

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO  
TRIÂNGULO MINEIRO – *Campus* Uberaba  
Programa de Pós-Graduação  
Mestrado Profissional em Produção Vegetal**

**RENIVAL ALMEIDA CARVALHO**

**ÍNDICES DE VEGETAÇÃO APLICADOS NA ESTIMATIVA DA PRODUTIVIDADE  
DA CANA - DE - AÇÚCAR NA REGIÃO DO TRIÂNGULO MINEIRO**

**Uberaba- MG  
2024**

**RENIVAL ALMEIDA CARVALHO**

**ÍNDICES DE VEGETAÇÃO APLICADOS NA ESTIMATIVA DA PRODUTIVIDADE  
DA CANA - DE - AÇÚCAR NA REGIÃO DO TRIÂNGULO MINEIRO**

Dissertação apresentada ao Programa de Pós-graduação em Produção Vegetal, do Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, como requisito para obtenção do Título de Mestre em Produção Vegetal.

Linha de Pesquisa: Sistemas Produtivos no Cerrado

Orientador: Prof. Dr. Daniel Pena Pereira

**Uberaba- MG  
2024**

Ficha Catalográfica elaborada pelo Setor de Referência do IFTM –  
*Campus Uberaba-MG*

C254i Carvalho, Renival Almeida  
Índices de vegetação aplicados na estimativa da produtividade da cana - de - açúcar na região do Triângulo Mineiro /  
Renival Almeida Carvalho - 2024.  
67 f.: il.

Orientador: Prof. Dr. Daniel Pena Pereira.  
Dissertação (Mestrado Profissional em Produção Vegetal) –  
Instituto Federal do Triângulo Mineiro- *Campus Uberaba-MG*,  
2024.

1. Sensoriamento remoto. 2. ATR. 3. TCH. 4. Previsão de  
Safrá. 5. Cerrado. I. Pereira, Daniel Pena. II. Título.

CDD 633.61

**RENIVAL ALMEIDA CARVALHO**

**ÍNDICES DE VEGETAÇÃO APLICADOS NA ESTIMATIVA DA PRODUTIVIDADE  
DA CANA - DE - AÇÚCAR NA REGIÃO DO TRIÂNGULO MINEIRO**

Dissertação apresentada ao Programa de Pós-graduação em Produção Vegetal, do Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, como requisito para obtenção do Título de Mestre em Produção Vegetal.

Linha de Pesquisa: Sistemas Produtivos no Cerrado

**Uberaba, 27 novembro de 2024.**

**BANCA EXAMINADORA**

---

Prof. Dr. Daniel Pena Pereira  
(IFTM- Orientador)

---

Prof. Dr. Renato Farias do Valle Junior  
(IFTM- Membro interno)

---

Prof. Dr. Nilton César Fiedler  
(UFES- Membro externo)



MINISTÉRIO DA EDUCAÇÃO  
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA  
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO TRIÂNGULO MINEIRO

---

**RENIVAL ALMEIDA CARVALHO**

**"ÍNDICES DE VEGETAÇÃO APLICADOS NA ESTIMATIVA DA PRODUTIVIDADE DA CANA - DE - AÇÚCAR  
NA REGIÃO DO TRIÂNGULO MINEIRO"**

**FOLHA DE APROVAÇÃO DEFESA DISSERTAÇÃO**

**Data da aprovação: 27/11/2024**

**MEMBROS COMPONENTES DA BANCA EXAMINADORA:**

<b>Presidente</b>	<b>Prof. Dr. Daniel Pena Pereira</b> <b>IFTM - CAMPUS UBERABA</b>
<b>Membro Titular</b>	<b>Prof. Dr. Renato Farias do Valle Júnior</b> <b>IFTM - CAMPUS UBERABA</b>
<b>Membro Titular</b>	<b>Prof. Dr. Nilton César Fiedler</b> <b>Universidade Federal do Espírito Santo</b>

**Local: Sala de videoconferências Microsoft Teams:**

**[https://teams.microsoft.com/l/meetup-join/19:DYz\\_guYTCF2HFt9zJNAjtLIRUVt2rQhL7uJEZGI49fM1@thread.tacv2/1731451831214?context=%7B%22Tid%22:%2283ba45b3-10ad-4452-a401-7bfd07b74688%22,%22Oid%22:%22465ab803-f67e-4313-bacf-747d3011f691%22%7D](https://teams.microsoft.com/l/meetup-join/19:DYz_guYTCF2HFt9zJNAjtLIRUVt2rQhL7uJEZGI49fM1@thread.tacv2/1731451831214?context=%7B%22Tid%22:%2283ba45b3-10ad-4452-a401-7bfd07b74688%22,%22Oid%22:%22465ab803-f67e-4313-bacf-747d3011f691%22%7D)**

**DANIEL PENA PEREIRA**  
**PROFESSOR DO ENSINO BÁSICO, TÉCNICO E TECNOLÓGICO**

---



Documento assinado eletronicamente por DANIEL PENA PEREIRA, PROFESSOR DO ENSINO BÁSICO, TÉCNICO E TECNOLÓGICO, em 27/11/2024, às 14:48, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NILTON CESAR FIEDLER  
MEMBRO EXTERNO EM BANCAS DE EXAME DE QUALIFICAÇÃO E DEFESA DE MESTRADO

---



Documento assinado eletronicamente por NILTON CESAR FIEDLER, MEMBRO EXTERNO EM BANCAS DE EXAME DE QUALIFICAÇÃO E DEFESA DE MESTRADO, em 27/11/2024, às 14:48, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).

RENATO FARIAS DO VALLE JUNIOR  
PROFESSOR DO ENSINO BÁSICO, TÉCNICO E TECNOLÓGICO

---



Documento assinado eletronicamente por RENATO FARIAS DO VALLE JUNIOR, PROFESSOR DO ENSINO BÁSICO, TÉCNICO E TECNOLÓGICO, em 27/11/2024, às 14:48, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://iftm.edu.br/autenticacao/> informando o código verificador **52D4684** e o código CRC **E8F0DF0A**.

Dedico este trabalho aos meus pais, Dario Fonseca Carvalho (*in memoriam*) e Marilene dos Reis Almeida Carvalho, que apesar do pouco estudo, não mediram esforços para levar educação a todos filhos. Aos meus Filhos, Isabella Cristina Machado Carvalho, Caroline Vitória Machado Carvalho e João Pedro Machado Carvalho que me encorajam todos os dias a nunca desistir. Amo vocês.

## **AGRADECIMENTOS**

A Deus que me sustentou até aqui.

Aos meus pais, Dário Fonseca Carvalho (in memoriam) e Marilene dos Reis Almeida Carvalho pela confiança no meu progresso e por todo apoio nessa caminhada.

Aos meus irmãos Ana Almeida Carvalho Lisboa, Rudival Almeida Carvalho, Claronice Almeida Carvalho Emídio, Ivoneide Almeida Carvalho e Liliane Almeida Carvalho por sempre me apoiarem nessa caminhada.

Aos meus filhos Isabella Cristina Machado Carvalho, Caroline Vitória Machado Carvalho e João Pedro Machado Carvalho que, apesar da distância, sempre me encorajaram para seguir em frente e nunca desistir.

À minha namorada Sílvia Cristina Galante que esteve sempre presente nos momentos difíceis com uma palavra de incentivo.

Ao meu orientador D Sc. Daniel Pena Pereira, que apesar da intensa rotina de sua vida acadêmica aceitou me orientar neste trabalho. Agradeço imensamente pela sua paciência nas valiosas orientações e na condução, tanto na dissertação quanto no processo de desenvolvimento de um indivíduo culto, ético, prático, determinado e por considerá-lo exemplo de professor, gostaria de expressar minha sincera gratidão por esse rápido período em sua companhia. Suas valiosas indicações fizeram toda a diferença.

A todos que me ajudaram e em especial, meu tio Mourival dos Reis Almeida, meu sobrinho Pablo Vinícius Carvalho, meu primo Adriano Almeida dos Santos e ao amigo Dinovam Bento da Costa, sem os quais não seria possível fazer as coletas e estimativas no campo.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro (IFTM) Campus Uberaba, pela oportunidade concedida para realização deste curso e obtenção do título de Mestre em Produção Vegetal.

À empresa IFB - Instituto de Fosfato Biológicos, por toda a estrutura disponibilizada a mim para a conclusão desse trabalho.

À Fazenda Agro Export São Sebastião, por ceder as áreas para este estudo.

## RESUMO

O presente trabalho investiga a estimativa de produtividade de cana-de-açúcar no Cerrado brasileiro via sensoriamento remoto. A área de estudo é a Fazenda Agro Export São Sebastião, no Triângulo Mineiro, em parceria com a Usina Coruripe. O objetivo é prever a produção de cana por meio de dados espectrais e de radar, correlacionando-os com produtividade total (TCH), líquida (TCH\_L) e o Açúcar Total Recuperável (ATR). Para isso, foram utilizados índices de vegetação derivados de imagens de satélite Sentinel-2 e ScanSAR. Apesar dos resultados promissores, com coeficientes de determinação ( $R^2$ ) entre 54% e 60% para o NDVI e erros percentuais médios inferiores a 5% na estimativa do ATR com o índice VARI, o estudo enfrentou desafios significativos. Entre eles, destacam-se a variabilidade das condições climáticas e edáficas, a influência de fatores fenológicos e sazonais e limitações associadas à resolução espacial e à qualidade das imagens de satélite. Esses fatores podem introduzir incertezas na modelagem e exigem integração com outras fontes de dados, como sensores de campo ou drones, para aumentar a precisão das estimativas. A abordagem utilizada demonstra o potencial do sensoriamento remoto na otimização da gestão agrícola e no planejamento de safras, contribuindo diretamente para a sustentabilidade e a lucratividade no setor, ao mesmo tempo em que aponta para a necessidade de avanços tecnológicos e metodológicos para superar os desafios encontrados.

