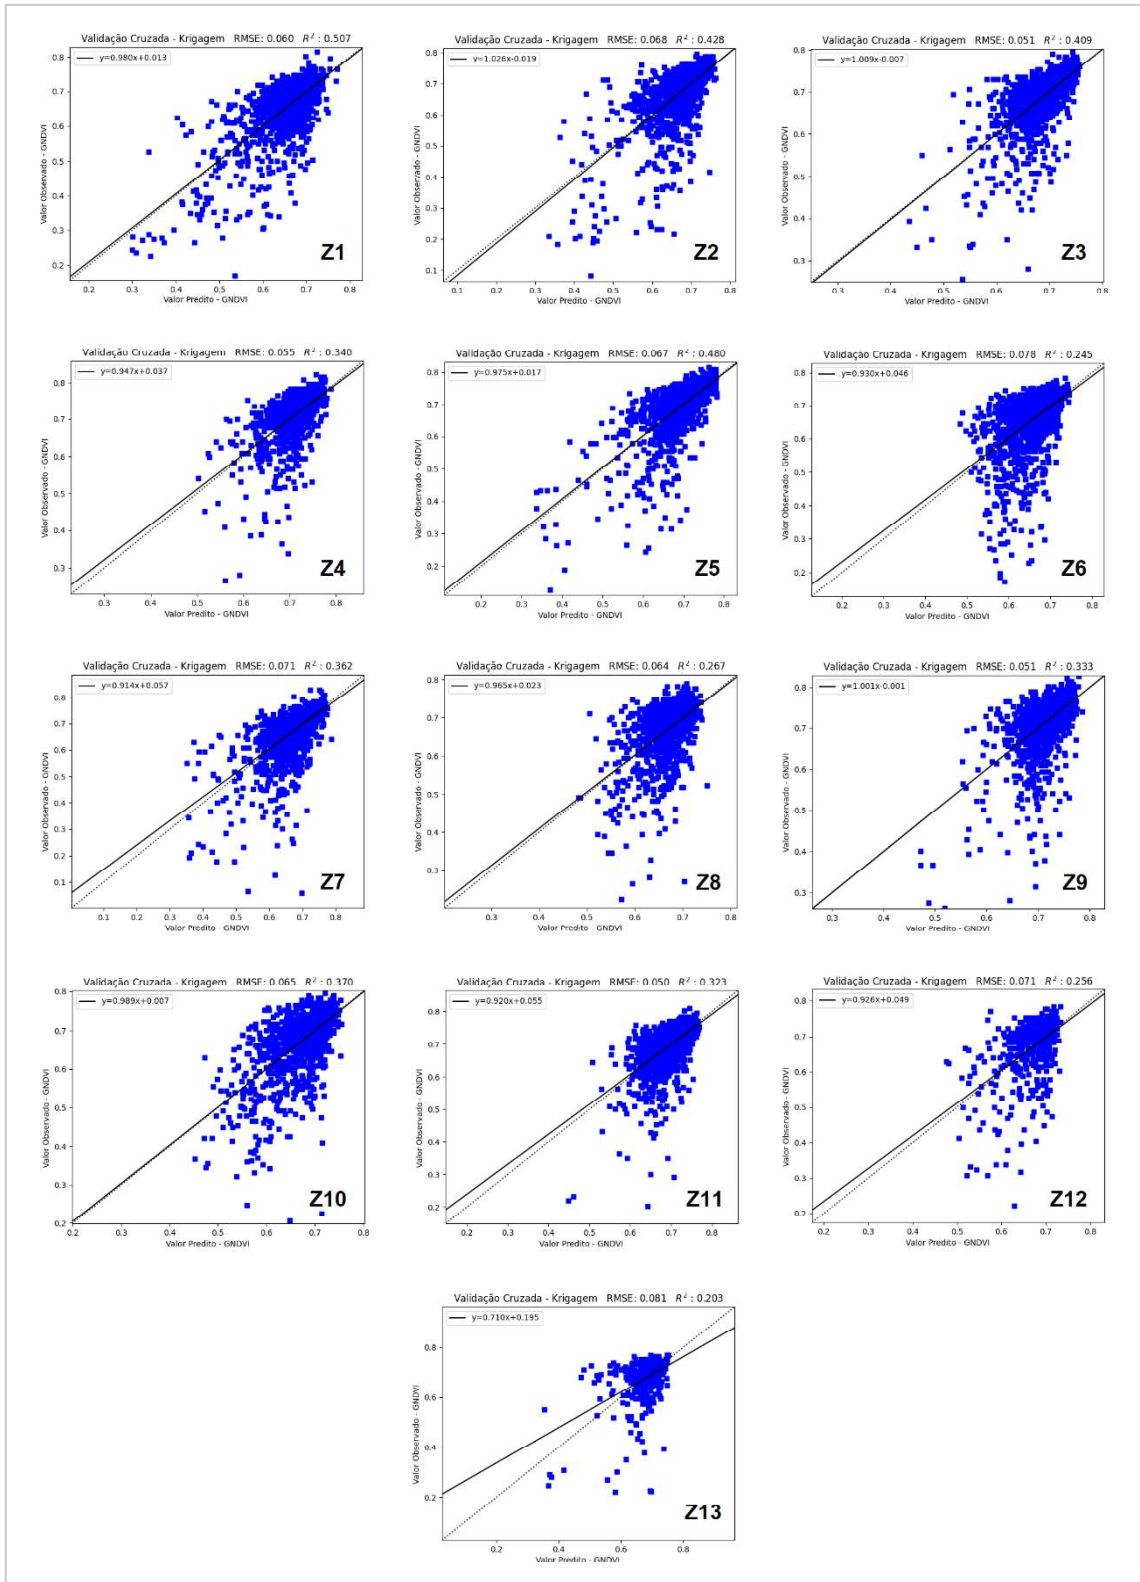
Fonte: autor.

Figura 11 - Gráfico com a validação cruzada da interpolação por *Krigagem* para a malha regular.



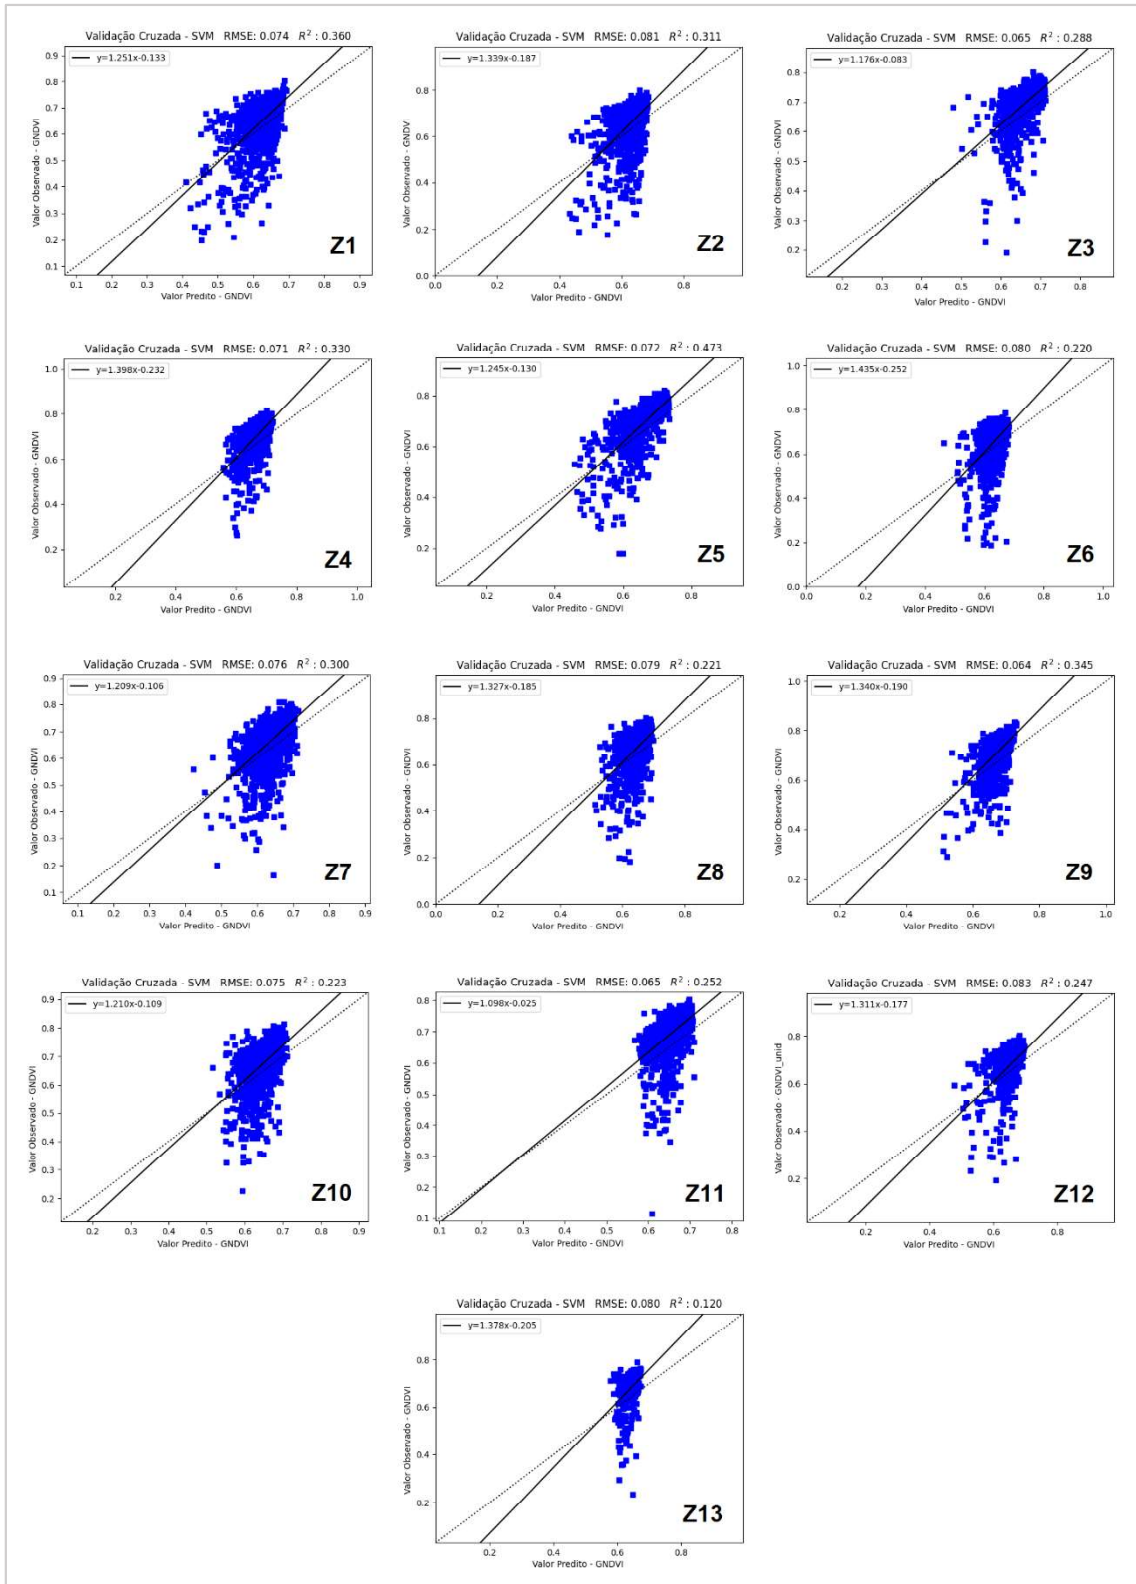
Fonte: autor.

Figura 12 - Gráfico com a validação cruzada da interpolação por *Krigagem* para a malha aleatória.



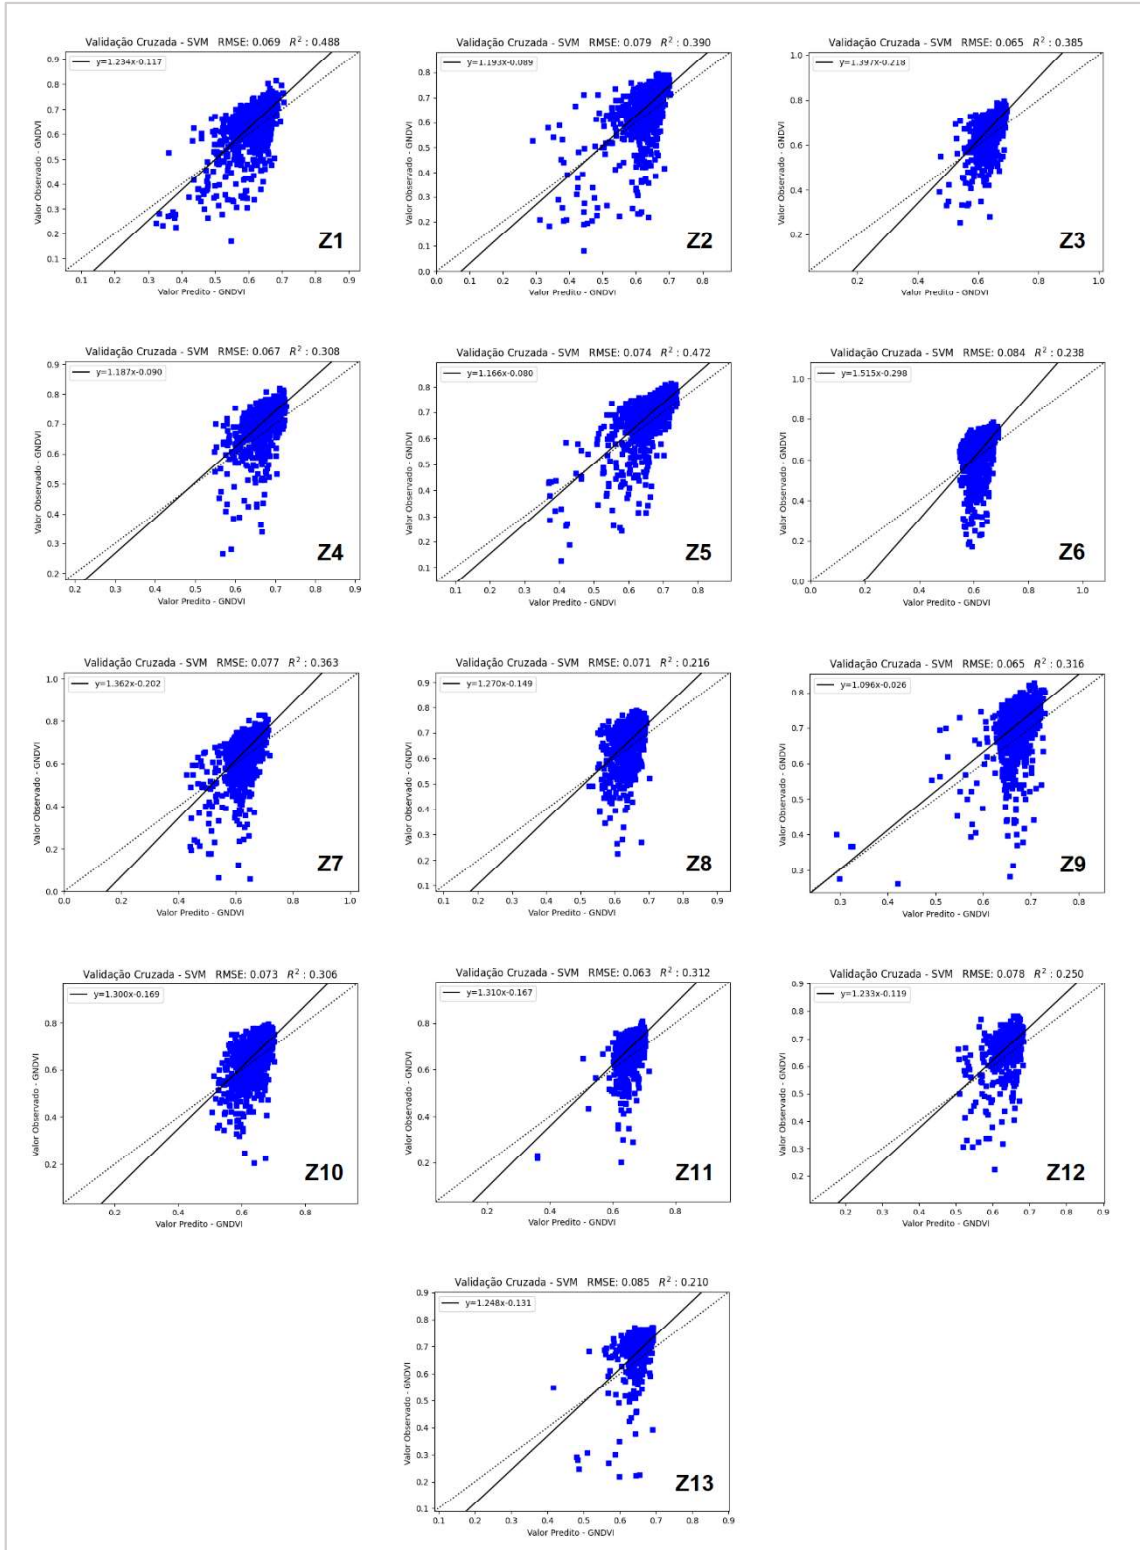
Fonte: autor.

Figura 13 - Gráfico com a validação cruzada da interpolação por *Support Vector Machine* para a malha regular.



Fonte: autor.

Figura 14 - Gráfico com a validação cruzada da interpolação por *Support Vector Machine* para a malha aleatória.




Fonte: autor.

4.3.4.3 Correlação entre os Interpoladores

Como relatado anteriormente, os valores de r^2 e RMSE apresentaram valores similares, conforme correlograma apresentado na Figura 14. Todas as correlações testadas, refletiram em r de Pearson acima de 0,70, variando de 0,78 a 0,98, considerado como correlações de magnitude forte, tanto para Cohen (1992) e Rumsey (2016). As fortes correlações apresentadas, justificaram a construção dos mapas de zonas de manejo com a integração entre KO e SVM com ambas as amostragens adotadas, como forma de otimizar os produtos gerados desta pesquisa.

Figura 15 - Correlograma com os valores de correlação de Pearson entre os valores de r^2 e RMSE entre as malhas regular e aleatória. KR: *Krigagem* malha Regular; KA: *Krigagem* malha Aleatória; SVMR: *Support Vector Machine* malha Regular; SVMMA: *Support Vector Machine* malha Aleatória.



Fonte: autor.

4.3.5 Mapas de Zonas de Manejo Fitossanitário

4.3.5.1 Relação entre FPI e NCE

O resultado das relações entre o Índice de Performance Fuzzy (FPI) e a Entropia de Classificação Normalizada (NCE), foi utilizado como critério para definir a quantidade ideal de classes para cada uma das 13 zonas de pesquisa (Tabela 10). Os valores de FPI podem variar de 0 a 1, onde, quanto mais próximos de 0, interpreta-se que há presença de classes distintas e, quanto mais próximo de 1, indicam ausência de classes distintas. É possível perceber que os valores estão bem próximos de 0, com uma média geral de 0,069. Já em relação aos valores de NCE, eles também estão bem próximos de 0, com uma média de 0,078. Vale ainda ressaltar, que existe uma forte correlação entre os valores obtidos de FPI e NCE, tanto para Cohen (1992) quanto para Rumsey (2016), representada por um valor r de Pearson igual a 0,906.

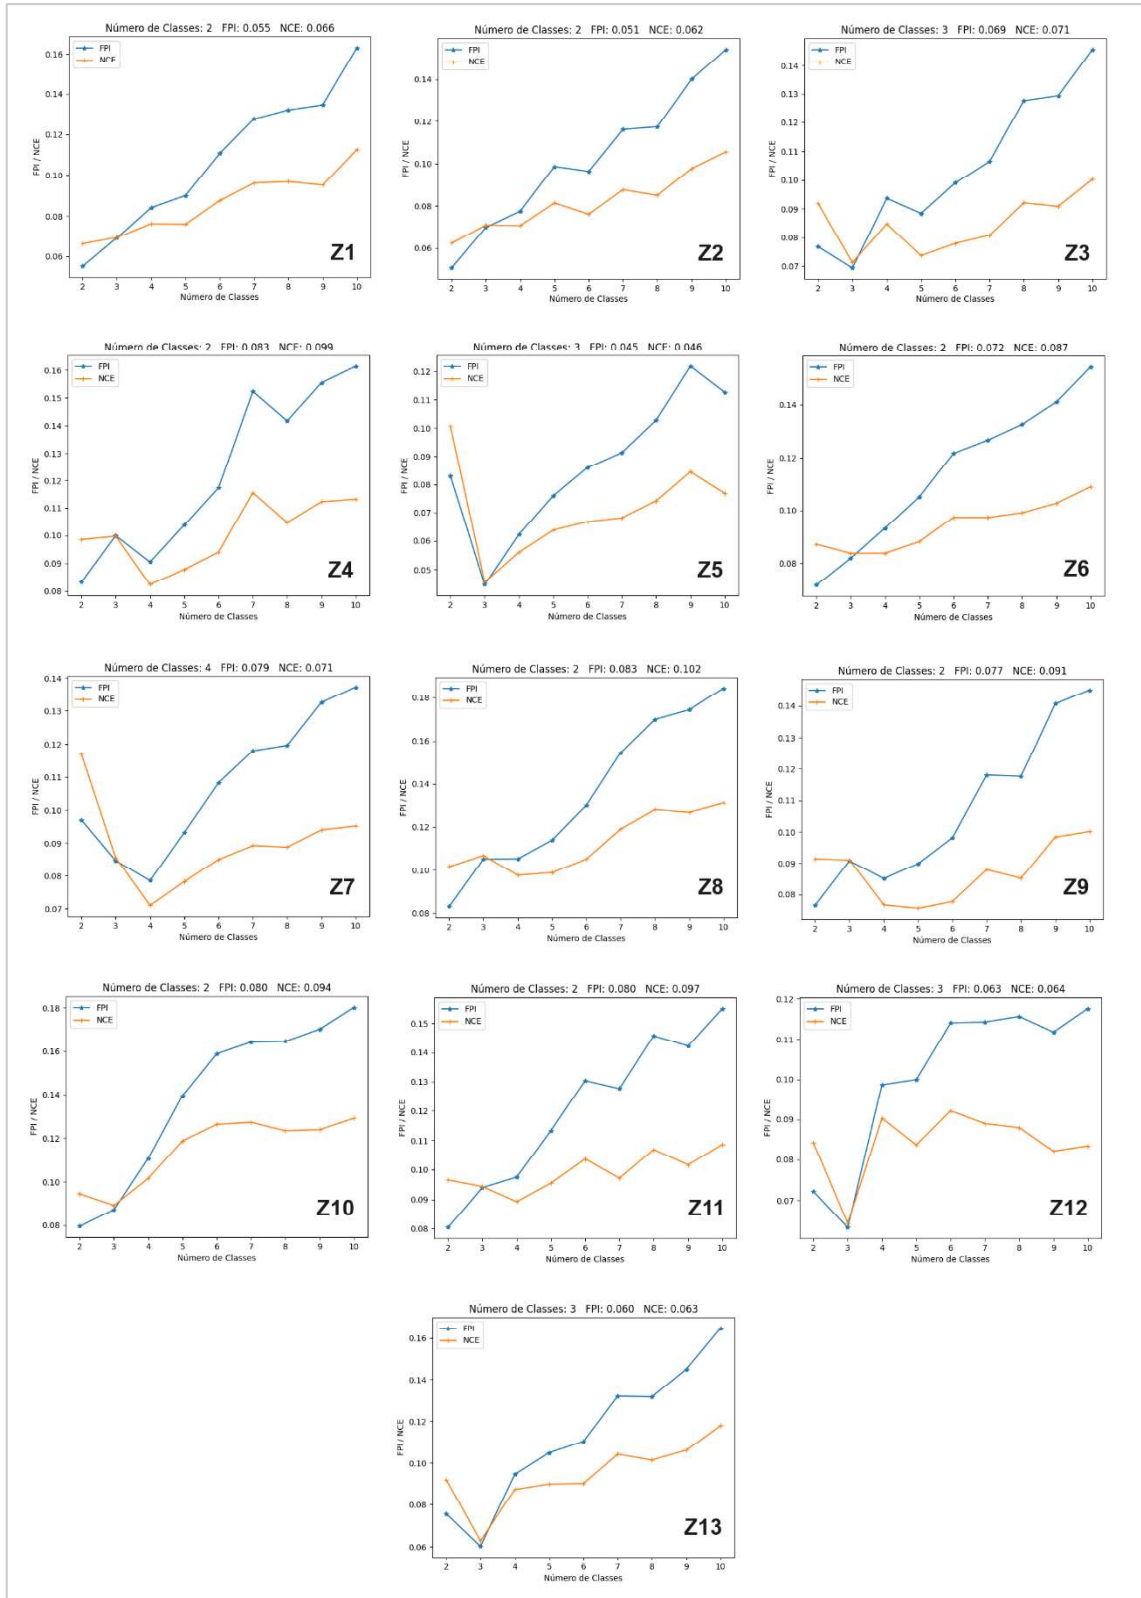
Segundo Moharana et al. (2020), o número ideal de classes é determinado quando cada índice está com valores mínimos, o que representa a menor participação dos membros (no caso do FPI) ou a maior quantidade de organização (no caso do NCE). Nesta pesquisa, é possível perceber que ambos os valores estão bem próximos de 0, demonstrando presença de uma boa relação para a detecção de classes distintas em cada zona de estudo. Por consequência disto, todas as zonas apresentaram classes distintas, sendo que a maioria apresentou 2 classes distintas. Por sua vez, a Zona 7 apresentou a maior quantidade de classes distintas dentre as zonas avaliadas, distinguindo 4 classes no total. A Figura 15 ilustra os gráficos com a relação existente entre FPI e NCE.