**Palavras-chave:** sensoriamento remoto; ATR; TCH; previsão de safra; cerrado.

## ABSTRACT

This study investigates the estimation of sugarcane productivity in the Brazilian Cerrado using remote sensing. The study area is the Agro Export São Sebastião Farm, in the Triângulo Mineiro region, in partnership with Usina Coruripe. The objective is to predict sugarcane production using spectral and radar data, correlating them with total productivity (TCH), net productivity (TCH\_L) and Total Recoverable Sugar (ATR). For this purpose, vegetation indices derived from Sentinel-2 and ScanSAR satellite images were used. Despite the promising results, with coefficients of determination ( $R^2$ ) between 54% and 60% for NDVI and average percentage errors below 5% in the ATR estimation with the VARI index, the study faced significant challenges. Among them, the variability of climatic and soil conditions, the influence of phenological and seasonal factors, and limitations associated with the spatial resolution and quality of satellite images stand out. These factors can introduce uncertainty into modeling and require integration with other data sources, such as field sensors or drones, to increase the accuracy of estimates. The approach used demonstrates the potential of remote sensing in optimizing agricultural management and crop planning, contributing directly to sustainability and profitability in the sector, while also highlighting the need for technological and methodological advances to overcome the challenges encountered.

**Keywords:** remote sensing; ATR; TCH; crop forecasting; cerrado.

## LISTA DE TABELAS

Tabela 1- Disponibilidade de imagens Sentinel-2 (S2) e SAR2 na área de estudo para o ciclo de colheita, 2022 a 2023.....	23
Tabela 2- Índices de vegetação e suas respectivas fórmulas.....	25
Tabela 3- Ano de corte, Tipo de solo de cada área experimental, resultados reais dos talhões e das medidas em parcelas feitas a campo, resultado do ATR de cada área e resultados de biometria dos colmos por propriedade.....	29
Tabela 4- Correlação percentual (R) e o erro percentual absoluto médio (%) aplicados às variáveis dependentes TCH_L, TCH e ATR no início de safra e na fase pré - corte da cana - de - açúcar.....	39

## LISTA DE FIGURAS

Figura 1- Localização dos talhões de estudo com cana - de - açúcar, Campo Florido-MG, Brasil.....	21
Figura 2- Croqui da coleta de dados em linhas espelhadas de cana - de - açúcar, Campo Florido-MG, Brasil.....	22
Figura 3.- Variação de temperatura média e deficiência hídrica nas áreas de estudo para a safra 2022-2023, Campo Florido- MG, Brasil.....	31
Figura 4- Série temporal dos índices de vegetação espectrais e de radar nas áreas de estudo para a safra 2022-2023, Campo Florido-MG, Brasil.....	31
Figura 5- Produtividade líquida da cana - de - açúcar (TCH_L), obtidas para a fase de planejamento de safra com a Equação (4) (a) e a Equação (5) (b) e para a fase de pré - corte com a Equação (6) (c) e a Equação (7) (d).....	34
Figura 6- Produtividade da cana –de - açúcar (TCH), obtidas para a fase de planejamento de safra com a Equação (8) (a) e a Equação (9) (b) e para a fase de pré - corte com a Equação (10) (c) e a Equação (11) (d).....	36
Figura 7- Produtividade do Açúcar Total Recuperável (ATR), obtidas para a fase de planejamento de safra com a Equação (12) (a) e para a fase de pré - corte com a Equação (13) (b).....	38

## LISTA DE ABREVIATURAS E SIGLAS

ATR	Açúcar total recuperável
CONAB	Companhia Nacional de Abastecimento
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EORCEarth	Observation Research Center
GEE	Google Earth Engine
LOOCV	Leave-One Out Cross-Validation
SIG	Sistema de Informações Geográficas
TCH	Tonelada de colmo por Hectare
EU	União Europeia

## LISTA DE SÍMBOLOS

cm <sup>2</sup>	Centímetros quadrado
CO <sub>2</sub>	Gás carbônico
CV%	Coeficiente de variação
Gt	Verdade Terrestre
IV	Índice de vegetação
Há	Hectares
Mm	Milímetros
°C	Graus Célsius
>	Maior
<	Menor
%	Porcentagem

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>15</b>
<b>2 REVISÃO DE LITERATURA.....</b>	<b>17</b>
2.1 A cana - de - açúcar.....	17
2.2 Predição de produtividade de cana - de - açúcar.....	17
2.3 Sensoriamento remoto.....	18
2.4 Índices de Vegetação .....	19
<b>3 MATERIAL E MÉTODOS .....</b>	<b>21</b>
3.1 Local do experimento.....	21
3.1.1. <i>Caracterização das áreas de estudo</i> .....	21
3.1.2 <i>Delineamento experimental</i> .....	22
3.1.3. <i>Índices de Vegetação</i> .....	24
3.1.3.1. <i>Análise dos pressupostos da regressão linear</i> .....	25
3.1.4. Análise estatística.....	27
3.1.4.1. <i>Métricas de avaliação</i> .....	27
<b>4 RESULTADOS E DISCUSSÃO .....</b>	<b>29</b>
4.1. Modelos de produtividade da cana - de - açúcar .....	33
4.1.1. <i>Modelagem da produtividade líquida da cana - de - açúcar (TCH_L)</i> .....	34
4.1.2. <i>Modelagem da produtividade total da cana - de - açúcar (TCH)</i> .....	35
4.1.3. <i>Modelagem da produtividade do Açúcar Total Recuperável (ATR)</i> . .....	37
<b>5 CONCLUSÃO.....</b>	<b>43</b>
<b>REFERÊNCIAS .....</b>	<b>45</b>
<b>APÊNDICES.....</b>	<b>55</b>

## 1 INTRODUÇÃO

O Cerrado brasileiro, um *hotspot* de biodiversidade, é uma área crucial para a agricultura sustentável devido a seus ricos recursos genéticos (Lambers *et al.*, 2020). A expansão do cultivo de cana - de - açúcar no bioma Cerrado do Brasil tem sido expressiva, impulsionada pelo aumento da demanda de etanol e dos preços internacionais do açúcar. Entre 2000 e 2010, as áreas ocupadas por cana - de - açúcar cresceram 97,59% (Oliveira; Ferreira; Araújo, 2012). A produção de cana - de - açúcar no Brasil poderá crescer até 45% para suprir a demanda da União Europeia (UE) por etanol até 2030 (Udop, 2021). O crescimento ocorreu principalmente em pastagens degradadas e áreas anteriormente usadas para culturas de grãos (Rodrigues; Castro, 2018). Embora contribua para benefícios socioeconômicos e reduza o déficit alimentar global, o rápido crescimento do cultivo de cana - de - açúcar no Cerrado gera preocupações sobre as possíveis consequências negativas para a biodiversidade, os recursos hídricos e os serviços ambientais (Udop, 2021; Cherubin *et al.*, 2016).

A cana - de - açúcar é uma planta perene da família Poaceae com ciclo de longa duração, mas com rápido crescimento Zhu *et al.* (2023) e desenvolvimento, principalmente em áreas tropicais e subtropicais, necessitando de muita luz solar e chuvas regulares (Hu *et al.*, 2019; Liu *et al.*, 2023). A importância econômica da cana - de - açúcar é evidente em sua área de cultivo global de aproximadamente 27 milhões de hectares, com 10 milhões somente no Brasil Heirinchs; Magalhães; Meirelles, (2017), mas com a expansão de áreas cultivadas para a cultura da cana - de - açúcar, o processo de estimativa de produção de safra aumenta a dificuldade para ser executado. Esta operação demanda muita mão de obra e é um processo lento e de certa forma subjetivo. Mas é de extrema importância para prever a lucratividade do setor no início do ano safra.

O sensoriamento remoto é uma importante ferramenta para mapear as vegetações, havendo cada vez mais oferta de imagens orbitais em combinação com os avanços tecnológicos computacionais (Souza Jr. *et al.*, 2020). A utilização de tecnologias de sensoriamento remoto tem se destacado como uma importante aliada nas investigações relacionadas à antecipação da colheita de cana - de - açúcar (Som-Ard *et al.*, 2021). Diversas abordagens têm sido propostas no sentido da estimativa de

produtividade por meio do sensoriamento remoto. Dentre estas, pode-se destacar as que fazem uso de algoritmos e aprendizado de máquina na previsão da produtividade (Abebe; Tadesse; Gessesse, 2023; Narmilan *et al.*, 2022; Saini *et al.*, 2023) e de relações diretas entre índices de vegetação (IV) ou reflectância na região do infravermelho próximo e a produtividade medida no campo (Singla; Garg; Dubey; 2020; Sumeshk; Ninsawat; Som-Ard, 2021).

A despeito desses estudos destacarem coletivamente o potencial do sensoriamento remoto e dos índices de vegetação para estimar com precisão a produtividade da cana - de - açúcar, também ressaltam a necessidade de mais pesquisas para lidar com as incertezas e melhorar a precisão desses índices. O estudo se destaca por relacionar informações espectrais e de radar com indicadores de produtividade, como TCH, TCH\_L e ATR, apresentando uma abordagem que pode ser reproduzida para estimar a produtividade de maneira bastante precisa. Ao usar imagens de satélites de média e alta resolução e métodos de regressões lineares, este estudo propõe que os dados obtidos possam auxiliar na gestão agrícola, planejamento de safra e otimizar de forma econômica e eficaz em comparação com métodos convencionais. O trabalho busca aplicar os índices RGB (Vegetation Adjusted Red Index - VARI =  $(G - R) / (G + R - B)$ ) para estimar a safra tanto no começo (fevereiro de 2023) quanto na fase de pré - corte (julho a agosto de 2023). Isso amplia a aplicação desses índices em cultivos como a cana - de - açúcar, evidenciando sua relevância não apenas na previsão de produtividade, mas também na fundamentação de decisões estratégicas no setor agrícola. Ainda há incertezas no processo de estimativa, especialmente em regiões com características físicas diversas e na integração de métricas eficazes derivadas de satélite com novos sensores integrados para aumentar o poder preditivo. No geral, a busca pela redução das incertezas na estimativa do rendimento da cana - de - açúcar através de sensoriamento remoto continua sendo uma área crítica de pesquisa em sustentabilidade agrícola e segurança alimentar (Wu *et al.*, 2023; Silva *et al.*, 2024).

Diante deste contexto, este trabalho tem como objetivo obter dados de perfil espectral e de radar, para diferentes estágios de desenvolvimento da cana - de - açúcar, e estimar a produtividade a fim de detectar tendências antes da colheita.

## 2 REVISÃO DE LITERATURA

### 2.1 A cana - de - açúcar

A cana - de - açúcar é uma cultura perene pertencente à ordem Gramíneas, à família Poaceae e ao gênero *Saccharum*, apresenta um crescimento vigoroso e seu processo de desenvolvimento normalmente leva de 12 a 18 meses até a colheita (Som-Ard *et al.*, 2021). Esse período de crescimento pode diferir entre países, influenciado pela espécie, pelas condições locais de cultivo e por fatores geográficos (Rudorff *et al.*, 2010; Sukyai *et al.*, 2016; Shukla *et al.*, 2017,). As plantas costumam medir entre 2 e 6 metros de altura, apresentam caules fortes, segmentados e fibrosos, que são abundantes em sacarose, a qual se concentra nos entrenós do tronco (Som-Ard *et al.*, 2021). O sistema radicular é composto por raízes fasciculadas que em sua maioria estão presentes nos primeiros 50 centímetros da superfície.

Em sua maioria comercial são híbridas. Fisiologicamente é caracterizada como planta C4, por possuir alta taxa fotossintética, grande eficiência no resgate de CO<sub>2</sub> Suwanlee *et al.* (2024), adaptabilidade às condições de altas temperaturas e falta de água. Seu sistema radicular é responsável pela maior taxa de absorção, porém a cana também apresenta uma elevada capacidade de absorção foliar (Martinez Uríde, 2010).

O cultivo da cana - de - açúcar se estende por todo território nacional, sendo predominante na região Sudeste, por indicar maiores índices de produtividade (Udop, 2021). No seu processamento também se produzem subprodutos como vinhaça e bagaço, os quais são usados como matéria prima para a produção de energia, fertilizantes e diversos produtos recicláveis (Goldemberg, 2008).

### 2.2 Predição de produtividade de cana - de - açúcar

É fundamental medir e prever a produtividade da cultura para aprimorar o rendimento do desenvolvimento. Segundo Petersen (2011), diversas estratégias foram testadas, incluindo medidas fundamentadas na razão, análise do contexto de dados. Silva *et al.* (2022) criaram um modelo de regressão linear múltipla com base em dados agrometeorológicos, alcançando resultados positivos com uma diferença relativa média de menos de 3%.

Silvestre, Vieira e Nascimento (2019) utilizaram o modelo AquaCrop para calcular a produtividade da cana - de - açúcar em diferentes épocas de plantio, evidenciando abril como o mês ideal. Rodrigues e Pereira (2021) aplicaram técnicas de aprendizado de máquina para examinar imagens de satélite NDVI, constatando que o algoritmo Random Forest apresentou a melhor performance na previsão da produtividade. Souza Jr. *et al.* (2020) recorreram a modelos ARIMA para prever a produção de cana - de - açúcar e seus subprodutos na região Centro-Sul do Brasil entre 2020 e 2025, obtendo resultados positivos, apesar dos erros percentuais absolutos médios considerados relativamente altos.

Silva *et al.* (2022) criaram um modelo de regressão linear múltipla para calcular a produtividade da cana - de - açúcar no semiárido brasileiro, utilizando variáveis agrometeorológicas e obtendo resultados favoráveis, com uma variação média relativa inferior a 3%. Já Godoy (2007) introduziu um modelo fuzzy para prever a formação de biomassa e açúcar na cana - de - açúcar, conseguindo desempenho superior ao modelo QCANE. Santos *et al.* (2004) avaliaram a consistência das propriedades agroindustriais em diferentes genótipos de cana - de - açúcar, identificando alta consistência nos teores de fibra e na produtividade por hectare. Leda, Golçalves e Lima (2019) destacaram que diferentes índices de vegetação obtidos a partir de imagens de satélite, como NDVI e GVI são utilizados para prever a produtividade agrícola. A avaliação temporal desses índices durante o desenvolvimento da cultura exibiu correlações significativas com os rendimentos efetivos observados (Pontes; Rocha; Lamparelli, 2005).

As diversas metodologias empregadas na previsão do cultivo da cana - de - açúcar, incluindo modelos de regressão, sistemas fuzzy, análise de séries temporais e estimativa de repetibilidade, têm contribuído para melhorar o planejamento agrícola e a tomada de decisões na indústria da cana - de - açúcar.

### **2.3 Sensoriamento remoto**

O sensoriamento remoto refere-se à prática de observar e medir objetos a uma certa distância, sem a necessidade de contato físico (Graham, 1999). Essa técnica se baseia na utilização de radiação eletromagnética refletida ou emitida pela superfície terrestre, a qual é capturada por sensores instalados em satélites ou aeronaves (Aggarwal, 2004). O sensoriamento remoto serve a diversas finalidades, como o

mapeamento do uso da terra, agricultura, manejo florestal, planejamento urbano e vigilância ambiental (Read; Chambers; Torrado, 2020).

Os métodos de sensoriamento remoto proporcionam ferramentas importantes para o acompanhamento e a gestão do cultivo de cana - de - açúcar. Sensores ópticos e de radar de abertura sintética (SAR) oferecem dados precisos e em tempo útil para diversas finalidades, como a classificação de culturas, previsão de produtividade e monitoramento da saúde das plantas (Abdel-Rahman; Ahmed, 2008; Molijn *et al.*, 2019). A integração de dados multitemporais e de diferentes fontes, juntamente com técnicas de aprendizado de máquina, como a floresta aleatória, é crucial para um monitoramento e mapeamento eficaz do crescimento, saúde e produtividade da cana - de - açúcar (Som-Ard *et al.*, 2021). A utilização do SR na cultura da cana - de - açúcar também se mostra importante na identificação de diferentes variedades, auxiliando na estimativa de produtividade e avaliação de riscos à cultura (Schultz *et al.*, 2016). Contudo, desafios ainda persistem, como o longo tempo de pré-processamento de séries temporais ópticas, a escassez de dados prontos para análise e as diferentes condições ambientais que influenciam as informações radiométricas das culturas (Som-Ard *et al.*, 2021; Molijn, 2020).

Essa técnica oferece dados espaciais que, de outra forma, seriam difíceis ou até impossíveis de serem obtidos, permitindo que pesquisadores analisem as transformações ao longo do tempo através de imagens coletadas em diferentes períodos.

## **2.4 Índices de vegetação**

Os Índices de Vegetação (IVs) são modelos matemáticos ou algoritmos – baseados no sensoriamento remoto, empregados na análise da cobertura de vegetação e no acompanhamento de mudanças vegetais em diferentes escalas (Marcussi *et al.* (2010), os quais avaliam e caracterizam a cobertura vegetal em uma determinada área de acordo com a sua reflectância, isto é, na sua capacidade de refletir a luz solar de acordo com as características do seu desenvolvimento. Há inúmeros índices de vegetação e cada um apresenta uma finalidade específica. Esses índices atuam como representações para avaliar variáveis de dossel e processos biofísicos, tais como a fotossíntese e a produção primária líquida (Huete *et al.*, 2006).

Esses índices são gerados a partir de medições espectrais, com o objetivo de aprimorar a detecção da vegetação e ao mesmo tempo reduzir os impactos ambientais (Bannari *et al.*, 1995). Eles são eficazes para medir a cobertura vegetal, a vitalidade e o crescimento, utilizando diversas plataformas de sensoriamento remoto, como satélites e drones (Xue; Su, 2017). Os IVs são obtidos por meio de razões simples ou normalizadas, diferenciações e combinações de dados de bandas espectrais (Marion; Andres; Hendges, 2021).

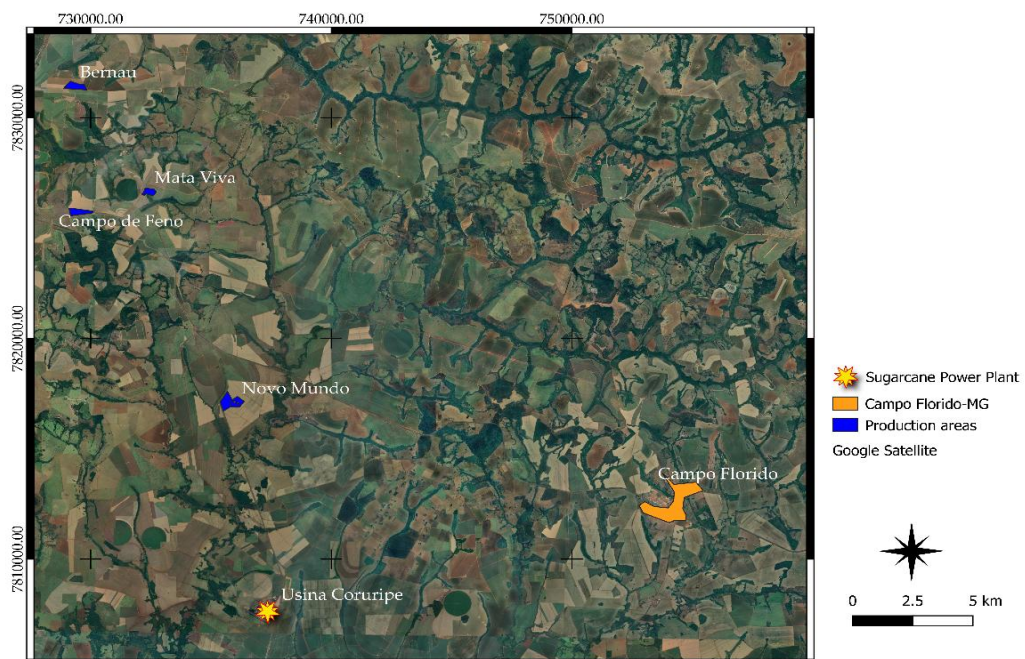
Os índices de vegetação gerados a partir de imagens de satélite e UAV têm se mostrado úteis para acompanhar plantações de cana - de - açúcar e prever lucros. Diversos índices, como NDVI, NDRE e MCARI/OSAVI, têm a capacidade de avaliar a situação do nitrogênio na cana - de - açúcar, apesar de alguns poderem ser afetados por fatores ambientais (Taubinger; Amaral; Molin, 2012). Os índices de vegetação também proporcionam um método econômico e não prejudicial para o acompanhamento de culturas, assegurando uma estratégia amplamente acessível e ecologicamente correta para avaliar a saúde das plantações (Ahmad *et al.*, 2020).