Tabela 10 - Relação entre o Índice de Performance Fuzzy (FPI), a Entropia de Classificação Normalizada (NCE) e o resultado do número considerado ideal de classes para cada zona de pesquisa.

ZONAS	FPI	NCE	NÚMERO DE CLASSES
Z1	0,055	0,066	2
Z2	0,051	0,062	2
Z3	0,069	0,071	3
Z4	0,083	0,099	2
Z5	0,045	0,046	3
Z6	0,072	0,087	2
Z7	0,079	0,071	4
Z8	0,083	0,102	2
Z9	0,077	0,091	2
Z10	0,080	0,094	2
Z11	0,080	0,097	2
Z12	0,063	0,064	3
Z13	0,060	0,063	3

Fonte: autor.

Figura 16 – Gráficos com as relações entre o Índice de Performance Fuzzy (FPI) e a Entropia de Classificação Normalizada (NCE) para cada zona de pesquisa.



Fonte: autor.

4.3.5.2 Zonas de Manejo Fitossanitário

Os mapas com as zonas de manejo fitossanitário representam os principais produtos deste trabalho, permitindo a visualização de potenciais porções onde há maior incidência da ação da planta daninha mucuna-preta nas zonas de pesquisa (Figura 16). Pedroso et al. (2010), fazem um excelente retrospecto relacionado a alguns termos voltados para a agricultura de precisão, definindo Zona de Manejo, como uma área espacialmente contígua à qual um tratamento específico pode ser aplicado.

Neste sentido, como as classes identificadas nas 13 zonas de pesquisa deste trabalho, por meio da relação FPI e NCE, apresentam padrões semelhantes, a tendência é a de que possam receber o mesmo tratamento fitossanitário, como a aplicação de determinados herbicidas, por exemplo, no intuito de combater os focos de incidência da planta daninha nas zonas de estudo, variando a dosagem e metodologia de aplicação, de acordo com o período do ciclo da planta.

Vários estudos, incluindo os conduzidos por Silva et al. (2012), Bressanin et al. (2015) e Dias et al. (2021), empregaram diversos herbicidas para resolver problemas semelhantes. Suas descobertas se alinham e contribuem para os resultados desta pesquisa, visando uma abordagem de gestão mais integrada, otimizada e sustentável para o problema. Esta abordagem visa minimizar o impacto ambiental, aumentar a eficácia e reduzir custos para os produtores.

A maioria dos mapas de manejo produzidos, conseguiram distinguir apenas duas classes, diferenciadas por meio de determinadas colorações. A coloração verde-escura, representa as porções onde se encontram as plantas de cana-de-açúcar possivelmente mais saudáveis, enquanto as porções em coloração vermelho mais escuro, representam as porções, onde, provavelmente, a leguminosa prejudica o desenvolvimento e crescimento saudável da cana.

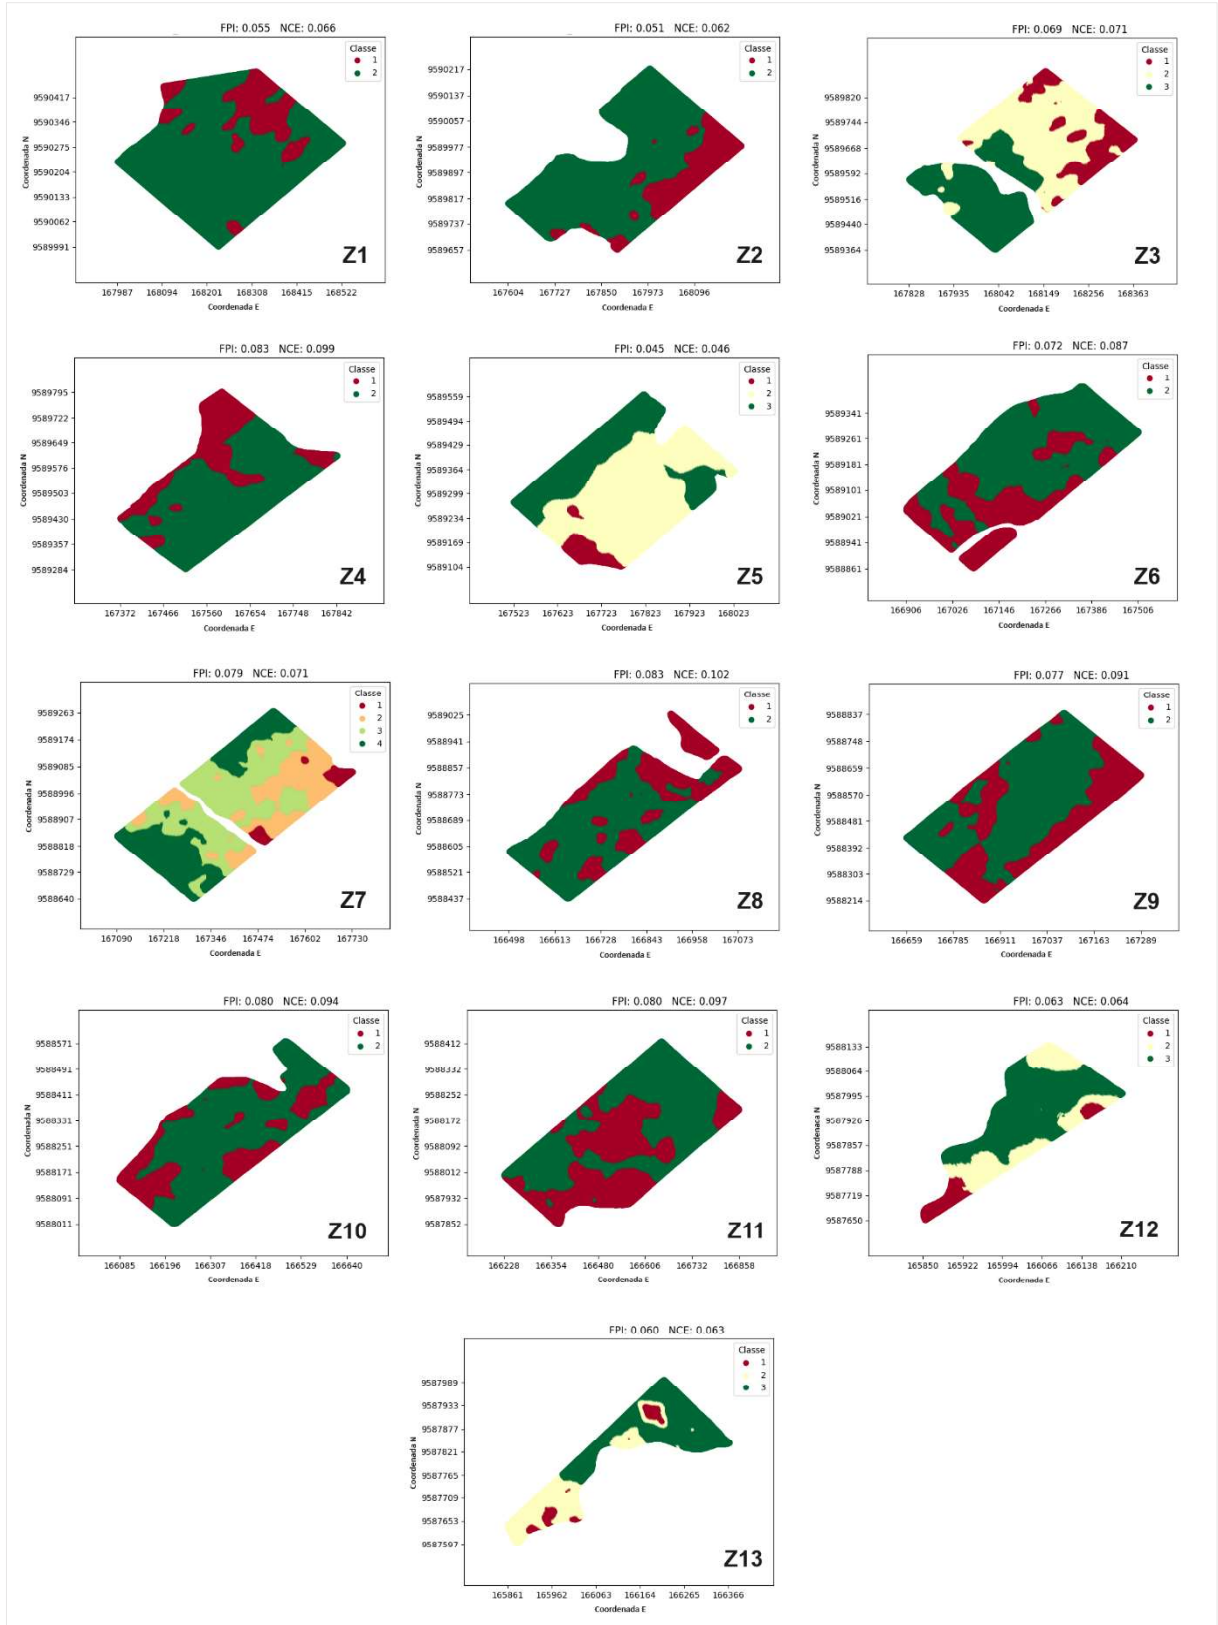
Além dessas duas colorações presentes em todas as zonas de estudo, nas Zonas 3, 5, 12 e 13, também foi possível a identificação de uma terceira classe, diferenciada com uma coloração amarelada, possivelmente representando locais de transição entre as porções com plantas mais saudáveis e porções com a presença mais ativa da mucuna-preta.

A Zona 7 foi a única que apresentou quatro classes, apresentando, assim, uma maior variabilidade. Duas dessas classes também se fizeram presentes nas demais zonas de estudo, porém foi possível a captação de outras duas classes, bem próximas às duas normalmente identificadas. A interpretação é a de que a porção verde mais clara, seja uma área saudável, porém com parâmetros fitossanitários inferiores às de coloração verde mais escuro. No mesmo sentido, segue a interpretação para a classe com a coloração mais alaranjada, que, possivelmente, representa uma porção menos saudável, porém com indicadores melhores que o da classe de coloração vermelha mais escura.

De acordo com Maia et al. (2023), a implementação de zonas de gestão destaca-se como uma das estratégias mais eficazes para aumentar a eficiência agrícola. Isso ressalta a importância das tecnologias inovadoras em comparação com as abordagens convencionais, servindo como meio de otimizar tempo, mão de obra e recursos financeiros no setor sucroalcooleiro. Tal ênfase reforça a importância de esforços de pesquisa contínuos, semelhantes ao trabalho realizado neste estudo.

O presente estudo alinha-se com a tendência destacada por Somard et al. (2021), que observaram um número substancial de estudos dedicados ao manejo e monitoramento da cana-de-açúcar. Esses estudos visam aumentar a produtividade e as atividades operacionais, ressaltando a importância de pesquisas com foco no comportamento espectral da cultura.

Figura 17 - Mapas de Zonas de Manejo Fitossanitário produto das relações entre o Índice de Performance Fuzzy (FPI) e a Entropia de Classificação Normalizada (NCE) para cada zona de pesquisa.



Fonte: autor.

4.4 Conclusões

As principais conclusões relevantes para o objetivo desta pesquisa estão listadas abaixo:

- Os dados extraídos do GNDVI para as malhas regular e aleatória apresentaram bons parâmetros para a estatística descritiva, principalmente devido aos baixos valores de variância e desvio padrão, próximos à média, o que demonstra homogeneidade no conjunto de dados. O coeficiente de variação apresentou valores que o classificaram como ótimo ou bom, validando a qualidade e precisão da metodologia de amostragem.

- Houve dependência espacial em todas as zonas de pesquisa, em sua grande maioria classificada como moderada, apresentando bons resultados para os parâmetros Grau de Dependência Espacial (GDE), Índice de Dependência Espacial (IDE) e Índice de Moran (IM), possibilitando sua representação por meio dos semivariogramas e mapas de *krigagem*.

- Os interpoladores *Krigagem* Ordinária (KO) e Máquina de Vetores de Suporte (SVM) mostraram-se eficientes na demonstração da variabilidade espacial presente nas 13 zonas de pesquisa, tanto para amostragem regular quanto aleatória, o que foi confirmado pelos bons resultados da validação cruzada. No entanto, a KO com amostragem aleatória foi ligeiramente melhor que os demais, pois apresentou menores valores de erro (RMSE) e maiores coeficientes de determinação (r^2).

- A relação entre o Índice de Desempenho Fuzzy (FPI) e a Entropia de Classificação Normalizada (NCE) permitiu a integração dos mapas gerados pelos interpoladores propostos e a identificação de diferentes classes em todas as zonas, possibilitando a criação de mapas de zonas de manejo fitossanitário para aplicação em áreas com incidência da planta daninha mucuna-preta, durante a janela crítica de desenvolvimento da praga, a fim de otimizar a tomada de decisão do produtor.

REFERÊNCIAS

- ABRANCHES, M. O.; SILVA, G. A. M.; SANTOS, L. C.; PEREIRA, L. F.; FREITAS, G. B. Contribuição da adubação verde nas características químicas, físicas e biológicas do solo e sua influência na nutrição de hortaliças. **Research, Society and Development**, v. 10, n. 7, p. e7410716351, 2021. <https://doi.org/10.33448/rsd-v10i7.16351>.
- ABREU, J. F. Tributo a Waldo Tobler: cientista, geógrafo, cartógrafo. **Geografia**, v. 43, n. 2, p. 335-337, 2018.
- AMBROSANO, E. J.; FOLTRAN, D. E.; CAMARGO, M. S.; ROSSI, F.; SCHAMMASS, E. A.; SILVA, E. C.; AMBROSANO, G. M. B.; DIAS, F. L. F. Acúmulo de biomassa e nutrientes por adubos verdes e produtividade da cana-de-açúcar cultivada em sucessão, em duas localidades de São Paulo, Brasil. **Revista Brasileira de Agroecologia**, v. 8, n. 1, p. 199-209, 2013.
- ARANTES, T. B.; CARVALHO, L. M. T.; ZANELLA, L.; BELCHIOR, I.; ARAUJO, L. Comparação de métodos de amostragens para aplicação da geoestatística em imagem Landsat NDVI. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**, 2019.
- ASSUMPÇÃO, H. C. P.; HADLICK, G. M. Estatística descritiva e estacionariedade em variáveis geoquímicas ambientais. **Engenharia Sanitária e Ambiental**, v. 22, n. 4, p. 671-677, 2017. <https://doi.org/10.1590/S1413-41522017142739>.
- BEZDEK, J. C. **Pattern recognition with fuzzy objective function algorithms**. Estados Unidos: Springer, 1981. 256 p. <https://doi.org/10.1007/978-1-4615-5001-3>.
- BORG, D.; SESTITO, G. S.; SILVA, M. M. Machine-learning classification of environmental conditions inside a tank by analyzing radar curves in industrial level measurements. **Flow Measurement and Instrumentation**, v. 79, p. 101940, 2021. <https://doi.org/10.1016/j.flowmeasinst.2021.101940>.
- BRESSANIN, F. N.; GIANCOTTI, P. R. F.; JAYME NETO, N.; AMARAL, C. L.; ALVES, P. L. C. A. Eficácia de herbicidas aplicados isolados em pré e pós-emergência no controle de mucuna-preta. **Revista Brasileira de Ciências Agrárias**, v. 10, n. 3, p. 426-431, 2015. <https://doi.org/10.5039/agraria.v10i3a5337>.
- BRESSANIN, F. N.; JAYME NETO, N.; NEPOMUCENO, M. P.; ALVES, P. L. C. A.; CARREGA, W. C. Interference periods of velvet bean in sugarcane. **Ciência Rural**, v. 46, n. 8, p. 1329-1336, 2016. <https://doi.org/10.1590/0103-8478cr20150630>.
- CAMARGO, E. C. G. **Desenvolvimento, implementação e teste de procedimentos geostatísticos (krigeagem) no sistema de processamento de informações georreferenciadas (SPRING)**. Mestrado em Sensoriamento Remoto - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1997.
- CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa

soils. **Soil Science Society of America Journal**, v. 58, n. 5, p. 1501-1511, 1994. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>.

CARDOSO, L. A. S.; FARIAS, P. R. S.; SOARES, J. A. C.; CALDEIRA, C. R. T.; OLIVEIRA, F. J. Use of a UAV for statistical-spectral analysis of vegetation indices in sugarcane plants in the Eastern Amazon. **International Journal of Environmental Science and Technology**, 2024. <https://doi.org/10.1007/s13762-024-05477-z>.

CARDOSO, L. A. S.; FARIAS, P. R. S.; SOARES, J. A. C.; OLIVEIRA, F. J. Use of geostatistics in the sugarcane context in Brazil: a review. **Environment, Development and Sustainability**, 2023. <https://doi.org/10.1007/s10668-023-03927-1>.

CERVANTES, J.; GARCIA-LAMONT, F.; RODRÍGUEZ-MAZAHUA, L.; LOPES, A. A comprehensive survey on support vector machine classification: applications, challenges and trends. **Neurocomputing**, v. 408, n. 30, p. 189-215, 2020. <https://doi.org/10.1016/j.neucom.2019.10.118>.

COHEN, J. Statistical power analysis. **Current Directions in Psychological Science**, v. 1, n. 3, 1992. <https://doi.org/10.1111/1467-8721.ep10768783>.

CONAB. Acompanhamento da safra brasileira de cana-de-açúcar, safra 2023/2024, segundo levantamento, agosto/2023. **Companhia Nacional de Abastecimento**, v. 11, n. 2, 2023.

DIAS, R. C.; MUNHOZ, D. G.; BIANCHI, L.; ANUNCIATO, V. M.; TROPALDI, L.; SILVA, P. V.; CARBONARI, C. A.; VELINI, E. D. Resposta de glyphosate em mucuna-preta desenvolvida em diferentes temperaturas. **Research, Society and Development**, v. 10, n. 4, p. e49710414355, 2021. <https://doi.org/10.33448/rsd-v10i4.14355>.

FERREIRA, J. H. S.; OLIVEIRA, A. S.; DUARTE, D. G.; ALMEIDA, F. J.; PAES, J. S.; DELGADO, C. H. O. Eficácia do amicarbazone e flumioxazim no controle de *Merremia aegyptia*, *Mucuna aterrima* e *Ricinus communis* no sistema de cana crua. **Revista Brasileira de Herbicidas**, v. 19, n. 3, 2020. <https://doi.org/10.7824/rbh.v19i3.701>.

FERREIRA, P. V. **Estatística Experimental aplicada às ciências agrárias**. Viçosa: UFV, 2018. 588 p.

FOLEGATTI, M. V. **Estabilidade temporal e variabilidade espacial da umidade e do armazenamento de água em solo siltoso**. Tese (Livre-Docência) - Universidade de São Paulo, Piracicaba, 1996.

GITELSON, A. A.; MERZLYAK, M. N.; LICHTENTHALER, H. K. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. **Journal of Plant Physiology**, v. 148, n. 3-4, p. 501-508, 1996. [https://doi.org/10.1016/S0176-1617\(96\)80285-9](https://doi.org/10.1016/S0176-1617(96)80285-9).

GREENER, J. G.; KANDATHIL, S. M.; MOFFAT, L.; JONES, D. T. A guide to machine learning for biologists. **Nature Reviews Molecular Cell Biology**, v. 23, p. 40-45, 2022. <https://doi.org/10.1038/s41580-021-00407-0>.

GREGO, C. R.; OLIVEIRA, R. P.; VIEIRA, S. R. Geoestatística aplicada a Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.;

INAMASU, R. Y. **Agricultura de precisão: resultados de um novo olhar**. Brasília: Embrapa, 2014. p. 74-83.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. Estados Unidos: Oxford University, 1989. 575 p.

LEGENDRE, P.; FORTIN, M. J. Spatial pattern and ecological analysis. **Vegetatio**, v. 80, p. 107-138, 1989. <https://doi.org/10.1007/BF00048036>.

MACHADO, J.; SHINOHARA, N. K. S.; PADILHA, M. R. F.; SILVA, K. E.; BARRETO, T. S. C.P.; SILVA, A. G. S. S. Agricultura de precisão: programas tecnológicos no Brasil. **Revista Geama**, v. 4, n. 2, p. 23-30, 2018.

MAIA, F. C. O.; BUFON, V. B.; LEÃO, T. P. Vegetation indices as a tool for mapping sugarcane management zones. **Precision Agriculture**, v. 24, p. 213-234, 2023. <https://doi.org/10.1007/s11119-022-09939-7>.

McBRATNEY, A. B.; MOORE, A. W. Application of fuzzy sets to climatic classification. **Agricultural and Forest Meteorology**, v. 35, n. (1-4), p. 165-185, 1985. [https://doi.org/10.1016/0168-1923\(85\)90082-6](https://doi.org/10.1016/0168-1923(85)90082-6).

MINITAB. Análise da regressão: como interpretar o R-quadrado e avaliar a qualidade de ajuste. **Minitab**, 2019. Disponível em: <https://blog.minitab.com/pt/analise-de-regressao-como-interpretar-o-r-quadrado-e-avaliar-a-qualidade-de-ajuste/>. Acesso em: 21 mar. 2023.

MINITAB. Interpretar todas as estatísticas para armazenamento de estatísticas descritivas. **Minitab**, 2023. Disponível em: <https://support.minitab.com/pt-br/minitab/21/help-and-how-to/statistics/basic-statistics/how-to/store-descriptive-statistics/interpret-the-statistics/all-statistics/#stdev/>. Acesso em: 5 mai. 2023.

MOHARANA, P. C.; JENA, R. K.; PRADHAN, U. K.; NOGIYA, M.; TAILOR, B. L.; SINGH, R. S.; SINGH, S. K. Geostatistical and fuzzy clustering approach for delineation of site-specific management zones and yield limiting factors in irrigated hot arid environment of India. **Precision Agriculture**, v. 21, p. 426-448, 2020. <https://doi.org/10.1007/s11119-019-09671-9>.

OBROŚLAK, R.; DOROZHYNKY, O. Selection of a semivariogram model in the study of spatial distribution of soil moisture. **Journal of Water and Land Development**, v. 35, n. 4, p. 161-166, 2017. <https://doi.org/10.1515/jwld-2017-0080>.

OLEA, R. A. **Geostatistics for engineers and earth scientists**. Estados Unidos: Springer Science + Business Media - LLC, 1999. 303 p. <https://doi.org/10.1007/978-1-4615-5001-3>.

PEDROSO, M.; TAYLOR, J.; TISSEYRE, B.; CHARNOMORDIC, B.; GUILLAUME, S. A segmentation algorithm for the delineation of agricultural management zones. **Computers and Electronics in Agriculture**, v. 70, n. 1, p. 199-208, 2010. <https://doi.org/10.1016/j.compag.2009.10.007>.

PEREIRA, G. W.; VALENTE, D. S. M.; QUEIROZ, D. M.; COELHO, A. L. F.; COSTA, M. M.; GRIFT, T. Smart-Map: an open-source QGIS plugin for digital mapping using machine

learning techniques and ordinary kriging. **Agronomy**, v. 12, n. 6, p. 1350, 2022. <https://doi.org/10.3390/agronomy12061350>.