### 3 MATERIAL E MÉTODOS

#### 3.1 Local do experimento

O presente trabalho foi desenvolvido no bioma Cerrado, na região do Triângulo Mineiro, em parceria com a Fazenda Agro Export São Sebastião, em cinco talhões com a variedade CTC-04, totalizando 98,1 ha. Esta fazenda fornece a cana - de - açúcar para a Usina Coruripe, ambas situadas no município de Campo Florido-MG, Brasil (Figura 1).

Figura 1- Localização dos talhões de estudo com cana - de - açúcar, Campo Florido-MG, Brasil.



Fonte: Elaborada pelo autor, 2024.

##### 3.1.1. Caracterização das áreas de estudo

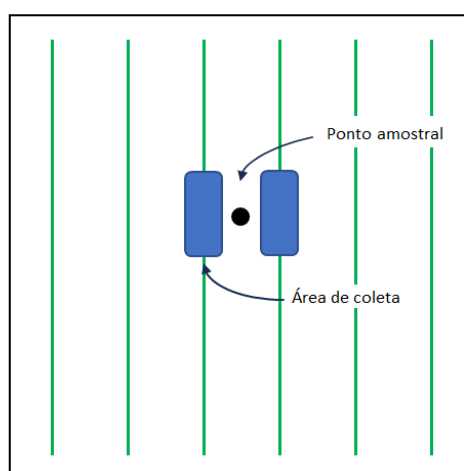
O clima da região é classificado como Aw, tropical quente, segundo Köppen e Geiger, apresentando inverno frio e seco, com verão quente e chuvoso, com precipitação e temperatura média anual de 1.500 mm e 21°C, respectivamente

(Climate-Data, 2022). O sistema de coordenadas geográficas utilizado foi o Universal Transversa de Mercator (UTM) com DATUM SIRGAS 2000 fuso 22S. Foram definidas cinco (05) unidades produtivas: Novo Mundo e Bernau, respectivamente, com cana de 2º ano. Já Novo Mundo, Mata Viva e Campo de Feno, respectivamente, com cana de 3º ano; em diferentes ambientes de produção (solo arenoso, médio e argiloso). As características químicas do solo estão descritas no Apêndice A.

### 3.1.2 Delineamento experimental

Realizamos a coleta de amostras em 51 locais específicos, escolhidos de forma aleatória e estrategicamente com o auxílio de um Sistema de Informações Geográficas. Este procedimento de escolha assegurou que os locais amostrais fossem distribuídos de maneira equilibrada em toda a área de estudo, considerando suas diversas características. O Sistema de Informação Geográfica (SIG) foi empregado na elaboração de um arranjo em grade, na qual os pontos foram selecionados de maneira controlada para cobrir de maneira adequada as variações da área, tais como tipos de solo e estado da vegetação. O Apêndice B contém informações sobre a distribuição dos pontos. Cada ponto foi representado por uma área de coleta de dados de três metros quadrados, englobando duas (2) linhas de plantio com um (1) metro de comprimento cada (espelhadas), no espaçamento de 1,5 m entre linhas (Figura 2).

Figura 2- Croqui da coleta de dados em linhas espelhadas de cana - de - açúcar, Campo Florido-MG, Brasil



Fonte: Elaborada pelo autor, 2024.

As amostras foram colhidas e pesadas nos meses de julho e agosto de 2023. Foram pesadas com palha para calcular e gerar a produtividade total, TCH; depois foi feita a despalha e o corte dos ponteiros no ponto de quebra e pesadas novamente para calcular e gerar a produtividade líquida, TCH\_L. As pesagens foram feitas com balança eletrônica da marca Tomate com precisão de 10g para determinação de massa fresca. De acordo com o espaçamento da cultura, foi calculada a produtividade total, em ton. ha<sup>-1</sup> (TCH) e líquida (TCH\_L). Logo após as pesagens, foram feitas as medidas de diâmetro de colmo e altura da cana - de - açúcar. As medidas do diâmetro foram feitas em três partes da cana - de - açúcar: na base do colmo, no terço médio e no terceiro colmo do ponteiro. Ao término das medidas de cada ponto foram separados aleatoriamente dez colmos para fins das avaliações laboratoriais (cinco colmos de cada linha), totalizando cinquenta e uma amostras totais. Essas amostras foram encaminhadas para o laboratório da Usina Coruripe, na cidade de Campo Florido-MG, para a determinação do Açúcar Total Recuperável (ATR), em kg. ha<sup>-1</sup>.

As coletas das imagens foram geradas através de scripts no ambiente Google Earth Engine (GEE) para a coleta de imagens e cálculo dos índices de vegetação (IVs). Para obter os IVs em cada ponto amostral foram usadas as imagens de satélite Sentinel-2, fornecidas pelo Copernicus Sentinel (COPERNICUS/S2\_SR\_HARMONIZED/, acessado em 16 de agosto 2024), com resolução espacial de 10 m e pelo Earth Observation Research Center (EORC), da Japan Aerospace Exploration Agency (JAXA/ALOS/PALSAR-2/Level2\_2/ScanSAR/, acessado em 16 agosto 2024), com imagens de radar de resolução espacial de 25 m e ângulo médio de imageamento de -11,67°. Foram coletadas imagens em duas épocas: planejamento da safra (estimada para fevereiro de 2023) e pré - corte, 30 dias antes da colheita do talhão. Os modelos de estimativa da produção de cana - de - açúcar e do teor de açúcar foram ajustados com oito imagens obtidas para o ano de 2023 (Tabela 1).

Tabela 1- Disponibilidade de imagens Sentinel-2 (S2) e SAR2 na área de estudo para o ciclo de colheita, 2022 a 2023.

Mês da estimativa	Data da Imagem	
	S2	SAR2
Fevereiro	2023-02-08	2023-02-08

Junho	2023-06-06	2023-05-12
Julho	2023-07-01	2023-06-14
Agosto	2023-07-28	2023-07-12

Fonte: Elaborada pelo autor, 2024.

Nesta pesquisa foram analisados e correlacionados os IVs obtidos das imagens dos satélites e o resultado laboratorial de Açúcar Total Recuperável (ATR), assim como as produtividades total (TCH) e líquida (TCH\_L) colhidas no campo. Os índices (IVs) a serem avaliados foram: NDVI, EVI, NDRE, VARI, GNDVI e SAR (HH, HV, a diferença “HH-HV”).

O VARI (Vegetation Adjusted Red Index) foi incluído no estudo porque usa apenas cores RGB (vermelho, verde e azul), o que torna possível usar imagens RGB convencionais, que são mais baratas que imagens RGB próximas, como o NDVI. O VARI é aplicável em cenários onde não há imagens multiespectrais ou hiperespectrais. Assim, usar esse índice na cana - de - açúcar torna mais fácil usar sensores remotos para monitorar as plantações e tomar decisões melhores na indústria agrícola.

### 3.1.3. Índices de vegetação

O Índice de Vegetação por Diferença Normalizada (NDVI) é o mais prevalente e tem sido utilizado em pesquisas que relacionam a saúde humana, examinando a relação entre a exposição a áreas verdes e à qualidade de vida (Santos; Hacon; Neves, 2023). A combinação de IVs com sistemas de informação geográfica tem sido útil em várias investigações, especialmente em monitoramento ambiental (Marcussi *et al.*, 2010).

Os IVs passaram por um desenvolvimento considerável, tornando-se instrumentos valiosos para avaliar a saúde das plantas e as condições do meio ambiente. O Índice de Vegetação por Diferença Normalizada (NDVI) permanece como o índice mais utilizado, especialmente em pesquisas relacionadas ao bioma Caatinga e à nutrição nitrogenada (Lopes *et al.*, 2020; Soares; Amaral; Amado, 2021).

Os índices de vegetação desempenham um papel fundamental na agricultura de precisão e na supervisão de plantações, pois proporciona uma análise direta e segura do estado e saúde das culturas (Nduku *et al.*, 2023). Conforme o índice de

vegetação, é possível acompanhar dados sobre diversos aspectos do crescimento e evolução das plantas, como a quantidade de clorofila, a área foliar, a estrutura do dossel e a condição da água (Cui *et al.*, 2019).

Tabela 2- Índices de vegetação e suas respectivas fórmulas.

Descrição	Índice
<b>Características Estruturais</b>	
NDVI (Normalized Difference Vegetation Index)	$NDVI = (NIR - R) / (NIR + R)$
EVI (Enhanced Vegetation Index)	$EVI = 2,5 (NIR - R) / (1 + NIR + 6R - 7,5B)$
NDRE (Normalized Difference Red Edge)	$NDRE = (NIRed - R) / (NIRed + R)$
GNDVI (Green-Red Vegetation Index)	$GNDVI = (G - R) / (G + R)$
VARI (Visible Atmospherically Resistant Index)	$VARI = (G - R) / (G + R - B)$
HH (Horizonte Horizontal)	Imagens do SAR
HV (Horizonte Vertical)	Imagens do SAR
“HH-HV (Horizonte horizontal- Horizonte Vertical)	Imagens do SAR

Fonte: Elaborada pelo autor, 2024.

Nota: R=red, G=green, B=blue, NIR=infravermelho próximo, NIRed=borda do vermelho.

### 3.1.3.1. Análise dos pressupostos da regressão linear

Os resultados serão provenientes do pacote `gvlma()` no R, que realiza o Global Validation of Linear Model Assumptions (GVLMA). Essa função testa os pressupostos da análise de regressão linear em relação a cinco principais condições, que são essenciais para garantir que os resultados da regressão sejam válidos.

Com base nos resultados apresentados verificaram-se evidências de violações significativas dos pressupostos da regressão linear com todas as variáveis. Ainda, outro pressuposto, a independência, foi verificada através do Gráfico de Resíduos vs.

Ajustados; como complemento. Já o teste de Durbin-Watson foi usado para verificar a autocorrelação dos resíduos de uma regressão linear, ou seja, para testar se existe dependência serial entre os resíduos. Os valores do estatístico Durbin-Watson variam de 0 a 4:

- $DW \approx 2$ : Não há autocorrelação significativa.
- $DW < 2$ : Indica autocorrelação positiva (resíduos consecutivos estão positivamente correlacionados).
- $DW > 2$ : Indica autocorrelação negativa (resíduos consecutivos estão negativamente correlacionados).

Resumo geral da expectativa da análise dos pressupostos:

- Pressuposto de Normalidade (Skewness e Kurtosis):
  - Ambos os testes (assimetria e curtose) indicam que os resíduos não violam o pressuposto de normalidade.
- Pressuposto de Linearidade (Link Function):
  - O teste de função de ligação confirma que a relação entre a variável dependente e as variáveis independentes segue uma relação linear.
- Pressuposto de Homoscedasticidade (Heteroscedasticity):
  - O teste de heterocedasticidade não encontrou problemas, indicando que a variância dos resíduos é constante.
- Pressuposto da Independência (análise gráfica e Teste Dublin-Watson):
  - Não houve anomalias no gráfico, sugerindo que os resíduos são independentes. Se o valor do teste de Durbin-Watson for perto de 2, isso indica que os resíduos não estão autocorrelacionados (ou seja, são independentes).
- Pressuposto Global:
  - O teste global sugere que os pressupostos do modelo de regressão linear são em sua maioria, aceitos.

### 3.1.4. Análise estatística

As análises foram conduzidas por meio do Google Colab com a linguagem R com o pacote 'leaps' (Lumely, 2024), com o objetivo de encontrar a equação matemática (linear) que melhor representasse a relação entre as variáveis dependentes (ATR, TCH e TCH\_L) e independentes (IVs). Os modelos foram ajustados para cada período por meio de validação cruzada, utilizando a função `trainControl` e o método LOOCV (Leave one out cross-validation), ambos presentes no pacote 'caret' (Kuhn, 2008). O comando '`set.seed(42)`' foi empregado para assegurar a replicabilidade dos resultados da validação cruzada. A presença de outliers foi analisada utilizando um gráfico Boxplot, além de testes realizados para verificar os pressupostos dos modelos lineares por meio da biblioteca 'gvlma' (Pena; Slate, 2006), considerando um nível de significância de 0,05. As variáveis selecionadas foram utilizadas para estimar a produtividade agrícola com um modelo baseado na técnica de regressão linear múltipla com  $n$  variáveis explicativas (eq.1):

$$\hat{Y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + (\dots) + \beta_n X_n + \varepsilon, \quad (1)$$

em que: o  $\hat{Y}$  é o índice de produtividade agrícola estimada, sendo consideradas as variáveis dependentes (TCH, TCH\_L e ATR),  $\beta_0$  é o intercepto;  $X_n$  são as variáveis independentes ou explicativas (NDVI, EVI, NDRE, VARI, GNDVI, HH, HV e "HV-HH");  $\beta_n$  são os parâmetros a serem estimados e  $\varepsilon$  é o erro aleatório.

A hipótese nula ( $H_0$ ) é que todos os valores de  $\beta$  são estatisticamente iguais a zero, ou seja, não há efeito nos índices de vegetação nas variáveis de produção. Na hipótese de rejeição de  $H_0$ , verificou-se a significância da regressão. Se o p-valor for inferior ao nível de significância de 5%, a regressão linear múltipla (MLR) foi considerada significativa.

#### 3.1.4.1. Métricas de avaliação

Na sequência, foi realizada a avaliação com cinco métricas avaliadoras utilizadas para selecionar o modelo matemático mais ajustado para cada variável dependente: o coeficiente de determinação ( $R^2$  e  $R^2$  ajustado) derivados das

regressões; a raiz quadrada do  $R^2$  (correlação), Root Mean Square Error (RMSE) e o erro médio absoluto percentual (MAPE) derivadas da validação cruzada.

A classificação das correlações ( $R$ ) segundo Hopkins (2000) [22] interpreta a força da correlação e é considerada variando de muito baixa ( $R \leq 0,1$ ) a quase perfeita ( $R \geq 0,90$ ). Esta

métrica foi derivada da raiz quadrada do  $R^2$  da validação cruzada. A raiz do erro quadrático médio (RMSE) é a raiz da diferença quadrada entre a verdade terrestre ( $G_t$ ) e o valor de saída ( $Y$ ), dividida pelo número de indivíduos ( $n$ ) (Eq. 2).

$$RMSE = \sqrt{\left(\sum (G_t - Y)^2 / n\right)} \quad (2)$$

O erro percentual absoluto médio (MAPE) é a média computada dos erros percentuais absolutos pelos quais os resultados de um modelo diferem dos valores reais do que está sendo estimado. O MAPE é dado pela soma da diferença absoluta entre a verdade básica ( $G_t$ ) e a saída do modelo ( $Y$ ) dividida pela verdade básica, que é então dividida pelo número de indivíduos ( $n$ ). A fórmula para o MAPE é apresentada na Eq. 3.

$$MAPE = 1/n \sum \left| \frac{G_t - Y}{G_t} \right| \quad (3)$$

#### 4 RESULTADOS E DISCUSSÃO

Com base nos resultados apresentados no Apêndice C, dos resultados da MLR e da análise dos pressupostos, não há evidências de violações significativas dos pressupostos da regressão linear com todas as variáveis. Os pressupostos de normalidade, linearidade e homoscedasticidade estão adequadamente atendidos, o que sugere que a análise de regressão linear realizada é válida e os resultados podem ser confiáveis. Ainda, os resíduos não tiveram padrões e estiveram distribuídos aleatoriamente ao redor da linha de ZERO, sugerindo que a independência dos resíduos pode ser válida, uma vez que o teste de Durbin-Watson verificou que não existe dependência serial entre os resíduos.

Neste estudo foram utilizados índices de vegetação derivados de imagens de satélite (NDVI, NDRE, VARI, GNDVI) para prever a produtividade total (TCH), produtividade líquida (TCH\_L) e o Açúcar Total Recuperável (ATR). Os resultados indicam que o NDVI se destacou na previsão de TCH\_L e TCH, com coeficientes de determinação ( $R^2$ ) variando entre 55% e 60%, enquanto o índice NDVI foi eficaz para modelar o ATR, com erro percentual absoluto médio (MAPE) de 3,84%. Esses achados mostram a viabilidade do uso de dados de satélite na previsão de safra, contribuindo para o planejamento agrícola mais eficiente (Apêndice C).

A avaliação das análises realizadas é apresentada na tabela 3, assim como os parâmetros descritivos de cada variável.

Tabela 3- Ano de corte, Tipo de solo de cada área experimental, resultados reais dos talhões e das medidas em parcelas feita a campo, resultado do ATR de cada área e resultados de biometria dos colmos por propriedade.

<b>Fazenda</b>	<b>Área (ha)</b>	<b>Ano</b>	<b>Textura</b>	<b>TCH_R</b>	<b>TCH</b>	<b>TCH_L</b>	<b>ATR</b>	<b>Diam_Med</b>	<b>Nº_Colm/ mL</b>	<b>C_Colmo</b>
<b>Novo Mundo</b>	17.64	2	Argiloso	109,82	130.281	100.645	162,12	8,59	27,3	2,68
<b>Novo Mundo</b>	24.14	3	Argiloso	109,82	118.303	98.058	161,03	8,35	28,3	2,57

<b>Campo de Feno</b>	20.67	3	Média	85,80	107.632	86.535	165,31	7,51	35,0	2,56
<b>Mata Viva</b>	13.82	3	Arenoso	85,80	82.465	70.665	171,34	7,93	23,9	2,81
<b>Bernau</b>	21.83	2	Arenoso	91,0	105.870	86.536	160,26	7,84	25,5	2,42
Média*				-	138,18	111,84	163,63	8,09	27,25	2,63
Erro padrão				-	5,70	4,50	1,53	0,09	0,85	0,16
Mediana				-	124,27	100,5	165,34	7,96	27,00	2,45
Desvio padrão				-	40,74	32,16	10,80	0,67	6,10	1,03
Curtose				-	-0,18	-0,40	5,15	1,32	0,50	17,1
Assimetria				-	0,61	0,51	-1,67	0,53	0,73	3,97
Mínimo				-	71	57	119,54	6,34	17,0	1,64
Máximo				-	252,5	194,7	178,87	10,1	44,0	7,73
Coefficiente de variação (CV%)				-	29,49	28,76	6,6	8,3	22,4	39,4

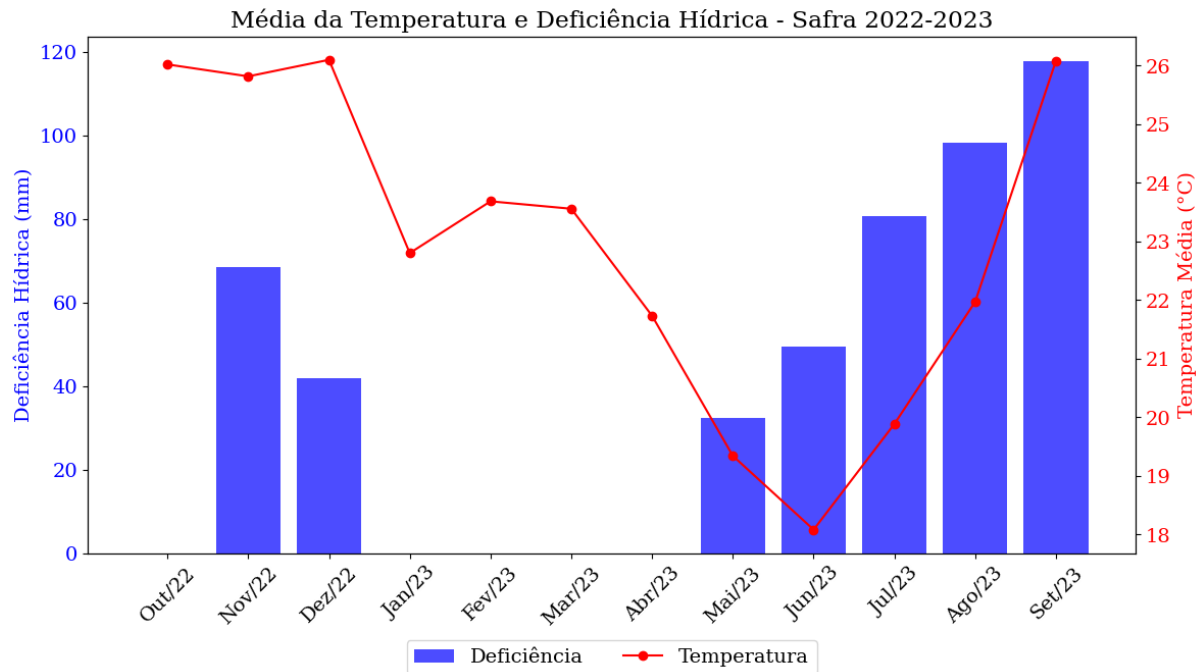
Fonte: Elaborada pelo autor, 2024.