RAMOS, A. R.; FELISBERTO, P. A. C.; TIMOSSI, P. C.; COSTANETTO, A. P. Características agronômicas da mucuna-preta em diferentes épocas de sementeira. **Revista de Ciências Agrárias**, v. 41, n. 4, p. 1051-1058, 2018. <https://doi.org/10.19084/RCA17140>.

RUMSEY, D. J. **Statistics for Dummies**. Estados Unidos: For Dummies, 2016. 416 p.

SILVA, G. B. F.; AZANIA, C. A. M.; NOVO, M. C. S. S.; WUTKE, E. B.; ZERA, F. S.; AZANIA, A. A. P. M. Tolerância de espécies de mucuna preta a herbicidas utilizados na cultura da cana-de-açúcar. **Planta Daninha**, v. 30, n. 3, p. 589-597, 2012. <https://doi.org/10.1590/S0100-83582012000300015>.

SILVA, S. A.; LIMA, J. S. S.; SOUZA, G. S.; OLIVEIRA, R. B.; SILVA, A. F. Variabilidade espacial do fósforo e das frações granulométricas de um Latossolo Vermelho Amarelo. **Revista Ciência Agronômica**, v. 41, n. 1, p. 1-8, 2010. <https://doi.org/10.5935/1806-6690.20100001>.

SOM-ARD, J.; ATZBERGER, C.; IZQUIERDO-VERDIGUIER, E.; VUOLO, F.; IMMITZER, M. Remote sensing applications in sugarcane cultivation: a review. **Remote Sensing**, v. 13, n. 20, p. 4040, 2021. <https://doi.org/10.3390/rs13204040>.

SOUSA, H. F.; TIMOSSI, P. C.; COSTA NETTO, A. P.; TEIXEIRA, I. R.; SOUZA, G. C. Response of velvet bean seeds under the burning of sugarcane straw. **Revista Científica Rural**, v. 25, n. 1, p. 249-255, 2023. <https://doi.org/10.29327/246831.25.1-16>.

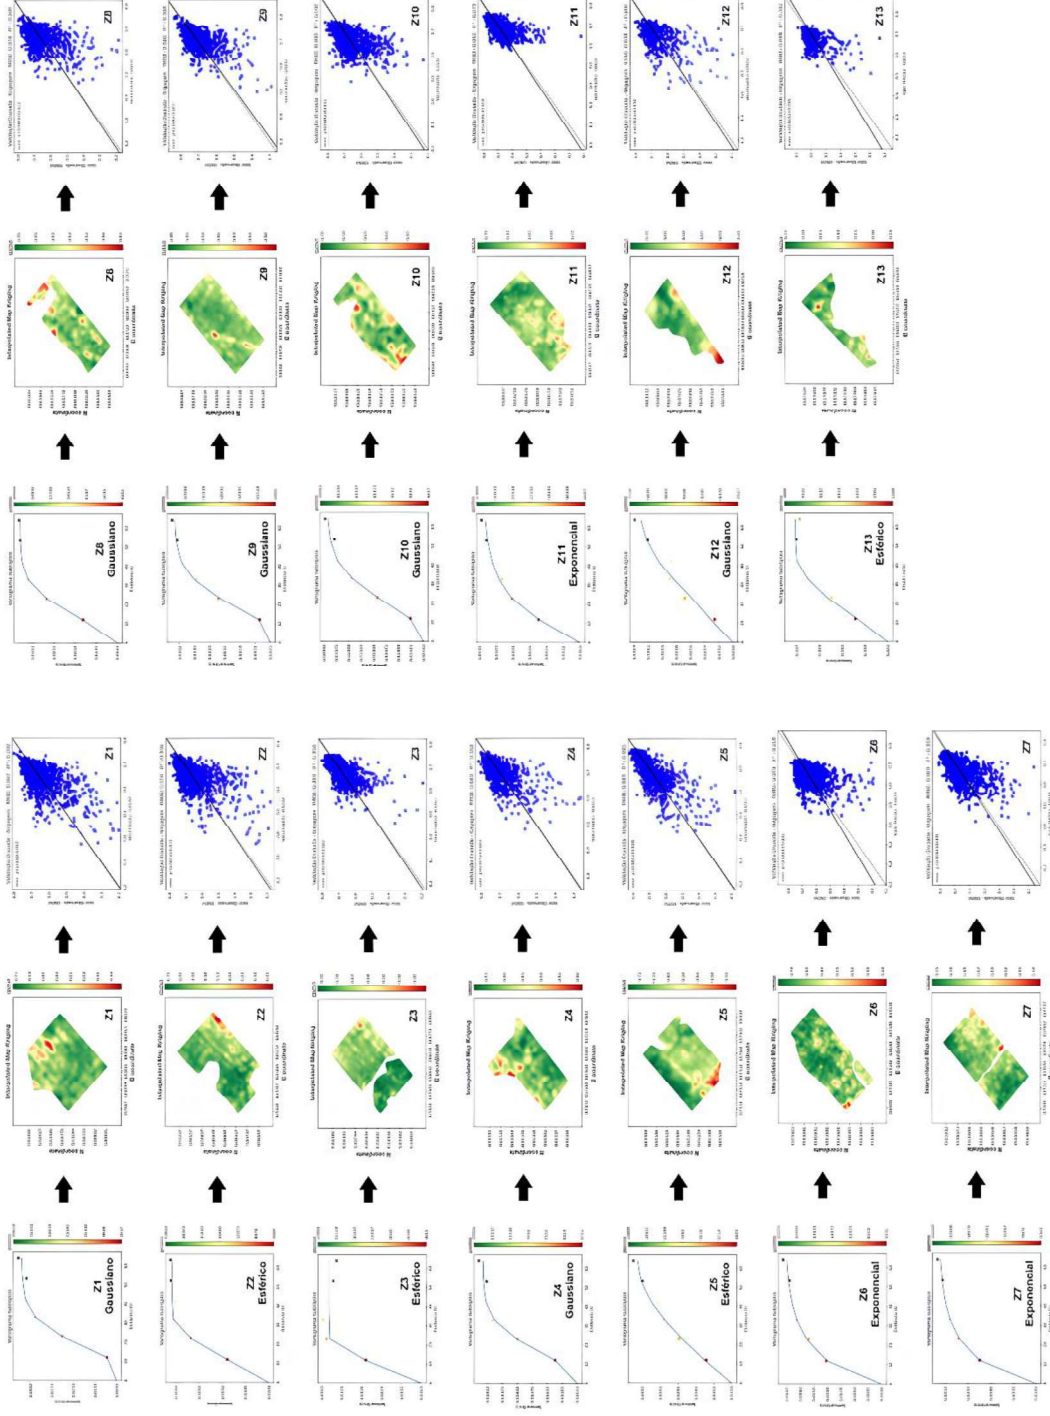
WIRIADINATA, H.; OHASHI, H.; ADEMA, F. Notes on Malesian Fabaceae (*Leguminosae-Papilionoideae*). 16. The genus *Mucuna*. **Blumea**, v. 61, p. 90-124, 2016. <http://dx.doi.org/10.3767/000651916X692799>.

WUTKE, E. B. Adubação verde: manejo da fitomassa e espécies utilizadas no estado de São Paulo. In: WUTKE, E. B.; BULISANI, E. A.; MASCARENHAS, H. A. A. **Curso sobre adubação verde no Instituto Agronômico**. Campinas: Instituto Agronômico, 1993. p. 17-29.

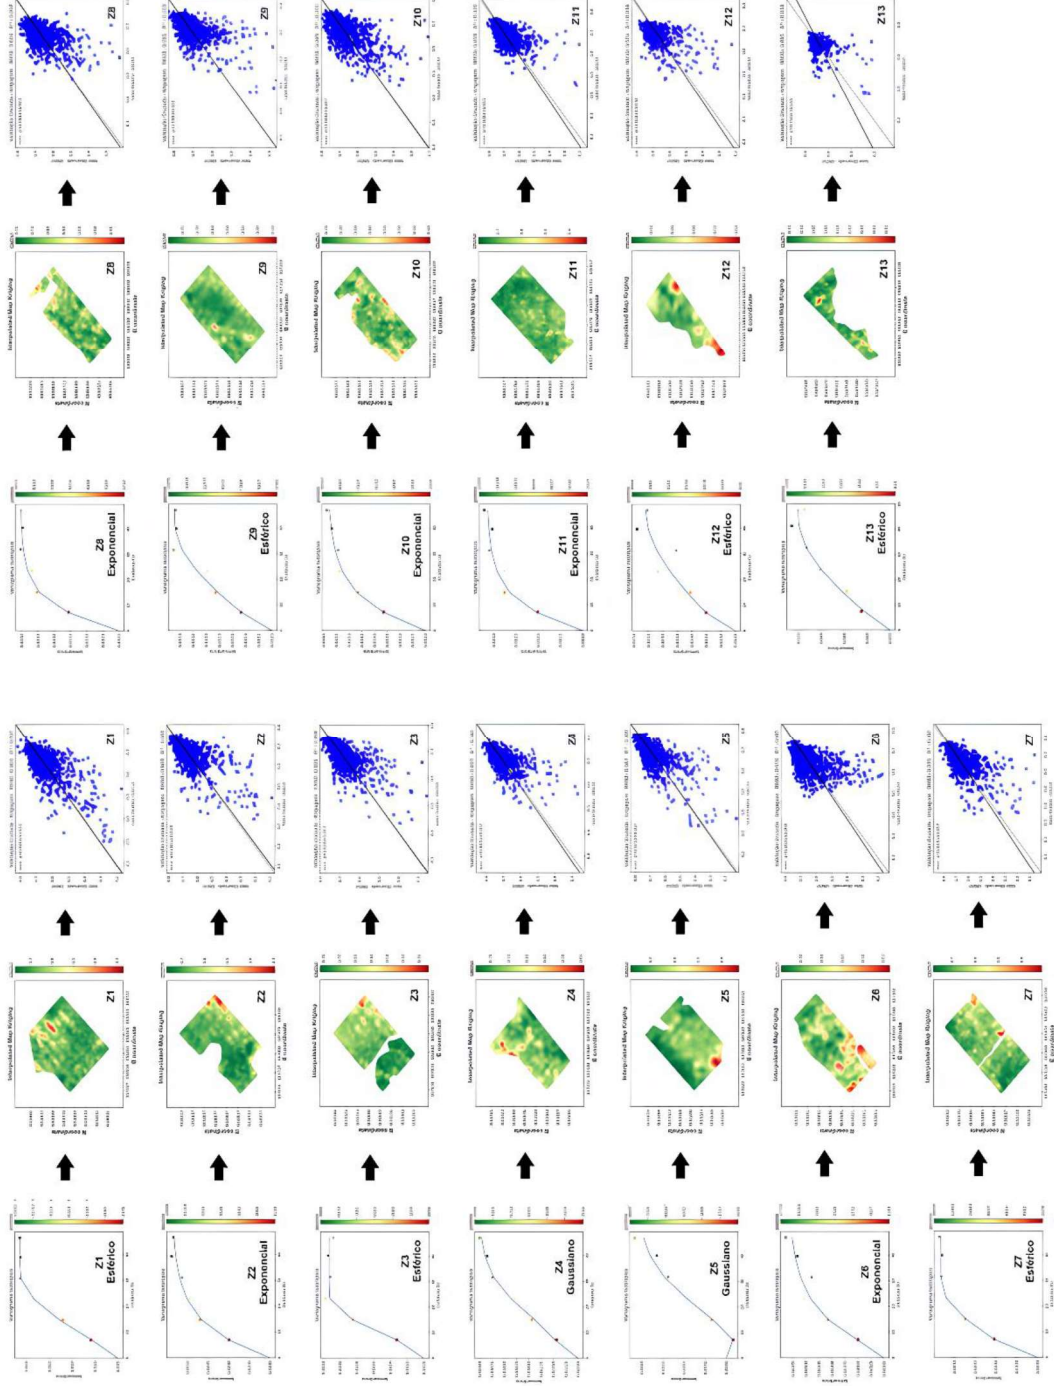
YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de Textos, 2013. 215 p.

ZIMBACK, C. R. L. **Análise espacial de atributos químicos de solos para fins de mapeamento da fertilidade**. Tese (Livre-Docência) - Universidade Estadual Paulista, Botucatu, 2001.

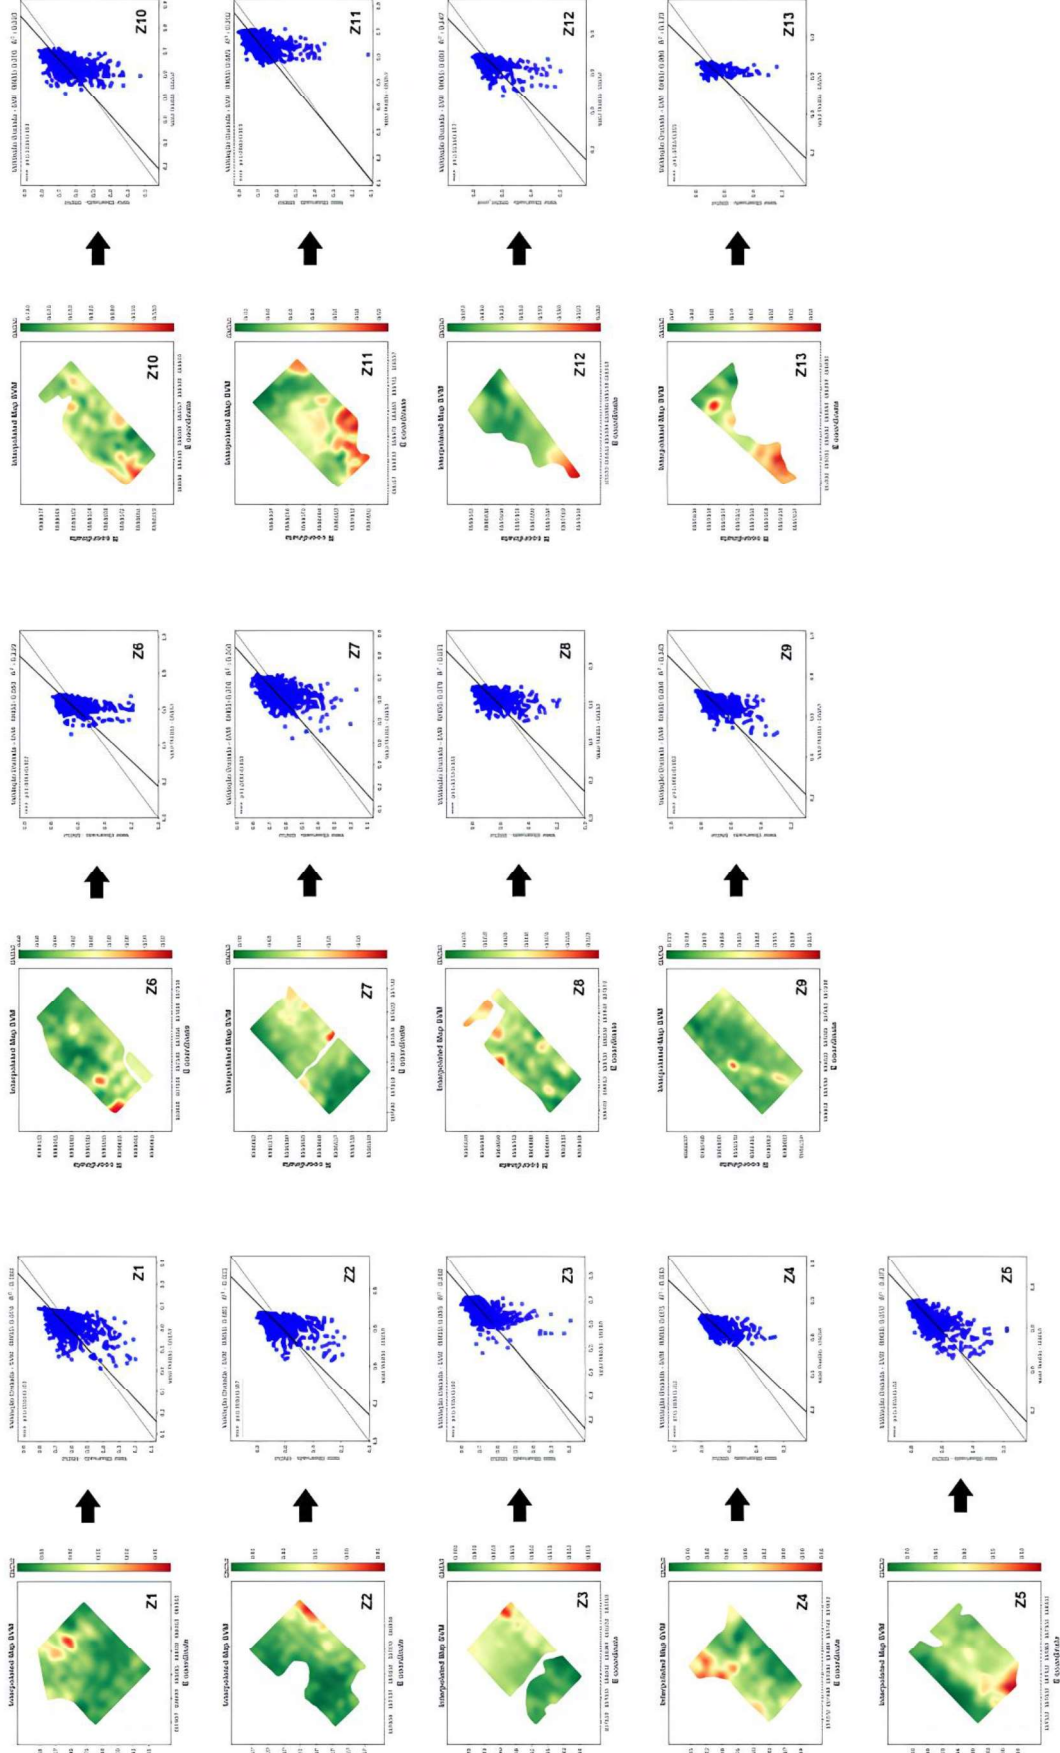
APÊNDICE I - Fluxo entre semivariogramas, mapas de krigagem ordinária e validações cruzadas para cada zona de estudo com malha de amostragem regular.



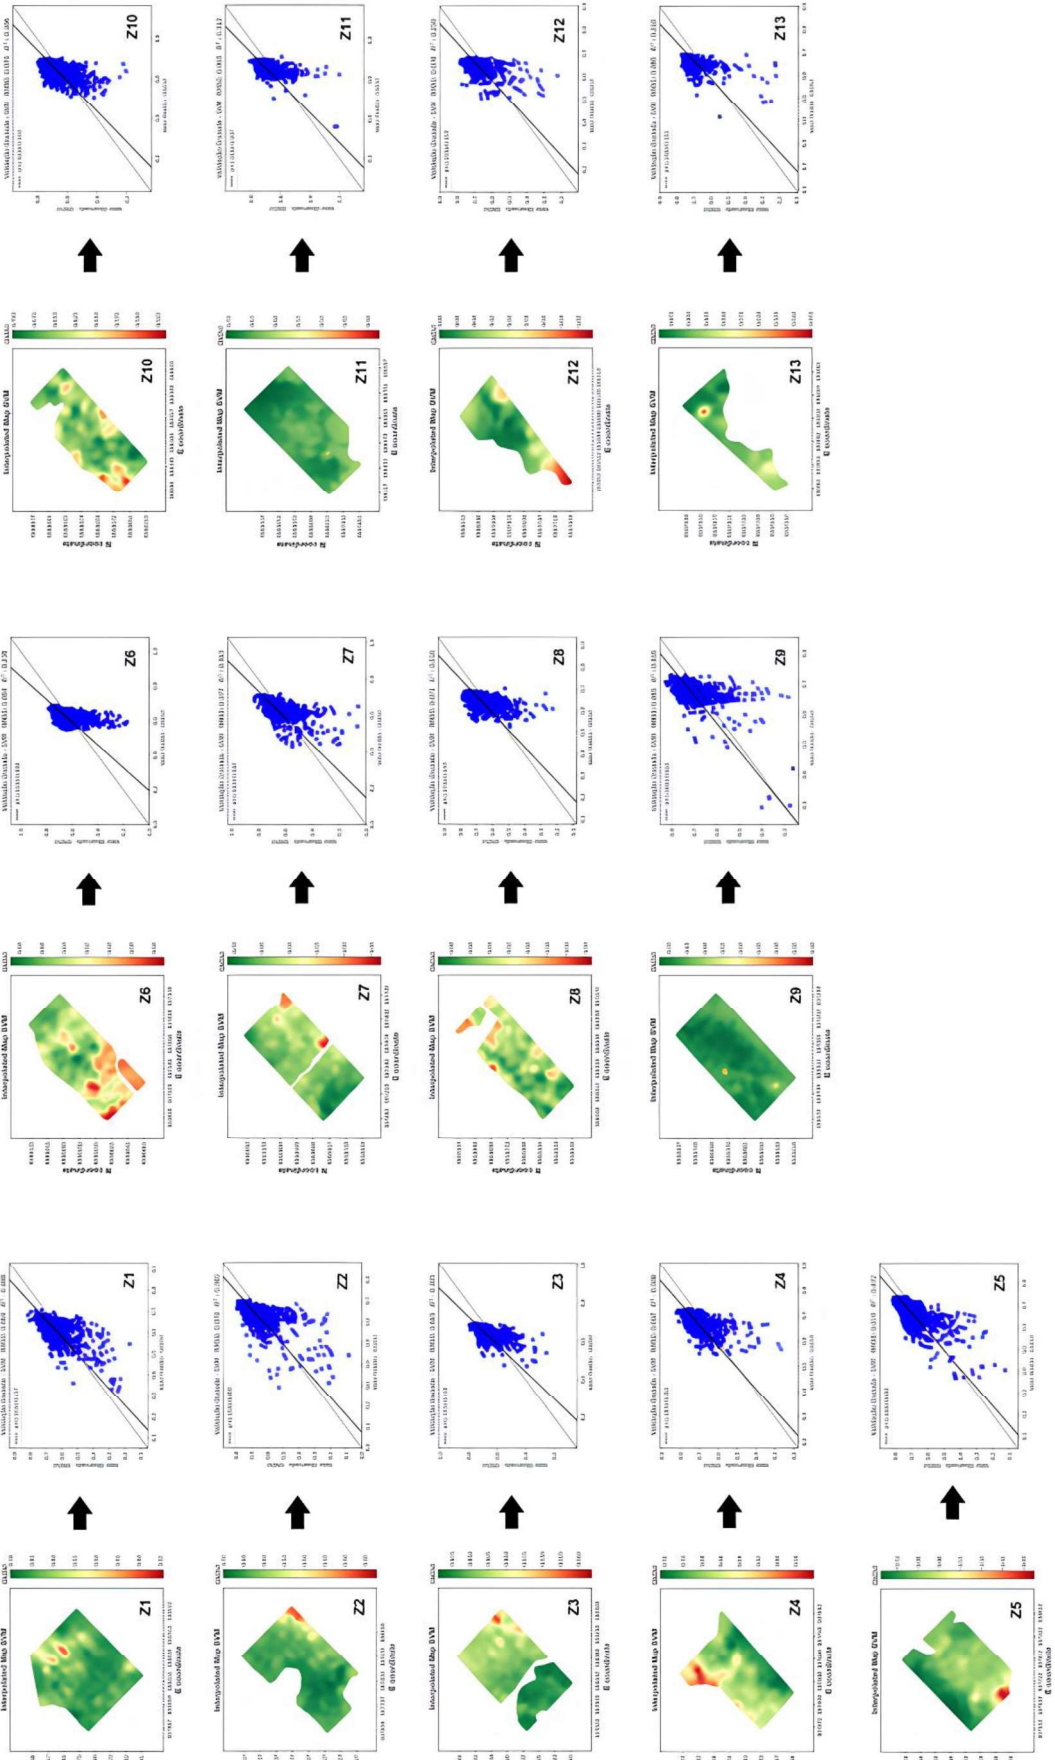
APÊNDICE II - Fluxo entre semivariogramas, mapas de *krigagem* ordinária e validações cruzadas para cada zona de estudo com malha de amostragem aleatória.