Nota: \* Média geral de 51 amostras; TCH\_R (produtividade real posto usina, ton. ha<sup>-1</sup>); TCH, TCH\_L e ATR (média de cada fazenda); Diam\_Med (diâmetro médio dos colmos, cm); N°\_Colm/ml (número médio de colmos por metro linear); C\_Colmo (comprimento médio dos colmos, m).

A produção das áreas experimentais, especialmente para TCH\_R e TCH, varia consideravelmente e TCH\_L é mais consistente. O ATR e as medições físicas dos colmos também mostram variabilidade, mas com menor dispersão relativa comparada às produções, exceto para o comprimento médio dos colmos que apresentaram maior CV%. Importante notar como a textura argilosa do solo propicia maiores produções e a maiores medidas para o diâmetro médio dos colmos, indicando sítios mais produtivos (Tabela 2).

Os gráficos das Figura 3 e 4 representam, respectivamente, a variação da temperatura média e da deficiência hídrica na área de estudo e a variação temporal dos valores dos índices de vegetação médio dos talhões de cana na safra 2022/2023.


Figura 3- Variação de temperatura média e deficiência hídrica nas áreas de estudo para a safra 2022-2023, Campo Florido- MG, Brasil.



Fonte: Elaborada pelo autor, 2024.

Conforme a Figura 3, o déficit hídrico aumenta de forma mais acentuada a partir de junho, atingindo o pico máximo em setembro de 2023, com 117,8 mm. A deficiência hídrica total registrada foi de 488,58 mm, e a temperatura média no ano foi de 22,9°C.

Figura 4- Série temporal dos índices de vegetação espectrais e de radar nas áreas de estudo para a safra 2022-2023, Campo Florido-MG, Brasil.



Fonte: Elaborada pelo autor, 2024.

Os valores dos índices de vegetação (IVs) que utilizam a banda do infravermelho, por estarem relacionados à quantidade de biomassa da cultura, indicam que o maior acúmulo de biomassa da cana - de - açúcar no Cerrado ocorre entre janeiro e maio. Com o declínio do vigor das plantas e o aumento do acúmulo de açúcar, acentuado pelo período de seca em setembro, ocorre uma queda acentuada em todos os índices, relacionada à colheita e remoção da cultura. Após essa fase, com o reinício do crescimento vegetativo da cana, os índices voltam a subir (Figura 4). O mesmo padrão é observado nos índices de radar (SAR), com uma queda evidente após a colheita.

Com base nesse resultado, o cálculo da estimativa da produtividade da cana - de - açúcar pelas regressões lineares, feito para dois períodos compreendidos (1) à época do planejamento de safra e (2) à época da colheita, foi estimado adequadamente conforme resultados a seguir.

#### 4.1. Modelos de produtividade da cana - de - açúcar

Prever a produtividade da cultura da cana - de - açúcar é crucial para o planejamento e a tomada de decisões eficazes na indústria açucareira. Mas o que ocorre é que muitas propriedades usam estimativas visuais de produtividade em áreas canavieiras, o que frequentemente produz dados imprecisos e não mostram a produtividade real dos cultivos.

Os resultados obtidos na fase de início ou de planejamento de safra geraram equações lineares simples significantes e obtivemos equações múltiplas apenas para o ATR na fase pré - corte (NDRE+NDVI). Observamos que a avaliação da precisão da estimativa dos modelos de regressão linear para o início da safra 2022/2023 explicaram 35,69%, 41,29% e 15,81% a variabilidade da produtividade observada, respectivamente para TCH\_L, TCH e ATR. Para a fase pré - corte, as melhores estimativas explicaram 40,59%, 44,75% e 7,89% a variabilidade da produtividade observada, respectivamente para TCH\_L, TCH e ATR. O Apêndice C (1 a 6) dispõem os resultados de  $R^2$ ,  $R^2$  ajustado e p-valor dos modelos MLR de produtividade da cana - de - açúcar de acordo com a primeira abordagem. Em geral, o  $R^2$  e o  $R^2$  ajustado apresentaram uma tendência crescente a partir de fevereiro (início da safra) até agosto-setembro (fase pré - corte), exceto para ATR. A mesma propensão se verificou na precisão das estimativas, *p-valor* com tendência a melhorar as estimativas no período equivalente para TCH\_L e TCH ( $3,933e-07$  e  $6,615e-08$  em setembro). Entretanto, como veremos mais à frente, para o ATR, houve piora no mesmo período (*p-valor* = 0,06168), mas sua estimativa continuou significativa para os coeficientes da equação (*p-valor* < 0,05).

Nessas etapas foi possível observar a eficácia de abordagens de regressão linear na estimativa de rendimento da cana - de - açúcar (TCH\_L e TCH), nas quais incorporamos IVs alternativos (VARI e GNDVI) para gerar as equações. E, com isso, obtivemos uma forma de análise e previsão de safra igualmente eficiente e significativa com índices de vegetação RGB. Já para o ATR, apenas os índices NDVI e sua associação com o NDRE para a fase pré - corte foram eficazes para sua estimativa.

Tendo em conta todas as métricas de avaliação, um passo importante é compreender como interpretar esses resultados. O Coeficiente de determinação ( $R^2$  e

R<sup>2</sup> ajustado) indica o quanto a equação explica o fenômeno. O RMSE apresenta o mesmo erro absoluto da regressão nas unidades originais utilizadas no conjunto de dados, sendo adequado para comparar diferentes regressões no mesmo conjunto de dados. O MAPE apresenta o erro de regressão absoluto em porcentagem, sendo adequado para comparar os resultados quando os conjuntos de dados têm unidades ou magnitudes diferentes.

#### 4.1.1. Modelagem da produtividade líquida da cana - de - açúcar (TCH<sub>L</sub>)

Os modelos selecionados para a produtividade líquida de cana - de - açúcar são apresentados nas Equações  $TCH_{L_{plan\_safra}} = \text{intercepto} + \text{coeficiente do melhor índice} * \text{melhor índice}$  (4 e 5) e  $TCH_{L_{pré-30dd}} = \text{Intercepto} + \text{coeficiente do índice} * \text{melhor índice}$  (6 e 7), juntamente com os resultados da MLR no Apêndice C – 1 e 2.

$$TCH_{L_{plan\_safra}} = -154.25 + 307.05 * NDVI \quad (4)$$

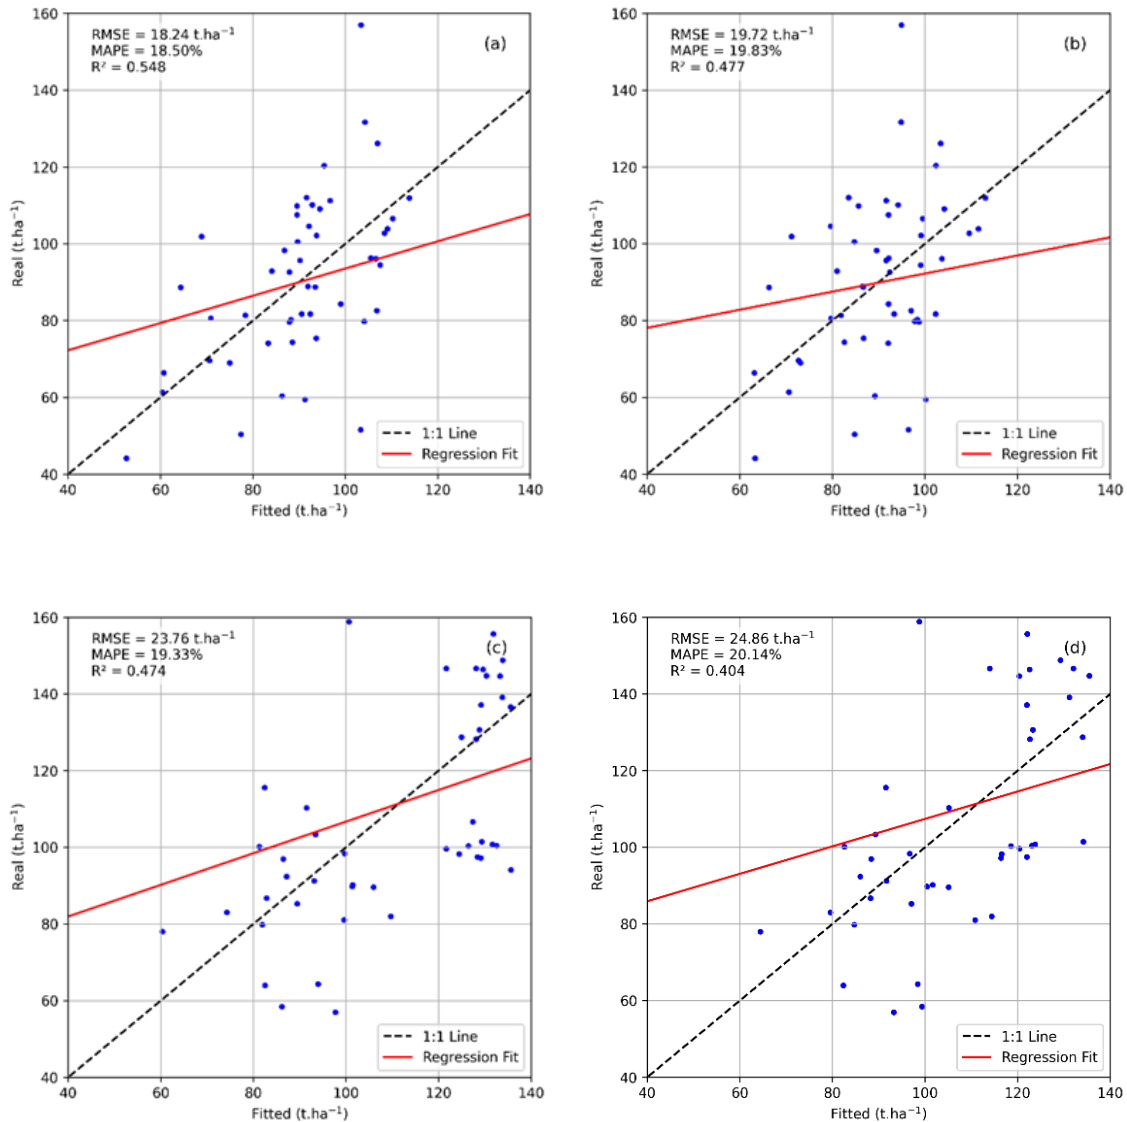
$$TCH_{L_{plan\_safra}} = 47.05 + 115.41 * VARI \quad (5)$$

$$TCH_{L_{pré-30dd}} = -78.17 + 258.63 * NDVI \quad (6)$$

$$TCH_{L_{pré-30dd}} = 68.208 + 295.528 * GNDVI \quad (7)$$

Conforme avaliadas pela validação cruzada, essas equações (4 e 5 para a fase de planejamento de safra) e (6 e 7 para a fase pré - corte) descrevem modelos de regressão que apresentaram os resultados para a estimativa da produtividade da cana - de - açúcar (TCH<sub>L</sub>), obtendo o melhor modelo com o NDVI que explicou 55% da variância (R<sup>2</sup> de 0,548), com um RMSE de 18,24 ton. ha<sup>-1</sup> e MAPE de 18,50% (Fig. 5) para a fase em início de safra.