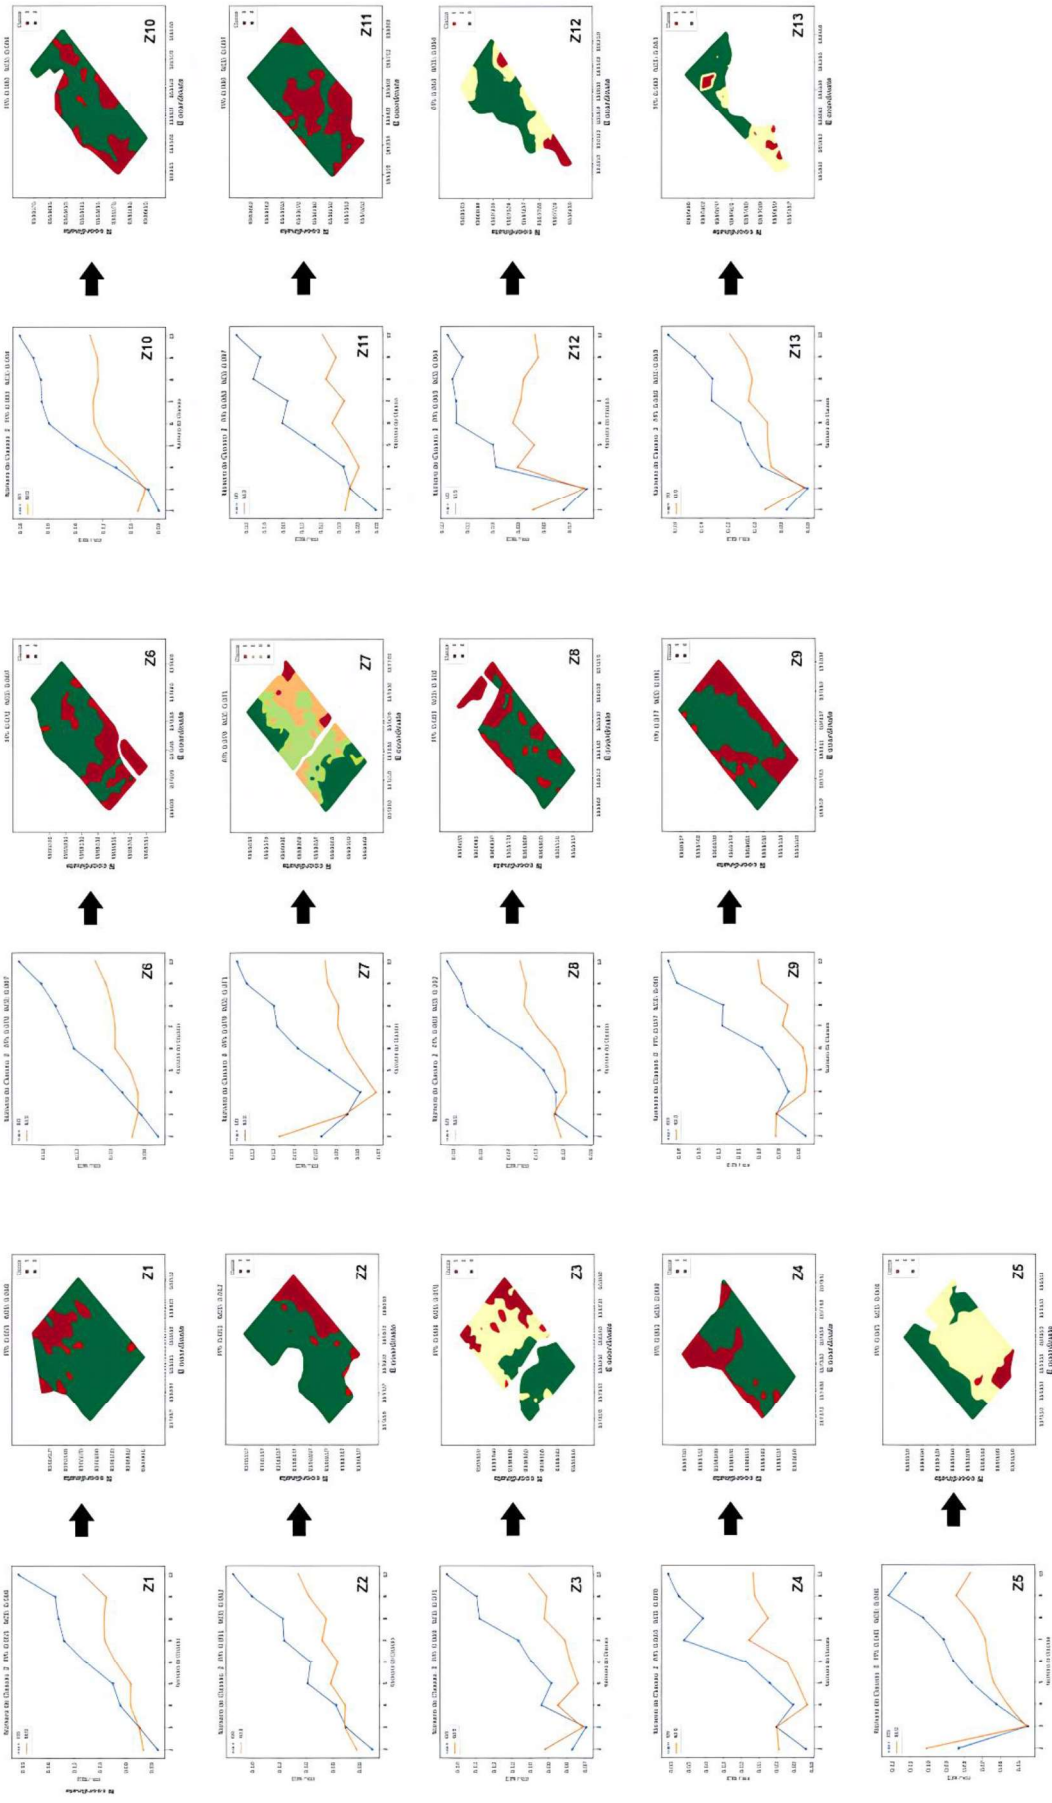
APÊNDICE III - Fluxo entre mapas de *support vector machine* e as validações cruzadas para cada zona de estudo com malha de amostragem regular.



APÊNDICE IV - Fluxo entre mapas de *support vector machine* e as validações cruzadas para cada zona de estudo com malha de amostragem aleatória.



APÊNDICE V - Fluxo entre as relações de FPI e NCE e os mapas fitossanitário para cada zona de estudo.



ANEXO I - Uso da Geoestatística no contexto da cana-de-açúcar no Brasil⁴

Tabela 1 - Autoria, objetos de estudo, resultados e/ou conclusões, modelos que melhor se ajustam aos dados e municípios dos trabalhos identificados sobre o tema na região Sudeste do Brasil.

ESTADO DE SÃO PAULO (SP)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA	MUNICÍPIO
Tominaga et al. (2002)	Atributos físicos do solo	Foi possível monitorar diferenças no teor de água do solo devido a mudanças nas práticas de manejo da cana-de-açúcar	***	Piracicaba
Corá et al. (2004)	Atributos químicos e físicos do solo	A investigação da variabilidade espacial dos atributos químicos do solo e do teor de argila proporcionou condições para a definição de zonas homogêneas de manejo	Exponencial, seguido pelo Esférico	Jaboticabal
Souza et al. (2004a)	Atributos químicos e físicos do solo	Pequenas variações na declividade e nas formas do relevo condicionaram a variabilidade espacial diferenciada da matéria orgânica e estabilidade dos agregados nas profundidades estudadas	Esférico para a maioria das variáveis	Guariba

⁴ Este anexo foi base para o artigo: **Use of Geostatistics in the sugarcane context in Brazil a review**, publicado na revista “*Environment, Development and Sustainability*”. DOI: <https://doi.org/10.1007/s10668-023-03927-1>.

Souza et al. (2004b)	Atributos físicos do solo	Pequenas variações nas formas do relevo condicionam variabilidade diferenciada nos atributos físicos dos solos	Esférico para a maioria das variáveis	Guariba
Souza et al. (2004c)	Atributos físicos do solo	Os Latossolos, apesar de homogêneos, mesmo em áreas de mesma classe de solo e manejo, apresentaram variabilidade diferente para atributos granulométricos	Exponencial, seguido pelo Esférico	Guariba
Izidorio et al. (2005)	Perdas de nutrientes devido à erosão do solo	A distribuição dos padrões de variabilidade espacial das perdas por erosão indicou que o cultivo da cana-de-açúcar conserva as propriedades químicas e físicas do solo na maior parte da área	Esférico	Guariba
Montanari et al. (2005)	Atributos químicos do solo	A pedoforma côncava apresentou maior variabilidade espacial dos atributos químicos que a pedoforma linear	Esférico e Exponencial, dependendo da profundidade	Jaboticabal
Nicoletta et al. (2005)	Comportamento do herbicida <i>Tebutiuron</i> usando o modelo de simulação CMLS	Os dados apoiaram a adequação do modelo para avaliar o destino do <i>Tebutiuron</i> tanto no Neossolo Quartzarênico quanto no Latossolo Vermelho-distrófico	Esférico, seguido pelo Gaussiano	Cravinhos Ribeirão Preto Serrana
Corá; Beraldo (2006)	Influência da aplicação de calcário e fosfato nos atributos do solo	Houve aumento na continuidade espacial dos atributos após calagem e fosfatização nas diferentes doses	Esférico para a maioria das variáveis	Guariba

Motomiya et al. (2006)	Atributos químicos do solo	Regiões com diferentes níveis de fertilidade do solo foram identificadas na área experimental	Exponencial, seguido pelo Esférico	Jaboticabal
Souza et al. (2006)	Efeito do teor de água do solo na sua resistência à penetração	O teor de água do solo afetou consideravelmente a variabilidade espacial da resistência do solo à penetração e quanto maior o teor de água, menor a dependência espacial	Esférico, seguido pelo Exponencial	Jaboticabal
Dinardo-Miranda et al. (2007)	<i>Mahanarva fimbriolata</i> (Stål)	Foi possível determinar a dependência espacial quando a praga estava em sua segunda geração, sendo necessários três pontos amostrais por hectare para uma estimativa confiável	Esférico	Guaira
Souza et al. (2007)	Atributos químicos do solo	Possibilitou uma descrição precisa dos atributos do solo, permitindo a definição de zonas de manejo	Praticamente todos se ajustaram ao Esférico	Guariba
Campos et al. (2008)	Atributos químicos para aplicação de fertilizantes e calcário no solo	Detectou, para a área em estudo, que não é recomendada a aplicação de fósforo e calagem em doses variadas	Esférico, seguido pelo Exponencial	Pereira Barreto
Montanari et al. (2008)	Atributos químicos do solo	O Latossolo na pedofoma convexa apresentou maior variabilidade espacial para os atributos químicos em relação ao Argissolo na pedofoma linear	Esférico, seguido pelo Exponencial	Jaboticabal
Scarpari; Beauclair (2008)	Variação espaço-temporal do índice de área foliar e sólidos solúveis (Brix)	Há grande variabilidade espaço-temporal no índice de área foliar, recomendando-se a	Exponencial para a maioria das variáveis	Piracicaba

Weill; Sparovek (2008)	Índice com valor preditivo para ser aplicado como ferramenta de planejamento	utilização de valores variáveis do coeficiente de extinção para melhor estimar a produtividade O índice proposto provou ser uma ferramenta promissora para interpretar a tolerância à perda de solo aplicada ao planejamento do uso agrícola sustentável	Esférico para a maioria das variáveis	Piracicaba
Barbieri et al. (2009)	Adsorção de fósforo e mineralogia do solo	Os menores valores de fósforo foram encontrados na área convexa, assim como as maiores proporções de gibbsita e os maiores valores de capacidade de adsorção de fósforo	Esférico para a maioria das variáveis	Catanduva
Campos et al. (2009)	Atributos químicos e físicos do solo	Foi possível planejar o cultivo da cana-de-açúcar, separando ambientes e alocando variedades adaptadas às restrições impostas pelos atributos do solo	Esférico	Pereira Barreto
Dinardo-Miranda; Fracasso (2009)	<i>Meloidogyne javanica</i> , <i>Pratylenchus zeae</i> e populações mistas de <i>Pratylenchus zeae</i> e <i>Pratylenchus brachyurus</i>	Foi possível estimar a área de agregação do nematóide, sendo necessários pelo menos cinco pontos amostrais por hectare para obter uma estimativa populacional confiável	Esférico	Guariba
				Itirapina
				Piracicaba
				Santa Rita do Passa Quarto
Panosso et al. (2009)	Emissão de dióxido de carbono do solo	Os resultados indicam que o sistema de gestão verde resulta em uma emissão de CO ₂ mais homogênea quando se considera a variabilidade espacial e temporal	Esférico, seguido pelo Exponencial	Guariba

Silva et al. (2009)	Pressão de pré-consolidação do solo e tensão de cisalhamento	Os mapas provaram ser um recurso valioso para avaliar o impacto do tráfego nas áreas cultivadas com cana-de-açúcar na área de estudo	Esférico	Piracicaba
Souza et al. (2009)	Atributos físicos e mineralogia do solo	A identificação das formas do solo mostrou-se muito eficiente para compreender a variabilidade espacial das propriedades do solo estudado	Esférico, seguido pelo Exponencial	Guariba
Anjos et al. (2010)	<i>Mahararva fimbriolata</i> (Stål)	A análise geoestatística permitiu a construção de mapas de contorno por interpolação por <i>krigagem</i> , utilizando a dependência espacial expressa nos semivariogramas	Esférico	Catanduva
Brito et al. (2010)	Emissão de dióxido de carbono do solo	Houve maior descontinuidade na distribuição espacial das emissões de CO ₂ do solo na forma linear em relação à forma côncava	Exponencial para as porções côncavas e Esférica para as porções lineares	Jaboticabal
Camargo et al. (2010)	Atributos físicos do solo	A área côncava apresentou maior número de atributos do solo com maior variabilidade espacial	Esférico para a maioria das variáveis	Catanduva
Campos et al. (2010)	Influência das superfícies geomórficas nos atributos do solo	O auxílio de técnicas geoestatísticas e de um modelo digital de elevação possibilitou observar que os atributos do solo apresentavam limites próximos aos das superfícies geomórficas	Esférico	Pereira Barreto
Grego et al. (2010)	Relação entre atributos biométricos de plantas e propriedades físico-químicas do solo	A amostragem permitiu boa representatividade da dependência espacial do solo e das plantas, descartando a hipótese de aleatoriedade para a disposição das parcelas	Esférico para a maioria das variáveis	Ribeirão Preto

Souza et al. (2010a)	Atributos químicos do solo	As variáveis altitude e potássio apresentaram os maiores valores de correlação com a produtividade da cana-de-açúcar, sendo a altitude a variável com maior potencial	Esférico	Catanduva
Souza et al. (2010b)	Atributos químicos e físicos do solo e produtividade	O uso do relevo e da geostatística permitiu definir áreas com diferentes variabilidades espaciais para atributos do solo e produtividade da cana-de-açúcar	Esférico para a maioria das variáveis	Araras
Montanari et al. (2012)	Atributos químicos do solo	Os resultados mostraram que as técnicas empregadas podem auxiliar no mapeamento da fertilidade do solo, melhorando o manejo dos nutrientes na cultura da cana-de-açúcar	Exponencial, seguido pelo Esférico	Jaboticabal
Panosso et al. (2012)	Atributos físicos e emissão de dióxido de carbono do solo	Observou-se que fatores inerentes aos processos de formação do solo e práticas de manejo durante a colheita e semeadura afetaram as emissões de CO ₂ do solo	***	Guariba
Sanchez et al. (2012)	Estimativa de gastos com fertilização	Observou-se que quando os acidentes geográficos são incorporados nas análises, há um aumento na eficiência de aplicação de Ca, P e K no solo	Exponencial, seguido pelo Esférico	Catanduva
Teixeira et al. (2012)	Atributos físicos e químicos e emissão de dióxido de carbono do solo	O conhecimento das incertezas geradas por diferentes cenários de estimativa pode ser incluído nos inventários de gases de efeito estufa, resultando em estimativas mais conservadoras	Gaussiano, seguido pelo Exponencial e Esférico	Guariba

Barbieri et al. (2013)	Mineralogia e relação com atributos físicos e químicos do solo	A variabilidade espacial dos atributos químicos é maior nas áreas de colheita de cana-de-açúcar crua, diferentemente dos atributos mineralógicos	Esférico, seguido por Gaussiano e Exponencial	Ribeirão Preto
Dalchiavon et al. (2013a)	Atributos físicos e químicos do solo	A população de plantas e o teor de matéria orgânica do solo foram indicadores da zona de manejo fortemente associados à produtividade	Gaussiano, seguido pelo Exponencial	Suzanópolis
Dalchiavon et al. (2013b)	Produtividade da cana-de-açúcar e atributos físicos e químicos do solo	Os resultados do tratamento com cobertura morta foram melhores, em geral, no que diz respeito ao manejo e conservação do solo	Gaussiano, Esférico e Exponencial	Rubineia
Oliveira et al. (2013c)	Fósforo disponível no solo	A avaliação das incertezas por Simulação Sequencial Gaussiana (SSG) mostrou-se mais informativa e pode ser utilizada para definir e delimitar áreas com maior precisão	Esférico para a maioria das variáveis	Tabapuã
Pereira et al. (2013)	Atributos físicos e químicos do solo	Os resultados mostraram que a utilização de uma malha amostral inicial e do variograma médio escalonado foram muito promissores, aumentando a precisão das estimativas de <i>krigagem</i>	Esférico	Guariba
Rodrigues Junior et al. (2013)	Atributos químicos do solo e parâmetros de qualidade da cana-de-açúcar	Não foram encontrados padrões claros de estabilidade temporal dos parâmetros de qualidade, o que sugere a necessidade de estudos que incluam mais ciclos de cultivo	Exponencial para a maioria das variáveis	Araras

Teixeira et al. (2013)	Densidade aparente para prever as emissões de dióxido de carbono do solo	O procedimento utilizado evitou problemas relacionados à alta variabilidade temporal associada às emissões de CO ₂ do solo	Esférico para a maioria das variáveis	Guariba
Zanzarini et al. (2013)	Atributos físicos e químicos do solo e NDVI	A imagem do sensor utilizado no estudo, em relação ao NDVI, mostrou boa aplicação para observar a variabilidade espacial dos atributos estudados	Esférico	Itajobi
Bahia et al. (2014)	Mineralogia do solo para prever emissões de dióxido de carbono	Os resultados mostraram o potencial da espectroscopia de refletância difusa para auxiliar na determinação de propriedades tipicamente associadas à emissão de CO ₂ do solo	Esférico, seguido pelo Exponencial	Guariba
Bicalho et al. (2014)	Emissão de dióxido de carbono do solo	A estrutura de variabilidade espacial da emissão de CO ₂ do solo apresentou relação significativa com a estrutura de variabilidade espacial para a maioria dos atributos do solo	***	Guariba
Dinardo-Miranda et al. (2014)	<i>Diatraea saccharalis</i> e controle biológico com <i>Cotesia flavipes</i>	As larvas parasitadas estavam presentes aleatoriamente em uma área e em três áreas a distribuição foi agregada, com intervalo de 15 a 25 m	Esférico	Ribeirão Preto
Marques Junior et al. (2014)	Espectroscopia de suscetibilidade magnética e refletância difusa para caracterização de atributos físicos e químicos do solo	Observou-se que os resultados podem orientar futuros trabalhos de mapeamento detalhado e estabelecer a melhor estratégia para combinar geoestatística e análise de correlação canônica	Esférico para a maioria das variáveis	Catanduva

Oliveira et al. (2014)	Potássio disponível no solo	A simulação sequencial de indicadores tem melhor desempenho que a simulação sequencial gaussiana na estimativa dos teores de K disponível na área canavieira	Esférico para a maioria das variáveis	Tabapuã
Souza et al. (2014)	Atributos químicos e físicos do solo	Observou-se que aumentar o intervalo amostral e diminuir o número de pontos promove o maior erro na estimativa da <i>krigagem</i>	Esférico para a maioria das variáveis	Jaboticabal
	Análise de diferentes intensidades na amostragem de solo			Pradópolis
Volpe et al. (2014)	<i>Diatraea saccharalis</i> e controle biológico com <i>Cotesia flavipes</i>	Análises geoestatísticas permitiram avaliar e mapear o número de larvas parasitadas	Gaussiano, seguido pelo esférico	Jaboticabal
Bahia et al. (2015)	Mineralogia, emissão de dióxido de carbono e atributos físicos do solo	Todos os atributos do solo exibiram uma estrutura de dependência espacial, mostrando que o uso da espectroscopia de reflectância difusa é útil para mapear grandes áreas	Esférico e Exponencial	Guariba
Leal et al. (2015)	Susceptibilidade magnética e emissão de dióxido de carbono no solo	Observou-se que a susceptibilidade magnética do solo seco ao ar pode ser um meio adicional de identificação de regiões com alto potencial de emissão de CO ₂	Esférico, seguido pelo Gaussiano	Guariba
Mendonça et al. (2015)	Esgotamento de nutrientes pela erosão do solo	O empobrecimento do solo para todos os nutrientes avaliados foi maior no cenário de cana queimada do que no cenário de cana crua, também associado à maior declividade	Exponencial	Tabapuã

Peluco et al. (2015)	Fósforo adsorvido e suscetibilidade magnética	Observou-se que o índice de vermelhidão e a suscetibilidade magnética são espacialmente dependentes do fósforo adsorvido	Exponencial e Esférico	Guataparã
Pereira et al. (2015)	Teor de cálcio no solo	As técnicas mostraram-se eficazes, com exceção da <i>krigagem</i> ordinária, que não reproduziu satisfatoriamente as estatísticas globais de teor de Ca	***	Guariba
Silva et al. (2015)	Precisão de classificação supervisionada usando <i>krigagem</i> indicatriz (KI) e ferramentas de classificação fuzzy	As faixas apresentaram dependência espacial para cana-de-açúcar; o classificador IK superestimou as áreas de cultivo de cana-de-açúcar, enquanto o classificador fuzzy as subestimou	Exponencial para a maioria das variáveis	Botucatu São Manuel
Silva Junior et al. (2015)	Mineralogia do solo	De modo geral, as estimativas da <i>Krigagem</i> Trans-Gaussiana reproduziram os melhores resultados, destacando a importância da classificação do relevo para maior eficiência	Esférico para a maioria das variáveis	Catanduva
Moraes et al. (2016)	Risco de contaminação de águas subterrâneas pelo herbicida <i>tebuthiuron</i>	As estimativas da concentração de <i>tebuthiuron</i> não mostraram dependência espacial, portanto foi utilizado o método de interpolação pelo inverso da distância	***	São Manuel
Pavlu; Molin (2016)	<i>Sphenophorus levis</i>	Os resultados indicaram que o fato de os avaliadores entrarem a cada 20 fileiras de cana e amostrarem a cada 20 m foi suficiente para caracterizar a dependência espacial	Esférico, seguido pelo Exponencial	Piracicaba

Rodrigues et al. (2016)	Atributos físicos e químicos do solo com produtividade da cana-de-açúcar	Os resultados mostraram que a produtividade da cana-de-açúcar esteve relacionada principalmente aos teores de matéria orgânica, pH, cálcio, magnésio, somatório de bases e silte, independente da profundidade	Esférico, seguido pelo Exponencial e Gaussiano	Mogi Mirim
Siqueira et al. (2016)	Susceptibilidade magnética e atributos físicos, químicos e de produtividade do solo	A susceptibilidade magnética mostrou-se útil para caracterizar a variabilidade espacial dos atributos do solo e identificar áreas com diferentes potenciais para produção de cana-de-açúcar	Esférico, seguido pelo Exponencial	Guariba
Dalchiavon et al. (2017)	Produtividade da cana-de-açúcar e atributos químicos do solo	O potássio extraível (0,20-0,40 m) foi o atributo do solo que proporcionou melhor ajuste semivariográfico	Esférico, seguido por Exponencial e Gaussiano	Rubineia
Tavares et al. (2017)	Emissão de dióxido de carbono e macroporosidade do solo	Pode-se concluir que a macroporosidade do solo influenciou as emissões de CO ₂ nos sistemas de manejo da cana-de-açúcar	Exponencial para a maioria das variáveis	Pradópolis
Teixeira et al. (2017)	Susceptibilidade magnética, teor de argila e saturação por bases	Observou-se que estimativas de padrões espaciais de geologia e geomorfologia têm potencial para modelar propriedades do solo	***	Guataporã
Mendonça et al. (2018)	Esgotamento de nutrientes pela erosão do solo	Concluiu-se que a análise das incertezas espaciais e temporais na probabilidade de perda de solo permite delimitar áreas prioritárias para práticas conservacionistas	Esférico para a maioria das variáveis	Tabapuã
			Esférico, seguido pelo Exponencial	Capivari

Satiro et al. (2018)	Modelo de produtividade da cana-de-açúcar por atributos do solo	Os resultados mostraram que a produção de palha e caule pode ser prevista usando dados de atributos do solo em locais onde a palha é removida	Valparaíso
Barbosa et al. (2019)	Suscetibilidade magnética e erosão do solo	Ao final, observou-se que a suscetibilidade magnética pode ser utilizada como preditora de fatores de erodibilidade para Latossolos com teor de ferro total variando de 1 a 20% Fe ₂ O ₃	Guatapará
Cortez et al. (2020)	Resistência do solo	O mapeamento baseado na gestão específica do local mostrou bons indicadores de sustentabilidade, como redução do consumo de energia e menores emissões de CO ₂	Guariba
Maldaner; Molin (2020)	Método de limpeza de dados de produtividade de cana-de-açúcar, investigando se a frequência de registro dos dados influencia na caracterização das variações de produtividade	A geostatística permitiu observar que, mesmo eliminando a incerteza dos dados, existe uma grande variação de produtividade entre linhas adjacentes	Jaboticabal
Silva et al. (2020a)	Emissão de dióxido de carbono e atributos físicos do solo	O padrão espacial de todos os atributos do solo apresentou pouca persistência temporal, indicando alta complexidade para emissão de CO ₂ do solo durante a precipitação	Barrinha
		***	Guariba

Silva et al. (2020b)	Emissão de dióxido de carbono e relação com atributos físicos e químicos do solo	Os resultados indicam que o potencial de acúmulo de carbono no solo apresentou alta variabilidade espacial em pequena escala	***	Motuca
Corrêdo et al. (2021)	Espectroscopia no infravermelho próximo para prever e mapear o conteúdo de Brix, Pol e Fibra	Os resultados mostraram que a espectroscopia no infravermelho próximo tem potencial para ser aplicada como método de detecção proximal baseado na variabilidade espacial de atributos de qualidade	Esférico para a maioria das variáveis	Pradópolis
Cursi et al. (2021)	Identificar e ajustar a dependência espacial na fase inicial do melhoramento da cana-de-açúcar	Foi demonstrado que o parâmetro genético aumentou quando ambas as abordagens (análise espacial e covariáveis ambientais) foram empregadas	Exponencial, Gaussiano e Esférico	Araras
Moitinho et al. (2021)	Emissão de dióxido de carbono, atributos físicos, químicos e microbiológicos do solo	Diferenças na emissão de CO ₂ do solo foram associadas à dinâmica da atividade microbiana e à atividade enzimática	Esférico para a maioria das variáveis	Valparaíso
Pusch et al. (2021)	Sensoriamento remoto e proximal para mapeamento de solos	Observou-se que a condutividade elétrica aparente do solo é uma covariável mais promissora que a banda SWIR2 da imagem orbital	Esférico para a maioria das variáveis	Barrinha
Sanches et al. (2021)	Aplicação de fertilizantes no solo	Os resultados mostraram que a aplicação de fertilizantes de acordo com a variabilidade espacial do solo pode produzir melhores ganhos econômicos e ambientais	***	Motuca
				Serra Azul

*** Os autores não informaram.

Fonte: autor.

Tabela 2 – Autoria, objetos de estudo, resultados e/ou conclusões, modelos que melhor se ajustam aos dados e municípios dos trabalhos identificados sobre o tema na região Nordeste do Brasil.

ESTADO DA PARAÍBA (PB)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIÓGRAMA QUE MELHOR SE AJUSTA	MUNICÍPIO
Chaves; Farias (2009)	Conteúdo de cobre e manganês no solo	A utilização da geoestatística permitiu a descrição dos teores de cobre e manganês no solo, o que possibilitou a definição de zonas de manejo específicas	Esférico para a maioria das variáveis	Capim
Souza et al. (2020)	Resistência à penetração em solos submetidos a diferentes métodos de colheita	Não foram observadas áreas compactadas e a dependência espacial da resistência à penetração foi caracterizada como moderada a forte	***	Capim
ESTADO DO CEARÁ (CE)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIÓGRAMA QUE MELHOR SE AJUSTA	MUNICÍPIO
Cruz et al. (2010)	Atributos físicos do solo e carbono orgânico do solo	As variáveis analisadas apresentaram dependência espacial, o que foi observado nos mapas de <i>krigagem</i>	Exponencial e Gaussiana	Maracanau

Cruz et al. (2011)	Atributos químicos do solo	Os atributos apresentaram variabilidade baixa e média, com exceção do pH, que não apresentou dependência espacial	Esférico, seguido pelo Exponencial e Gaussiano	Maracanaú
Silva et al. (2014)	Atributos físicos de um solo não arado	Os resultados refletiram, na prática, a recomendação mínima de 100 pontos para viabilizar o uso da geoestatística e da <i>krigagem</i> na elaboração de mapas temáticos	Esférico, seguido pelo Exponencial	Maracanaú
ESTADO DO PERNAMBUCO (PE)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA	MUNICÍPIO
Cardoso et al. (2012)	Nematóides do solo e atributos físicos do solo	Houve dependência espacial para resistência à penetração, teor de água, porosidade total e densidade aparente; a quantidade total de nematóides não diferiu	Esférico e Exponencial	Goiana
Siqueira et al. (2015)	Produtividade da cana-de-açúcar, condutividade elétrica e textura do solo	A condutividade elétrica provou ser uma ferramenta importante para prever a produtividade; atributos texturais apresentaram alta variabilidade espacial	Gaussiano para a maioria das variáveis	Goiana
Tavares et al. (2015)	Efeito do preparo convencional e do cultivo na saúde do solo, para caracterização do solo e	A utilização de técnicas de mapeamento geoestatístico possibilitou a identificação de	Esférico, seguido pelo Gaussiano	Goiana

	estudo de atributos físicos e mecânicos do solo	áreas com maior conservação do solo e maior perturbação do solo		
Silva et al. (2018a)	Condutividade elétrica aparente do solo, condutividade elétrica do extrato de saturação, teor de água e textura do solo	A variabilidade espacial da condutividade elétrica aparente do solo foi afetada pelo relevo da área e foi elevada para os atributos de textura	Esférico	Goiana
Silva et al. (2018b)	Condutividade elétrica em águas subterrâneas após aplicação de vinhaça	A amplitude dos valores de dependência espacial demonstrou que o espaçamento de 32 m entre poços de observação é necessário para um manejo sustentável	Gaussiano	Rio Formoso
Schossler et al. (2019)	Determinação da melhor densidade amostral para representar os atributos físicos do solo e correlação com produtividade	A densidade amostral mínima para estimar a produtividade da cana-de-açúcar foi de 14 amostras por hectare e dependeu da resistência à penetração e da porosidade total do solo	Esférico e Exponencial	Carpina
Souza Junior et al. (2020)	Nematóides presentes no solo	Descobriu-se que a irrigação afeta a distribuição espacial e os comprimentos de correlação dos nematóides	Exponencial, seguido pelo Esférico	Timbauba

ESTADO DO RIO GRANDE DO NORTE (RN)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA	MUNICÍPIO
Oliveira Filho et al. (2015)	Aplicação de critérios de delimitação de zonas para manejo de compactação de solo	Os mapas produzidos permitiram definir quatro regiões do campo onde a subsolagem pode ser aplicada de diferentes maneiras	Esférico	Baía Formosa
Oliveira Filho et al. (2016)	Identificação de regiões com diferentes níveis de compactação para adoção de gestão localizada	A metodologia proposta permitiu identificar áreas com diferentes níveis de compactação do solo	***	Baía Formosa
ESTADO DO MARANHÃO (MA)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA	MUNICÍPIO
Leiva et al. (2019)	Resistência do solo à penetração	A metodologia proposta permitiu a diferenciação entre os perfis das unidades de relevo, resultando em uma importante ferramenta para estudos de resistência do solo à penetração	Exponencial para a maioria das variáveis	Coelho Neto

*** Os autores não informaram.

Fonte: autor.

Tabela 3 – Autoria, objetos de estudo, resultados e/ou conclusões, modelos que melhor se ajustam aos dados e municípios dos trabalhos identificados sobre o tema na região Norte do Brasil.

ESTADO DO AMAZONAS (AM)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA	MUNICÍPIO
Oliveira et al. (2013a)	Estabilidade de alguns agregados e conteúdo de matéria orgânica	Os atributos do solo apresentaram estrutura de dependência espacial e a maior variação foi observada para diâmetro médio ponderado e classe de agregados <1,00 mm	Esférico e Exponencial	
Oliveira et al. (2013b)	Atributos físicos do solo sob diferentes usos	Os atributos estudados apresentaram variabilidade espacial, e os intervalos foram diferentes entre os usos, mostrando que o manejo da cana-de-açúcar apresentou maior variabilidade	Esférico e Exponencial	Humaitá
Aquino et al. (2015a)	Atributos físicos do solo	Os atributos físicos apresentaram estrutura de dependência espacial e o uso do semivariograma mostrou-se eficiente para determinar a densidade amostral ideal	Exponencial	

Aquino et al. (2015b)	Atributos químicos em solo cultivado com cana-de-açúcar e agrofloresta	A maioria dos atributos do solo apresentou estrutura de dependência espacial, com predomínio do grau moderado	Esférico e Exponencial	
Oliveira et al. (2015)	Atributos químicos do solo e determinação da densidade mínima de amostragem em diferentes ambientes	A maioria dos atributos estudados apresentou estrutura de dependência espacial e a área canavieira apresentou heterogeneidade de atributos químicos	Exponencial	
Aquino et al. (2016)	Atributos químicos do solo em área composta por cana-de-açúcar e agrofloresta	Como conclusão, os resultados sugerem que foi observada dependência espacial para a maioria dos atributos químicos; a análise multivariada foi eficiente na seleção dos atributos químicos do solo	Esférico e Exponencial	
Cunha et al. (2016)	Distribuição de tamanho de alguns agregados usando teoria fractal em diferentes áreas	O grau de fragmentação dos agregados do solo foi influenciado pelo tipo de solo e fortemente correlacionado com partículas finas, sendo observada uma forte dependência espacial	Exponencial	
Oliveira et al. (2018a)	Atributos químicos em diferentes áreas: cana-de-açúcar, mandioca e sistema agroflorestral	Verificou-se que o pH pode ser um pedoindicador para áreas cultivadas com cana-de-açúcar, observando também a variabilidade espacial no sistema canavieiro	Esférico, seguido pelo Exponencial	

Oliveira et al. (2018b)	Estoques de carbono, estabilidade dos agregados do solo e atributos químicos do solo	Os mapas de <i>krigagem</i> apresentaram correlação positiva entre as variáveis estudadas e a declividade do terreno, com valores maiores para os terrenos mais baixos	Esférico	
----------------------------	---	---	----------	--

Fonte: autor.

Tabela 4 – Autoria, objetos de estudo, resultados e/ou conclusões, modelos que melhor se ajustam aos dados e municípios dos trabalhos identificados sobre o tema na região Centro-Oeste do Brasil.

ESTADO DO MATO GROSSO (MT)			
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA
Iaia et al. (2006)	Resistência do solo à penetração	Foi possível visualizar as isolinhas de maior compactação através dos mapas de <i>krigagem</i> , indicando onde houve maior tráfego nas linhas de cana	Esférico, seguido pelo Exponencial
			São José do Rio Claro
ESTADO DO MATO GROSSO DO SUL (MS)			
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA
Carvalho et al. (2011)	Atributos físicos de solos cultivados em sistema de colheita mecanizada	A redução da porosidade total e o consecutivo aumento da densidade do solo indicam compactação, justificada pelo intenso tráfego de veículos e ausência de perturbação do solo	Gaussiano e Exponencial
			Rio Brillante
Carvalho et al. (2014)	Efeito da aplicação de vinhaça no teor de potássio do solo	Os resultados mostraram que a dependência espacial do K aumentou com a profundidade para os FRce e diminuiu para o PHlv	Gaussiano para a maioria das variáveis
			Rio Brillante

Terçariol et al. (2016)	Emissões de dióxido de carbono do solo, temperatura e umidade do solo	As variáveis temperatura e umidade não apresentaram correlações significativas com as emissões de CO ₂	Exponencial, seguido pelo Esférico e Gaussiano	Selvíria
Silva et al. (2020b)	Emissão de dióxido de carbono e relação com atributos físicos e químicos do solo	Os resultados indicam que o potencial de acúmulo de carbono no solo apresentou alta variabilidade espacial em pequena escala	***	Aparecida de Taboado

*** Os autores não informaram.

Fonte: autor.

Tabela 5 - Autoria, objetos de estudo, resultados e/ou conclusões, modelos que melhor se ajustam aos dados e municípios dos trabalhos identificados sobre o tema na região Sul do Brasil.

ESTADO DO PARANÁ (PR)				
AUTORES	OBJETO DE ESTUDO	RESULTADOS E/OU CONCLUSÕES	SEMIVARIograma QUE MELHOR SE AJUSTA	MUNICÍPIO
Gualberto et al. (2016)	Atributos químicos do solo em diferentes tamanhos de grades amostrais	Os atributos cálcio, magnésio e potássio apresentaram correlação espacial em quase todas as grades amostrais, exceto na grade amostral de 200 m para cálcio e magnésio	Esférico e Gaussiano	Bom Sucesso

Fonte: autor.

REFERÊNCIAS

ANJOS, I. A.; DINARDO-MIRANDA, L. L.; GARCIA, J. C.; BRAZ, A. J.; TAVARES, C. B.; GEROMEL, R. J.; FERREIRA, S. S.; SOUZA, V. A.; DUARTE, J. C. S. Spatial distribution of sugarcane spittlebug, *Mahanarva fimbriolata*, in sugarcane fields. **Proceedings International Society of Sugar Cane Technologists**, v. 27, 2010.

AQUINO, R. E.; CAMPOS, M. C. C.; MARQUES JUNIOR, J.; OLIVEIRA, I. A.; TEIXEIRA, D. D. B.; CUNHA, J. M. Use of scaled semivariograms in the planning sample of soil physical properties in southern Amazonas, Brazil. **Revista Brasileira de Ciência do Solo**, v. 39, n. 1, p. 21-30, 2015a. <https://doi.org/10.1590/01000683rbcs20150524>.

AQUINO, R. E.; CAMPOS, M. C. C.; OLIVEIRA, I. A.; SIQUEIRA, D. S.; SOARES, M. D. R.; FREITAS, L. Técnicas geoestatísticas na avaliação de atributos químicos em Cambissolo com agrofloresta e cana-de-açúcar em Humaitá, Amazonas. **Agrária**, v. 10, n. 4, p. 544-552, 2015b. <https://doi.org/10.5039/agraria.v10i4a3346>.

AQUINO, R. E.; CAMPOS, M. C. C.; SOARES, M. D. R.; OLIVEIRA, I. A.; FRANCISCON, U.; SILVA, D. M. P.; CUNHA, J. M. Chemical soil attributes evaluated by multivariate techniques and geostatistics in the area with agroforestry and sugarcane in Humaitá, AM, Brazil. **Bioscience Journal**, v. 32, n. 1, p. 61-72, 2016. <https://doi.org/10.14393/BJ-v32n1a2016-29421>.

BAHIA, A. S. R. S.; MARQUES JUNIOR, J.; PANOSSO, A. R.; CAMARGO, L. A.; SIQUEIRA, D. S.; SCALA JUNIOR, N. L. Iron oxides as proxies for characterizing anisotropy in soil CO₂ emission in sugarcane areas under green harvest. **Agriculture, Ecosystems and Environment**, v. 192, n. 152-162, 2014. <https://doi.org/10.1016/j.agee.2014.04.017>.

BAHIA, A. S. R. S.; MARQUES JUNIOR, J.; PANOSSO, A. R.; CAMARGO, L. A.; SIQUEIRA, D. S.; TEIXEIRA, D. D. B.; SCALA JUNIOR, N. L. Field-scale spatial correlation between contents of iron oxides and CO₂ emission in an Oxisol cultivated with sugarcane. **Scientia Agricola**, v. 72, n. 2, p. 157-166, 2015. <https://doi.org/10.1590/0103-9016-2014-0142>.

BARBIERI, D. M.; MARQUES JUNIOR, J.; ALLEONI, L. R. F.; GARBUIO, F. J.; CAMARGO, L. A. Hillslope curvature, clay mineralogy, and phosphorus adsorption in an Alfisol cultivated with sugarcane. **Scientia Agricola**, v. 66, n. 6, p. 819-826, 2009. <https://doi.org/10.1590/S0103-90162009000600015>.

BARBIERI, D. M.; MARQUES JUNIOR, J.; PEREIRA, G. T.; SCALA JUNIOR, N. L.; SIQUEIRA, D. S.; PANOSSO, A. R. Comportamento dos óxidos de ferro da fração argila e do fósforo adsorvido em diferentes sistemas de colheita de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, v. 37, n. 6, p. 1557-1568, 2013. <https://doi.org/10.1590/S0100-06832013000600012>.

BARBOSA, R. S.; MARQUES JUNIOR, J.; BARRÓN, V.; MARTINS FILHO, M. V.; SIQUEIRA, D. S.; PELUCO, R. G.; CAMARGO, L. A.; SILVA, L. S. Prediction and mapping of erodibility factors (USLE and WEPP) by magnetic susceptibility in basalt-derived soils in northeastern São Paulo, Brazil. **Environmental Earth Sciences**, v. 78, n. 12, p. 1-12, 2019.

BRITO, L. F.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; SCALA JUNIOR, N. L. Spatial variability of soil CO₂ emission in different topographic positions. **Bragantia**, v. 69, Suplemento, p. 19-27, 2010. <https://doi.org/10.1590/S0006-87052010000500004>.

CAMARGO, L. A.; MARQUES JUNIOR, J.; PEREIRA, G. T. Spatial variability of physical attributes of an alfisol under different hillslope curvatures. **Revista Brasileira de Ciência do Solo**, v. 34, n. 3, p. 617-630, 2010. <https://doi.org/10.1590/S0100-06832010000300003>.

CAMPOS, M. C. C.; MARQUES JUNIOR, J.; PEREIRA, G. T. Influência das superfícies geomórficas na distribuição espacial dos atributos do solo em área sob cultivo de cana-de-açúcar. **Pesquisa Agropecuária Tropical**, v. 40, n. 2, p. 133-141, 2010. <https://doi.org/10.5216/pat.v40i2.4786>.

CAMPOS, M. C. C.; MARQUES JUNIOR, J.; PEREIRA, G. T.; SOUZA, Z. M.; BARBIERI, D. M. Aplicação de adubo e corretivo após o corte da cana-planta utilizando técnicas geoestatísticas. **Ciência Rural**, v. 38, n. 4, p. 974-980, 2008. <https://doi.org/10.1590/S0103-84782008000400011>.

CAMPOS, M. C. C.; MARQUES JUNIOR, J.; PEREIRA, G. T.; SOUZA, Z. M.; MONTANARI, R. Planejamento agrícola e implantação de sistema de cultivo de cana-de-açúcar com auxílio de técnicas geoestatísticas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 3, p. 297-304, 2009. <https://doi.org/10.1590/S1415-43662009000300011>.

CARDOSO, M. O.; PEDROSA, E. M. R.; ROLIM, M. M.; SILVA, E. F. F.; BARROS, P. A. Effects of soil mechanical resistance on nematode community structure under conventional sugarcane and remaining of Atlantic Forest. **Environmental Monitoring and Assessment**, v. 184, p. 3529-3544, 2012. <https://doi.org/10.1007/s10661-011-2206-4>.

CARVALHO, L. A.; MEURER, I.; SILVA JUNIOR, C. A.; CAVALIERI, K. M. V.; SANTOS, C. F. B. Dependência espacial dos atributos físicos de solo cultivados com cana-de-açúcar sob colheita mecanizada. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 9, p. 940-949, 2011. <https://doi.org/10.1590/S1415-43662011000900010>.

CARVALHO, L. A.; MEURER, I.; SILVA JUNIOR, C. A.; SANTOS, C. F. B.; LIBARDI, P. L. Spatial variability of soil potassium in sugarcane areas subjected to the application of vinasse. **Anais da Academia Brasileira de Ciências**, v. 86, n. 4, p. 1999-2011, 2014. <https://doi.org/10.1590/0001-3765201420130319>.

CHAVES, L. H. G.; FARIAS, C. H. A. Variabilidade espacial de cobre e manganês em Argissolo sob cultivo de cana-de-açúcar. **Revista Ciência Agronômica**, v. 40, n. 2, p. 211-218, 2009.

CORÁ, J. E.; ARAUJO, A. V.; PEREIRA, G. T.; BERALDO, J. M. G. Variabilidade espacial de atributos do solo para adoção do sistema de agricultura de precisão na cultura da cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, v. 28, n. 6, p. 1013-1021, 2004. <https://doi.org/10.1590/S0100-06832004000600010>.

CORÁ, J. E.; BERALDO, J. M. G. Variabilidade espacial de atributos do solo antes e após calagem e fosfatagem em doses variadas na cultura de cana-de-açúcar. **Engenharia Agrícola**, v. 26, n. 2, p. 374-387, 2006. <https://doi.org/10.1590/S0100-69162006000200005>.

CORRÊDO, L. P.; WEI, M. C. F.; FERRAZ, M. N.; MOLIN, J. P. Near-infrared spectroscopy as a tool for monitoring the spatial variability of sugarcane quality in the fields. **Biosystems Engineering**, v. 206, p. 150-161, 2021. <https://doi.org/10.1016/j.biosystemseng.2021.04.001>.

CORTEZ, L. A.; MARQUES JUNIOR, J.; PELUCO, R. G.; SIQUEIRA, D. S.; SIANSI, F. L.; BARBOSA, R. S.; FURLANI, C. E. A.; CAMARGO, L. A.; SILVA, L. S.; GOMES, R. P. Subsoiling of an oxisol at fixed and varying depth in areas under sugarcane. **Precision Agriculture**, v. 21, p. 1351-1365, 2020. <https://doi.org/10.1007/s11119-020-09724-4>.

CRUZ, J. S.; ASSIS JUNIOR, R. N.; MATIAS, S. S. R.; CAMACHO-TAMAYO, J. H. Spatial variability of an Alfisol cultivated with sugarcane. **Ciencia e Investigación Agraria**, v. 38, n. 1, p. 155-164, 2011. <https://doi.org/10.4067/S0718-16202011000100015>.

CRUZ, J. S.; ASSIS JUNIOR, R. N.; MATIAS, S. S. R.; CAMACHO-TAMAYO, J. H.; TAVARES, R. C. Análise espacial de atributos físicos e carbono orgânico em argissolo vermelho-amarelo cultivado com cana-de-açúcar. **Ciência e Agrotecnologia**, v. 34, n. 2, p. 271-278, 2010. <https://doi.org/10.1590/S1413-70542010000200001>.

CUNHA, J. M.; CAMPOS, M. C. C.; GAIO, D. C.; NOGUEIRA, J. S.; SOARES, M. D. R.; SILVA, D. M. P.; OLIVEIRA, I. A. Fractal analysis in the description of soil particle-size distribution under different land-use patterns in Southern Amazonas State, Brazil. **African Journal of Agricultural Research**, v. 11, n. 23, p. 2032-2042, 2016. <https://doi.org/10.5897/AJAR2015.10649>.

CURSI, D. E.; GAZAFFI, R.; HOFFMANN, H. P.; BRASCO, T. L.; AMARAL, L. R.; DOURADO NETO, D. Novel tools for adjusting spatial variability in the early sugarcane breeding stage. **Frontiers in Plant Science**, v. 12, p. 1-11, 2021. <https://doi.org/10.3389/fpls.2021.749533>.

DALCHIAVON, F. C.; DAL BEM, E. A.; PASSOS E CARVALHO, M.; SARTO, M. D.; MONTANARI, R.; KANEKO, F. H. Relações da produtividade de cana-de-açúcar com atributos químicos de um argissolo. **Revista de Ciências Agrárias**, v. 40, n. 4, p. 60-69, 2017. <https://doi.org/10.19084/RCA17061>.

DALCHIAVON, F. C.; PASSOS E CARVALHO, M.; MONTANARI, R.; ANDREOTTI, M. Sugarcane productivity correlated with physical-chemical attributes to create soil management zone. **Revista Ceres**, v. 60, n. 5, p. 706-714, 2013a. <https://doi.org/10.1590/S0034-737X2013000500015>.