Figura 5- Produtividade líquida da cana - de - açúcar (TCH<sub>L</sub>), obtida para a fase de planejamento de safra com a Equação (4) (a) e a Equação (5) (b) e para a fase de pré - corte com a Equação (6) (c) e a Equação (7) (d).



Fonte: Elaborada pelo autor, 2024.

#### 4.1.2. Modelagem da produtividade total da cana - de - açúcar (TCH).

Com um coeficiente de determinação R<sup>2</sup>-ajustado menor que as estimativas para TCH<sub>L</sub>, mas p-valor igualmente significativos tanto para a imagem na fase de planejamento de safra quanto para a de 30 dias antes do corte, os resultados da análise de regressão linear mostraram que os dados espectrais que melhor se aplicam à produtividade total da cana - de - açúcar também foram os índices NDVI, VARI e GNDVI (Apêndice C – 3 e 4). Os modelos selecionados para a produtividade total da cana - de - açúcar são apresentados nas Equações  $TCH_{plan\_safra} = \text{intercepto} + \text{coeficiente do melhor índice} * \text{melhor índice}$  (8 e 9) e  $TCH_{pré-30dd} = \text{Intercepto} + \text{coeficiente do índice} * \text{melhor índice}$  (10 e 11).

$$TCH_{plan\_safra} = -207.84 + 400.96 * NDVI \quad (8)$$


$$TCH_{plan\_safra} = 53.80 + 154.07 * VARI \quad (9)$$


$$TCH_{pré-30dd} = -113.96 + 343.32 * NDVI \quad (10)$$

$$TCH_{pré-30dd} = 78.84 + 402.62 * GNDVI \quad (11)$$

Com base na análise realizada através da validação cruzada, os modelos de regressão descritos pelas equações (8 e 9) para a fase de planejamento da safra e (10 e 11) para a fase pré - corte se destacam na previsão da produtividade total da cana - de - açúcar (TCH). O modelo com o NDVI revelou-se capaz de explicar 60% da variância observada (com um  $R^2$  de 0,603), apresentando um erro médio quadrático (RMSE) de 20,64 ton. ha<sup>-1</sup> e um percentual de erro médio absoluto (MAPE) de 18,17% (Figura 6).

Figura 6- Produtividade da cana - de - açúcar (TCH), obtida para a fase de planejamento de safra com a Equação (8) (a) e a Equação (9) (b) e para a fase de pré - corte com a Equação (10) (c) e a Equação (11) (d).





Fonte: Elaborada pelo autor, 2024.

Esses resultados encontrados nas condições desta pesquisa mostram que os índices NDVI, VARI e GNDVI podem ser aplicados com uma ferramenta válida tanto na elaboração da estimativa de safra na cultura da cana - de - açúcar quanto na previsão pré - corte. Os últimos resultados unicamente com índices RGB (Figura 6 (b) e (d)), mesmo apresentando redução de cerca de 9% do R<sup>2</sup> continuam sendo alternativas viáveis para o produtor.

#### 4.1.3. Modelagem da produtividade do Açúcar Total Recuperável (ATR)


A investigação por regressão linear múltipla revelou que as variáveis independentes NDRE+NDVI foram as mais adequadas para o ATR de plantações de cana - de - açúcar em fase de planejamento de safra com um coeficiente de determinação ajustado R<sup>2</sup> de 15,81% e para a fase pré - corte, apresentando R<sup>2</sup> ajustado de 7,89% (Apêndice C – 5 e 6). Foi possível observar que a avaliação da precisão da estimativa dos modelos de regressão linear para o ATR na fase de planejamento da safra 2022/2023 explicou 15,81% da variabilidade da produtividade observada, com o índice NDVI (Eq. 12). Nesta etapa, não foi igualmente possível observar eficácia de abordagens de regressão linear na estimativa de rendimento do ATR, adotando índices RGBs. Os resultados obtidos na fase de pré - corte, estimados 30 dias antes do corte dos talhões, geraram equações lineares significantes com os índices NDRE+NDVI (Eq. 13).

$$ATR_{plan\_safra} = 233.31 - 85.16 * NDVI \quad (12)$$

$$ATR_{pré-30dd} = 208.36 + 145.57 * NDRE - 163.85 * NDVI \quad (13)$$

Com base na análise realizada através da validação cruzada, os modelos de regressão descritos pelas equações (12 e 13) respectivamente para a fase de planejamento da safra e para a fase pré - corte se destacam na previsão do ATR. O modelo com o NDVI revelou-se capaz de explicar 55,0% da variância observada (com um  $R^2$  de 0,55), apresentando um erro médio quadrático (RMSE) de 7,34  $\text{kg. ha}^{-1}$  e um percentual de erro médio absoluto (MAPE) de 3,84% para a fase de planejamento de safra (Fig. 7-a). Depreende-se pela Fig. 7-b que o destaque para esta variável foi na fase pré - corte com o menores MAPE 3,61% e RMSE 7,19  $\text{kg. ha}^{-1}$ .

Figura 7- Produtividade do Açúcar Total Recuperável (ATR), obtida para a fase de planejamento de safra com a Equação (12) (a) e para a fase de pré - corte com a Equação (13) (b).



Fonte: Elaborada pelo autor, 2024.

Os índices RGB não se mostraram com resultados significativos para o ATR, para a análise realizada com imagens capturadas na fase de planejamento de safra e mesmo trinta dias antes da colheita.

Os modelos gerados para a estimativa de produtividades total e líquida no início da safra apresentaram valores de correlação muito altos, segundo a classificação de Hopkins (2000), exceto para TCH\_L no início de safra, com o índice RGB, que foi considerado alto. No início da safra, o modelo gerado para a estimativa do ATR foi considerado moderado ou médio e houve significância apenas com os índices RGB (Tab. 4). Na fase pré - corte, a correlação para o ATR foi considerada moderada, porém ainda significativa a MLR (p-valor < 0,05).

Nossos resultados referentes à correlação, compilados na Tabela 4, indicam que os modelos gerados têm um desempenho adequado em sua previsão da produtividade de cana - de - açúcar e ATR para dados Sentinel-2 e Alos-Palsar.

Tabela 4- Correlação percentual (R) e o erro percentual absoluto médio (%) aplicados às variáveis dependentes TCH\_L, TCH e ATR no início de safra e na fase pré - corte da cana - de - açúcar.

Variável	Início de safra			Pré - Corte			
	IVs	NDVI	VARI	GNDVI	NDVI	NDRE+ NDVI	GNDVI
TCH_L		74,02	69,07	-	68,85	-	63,56
	MAPE	18,50	19,83	-	19,33	-	20,14
TCH		77,65	-	71,55	63,32	-	69,07
	MAPE	18,17	-	19,88	20,20	-	18,71
ATR		74,18	-	-	-	70,97	-
	MAPE	3,84	-	-	-	3,61	-

Fonte: Elaborada pelo autor, 2024.

Em geral, destacamos que o MAPE mostra uma boa regressão para a maioria das variáveis, com erros inferiores a 20%. Para a fase pré - corte e para início de safra, as estimativas da regressão da validação cruzada para ATR apresentam erros menores do que 5%, sendo uma previsão considerada melhor que para a TCH\_L e TCH. Considerando que o ATR é considerado o parâmetro mais importante por ser o balizador do preço pago aos produtores, a estimativa gerada neste trabalho é muito promissora. A precisão espacial dos satélites pode não ser adequada para representar

a diversidade de culturas agrícolas, particularmente em regiões com pequenas parcelas ou alta variabilidade. Imagens de alta resolução (por exemplo, 30 metros ou mais) podem combinar informações de vários tipos de vegetação ou áreas não cultiváveis. Dessa forma, é necessário utilizar satélites com menor resolução espacial, como o Sentinel-2 de 10 metros, ou complementá-lo com drones ou sensores de campo que forneçam dados de alta resolução submétrica para pequenas áreas de pesquisa.