DALCHIAVON, F. C.; PASSOS E CARVALHO, M.; MONTANARI, R.; ANDREOTTI, M.; DAL BEM, E. A. Sugarcane trash management assessed by the interaction of yield with soil properties. **Revista Brasileira de Ciência do Solo**, v. 37, n. 6, p. 1709-1719, 2013b. <https://doi.org/10.1590/S0100-06832013000600027>.

DINARDO-MIRANDA, L. L.; FRACASSO, J. V. Spatial distribution of plant-parasitic nematodes in sugarcane fields. **Scientia Agricola**, v. 66, n. 2, p. 188-194, 2009. <https://doi.org/10.1590/S0103-90162009000200007>.

DINARDO-MIRANDA, L. L.; FRACASSO, J. V.; COSTA, V. P.; LOPES, D. O. T. Dispersal of *Cotesia flavipes* in sugarcane field and implications for parasitoid releases. **Bragantia**, v. 73, n. 2, p. 163-170, 2014. <https://doi.org/10.1590/brag.2014.023>.

DINARDO-MIRANDA, L. L.; VASCONCELOS, A. C. M.; VIEIRA, S. R.; FRACASSO, J. V.; GREGO, C. R. Uso da geoestatística na avaliação da distribuição espacial de *Mahanarva fimbriolata* em cana-de-açúcar. **Bragantia**, v. 66, n. 3, p. 449-455, 2007. <https://doi.org/10.1590/S0006-87052007000300011>.

GREGO, C. R.; VIEIRA, S. R.; XAVIER, M. A. Spatial variability of some biometric attributes of sugarcane plants (variety IACSP93-3046) and its relation to physical and chemical soil attributes. **Bragantia**, v. 69, Suplemento, p. 107-119, 2010. <https://doi.org/10.1590/S0006-87052010000500012>.

GUALBERTO, A. A. S.; NANNI, M. R.; SILVA JUNIOR, C. A.; CRUSIOL, L. G. T.; SILVA, G. F. C.; GASPAROTTO, A. C. Spatial distribution of soil chemical attributes in sugar cane crop area. **African Journal of Agricultural Research**, v. 11, n. 48, p. 4886-4893, 2016. <https://doi.org/10.5897/AJAR2016.11829>.

IAIA, A. M.; MAIA, J. C. S.; KIM, M. E. Uso do penetrômetro eletrônico na avaliação da resistência do solo cultivado com cana-de-açúcar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 10, n.2, p. 523-530, 2006. <https://doi.org/10.1590/S1415-43662006000200038>.

IZIDORIO, R.; MARTINS FILHO, M. V.; MARQUES JUNIOR, J.; SOUZA, Z. M.; PEREIRA, G. T. Perdas de nutrientes por erosão e sua distribuição espacial em área sob cana-de-açúcar. **Engenharia Agrícola**, v. 25, n. 3, p. 660-670, 2005. <https://doi.org/10.1590/S0100-69162005000300011>.

LEAL, F. T.; FRANÇA, A. B. C.; SIQUEIRA, D. S.; TEIXEIRA, D. D. B.; MARQUES JUNIOR, J.; SCALA JUNIOR, N. L. Characterization of potencial CO₂ emissions in agricultural areas using magnetic susceptibility. **Scientia Agrícola**, v. 72, n. 6, p. 535-539, 2015. <https://doi.org/10.1590/0103-9016-2014-0420>.

LEIVA, J. O. R.; SILVA, R. A.; BUSS, R. N.; FRANÇA, V. L.; SOUZA, A. A.; SIQUEIRA, G. M. Multifractal analysis of soil penetration resistance under sugarcane cultivation. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 7, p. 538-544, 2019. <https://doi.org/10.1590/1807-1929/agriambi.v23n7p538-544>.

MALDANER, L. F.; MOLIN, J. P. Data processing within rows for sugarcane yield mapping. **Scientia Agrícola**, v. 77, n. 5, p. 1-8, 2020. <https://doi.org/10.1590/1678-992X-2018-0391>.

MARQUES JUNIOR, J.; SIQUEIRA, D. S.; CAMARGO, L. A.; TEIXEIRA, D. D. B.; BARRÓN, V.; TORRENT, J. Magnetic susceptibility and diffuse reflectance spectroscopy to characterize the spatial variability of soil properties in a brazilian haplustalf. **Geoderma**, v. 219-220, p. 63-71, 2014. <https://doi.org/10.1016/j.geoderma.2013.12.007>.

MENDONÇA, P. G.; SILVA JUNIOR, J. F.; OLIVEIRA, I. R.; TEIXEIRA, D. D. B.; MOITINHO, M. R.; MARTINS FILHO, M. V.; MARQUES JUNIOR, J.; PEREIRA, G. T. Spatial uncertainty of nutrient loss by erosion in sugarcane harvesting scenarios. **Revista**

Brasileira de Ciência do Solo, v. 39, n. 4, p. 1181-1189, 2015. <https://doi.org/10.1590/01000683rbc20140432>.

MENDONÇA, P. G.; TEIXEIRA, D. D. B.; MOITINHO, M. R.; SILVA JUNIOR, J. F.; OLIVEIRA, I. R.; MARTINS FILHO, M. V.; MARQUES JUNIOR, J.; PEREIRA, G. T. Temporal and spatial uncertainty of erosion soil loss from an argissol under sugarcane management scenarios. **Revista Brasileira de Ciência do Solo**, v. 42, 2018. <https://doi.org/10.1590/18069657rbc20170182>.

MOITINHO, M. R.; TEIXEIRA, D. D. B.; BICALHO, E. S.; PANOSSO, A. R.; FERRAUDO, A. S.; PEREIRA, G. T.; TSAI, S. M.; BORGES, B. M. F.; SCALA JUNIOR, N. L. Soil CO₂ emission and soil attributes associated with the microbiota of a sugarcane area in southern Brazil. **Scientific Reports**, v. 11, p. 1-15, 2021. <https://doi.org/10.1038/s41598-021-87479-2>.

MONTANARI, R.; MARQUES JUNIOR, J.; PEREIRA, G. T.; SOUZA, Z. M. Forma da paisagem como critério para otimização amostral de latossolos sob cultivo de cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, v. 40, n. 1, p. 69-77, 2005. <https://doi.org/10.1590/S0100-204X2005000100010>.

MONTANARI, R.; PEREIRA, G. T.; MARQUES JUNIOR, J.; SOUZA, Z. M.; PAZETO, R. J.; CAMARGO, L. A. Variabilidade espacial de atributos químicos em latossolo e argissolos. **Ciência Rural**, v. 38, n. 5, 1266-1272, 2008. <https://doi.org/10.1590/S0103-84782008000500010>.

MONTANARI, R.; SOUZA, G. S. A.; PEREIRA, G. T.; MARQUES JUNIOR, J.; SIQUEIRA, D. S.; SIQUEIRA, G. M. The use of scaled semivariograms to plan soil sampling in sugarcane fields. **Precision Agriculture**, v. 13, p. 542-552, 2012. <https://doi.org/10.1007/s11119-012-9265-6>.

MORAES, D. A. C.; SPADOTTO, C. A.; SARTORI, A. A. C.; ZIMBACK, C. R. L. Variabilidade espacial do risco de contaminação de águas subterrâneas por *tebuthiuron* em área de cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, v. 51, n. 12, p. 1992-1999, 2016. <https://doi.org/10.1590/S0100-204X2016001200010>.

MOTOMIYA, A. V. A.; CORÁ, J. E.; PEREIRA, G. T. Uso da krigagem indicatriz na avaliação de indicadores de fertilidade do solo. **Revista Brasileira de Ciência do Solo**, v. 30, n. 3, p. 485-496, 2006. <https://doi.org/10.1590/S0100-06832006000300010>.

NICOLELLA, G.; PEREZ FILHO, A.; SOUZA, M. D.; FERRACINI, V. L. Geostatistics as a basis to the CMLS pesticide simulation model with validation in soil columns. **Scientia Agricola**, v. 62, n. 1, p. 50-56, 2005. <https://doi.org/10.1590/S0103-90162005000100010>.

OLIVEIRA, I. A.; CAMPOS, M. C. C.; AQUINO, R. E.; FREITAS, L.; SILVA, D. M. P. Spatial dependence of the aggregate stability and organic matter in a cambisol under sugar cane cultivation. **Revista Caatinga**, v. 26, n. 4, p. 1-9, 2013a.

OLIVEIRA, I. A.; CAMPOS, M. C. C.; AQUINO, R. E.; FREITAS, L.; SOUZA, Z. M.; CUNHA, J. M.; SOARES, M. D. R.; SILVA, D. M. P.; FONSECA, J. S.; SILVA, L. S.; SOUZA, F. G. Spatial variability of chemical pedoindicators in haplic Inceptisol under different

management systems in southern Amazonas state, Brazil. **Australian Journal of Crop Science**, v. 12, n. 8, p. 1250-1258, 2018a. <https://doi.org/10.21475/ajcs.18.12.08.PNE963>.

OLIVEIRA, I. A.; CAMPOS, M. C. C.; FREITAS, L.; AQUINO, R. E.; CUNHA, J. M.; SOARES, M. D. R.; SILVA, L. S.; FONSECA, J. S.; SILVA, D. M. P.; SOUZA, Z. M.; SOUZA, F. G. Carbon stock variability and aggregate stability in soils of Amazon, Brazil. **Australian Journal of Crop Science**, v. 12, n. 6, p. 922-930, 2018b. <https://doi.org/10.21475/ajcs.18.12.06.PNE961>.

OLIVEIRA, I. A.; CAMPOS, M. C. C.; MARQUES JUNIOR, J.; AQUINO, R. E.; TEIXEIRA, D. D. B.; SILVA, D. M. P. Use of scaled semivariograms in the planning sample of soil chemical properties in southern Amazonas, Brazil. **Revista Brasileira de Ciência do Solo**, v. 39, n. 1, p. 31-39, 2015. <https://doi.org/10.1590/01000683rbc20150525>.

OLIVEIRA, I. A.; CAMPOS, M. C. C.; SOARES, M. D. R.; AQUINO, R. E.; MARQUES JUNIOR, J.; NASCIMENTO, E. P. Variabilidade espacial de atributos físicos em um cambissolo háplico, sob diferentes usos na região sul do Amazonas. **Revista Brasileira de Ciência do Solo**, v. 37, n. 4, p. 1103-1112, 2013b. <https://doi.org/10.1590/S0100-06832013000400027>.

OLIVEIRA, I. R.; TEIXEIRA, D. D. B.; PANOSSO, A. R.; CAMARGO, L. A.; MARQUES JUNIOR, J.; PEREIRA, G. T. Modelagem geoestatística das incertezas da distribuição espacial do fósforo disponível no solo, em área de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, v. 37, n. 6, p. 1481-1491, 2013c. <https://doi.org/10.1590/S0100-06832013000600005>.

OLIVEIRA, I. R.; TEIXEIRA, D. D. B.; PANOSSO, A. R.; MARQUES JUNIOR, J.; PEREIRA, G. T. Modelagem e quantificação da incerteza espacial do potássio disponível no solo por simulações estocásticas. **Pesquisa Agropecuária Brasileira**, v. 49, n. 9, p. 708-718, 2014. <https://doi.org/10.1590/S0100-204X2014000900007>.

OLIVEIRA FILHO, F. X.; MIRANDA, N. O.; MEDEIROS, J. F.; SILVA, P. C. M.; MESQUITA, F. O.; COSTA, T. K. G. Compactação de solo cultivado com cana-de-açúcar em Baía Formosa, Rio Grande do Norte. **Revista Ceres**, v. 63, n. 5, p. 715-723, 2016. <https://doi.org/10.1590/0034-737X201663050017>.

OLIVEIRA FILHO, F. X.; MIRANDA, N. O.; MEDEIROS, J. F.; SILVA, P. C. M.; MESQUITA, F. O.; COSTA, T. K. G. Zona de manejo para preparo do solo na cultura da cana-de-açúcar. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 19, n. 2, p. 186-193, 2015. <https://doi.org/10.1590/1807-1929/agriambi.v19n2p186-193>.

PANOSSO, A. R.; MARQUES JUNIOR, J.; PEREIRA, G. T.; SCALA JUNIOR, N. L. Spatial and temporal variability of soil CO₂ emission in a sugarcane area under green and slash-and-burn managements. **Soil and Tillage Research**, v. 105, n. 2, p. 275-182, 2009. <https://doi.org/10.1016/j.still.2009.09.008>.

PANOSSO, A. R.; PERILLO, L. I.; FERRAUDO, A. S.; PEREIRA, G. T.; MIRANDA, J. G. V.; SCALA JUNIOR, N. L. Fractal dimension and anisotropy fo soil CO₂ emission in a mechanically harvested sugarcane production area. **Soil and Tillage Research**, v. 124, p. 8-16, 2012. <https://doi.org/10.1016/j.still.2012.04.005>.

PAVLU, F. A.; MOLIN, J. P. A sampling plan and spatial distribution for site-specific control of *Sphenophorus levis* in sugarcane. **Acta Scientiarum. Agronomy**, v. 38, n. 3, p. 279-287, 2016. <https://doi.org/10.4025/actasciagron.v38i3.28599>.

PELUCO, R. G.; MARQUES JUNIOR, J.; SIQUEIRA, D. S.; PEREIRA, G. T.; BARBOSA, R. S.; TEIXEIRA, D. D. B. Mapeamento do fósforo adsorvido por meio da cor e da suscetibilidade magnética do solo. **Pesquisa Agropecuária Brasileira**, v. 50, n. 3, p. 259-266, 2015. <https://doi.org/10.1590/S0100-204X2015000300010>.

PEREIRA, G. T.; SOUZA, Z. M.; TEIXEIRA, D. D. B.; MONTANARI, R.; MARQUES JUNIOR, J. Optimization of the sampling scheme for maps of physical and chemical properties estimated by kriging. **Revista Brasileira de Ciência do Solo**, v. 37, n. 5, 1128-1135, 2013. <https://doi.org/10.1590/S0100-06832013000500002>.

PEREIRA, G. T.; TEIXEIRA, D. D. B.; SOUZA, Z. M.; OLIVEIRA, I. R.; MARQUES JUNIOR, J. Stochastic simulations of calcium contents in sugarcane area. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 19, n. 8, p. 767-772, 2015. <https://doi.org/10.1590/1807-1929/agriambi.v19n8p767-772>.

PUSCH, M.; OLIVEIRA, A. L. G.; FONTENELLI, J. V.; AMARAL, L. R. Soil properties mapping using proximal and remote sensing as covariate. **Engenharia Agrícola**, v. 41, n. 6, p. 634-642, 2021. <https://doi.org/10.1590/1809-4430-Eng.Agric.v41n6p634-642/2021>.

RODRIGUES, K. M.; HURTADO, S. M. C.; DECHEN, S. C. F.; VIEIRA, S. R. Spatial variability in soil fertility and particle size and their effects on sugarcane yield. **Sugar Tech**, v. 18, n. 1, p. 39-48, 2016. <https://doi.org/10.1007/s12355-014-0359-5>.

RODRIGUES JUNIOR, F. A.; MAGALHÃES, P. S. G.; FRANCO, H. C. J.; BEAUCLAIR, E. G. F.; CERRI, D. G. P. Correlation between chemical soil attributes and sugarcane quality parameters according to soil texture zones. **Soil Science**, v. 178, n. 3, p. 147-156, 2013. <https://doi.org/10.1097/SS.0b013e31829132c5>.

SANCHES, G. M.; MAGALHÃES, P. S. G.; KOLLN, O. T.; OTTO, R.; RODRIGUES JUNIOR, F.; CARDOSO, T. F.; CHAGAS, M. F.; FRANCO, H. C. J. Agronomic, economic, and environmental assessment of site-specific fertilizer management of Brazilian sugarcane fields. **Geoderma Regional**, v. 124, p. 1-11, 2021. <https://doi.org/10.1016/j.geodrs.2021.e00360>.

SANCHEZ, R. B.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; BARACAT NETO, J.; SIQUEIRA, D. S.; SOUZA, Z. M. Mapeamento das formas do relevo para estimativa de custos de fertilização em cana-de-açúcar. **Engenharia Agrícola**, v. 32, n. 2, p. 280-292, 2012. <https://doi.org/10.1590/S0100-69162012000200008>.

SATIRO, L. S.; CHERUBIN, M. R.; LISBOA, I. P.; NOIA JUNIOR, R. S.; CERRI, C. C.; CERRI, C. E. P. Prediction of sugarcane yield by soil attributes under straw removal management. **Agronomy Journal**, v. 110, n. 6, p. 14-23, 2018. <https://doi.org/10.2134/agronj2018.01.0021>.

SCARPARI, M. S.; BEAUCLAIR, E. G. F. Variação espaço-temporal do Índice de Área Foliar e Brix em cana-de-açúcar. **Bragantia**, v. 67, n. 1, p. 35-41, 2008. <https://doi.org/10.1590/S0006-87052008000100004>.

SCHOSSLER, T. R.; MANTOVANELLI, B. C.; ALMEIDA, B. G.; FREIRE, F. J.; SILVA, M. M.; ALMEIDA, C. D. G. C.; FREIRE, M. B. G. S. Geospatial variation of physical attributes and sugarcane productivity in cohesive soils. **Precision Agriculture**, v. 20, n. 6, p. 1274-1291, 2019. <https://doi.org/10.1007/s11119-019-09652-y>.

SILVA, A. F.; BARBOSA, A. P.; ZIMBACK, C. R. L.; LANDIM, P. M. B.; SOARES, A. Estimation of croplands using indicator kriging and fuzzy classification. **Computers and Electronics in Agriculture**, v. 111, p. 1-11, 2015. <https://doi.org/10.1016/j.compag.2014.11.020>.

SILVA, E. F.; MOITINHO, M. R.; TEIXEIRA, D. D. B.; BICALHO, E. D.; CASTIONI, G. A. F.; PEREIRA, G. T.; SCALA JUNIOR, N. L. Short-term spatiotemporal variation of soil CO₂ emission, temperature, moisture and aeration in sugarcane field reform areas under the influence of precipitation events. **Soil Use and Management**, v. 36, n. 4, p. 658-670, 2020a. <https://doi.org/10.1111/sum.12633>.

SILVA, J.; ASSIS JÚNIOR, R. N.; MATIAS, S. S. R.; TAVARES, R. C.; ANDRADE, F. R.; CAMACHO-TAMAYO. Using geostatistic to evaluate the physical attributes of a soil cultivated with sugarcane. **Revista de Ciências Agrárias**, v. 57, n. 2, p. 186-193, 2014. <https://doi.org/10.4322/rca.2014.013>.

SILVA, J. C.; FRANÇA E SILVA, E. F.; SIQUEIRA, G. M.; SILVA, G. F.; SOUZA, D. H. S. Spatial continuity of electrical conductivity, soil water content and texture on a cultivated area with cane sugar. **Revista Caatinga**, v. 31, n. 2, p. 434-445, 2018a. <https://doi.org/10.1590/1983-21252018v31n220rc>.

SILVA, P. A.; LIMA, B. H.; SCALA JUNIOR, N. L.; PERUZZI, N. J.; CHAVARETTE, PANOSSO, A. R. Spatial variation of soil carbon stability in sugarcane crops, central-south of Brazil. **Soil and Tillage Research**, v. 202, p. 1-6, 2020b. <https://doi.org/10.1016/j.still.2020.104667>.

SILVA, R. B.; LANÇAS, K. P.; MIRANDA, E. E. V.; SILVA, F. A. M.; BAILO, F. H. R. Estimation and evaluation of dynamic properties as indicators of changes on soil structure in sugarcane fields of Sao Paulo State – Brazil. **Soil and Tillage Research**, v. 103, n. 2, p. 265-270, 2009. <https://doi.org/10.1016/j.still.2008.10.018>.

SILVA, W. P.; ALMEIDA, C. D. G. C.; MARQUES, K. P. P.; ALMEIDA, G. L. P.; ALMEIDA, B. G. The effect of vinasse application in lowland areas cultivated with sugarcane on spatiotemporal variability of groundwater salinity in the northeast of Brazil. **Journal of Experimental Agriculture International**, v. 20, n. 5, p. 1-11, 2018b. <https://doi.org/10.9734/JEAI/2018/39561>.

SILVA JUNIOR, J. F.; MARQUES JÚNIOR, J.; CAMARGO, L. A.; TEIXEIRA, D. D. B.; PANOSSO, A. R.; PEREIRA, G. T. Estimation of contents of iron oxides using geostatistics in two hillslope curvatures of an Alfisol under sugarcane cultivation. **Australian Journal of Crop Science**, v. 9, n. 8, p. 701-708, 2015.

SIQUEIRA, D. S.; MARQUES JÚNIOR, J.; TEIXEIRA, D. D. B.; MATIAS, S. S. R.; CAMARGO, L. A.; PEREIRA, G. T. Magnetic susceptibility for characterizing areas with different potentials for sugarcane production. **Pesquisa Agropecuária Brasileira**, v. 51, n. 9, 1349-1358, 2016. <https://doi.org/10.1590/S0100-204X2016000900034>.

SIQUEIRA, G. M.; FRANÇA E SILVA, E. F.; DAFONTE, J. D. Spatial distribution of soil apparent electrical conductivity measured by electromagnetic induction and sugarcane yield. **Bragantia**, v. 74, n. 2, p. 215-223, 2015. <https://doi.org/10.1590/1678-4499.0234>.

SOUZA, M. C.; OLIVEIRA, F. P.; SILVA, J. R.; MARTINS, A. F.; SILVA, P. L. F. Spatial variability of resistance to penetration in soil under sugarcane crops with different harvest methods. **Revista Caatinga**, v. 33, n. 2, p. 480-489, 2020. <https://doi.org/10.1590/1983-21252020v33n220rc>.

SOUZA, Z. M.; BARBIERI, D. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; CAMPOS, M. C. C. Influência da variabilidade espacial de atributos químicos de latossolo na aplicação de insumos para a cultura de cana-de-açúcar. **Ciência e Agrotecnologia**, v. 31, n. 2, p. 371-377, 2007. <https://doi.org/10.1590/S1413-70542007000200016>.

SOUZA, Z. M.; CAMPOS, M. C. C.; CAVALVANTE, I. H. L.; MARQUES JÚNIOR, J.; CESARIN, L. G.; SOUZA, S. R. Dependência espacial da resistência do solo à penetração e do teor de água do solo sob cultivo contínuo de cana-de-açúcar. **Ciência Rural**, v. 36, n. 1, p. 128-134, 2006. <https://doi.org/10.1590/S0103-84782006000100019>.

SOUZA, Z. M.; CERRI, D. G. P.; COLET, M. J.; RODRIGUES, L. H. A.; MAGALHÃES, P. S. G.; MANDONI, R. J. A. Análise dos atributos do solo e da produtividade da cultura de cana-de-açúcar com o uso da geoestatística e árvore de decisão. **Ciência Rural**, v. 40, n. 4, p. 840-847, 2010a. <https://doi.org/10.1590/S0103-84782010005000048>.

SOUZA, Z. M.; CERRI, D. G. P.; MAGALHÃES, P. S. G.; SIQUEIRA, D. S. Spatial variability of soil attributes and sugarcane yield in relation to topographic location. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 12, p. 1250-1256, 2010b. <https://doi.org/10.1590/S1415-43662010001200001>.

SOUZA, Z. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Spatial variability of physical and mineralogical properties of the soil from the areas with variation in landscape shapes. **Brazilian Archives of Biology and Technology**, v. 52, n. 2, p. 305-316, 2009. <https://doi.org/10.1590/S1516-89132009000200007>.

SOUZA, Z. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Variabilidade espacial da estabilidade de agregados e matéria orgânica em solos de relevos diferentes. **Pesquisa Agropecuária Brasileira**, v. 39, n. 5, p. 491-499, 2004a.

SOUZA, Z. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Variabilidade espacial de atributos físicos do solo em diferentes formas de relevo sob cultivo de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, v. 28, n. 6, p. 937-944, 2004b. <https://doi.org/10.1590/S0100-06832004000600001>.

SOUZA, Z. M.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; BARBIERI, D. M. Variabilidade espacial da textura de um latossolo vermelho eutroférico sob cultivo de cana-de-açúcar. **Engenharia Agrícola**, v. 24, n. 2, p. 309-319, 2004c. <https://doi.org/10.1590/S0100-69162004000200009>.

SOUZA, Z. M.; SOUZA, G. S.; MARQUES JÚNIOR, J.; PEREIRA, G. T. Número de amostras na análise geoestatística e na krigagem de mapas de atributos do solo. **Ciência Rural**, v. 44, n. 2, p. 261-268, 2014. <https://doi.org/10.1590/S0103-84782014000200011>.

SOUZA JUNIOR, F. J. C.; PEDROSA, E. M. R.; MONTENEGRO, A. A. A.; MARANHÃO, S. R. V. L.; VICENTE, T. F. S. Variabilidade espaço-temporal de *Meloidogyne* e *Pratylenchus* em áreas de cana-de-açúcar sob manejo de irrigação. **Nematrópica**, v. 50, n. 2, p. 186-199, 2020.

TAVARES, R. L. M.; CAMPOS, M. C. C.; SOUZA, Z. M.; SCALA, N. L. Análise geoestatística da emissão de CO₂ e macroporosidade de um latossolo vermelho eutroférico sob cana-de-açúcar. **Energia na Agricultura**, v. 32, n. 4, p. 349-355, 2017. <https://doi.org/10.17224/EnergAgric.2017v32n4p349-355>.

TAVARES, U. E.; ROLIM, M. M.; OLIVEIRA, V. S.; PEDROSA, E. M. R.; SIQUEIRA, G. M.; MAGALHÃES, A. G. Spatial dependence of physical attributes and mechanical properties of ultisol in a sugarcane field. **The Scientific World Journal**, 2015. <https://doi.org/10.1155/2015/531231>.

TEIXEIRA, D. D. B.; BICALHO, E. S.; PANOSSO, A. R.; CERRI, C. E. P.; PEREIRA, G. T.; SCALA JÚNIOR, N. L. Spatial variability of soil CO₂ emission in a sugarcane area characterized by secondary information. **Scientia Agrícola**, v. 70, n. 3, p. 195-203, 2013. <https://doi.org/10.1590/S0103-90162013000300008>.

TEIXEIRA, D. D. B.; BICALHO, E. S.; PANOSSO, A. R.; PERILLO, L. I.; IAMAGUTI, J. L.; PEREIRA, G. T.; SCALA JÚNIOR, N. L. Uncertainties in the prediction of spatial variability of soil CO₂ emissions and related properties. **Revista Brasileira de Ciência do Solo**, v. 36, n. 5, p. 1466-1475, 2012. <https://doi.org/10.1590/S0100-06832012000500010>.

TEIXEIRA, D. D. B.; MARQUES JÚNIOR, J.; SIQUEIRA, D. S.; VASCONCELOS, V.; CARVALHO JUNIOR, O. A.; MARTINS, E. S.; PEREIRA, G. T. Sample planning for quantifying and mapping magnetic susceptibility, clay content, and base saturation using auxiliary information. **Geoderma**, v. 305, p. 208-218, 2017. <https://doi.org/10.1016/j.geoderma.2017.06.001>.

TERÇARIOL, M. C.; BRANCAGLIONI, V. A.; ARTÊNCIO JÚNIOR, J. P.; MONTANARI, R.; TEIXEIRA FILHO, M. C. M.; BOLONHEZI, A. C.; SCALA, JÚNIOR, N. L.; CHAVARETTE, F. R.; PANOSSO, A. R. Spatial variability of soil CO₂ emission in soybean and sugarcane areas in Mato Grosso do Sul cerrado, Brazil. **Journal of Geospatial Modelling**, v. 2, n. 1, p. 44-66, 2016. <https://doi.org/10.22615/2526-1746-jgm-2.1-5888>.

TOMINAGA, T. T.; CÁSSARO, F. A. M.; BACCHI, O. O. S.; REICHARDT, K.; OLIVEIRA, J. C. M.; TIMM, L. C. Variability of soil water content and bulk density in a sugarcane field. **Australian Journal of Soil Research**, v. 40, n. 4, p. 605-614, 2002. <https://doi.org/10.1071/SR01020>.

VOLPE, H. X. L.; BARBOSA, J. C.; VIEL, S. R.; GOULART, R. M.; VACARI, A. M.; SALAS, C.; VEIGA, A. C. P.; BORTOLI, S. A. D. Determination of method to evaluate parasitism and cover area for studies on *Cotesia flavipes* in sugarcane. **African Journal of Agricultural Research**, v. 9, n. 4, p. 436-447, 2014. <https://doi.org/10.5897/AJAR2013.6991>.

WEILL, M. A. M.; SPAROVEK, G. Estudo da erosão na microbacia do Ceveiro (Piracicaba, SP): II – Interpretação da tolerância de perda de solo utilizando o método do Índice de Tempo de Vida. **Revista Brasileira de Ciência do Solo**, v. 32, n. 2, p. 815-824, 2008. <https://doi.org/10.1590/S0100-06832008000200035>.

ZANZARINI, F. V.; PISSARA, T. C. T.; BRANDÃO, F. J. C.; TEIXEIRA, D. D. B. Correlação espacial do índice de vegetação (NDVI) de imagem Landsat/ETM+ com os atributos do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 6, p. 608-614, 2013. <https://doi.org/10.1590/S1415-43662013000600006>.

ANEXO II – Uso de Aprendizado de Máquinas no contexto da cana-de-açúcar no Brasil

Tabela 1 - Autoria, objetos de estudo, resultados e/ou conclusões, métodos/algoritmos testados e municípios dos trabalhos identificados sobre o tema no Brasil.

AUTORES	OBJETIVO	RESULTADOS E/OU CONCLUSÕES	MÉTODOS/ALGORITMOS	MUNICÍPIO/UF
Dias & Neto (2004)	Apresentar uma abordagem para automatizar o processo de identificação e avaliação da ferrugem da cana-de-açúcar, por meio de análise de imagens adquiridas por aeromodelos	Os resultados mostraram que o método foi capaz de discriminar 3 níveis de infecção disponíveis em uma escala que abrange 9 níveis de infecção	<i>Artificial Neural Network</i> <i>Support Vector Machine</i> <i>Decision Tree</i>	**
Formaggio et al. (2010)	Desenvolver uma metodologia para automatizar a tarefa de mapeamento da cana-de-açúcar por meio de dados de sensoriamento remoto	A metodologia se mostrou eficiente e promissor para automatizar o processo de classificação da cana-de-açúcar para imagens do projeto Landsat	<i>Decision Tree</i>	Guará/SP Ipuã/SP São Joaquim da Barra/SP
Quinta et al. (2010)	Apresentar experimentos com algumas técnicas de visão computacional com o intuito de automatizar o processo de identificação e contagem de leveduras	O algoritmo de <i>Decision Tree</i> obteve melhores resultados, trazendo boa distinção entre classes	<i>Bayesian Networks</i> <i>Decision Tree</i>	**

Farias Junior et al. (2014)	Apresentar uma nova metodologia para monitoramento online da produção de etanol	O algoritmo <i>Extreme Learning Machine</i> forneceu uma alternativa muito boa à tradicional <i>Multilayer Perceptron Neural Network</i>	<i>Extreme Learning Machine</i> <i>Multilayer Perceptron Neural Network</i>	Estado de SP*
Barbosa et al. (2015)	Propor um controle prático e fácil da autenticidade de amostras de cana-de-açúcar	Se mostrou uma alternativa simples para avaliação da autenticidade de amostras de cana-de-açúcar em conjunto com dados de oligoelementos	<i>Naive Bayes</i> <i>Random Forest</i>	**
Bocca & Rodrigues (2016)	Avaliar o impacto de diferentes etapas da cadeia agroindustrial para modelar o rendimento da cana-de-açúcar	Os resultados permitiram a recomendação de um fluxo a ser seguido para o desenvolvimento de modelos de rendimento	<i>Support Vector Machine</i> <i>Random Forest</i> <i>Regression Tree</i> <i>Artificial Neural Network</i> <i>Boosted Regression Tree</i>	Teodoro Sampaio/SP
Yano et al. (2016)	Propor um sistema para levantamento de plantas daninhas, baseado no reconhecimento de padrões de imagens de VANT	A solução proposta alcançou uma precisão global de 82% e um coeficiente kappa de 0,73 em testes preliminares	<i>Random Forest</i>	Estado de SP*
Fernandes et al. (2017)	Prever a produtividade da cana-de-açúcar com auxílio de <i>Artificial Neural Network</i> e outras métricas derivadas de séries temporais	O método proposto foi capaz de estimar a produtividade da cana-de-açúcar, antecipando a previsão da safra em três meses antes da colheita	<i>Artificial Neural Network</i>	Estado de SP*

Fischer et al. (2017)	Investigar o uso de técnicas de <i>machine learning</i> para estudar o efeito de diferentes condições de processo na produção do etanol a partir do bagaço de cana-de-açúcar	Os resultados mostram claramente que as técnicas de machine learning podem ser usadas para avaliar o processo simultâneo de hidrólise e fermentação e prever condições otimizadas	<i>Artificial Neural Network</i> <i>Random Forest</i> <i>Classification Tree</i>	**
Oliveira et al. (2017)	Desenvolver modelos empíricos usando diferentes técnicas para antecipar teor de açúcar para estabelecimento de estratégia comercial	O melhor modelo foi obtido com o <i>Random Forest</i> , superando o <i>Support Vector Machine</i> e <i>Regression Tree</i>	<i>Support Vector Machine</i> <i>Random Forest</i> <i>Regression Tree</i>	Teodoro Sampaio/SP
Benites-Lazaro et al. (2018)	Identificar o compromisso das empresas produtoras de etanol, com a sustentabilidade e a governança para os negócios	Os resultados revelaram 36 temas principais para a definição de regras para setor, porém também demonstraram questões socioambientais críticas que podem afetar na imagem	<i>Latent Dirichlet Allocation</i>	**
Freitas et al. (2018)	Investigar o uso de algoritmo de <i>machine learning</i> para prever padrões espaciais de emissão de CO ₂ do solo durante curtos períodos em áreas de cana-de-açúcar	Os resultados indicam que a metodologia proposta forneceu estimativas confiáveis para a avaliação da emissão de gás carbônico, descrevendo a sua variabilidade espacial nos canaviais	<i>Multilayer Perceptron Neural Network</i>	Motuca/SP Guariba/SP Pradópolis/SP

Luciano et al. (2018)	Testar classificadores de imagens generalizados aplicáveis a grandes escalas e a diferentes anos	O algoritmo forneceu um classificador preciso e generalizado no espaço-tempo, reduzindo o tempo, custo e os recursos para mapear áreas de cana-de-açúcar em grandes escalas.	<i>Random Forest</i>	Paraguçu Paulista/SP Quatá/SP Rancharia/SP João Ramalho/SP
Tavares et al. (2018)	Identificar a predição de variáveis de fluxo de CO ₂ do solo em sistemas de manejo de cana-de-açúcar por meio de <i>machine learning</i>	O teor de argila do solo foi o mais importante para explicar o fluxo de CO ₂ . O <i>Random Forest</i> originou um modelo com bom ajuste.	<i>Random Forest</i>	Pradópolis/SP
Hespanhol et al. (2019)	Identificar padrões na produção de cana-de-açúcar	Foi possível a identificação de padrões, podendo ser observado as variáveis que menos e mais influenciaram	<i>K-Means</i>	Estado de SP*
Ferraciolli et al. (2019)	Implementar um protocolo com reconhecimento espacial e comparar com a abordagem de assumir independência entre amostras	O fato de assumir a independência, ao modelar o rendimento, levou à uma subestimação dos erros do modelo e uma superestimação durante o ajuste do modelo	<i>Boosted Regression Tree</i> <i>Random Forest</i> <i>Support Vector Regression</i>	Parapanema/SP Costa Rica/MS Caçu/GO Nova Alvorada do Sul/MS
Luciano et al. (2019)	Desenvolver um esquema operacional de classificação para mapeamento de áreas de cana-de-	O modelo final permitiu monitorar os plantios de cana-de-açúcar em escala regional, com eficiência, baixo custo,	<i>Random Forest</i>	Estado de SP*

	açúcar em escala regional por meio de imagens do projeto Landsat	recursos limitados e precisão próxima à de uma fotointerpretação		
Silva et al. (2019a)	Investigar a aplicação de algoritmos de <i>machine learning</i> para previsão de preços de açúcar, etanol hidratado e etanol anidro	Os resultados mostram que a aplicação do <i>Extreme Learning Machines</i> obteve os melhores resultados globais, se mostrando viáveis para este tipo de problema	<i>Extreme Learning Machine</i> <i>Echo States Network</i> <i>Multilayer Perceptron Neural Network</i>	Estado de SP*
Silva et al. (2019b)	Propor e avaliar o uso de algoritmo de <i>machine learning</i> par adequação da cultura da cana-de-açúcar, comparando-o com o método tradicional	Os resultados indicam que a metodologia pode fornecer informações importantes para a tomada de decisões, especialmente sobre cenários de mudanças climáticas	<i>K-Means</i>	Estado de SP*
Aono et al. (2020)	Utilizar algoritmos de <i>machine learning</i> para verificar a complexidade genômica da cana-de-açúcar para fins de melhoramento genético e resistência à ferrugem marrom	A metodologia se mostrou com potencial para auxiliar estudos sobre a organização genômica e a resistência à ferrugem marrom na cana-de-açúcar	<i>K-Nearest Neighbours</i> <i>Support Vector Machine</i> <i>Gaussian Process</i> <i>Decision Tree</i> <i>Random Forest</i> <i>Multilayer Perceptron Neural Network</i> <i>Adaptive Boosting</i> <i>Gaussian Naive Bayes</i>	Ribeirão Preto/SP Piracicaba/SP
Cardoso et al. (2020)	Desenvolver um sistema capaz de classificar imagens através do	Os testes revelaram que a precisão de cada classificador foi diferente e	<i>K-Nearest Neighbours</i> <i>Decision Tree</i>	Barretos/SP

	reconhecimento de padrões pré-estabelecidos	diretamente proporcional à quantidade e equilíbrio das amostras	<i>Random Forest</i> <i>Multilayer Perceptron Neural Network</i>	
Oliveira & Rodrigues (2020)	Avaliar as estimativas do teor de açúcar nos colmos de cana, por meio do desenvolvimento de modelos de <i>machine learning</i>	A avaliação sugere que as técnicas de <i>machine learning</i> , por si só, não são capazes de capturar todos os efeitos que influenciam no acúmulo de sacarose nos colmos da cana-de-açúcar	<i>Support Vector Machine</i> <i>Random Forest</i>	Nova Europa/SP
Rocha et al. (2020)	Detectar linhas de plantio e medir suas falhas, além de avaliar as linhas curvas que limitam substancialmente soluções e aplicações práticas	A proposta apresentou um erro relativo baixo, demonstrando que consegue identificar e medir as linhas de plantio com alta precisão	<i>K-Nearest Neighbours</i>	Quirinópolis/GO
Souza et al. (2020)	Mostrar a possibilidade de diferenciar plantas de cana-de-açúcar de plantas daninhas pelo comportamento espectral das folhas	Foi demonstrado que a metodologia pode permitir o mapeamento de ervas daninhas e facilitar a aplicação localizada de herbicidas	<i>Random Forest</i>	**
Almeida et al. (2021)	Determinar ambientes de produção de cana-de-açúcar com número reduzido de varáveis de baixo custo	O algoritmo foi eficaz para a determinação dos ambientes e geração de ambientes de manejo mais contínuos na área de cultivo.	<i>Decision Tree</i>	Guataparã/SP
Borg et al. (2021)	Utilizar dados reais de uma planta industrial sucroalcooleira para	Os classificadores obtiveram precisão superior a 98% para diferentes	<i>Support Vector Machine</i> <i>Multilayer Perceptron Neural Network</i>	**

	identificar a presença de turbulência e espuma em tanques de fermentação	condições ambientais, comprovando a eficácia da metodologia		
Canata et al. (2021)	Explorar o potencial de dados de imagens multitemporais do projeto Sentinel-2, como alternativa para o mapeamento da produtividade da cana-de-açúcar	No geral o algoritmo <i>Random Forest</i> apresentou o melhor desempenho para prever a produtividade da cana-de-açúcar, quando comparado à Regressão Múltipla Linear.	<i>Random Forest</i> <i>Multiple Linear Regression</i>	Botucatu/SP
Luciano et al. (2021)	Prever a produtividade da cana-de-açúcar por meio de imagens do projeto Landsat	Os resultados demonstraram potencial para auxiliar no manejo da produção da cana-de-açúcar	<i>Random Forest</i>	Estado de SP*
Maldaner et al. (2021a)	Treinar algoritmos de <i>machine learning</i> utilizando dados disponíveis no computador de bordo de uma colheitadeira	No geral o algoritmo <i>Random Forest</i> apresentou os melhores resultados para os parâmetros considerados	<i>Random Forest</i> <i>Multiple Linear Regression</i> <i>Artificial Neural Network</i>	Cândido Rodrigues/SP
Maldaner et al. (2021b)	Testar um sistema alternativo de detecção em fileiras de plantios de cana-de-açúcar	O algoritmo <i>Decision Tree</i> apresentou a melhor precisão na detecção de plantas, podendo apoiar no manejo	<i>Decision Tree</i> <i>Random Forest</i> <i>Support Vector Machine</i>	Piracicaba/SP São Manuel/SP
Moreira et al. (2021)	Comparar técnicas de classificação de <i>machine learning</i> para seleção entre famílias de cana-de-açúcar, além de avaliar o mais prático e rápido	O melhor desempenho observado foi do algoritmo <i>Support Vector Machine</i>	<i>Logistic Regression</i> <i>K-Nearest Neighbours</i> <i>Random Forest</i> <i>Support Vector Machine</i>	Oratórios/MG

Ozelame et al. (2021)	Encontrar uma arquitetura preditiva e interpretável para proporção de falhas em talhões de cana-de-açúcar	Os resultados demonstram que houve indícios de que a metodologia proposta reflete em uma melhora das medidas de adequação e das possibilidades de interpretação	<i>Bayesian Networks</i>	**
Pimenta et al. (2021)	Investigar a base genética da doença da folha amarela da cana-de-açúcar para o melhoramento genético da cana-de-açúcar	A abordagem pode ser útil para acelerar o melhoramento da cana-de-açúcar visando a resistência à doença da folha amarela da cana-de-açúcar e facilitar estudos sobre os processos biológicos	<i>Adaptive Boosting</i> <i>Decision Tree</i> <i>Gaussian Naive Bayes</i> <i>Gaussian Process</i> <i>K-Nearest Neighbours</i> <i>Multilayer Perceptron Neural Network</i> <i>Random Forest</i> <i>Support Vector Machine</i>	Ribeirão Preto/SP
Rodrigues & Pereira (2021)	Apresentar uma abordagem através de modelos baseados em machine learning aplicados em imagens NDVI para estimativas da produtividade da cultura da cana-de-açúcar	O algoritmo <i>Random Forest</i> apresentou-se mais eficiente, mostrando-se, juntamente com os demais, consistente para as estimativas da produtividade da cana-de-açúcar	<i>Convolution Neural Network</i> <i>K-Nearest Neighbours</i> <i>Random Forest</i> <i>Support Vector Machine</i> <i>Adaptive Boosting</i>	**
Shibuya et al. (2021)	Preencher lacunas em imagens do projeto Venus, ocasionadas por nuvens ou sombras de nuvens	Os resultados se mostraram uma boa adaptação para a cana-de-açúcar, apresentando alta precisão global e	<i>Random Forest</i>	Estado de SP*

		permitindo uma melhor discriminação nas classes de uso da terra.			
Andrade & Ramires (2022)	Propor um modelo de machine learning supervisionado para identificar a invasão de plantas daninhas em um cultivar de cana-de-açúcar	Foi possível a identificação exata da infestação, o que possibilitou realizar aplicação de herbicida de forma precisa, evitando aumento de custo	<i>Random Forest</i>	**	
Aono et al. (2022)	Desenvolver um método de <i>machine learning</i> para prever característica complexas a partir de dados genotípicos	Foi desenvolvido um sistema preditivo com resultados promissores, alcançando melhorias de precisão superiores a 50% quando comparado a métodos tradicionais de previsão genômica	<i>K-Nearest Neighbours</i> <i>Support Vector Machine</i> <i>Random Forest</i> <i>Adaptive Boosting</i>	Ribeirão Preto/SP Sales de Oliveira/SP Piracicaba/SP	
Kai et al. (2022)	Classificar 4 variedades de cana-de-açúcar por meio de técnicas de Artificial Neural Networks e posterior comparação com técnicas tradicionais de <i>machine learning</i> , a partir de imagens do projeto Sentinel-2	O algoritmo <i>Support Vector Machine</i> apresentou melhor precisão, demonstrando que as bandas espectrais do infravermelho próximo e do infravermelho de ondas curtas, são adequadas para a discriminação de variedade de cana-de-açúcar.	<i>K-Nearest Neighbours</i> <i>Support Vector Machine</i> <i>Random Forest</i> <i>Artificial Neural Network</i>	Estado do GO*	
Luciano et al. (2022)	Mapear áreas de cana-de-açúcar em um intervalo temporal de 33 anos,	Os resultados se mostraram aplicáveis ao monitoramento em grandes áreas canavieiras e por vários anos,	<i>Random Forest</i>	Estado de SP*	

	por meio de imagens do projeto Landsat	podendo auxiliar o setor energético canavieiro.		
Melo et al. (2022a)	Avaliar o desempenho de um espectrômetro portátil, com a banda do infravermelho próximo, para o desenvolvimento de modelos de calibração para quantificação de brix e pol em diversas etapas de um processo industrial de produção de açúcar	Dentre os métodos utilizados, o <i>Support Vector Machine</i> apresentou o melhor desempenho, destacando o emprego mais barato e simples do espectrômetro portátil	<i>Partial Least Squares</i> <i>Support Vector Machine</i>	Estado do PE*
Melo et al. (2022b)	Propor um método para avaliação de imagens térmicas da cultura da cana-de-açúcar para prever seu estado hídrico	Os resultados mostraram que o sistema desenvolvido obteve desempenho superior em comparação às avaliações feitas pelo ser humano e auxiliou na classificação do estresse hídrico	<i>Artificial Neural Network</i>	Piracicaba/SP
Mendes & Dematté (2022)	Utilizar algoritmo de <i>machine learning</i> para previsão de Unidades de Mapeamento do Solo e suas respectivas ordens	O nível de associação entre Unidades de Mapeamento do Solo e os ambientes produtivos foi considerada como uma relação muito forte	<i>Random Forest</i>	Capivari/SP Charqueada/SP Iracemópolis/SP Mombuca/SP Piracicaba/SP Rafard/SP Rio das Pedras/SP

	Prever parâmetros biométricos da cana-de-açúcar com uso de <i>machine learning</i> e análise de imagens multiespectrais de VANT	O algoritmo utilizado apresentou previsões precisas para os parâmetros: número de perfilhos, altura da planta e diâmetro do colmo.	<i>Multiple Linear Regression</i> <i>Random Forest</i>	Saltinho/SP
Oliveira et al. (2022)		Para a 1ª abordagem a melhores previsões foram para o <i>eXtreme Gradient Boosting – Linear Method</i> e <i>eXtreme Gradient Boosting – Tree Method</i> , enquanto para a 2ª abordagem o <i>eXtreme Gradient Boosting – Linear Method</i> apresentou superioridade	<i>Linear Regression</i> <i>Cubist</i> <i>eXtreme Gradient Boosting – Linear Method</i> <i>eXtreme Gradient Boosting – Tree Method</i>	Jaboticabal/SP
Santos et al. (2022)	Propor a aplicação de algoritmos de <i>machine learning</i> para estimar evapotranspiração com dados dos projetos Landsat e Sentinel-2	O <i>Random Forest</i> foi o mais adequado para classificar todas as categorias de rendimento. O <i>Naive Bayes</i> apresentou potencial para resolver problemas multiclases na agricultura. A matéria orgânica foi a propriedade mais relacionada com a produtividade da biomassa pelos algoritmos <i>Random Forest</i> e <i>Decision Tree</i> .	<i>Naive Bayes</i> <i>Decision Tree</i> <i>Random Forest</i>	Estado de MG*
Yepes et al. (2022)	Descrever um método de classificação da produtividade da cana-de-açúcar com base em propriedades do solo, para determinar qual mais se associa à produção de biomassa			Campinas/SP

Barbosa Junior et al. (2023)	Analisar se a fusão de imagens multiespectrais de VANT e algoritmos de <i>machine learning</i> , podem desenvolver uma estrutura preditiva para mapear a refletância do dossel para dimensionar o Brix e a Pureza	Foi possível observar evidências de funções biofísicas prevendo com precisão o Brix e a Pureza, com pelo menos 80% de adequação à modelagem	<i>Multiple Linear Regression</i> <i>Random Forest</i> <i>Decision Tree</i> <i>Support Vector Machine</i>	Jaboticabal/SP
Costa et al. (2023a)	Estimar a produtividade média de talhões de cana-de-açúcar utilizando séries temporais de imagens do sensor MSI/Sentinel-2	Os resultados que a metodologia utilizada pode ser útil para estimar com eficiência a produtividade média de talhões de cana-de-açúcar	<i>Gradient Boosting Regressor</i>	Nova Londrina/PR
Costa et al. (2023b)	Utilizar algoritmos de <i>machine learning</i> para estabelecer um modelo de estimativa da evapotranspiração em imagens do projeto Sentinel-2 e análise da aplicabilidade temporal e espacial	Observou-se que a evapotranspiração pode ser monitorada espacial e temporalmente sem a utilização da banda térmica, o que faz com que a estimativa deste parâmetro seja realizada com maior frequência temporal	<i>Multiple Linear Regression</i> <i>Linear Support Vector Machine</i> <i>Cubist</i> <i>Bayesian-Regularized Neural Network</i> <i>eXtreme Gradient Boosting Linear</i> <i>Tree Methods</i>	Itapaci/GO
Fukuzava & Luciano (2023)	Utilizar séries temporais do projeto Sentinel-2 e algoritmos de <i>machine learning</i> para identificar diferentes estágios da cana-de-açúcar	A metodologia possibilitou uma boa discriminação entre os diferentes estágios de desenvolvimento da cana-de-açúcar	<i>Random Forest</i>	Estado de SP*

Gómez et al. (2023)	<p>Mapear a capacidade de água disponível no solo como forma de apoiar o planejamento agrícola em resposta aos efeitos do clima nos plantios</p>	<p>A metodologia aplicada forneceu suporte para o mapeamento proposta, fornecendo informações sobre a adaptação dos períodos de crescimento da cultura em relação aos efeitos das mudanças climáticas</p>	<p><i>Random Forest</i></p>	<p>Capivari/SP Charqueada/SP Iracemópolis/SP Mombuca/SP Piracicaba/SP Rafard/SP Rio das Pedras/SP Saltinho/SP</p>
Greschuk et al. (2023)	<p>Avaliar o potencial produtivo de solos utilizados para plantio de cana-de-açúcar, através da abordagem “SoilPP”, que se baseia na análise de solos e <i>machine learning</i></p>	<p>Através das ferramentas e da análise dos rendimentos históricos da cana-de-açúcar, foi possível identificar que 38% das áreas nacionais de cana-de-açúcar podem ser melhoradas</p>	<p><i>Random Forest</i></p>	<p>**</p>
Muetanene et al. (2023)	<p>Comparar alguns índices de seleção e o <i>machine learning</i>, para definir famílias de cana-de-açúcar</p>	<p>O algoritmo <i>Support Vector Machine</i> obteve piores desempenhos que os outros índices de seleção, isso se deve, provavelmente, ao menor número de amostras utilizados para estimar a matriz de correlação</p>	<p><i>Support Vector Machine</i></p>	<p>Oratórios/MG</p>
Petrielli et al. (2023)	<p>Integrar a classificação de imagens de satélite para áreas de cana-de-açúcar com modelagem</p>	<p>A estrutura georreferenciada mostrou variações espaciais significativas que</p>	<p><i>Random Forest</i></p>	<p>Estado de SP* Estado do PR* Estado do MS*</p>

	georeferenciada para a produtividade de cana-de-açúcar e produção de etanol	devem ser levadas em conta em futuras avaliações de susceptibilidade		Estado do MT* Estado de MG* Estado de GO*
Shibuya et al. (2023)	Realizar um estudo de monitoramento agrícola e analisar a mudança de uso da terra devido ao crescimento da implantação da cultura de cana-de-açúcar	Os resultados demonstram que a mudança no uso da terra de fato ocorreu, muito devido a chegada de usinas para produção de etanol no contexto da área de estudo	<i>Random Forest</i> <i>Gradient Tree Boosting</i> <i>Support Vector Machine</i>	Alto Taquari/MT
Speranza et al. (2023)	Descrever a importância da utilização de diferentes índices de vegetação obtidos de imagens suborbitais, nas diferentes fases de desenvolvimento da cana-de-açúcar, como variáveis preditoras para a estimativa da produtividade	Os resultados demonstraram que determinados índices de vegetação possibilitaram a geração de modelos de estimativa de produtividade, tanto na fase de crescimento quanto na fase de maturação	<i>Random Forest</i>	Piracicaba/SP Charqueada/SP

* Foi identificado a Unidade Federativa do Brasil onde a pesquisa foi desenvolvida, porém não foi identificado qual o seu município.

** Pesquisa realizada no Brasil, porém sem a identificação da Unidade Federativa onde foi realizada.

REFERÊNCIAS

- ALMEIDA, G. M.; PEREIRA, G. T.; BAHIA, A. S. R. S.; FERNANDES, K.; MARQUES JUNIOR, J. Machine learning in the prediction of sugarcane production environments. **Computers and Eletronics in Agriculture**, v. 190, p. 106452, 2021. <https://doi.org/10.1016/j.compag.2021.106452>.
- ANDRADE, R.; RAMIRES, T. Precision agriculture: herbicide reduction with AI models. **Proceedings of the 4th International Conference on Statistics**, v. 152, 2022. <https://doi.org/10.11159/icsta22.152>.
- AONO, A. H.; COSTA, E. A.; RODY, H. V. S.; NAGAI, J. S.; PIMENTA, R. J. G.; MANCINI, M. C.; SANTOS, F. R. C.; PINTO, L. R.; LANDELL, M. G. A.; SOUZA, A. P.; KUROSHU, R. M. Machine learning approaches reveal genomic regions associated with sugarcane brown rust resistance. **Scientific Reports**, v. 10, n. 1, p. 20057, 2020. <https://doi.org/10.1038/s41598-020-77063-5>.
- AONO, A. H.; FERREIRA, R. C. U.; MORAES, A. C. L.; LARA, L. A. C.; PIMENTA, R. J. G.; COSTA, E. A.; PINTO, L. R.; LANDELL, M. G. A.; SANTOS, M. F.; JANK, L.; BARRIOS, S. C. L.; VALLE, C. B.; CHIARI, L.; GARCIA, A. A. F.; KUROSHU, R. M.; LORENA, A. C.; GORJANC, G.; SOUZA, A. P. A joint learning approach for genomic prediction in polyploid grasses. **Scientific Reports**, v. 12m n. 1, p. 12499, 2022. <https://doi.org/10.1038/s41598-022-16417-7>.
- BARBOSA, R. M.; BATISTA, B. L.; BARIÃO, C. V.; VARRIQUE, R. M.; COELHO, V. A.; CAMPIGLIA, A. D.; BARBOSA JUNIOR. A simple and practical controlo of the authenticity of organic sugarcane samples based on the use of machine-learning algorithms and trace elements determination by inductively coupled plasma mass spectrometry. **Food Chemistry**, v. 184, p. 154-159, 2015. <https://doi.org/10.1016/j.foodchem.2015.02.146>.
- BARBOSA JUNIOR, M. R.; MOREIRA, B. R. A.; OLIVEIRA, R. P.; SHIRATSUCHI, L. S.; SILVA, R. P. UAV imagery data and machine learning: a driving merger for predictive analysis of qualitative yield in sugarcane. **Frontiers in Plant Science**, v. 14, p. 1114852, 2023. <https://doi.org/10.3389/fpls.2023.1114852>.
- BENITES-LAZARO, L. L.; GIATTI, L.; GIAROLLA, A. Sustainability and governance of sugarcane ethanol companies in Brazil: topic modeling analysis of CSR reporting. **Journal of Cleaner Production**, v. 197, n. 1, p. 583-591, 2018. <https://doi.org/10.1016/j.jclepro.2018.06.212>.
- BOCCA, F. F.; RODRIGUES, L. H. A. The effect of tuning, feature engineering, and feature selection in data mining applied to rainfed sugarcane yield modelling. **Computers and Eletronics in Agriculture**, v. 128, p. 67-76, 2016. <https://doi.org/10.1016/j.compag.2016.08.015>.
- BORG, D.; SESTITO, G. S.; SILVA, M. M. Machine-learning classification of environmental conditions inside a tank by analyzing radar curves in industrial level measurements. **Flow Measurement and Instrumentation**, v. 79, p. 101940, 2021. <https://doi.org/10.1016/j.flowmeasinst.2021.101940>.

CANATA, T. F.; WEI, M. C. F.; MALDANER, L. F.; MOLIN, J. P. Sugarcane yield mapping using high-resolution imagery data and machine learning technique. **Remote Sensing**, v. 13, n. 2, p. 232, 2021. <https://doi.org/10.3390/rs13020232>.

CARDOSO, J. R. F.; FURLANI, C. E. A.; TURCO, J. E. P.; ZERBATO, C.; CARNEIRO, F. M.; ESTEVAM, F. N. L. Development of a robotic structure for acquisition and classification of images (ERACI) in sugarcane crops. **Revista Ciência Agronômica**, v. 51(Edição Especial), p. e20207741, 2020. <https://doi.org/10.5935/1806-6690.20200102>.

COSTA, J. P. S.; SILVA, L. G.; ADAMI, M.; SANCHES, I. D. A. Predição da produtividade média de cana-de-açúcar a partir de imagens orbitais do sensor MSI/Sentinel-2. **Anais do XX Simpósio Brasileiro de Sensoriamento Remoto**, 2023a.

COSTA, T. S.; FILGUEIRAS, R.; SANTOS, R. A.; CUNHA, F. F. Actual evapotranspiration by machine learning and remote sensing without the thermal spectrum. **PLoS ONE**, v. 18, n. 5, p. e0285535, 2023b. <https://doi.org/10.1371/journal.pone.0285535>.

DIAS, D. N.; NETO, J. B. Identificação de ferrugem por meio de imagens aéreas cultivadas com cana-de-açúcar. **IV Congresso Brasileiro de Computação**, 2004.

FARIAS JUNIOR, F. S.; AZEVEDO, R. A.; RIVERA, E. C.; HERRERA, W. E.; FILHO, R. M.; LIMA JUNIOR, L. P. Product quality monitoring using Extreme Learning Machines and Bat algorithms: a case study in second-generation ethanol production. **24th European Symposium on Computer Aided Process Engineering**, v. 33, p. 955-960, 2014. <https://doi.org/10.1016/B978-0-444-63456-6.50160-5>.

FISCHER, J.; LOPES, V. S.; CARDOSO, S. L.; COUTINHO FILHO, U.; CARDOSO, V. L. Machine learning techniques applied to lignocellulosic ethanol in simultaneous hydrolysis and fermentation. **Brazilian Journal of Chemical Engineering**, v. 34, n. 1, p. 53-63, 2017. <https://doi.org/10.1590/0104-6632.20170341s20150475>.

FERNANDES, J. L.; EBECKEN, N. F. F.; ESQUERDO, J. C. D. M. Sugarcane yield prediction in Brazil using NDVI time series and neural networks ensemble. **International Journal of Remote Sensing**, v. 38, n. 16, p. 4631-4644, 2017. <https://doi.org/10.1080/01431161.2017.1325531>.

FERRACIOLLI, M. A.; BOCCA, F. F.; RODRIGUES, L. H. A. Neglecting spacial autocorrelation causes underestimation of the error of sugarcane yield models. **Computers and Electronics in Agriculture**, v. 161(Edição Especial), p. 233-240, 2019. <https://doi.org/10.1016/j.compag.2018.09.003>.

FORMAGGIO, A. R.; VIEIRA, M. A.; RENNÓ, C. D.; AGUIAR, D. A.; MELLO, M. P. Object-Based Image Analysis and data mining for mapping sugarcane with Landsat imagery in Brazil. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, 2010.

FREITAS, L. P. S.; LOPES, M. L. M.; CARVALHO, L. B.; PANOSSO, A. R.; SCALA JUNIOR, N. L.; FREITAS, R. L. B.; MINUSSI, C. R.; LOTUFO, A. D. P. Forecasting the spatiotemporal variability of soil CO₂ emissions in sugarcane areas in southeastern Brazil using

artificial neural networks. **Environmental Monitoring and Assessment**, v. 190, p. 741, 2018. <https://doi.org/10.1007/s10661-018-7118-0>.

FUKUZAVA, H. M.; LUCIANO, A. C. S. Classificação dos estágios de corte da cana-de-açúcar a partir de imagens Sentinel-2 e aprendizagem de máquina. **Anais do XX Simpósio Brasileiro de Sensoriamento Remoto**, 2023.

GÓMEZ, A. M. R.; VAN LIER, Q. J.; SILVERO, N. E. Q.; INFORSATO, L.; MELO, M. L. A.; RODRÍGUEZ-ALBARRACÍN, H. S.; ROSIN, N. A.; ROSAS, J. T. F.; RIZZO, R.; DEMATTÊ, J. A. M. Digital mapping of the soil available water capacity: tool for the resilience of agricultural systems to climate change. **Sciences of the Total Environment**, v. 882, p. 163572, 2023. <https://doi.org/10.1016/j.scitotenv.2023.163572>.

GRESCHUK, L. T.; DEMATTÊ, J. A. M.; SILVERO, N. E. Q.; ROSIN, N. A. A soil productivity system reveals most Brazilian agricultural lands are below their maximum potential. **Scientific Reports**, v. 13, p. 14103, 2023. <https://doi.org/10.1038/s41598-023-39981-y>.

HESPANHOL, P. F. P.; COLETTA, L. F. S.; GABRIEL, C. P. C.; GABRIEL FILHO, L. R. A. Identificação de padrões na produção de cana-de-açúcar utilizando k-means e análise multivariada. **XLVIII Congresso Brasileiro de Engenharia Agrícola**, 2019.

KAI, P. M.; OLIVEIRA, B. M.; COSTA, R. M. Deep learning-based method for classification of sugarcane varieties. **Agronomy**, v. 12, n. 11, p. 2722, 2022. <https://doi.org/10.3390/agronomy12112722>.

LUCIANO, A. C. S.; CAMPAGNUCI, B. C. G.; LE MAIRE, G. Mapping 33 years of sugarcane evolution in São Paulo state, Brazil, using landsat imagery and generalized space-time classifiers. **Remote Sensing Applications: Society and Environment**, v. 26, p. 100749, 2022. <https://doi.org/10.1016/j.rsase.2022.100749>.

LUCIANO, A. C. S.; PICOLI, M. C. A.; DUFT, D. G.; ROCHA, J. V.; LEAL, M. R. L. V.; LE MAIRE, G. Empirical model for forecasting sugarcane yield on a local scale in Brazil using Landsat imagery and random forest algorithm. **Computers and Electronics in Agriculture**, v. 184, p. 106063, 2021. <https://doi.org/10.1016/j.compag.2021.106063>.

LUCIANO, A. C. S.; PICOLI, M. C. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C.; LEAL, M. R. L. V.; LE MAIRE, G. A generalized space-time OBIA classification scheme to map sugarcane areas at regional scale, using Landsat images time-series and the random forest algorithm. **International Journal of Applied Earth Observation and Geoinformation**, v. 80, p. 127-136, 2019. <https://doi.org/10.1016/j.jag.2019.04.013>.

LUCIANO, A. C. S.; PICOLI, M. C. A.; ROCHA, J. V.; FRANCO, H. C. J.; SANCHES, G. M.; LEAL, M. R. L. V.; LE MAIRE, G. Generalized space-tempo classifiers for monitoring sugarcane áreas in Brazil. **Remote Sensing of Environment**, v. 215, p. 438-451, 2018. <https://doi.org/10.1016/j.rse.2018.06.017>.

MALDANER, L. F.; CORREDO, L. P.; CANATA, T. F.; MOLIN, J. P. Predicting the sugarcane yield in real-time by harvester engine parameters and machine learning approaches.

Computers and Eletronics in Agriculture, v. 181, p. 105945, 2021a. <https://doi.org/10.1016/j.compag.2020.105945>.

MALDANER, L. F.; MOLIN, J. P.; CANATA, T. F.; MARTELLO, M. A system for plant detection using sensor fusion approach based on machine learning model. **Computers and Eletronics in Agriculture** 189: 106382, 2021b. <https://doi.org/10.1016/j.compag.2021.106382>.

MELO, B. H. S.; SALES, R. F.; BASTOS FILHO, L. S.; SILVA, J. S. P.; SOUSA, A. G. C. A.; PEIXOTO, D. M. C. P.; PIMENTEL, M. F. Handheld near infrared spectrometer and machine learning methods applied to the monitoring of multiple process stages in industrial sugar production. **Food Chemistry** 369: 130919, 2022a. <https://doi.org/10.1016/j.foodchem.2021.130919>.

MELO, L. L.; MELO, V. G. M. L.; MARQUES, P. A. A.; FRIZZONE, J. A.; COELHO, R. D.; ROMERO, R. A. F.; BARROS, T. H. S. Deep learning for idenfication of water déficits in sugarcane based on termal images. **Agricultural Water Management** 272: 107820, 2022b. <https://doi.org/10.1016/j.agwat.2022.107820>.

MENDES, W. S.; DEMATTÊ, J. A. M. Digital soil mapping outputs on soil classification and sugarcane production in Brazil. **Journal of South American Earth Sciences** 116: 103881, 2022. <https://doi.org/10.1016/j.jsames.2022.103881>.

MOREIRA, E. F. A.; BARBOSA, M. H. P.; PETERNELLI, L. A. Can statistical learning models make early selection among sugarcane families easier and still eficiente?. **Crop Science** 61(1): 456-465, 2021. <https://doi.org/10.1002/csc2.20334>.

MUETANENE, B. A.; PETERNELLI, L. A.; CARNEIRO, P.; SILVA, F. L.; BARBOSA, D. P.; RIBEIRO JUNIOR, J. I. Selection indices and Support Vector Machines in the selection of sugarcane families. **Brazilian Journal of Agriculture** 98(1): 23-37, 2023. <https://doi.org/10.37856/bja.v98i1.4321>.

OLIVEIRA, R. P.; BARBOSA JUNIOR, M. R.; PINTO, A. A.; OLIVEIRA, J. L. P.; ZERBATO, C.; FURLANI, C. E. A. Predicting sugarcane biometric parameters by UAV multispectral images and machine learning. **Agronomy** 12(9): 1992, 2022. <https://doi.org/10.3390/agronomy12091992>.

OLIVEIRA, M. P. G.; BOCCA, F. F.; RODRIGUES, L. H. A. From spreadsheets to sugar contente modeling: a data mining approach. **Computers and Eletronics in Agriculture** 132: 14-20, 2017. <https://doi.org/10.1016/j.compag.2016.11.012>.

OLIVEIRA, M. P. G.; RODRIGUES, L. H. A. How good are the models available for estimating sugar content in sugarcane?. **European Journal of Agronomy** 113: 125992, 2020. <https://doi.org/10.1016/j.eja.2019.125992>.

OZELAME, C. S.; LOPES, R.; ARA, A.; LOUZADA, F. Structure estimation in Bayesian Networks via scoring and restrict method: an application in the area of agriculture. **Sigmae** 10(1): 12-33, 2021.

PETRIELLI, G. P.; NOGUEIRA, G. P.; HENZLER, D. S.; SOUZA, N. R. D.; BRUNO, K. M. B.; LUCIANO, A. C. S.; LE MAIRE, G.; HERNANDES, T. A. D. Integrating carbon footprint to spatialized modeling: the mitigation potential of sugarcane ethanol production in the Brazilian Center-South. **Resources, Conservation & Recycling** 189: 106725, 2023. <https://doi.org/10.1016/j.resconrec.2022.106725>.

QUINTA, L. N. B.; QUEIROZ, J. H. F. S.; SOUZA, K. P.; PISTORI, H.; CEREDA, M. P. Classificação de leveduras para controle microbiano em processos de produção de etanol. **IV Workshop de Visão Computacional**, 2010.

PIMENTA, R. J. G.; AONO, A. H.; BURBANO, R. C. V.; COUTINHO, A. E.; SILVA, C. C.; ANJOS, I. A.; PERECIN, D.; LANDELL, M. G. A.; GONÇALVES, M. C.; PINTO, L. R.; SOUZA, A. P. Genome-wide approaches for the identification of markers and genes associated with sugarcane yellow leaf virus resistance. **Scientific Reports** 11(1): 15730, 2021. <https://doi.org/10.1038/s41598-021-95116-1>.

ROCHA, B. M.; VIEIRA, G. S.; FONSECA, A. U.; PEDRINI, H.; SOUSA, N. M.; SOARES, F. Evaluation and detection of gaps in curved sugarcane planting lines in aerial images. **2020 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)**, 2020. <https://doi.org/10.1109/ccece47787.2020.9255701>.

RODRIGUES, L. S.; PEREIRA, D. R. Aprendizado de máquina aplicado em imagem NDVI para previsão da produtividade da cana-de-açúcar. **Colloquium Exactarum** 13(4): 82-98, 2021. <https://doi.org/10.5747/ce.2021.v13.n4.e378>.

SANTOS, R. A.; MANTOVANI, E. C.; FERNANDES-FILHO, E. I.; FILGUEIRAS, R.; LOURENÇO, R. D. S.; BUFON, V. B.; NEALE, C. M. U. Modeling actual evapotranspiration with MSI-Sentinel images and machine learning algorithms. **Atmosphere** 13(9): 1518, 2022. <https://doi.org/10.3390/atmos13091518>.

SHIBUYA, D. H.; FIGUEIREDO, G. K. D. A.; ESQUERDO, J. C. D. M.; OLIVEIRA JUNIOR, J. G. Monitoramento agrícola para análise de mudança do uso da terra em Alto Taquari - MT. **Anais do XX Simpósio Brasileiro de Sensoriamento Remoto**, 2023.

SHIBUYA D. H.; PEREIRA, G. M. S.; FIGUEIREDO, G. K. D. A.; LUCIANO, A. C. S.; LAMPARELLI, R. A. C.; LE MAIRE, G. Evaluation of time series gap-filling of Venus satellite for land use classification. **IEEE International Geoscience and Remote Sensing Symposium IRGASS**, 2021. <https://doi.org/10.1109/IGARSS47720.2021.9553773>.

SILVA, N.; SIQUEIRA, I.; OKIDA, S.; STEVAN JUNIOR, S. L.; SIQUEIRA, H. Neural networks for predicting prices of sugarcane derivatives. **Sugar Tech** 21: 514-523, 2019a. <https://doi.org/10.1007/s12355-018-0648-5>.

SILVA, R. F.; SOUSA, A. S.; XAVIER, F.; GALVANI, E.; MOSTAÇO, G. M.; SARAIVA, A. M.; CUGNASCA, C. E.; ROSS, J. L. S. Use of unsupervised machine learning methods for sugarcane crop suitability evaluation. **Proceedings XX Brazilian Symposium on GeoInformatics GEOINFO**: 292-297, 2019b.

SOUZA, M. F.; AMARAL, L. R.; OLIVEIRA, S. R. M.; COUTINHO, M. A. N.; NETTO, C. F. Spectral differentiation of sugarcane from weeds. **Biosystems Engineering** 190: 41-46, 2020. <https://doi.org/10.1016/j.biosystemseng.2019.11.023>.

SPERANZA, E. A.; ANTUNES, J. F. G.; BARBOSA, L. A. F.; CANÇADO, G. M. A.; VANSCONCELOS, J. C. Importância de índices de vegetação para modelos de estimativa de produtividade em cana-de-açúcar. **Anais do XX Simpósio Brasileiro de Sensoriamento Remoto**, 2023.

TAVARES, R. L. M.; OLIVEIRA, S. R. M.; BARROS, F. M. M.; FARHATE, C. V. V.; SOUZA, Z. M.; SCALA JUNIOR, N. L. Prediction of soil CO₂ flux in sugarcane management systems using the random forest approach. **Scientia Agricola** 75(4): 281-287, 2018. <https://doi.org/10.1590/1678-992x-2017-0095>.

YANO, I. H.; ALVES, J. R.; SANTIAGO, W. E.; MEDEROS, B. J. T. Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier. **IFAC PaperOnline** 49(16): 415-420, 2016. <https://doi.org/10.1016/j.ifacol.2016.10.076>.

YEPES, J.; ORÉ, G.; ALCANTARA, M. S.; HERNANDEZ-FIGUEROA, H. E.; TERUEL, B. Classification of sugarcane yields according to soil fertility properties using supervised machine learning methods. **Engenharia Agrícola** 42(5): e20210239, 2022. <https://doi.org/10.1590/1809-4430-Eng.Agric.v42n5e20210239/2022>.