A elevada variabilidade dos dados (valores de correlação de moderados a muito altos) evidencia a provável interferência de outros fatores na estimativa da produtividade de cana - de - açúcar e ATR. As pesquisas sobre a produtividade da cana - de - açúcar destacam a influência das propriedades do solo e de fatores sazonais. O desenvolvimento da planta pode ser impactado por fatores climáticos e fenológicos (variações sazonais) e as imagens de satélite podem não ser obtidas no momento apropriado do ciclo da agricultura. A utilização de dados multitemporais de sensoriamento remoto pode auxiliar na detecção de tendências e irregularidades ligadas à produtividade

A textura do solo afeta a capacidade de retenção de água e a disponibilidade de nutrientes, especialmente o teor de argila influenciando a produtividade da cana - de - açúcar com maior teor de argila associado ao aumento da produtividade (Siqueira; Silva; Dafonte, 2015). De forma semelhante, Silva *et al.* (2022) identificaram variáveis importantes como irrigação, precipitação, temperatura do ar, déficit de saturação de vapor e fotoperíodo. Simões, Rocha e Lamparelli (2005), Cordeiro *et al.* (2019), Dalchiavon *et al.* (2014) e Silva *et al.* (2022) enfatizam a importância de se considerar vários fatores na previsão da produtividade da cana - de - açúcar, bem como a possibilidade de a análise com a regressão linear múltipla fornecer estimativas precisas em condições brasileiras. A existência de nuvens, aerossóis e outras partículas do ar pode alterar as medições de refletividade feitas pelos satélites, levando a resultados imprecisos. Com isso, há a necessidade de implementar ajustes atmosféricos nos dados de sensoriamento remoto, por meio da utilização de modelos de correção atmosférica ou da utilização de sensores de radar que não são impactados por nuvens.

Como resultados apresentados neste estudo, existe uma relação significativa entre a produtividade da cana - de - açúcar e os índices de vegetação, sendo o NDVI, VARI e GNDVI os IVs mais frequentemente explicativos. Conforme visto na Figura 3,

os IVs apresentam valores elevados de janeiro a maio, período de maior crescimento vegetativo. Alinhado com isso, as maiores correlações foram no período de planejamento de safra realizada no mês de fevereiro. Isso indica uma tendência de que com certo aumento nos valores dos IVs, maiores as produtividades (Figura 3), concordando com Vasconcelos *et al.* (2023). Esses autores obtiveram uma correlação positiva entre a produção de cana - de - açúcar e os valores médios de NDVI e VARI, em áreas experimentais no estado de São Paulo, os quais encontraram em relação ao desempenho do modelo baseado em NDVI que resultou em um  $R^2$  de 0,67 e um RMSE de 19,8 ton.ha<sup>-1</sup>, enquanto o modelo baseado em VARI produziu um  $R^2$  de 0,64 e um RMSE de 21,1 ton.ha<sup>-1</sup>, sendo comparáveis aos valores encontrados nesse estudo com os índices NDVI e VARI e as variáveis TCH e TCH\_L.

Estudos que utilizam a análise RMSE para prever a produtividade da cana - de - açúcar revelaram resultados encorajadores em diversas estratégias. Algoritmo que combina imagens Landsat com informações agrônômicas e meteorológicas alcançou um  $R^2$  de 0,76 e um RMSE de 9,9 ton. ha<sup>-1</sup>, mais baixos que os nossos achados, para a previsão da produtividade segundo Luciano *et al.* (2021). Esses autores usaram imagens de satélite Landsat e aplicaram um algoritmo Random Forest (RF) para prever a produção de cana - de - açúcar em escala local no Brasil, usando o NDVI e o Índice de Vegetação Aprimorado (EVI). Oliveira *et al.* (2012) utilizaram a metodologia da Zona Agroecológica para calcular a produtividade da cana - de - açúcar em Minas Gerais, obtendo valores de  $R^2$  de 0,89 e RMSE de 8,4 ton. ha<sup>-1</sup> após a calibração. Ao ser testado com dados históricos, o modelo apresentou uma concordância satisfatória ( $R^2 = 0,55$ , RMSE = 4,9 ton. ha<sup>-1</sup>), após a correção para superestimação, sendo este resultado mais próximo dos vistos neste estudo com ATR x os índices VARI e GNDVI.

Valores intermediários aos resultados deste estudo foram descobertos conforme a revisão realizada por Som-Ard *et al.* (2021), os quais discutem a relação entre os índices de vegetação (IVs) derivados de sensoriamento remoto e a produtividade da cana - de - açúcar. Usando IVs NDVI e EVI obtiveram valores específicos de RMSE variando de 9,4 ton. ha<sup>-1</sup> a 19,8 ton. ha<sup>-1</sup>, dependendo da complexidade do modelo e das entradas de dados.

Tais pesquisas, além de corroborarem os achados aqui neste nosso estudo, evidenciam a capacidade de diversas metodologias de modelagem para antecipar a produtividade da cana - de - açúcar no Brasil. Essas pesquisas evidenciam em conjunto a efetividade de diversos métodos na previsão do rendimento da cana - de -

açúcar. Essas abordagens baseadas em sensoriamento remoto oferecem soluções econômicas, oportunas e escaláveis para estimativa de seu rendimento, beneficiando o gerenciamento agrícola e os processos de tomada de decisão (Vasconcelos *et al.*, 2023). Conforme demonstrado neste estudo, pela Tabela 4, o uso dos índices de vegetação NDVI (fase de planejamento de safra ou fase pré-colheita) se destacou com eficiência para estimar a produtividade da cana - de - açúcar e o ATR.

De tal maneira, os IVs têm potencial de serem usados para estimar produtividade de outras culturas, contribuindo com a afirmação de Mercante *et al.* (2010). Estes autores desenvolveram modelos de regressão linear para estimar o rendimento da soja usando dados espectrais. Eles relataram valores de RMSE que variam de 0,35 a 1,42 ton. ha<sup>-1</sup>, dependendo do modelo específico e das condições aplicadas. Esses resultados, apesar de bem menores dos que encontrados aqui neste estudo, indicam um nível razoável de precisão na previsão da produtividade da soja com base nos dados espectrais analisados. O EVI e o NDVI, que são índices de vegetação derivados de imagens de satélite, também têm se mostrado promissores para prever a produtividade da soja (Nolasco *et al.*, 2020; Gusso; Arvor; Ducati, 2017). Os resultados da previsão deste estudo mostraram que os índices foram mais precisos à época de planejamento de safra. Isso reforçou a ideia de que o desempenho pode variar dependendo da metodologia e da região, com alguns estudos mostrando menor precisão (Pignède *et al.*, 2021). Para previsões antecipadas de produção, os modelos aqui testados e baseados em sensoriamento remoto podem fornecer informações úteis para planejamento agrícola e tomada de decisão. Os resultados desse estudo também complementam o que foi citado em Nolasco *et al.* (2020) e Gusso; Arvor; Ducati (2017), sugerindo uma capacidade confiável desses índices, especialmente o NDVI, para prever a produtividade da soja, fornecendo estimativas de produtividade em tempo hábil, úteis para a tomada de decisões e o planejamento.

Essas técnicas de sensoriamento remoto oferecem alternativas econômicas, eficientes em termos de mão de obra e oportunas aos métodos visuais tradicionais para estimar a produtividade da cana - de - açúcar e dar suporte a práticas de agricultura de precisão.

## 5 CONCLUSÃO

Neste estudo, avaliou-se a viabilidade da estimativa da produtividade da cana - de - açúcar e do ATR usando dados espectrais do Sentinel-2 e do radar Alos-Palsar. Foram obtidas importantes equações para a previsão de safra, 6 meses antes do corte dos talhões como também 30 dias antes da referida atividade, gerando uma ferramenta operacionalmente de fácil manuseio e assertiva no sentido de auxiliar a tomada de decisões.

Foi possível observar que não apenas o índice NDVI pôde ser usado para fazer a predição de safra, mas outros índices apresentaram assertividade também precisa, especialmente RGBs. De modo geral e dentre as variáveis analisadas, a melhor estimativa foi para o ATR com o índice NDVI, o qual apresentou menor erro MAPE (3,61%) e menor RMSE (7,19 kg ha<sup>-1</sup>) na fase pré - corte.

A avaliação estatística de regressão linear múltipla dos dados coletados para prever TCH-L indicou uma relação significativa entre o NDVI, VARI e GNDVI com a produtividade líquida da plantação de cana - de - açúcar. A hipótese nula (H0) foi testada para demonstrar que não há efeito nos índices de vegetação nas variáveis de produção. A análise de regressão linear múltipla para o TCH\_L revelou uma ligação significativa entre os índices de vegetação e a produtividade da cana - de - açúcar, sendo o NDVI o índice mais preciso. Os modelos criados demonstraram ser eficientes para a previsão de colheita, permitindo a antecipação da produtividade e fornecendo dados relevantes para o planejamento da safra de cana - de - açúcar. Os modelos criados demonstraram serem eficazes na previsão da colheita, permitindo a antecipação da produtividade e fornecendo dados relevantes para o planejamento da agricultura. O valor do erro MAPE previsto pelo modelo se encontra com erro de 18,50% do valor real e RMSE de 18,24 ton. ha<sup>-1</sup> na fase de previsão de safra para TCH\_L

Os índices NDVI, VARI e GNDVI para TCH se destacaram para serem utilizados como uma ferramenta útil na elaboração de uma estimativa de safra na cultura da cana - de - açúcar. Os resultados foram significativos tanto na fase de previsão de safra quanto na previsão pré - corte, ressaltando os resultados dos índices RGB que também se mostraram uma opção viável. Para TCH, a melhor estimativa também foi na fase de previsão de safra com o índice NDVI, exibindo erro MAPE de

18,17% e RMSE de 20,64 ton. ha<sup>-1</sup>. Além disso, a implementação de máquinas de modelagem, como Random Forest e redes neurais, poderia ser uma abordagem promissora para aprimorar as previsões de produtividade. Esses modelos têm se mostrado eficazes em diversas aplicações agrícolas, permitindo uma análise mais robusta dos dados espectrais e a identificação de padrões complexos.

Poucos estudos foram encontrados referenciando outros IVs como NDRE, GNDVI, HH, HV e “HV-HH” para a predição de safra em cana - de - açúcar, indicando lacunas para aumentar os estudos sobre esses índices também em diferentes culturas.

## REFERÊNCIAS

ABEBE, G.; TADESSE, T.; GESSESSE, B. Estimating Leaf Area Index and biomass of sugarcane based on Gaussian process regression using Landsat 8 and Sentinel 1<sup>a</sup> observations. **International Journal of Image and Data Fusion**, London, v. 14, n. 1, p. 58-88, Jan. 2023. DOI: <https://doi.org/10.1080/19479832.2022.2055157>.

Disponível em:

<https://www.tandfonline.com/doi/epdf/10.1080/19479832.2022.2055157?needAccess=true>. Acesso em: 13 ago. 2024.

ABDEL-RAHMAN, E.M.; AHMED, F. B. The application of remote sensing techniques to sugarcane (*Saccharum spp. hybrid*) production: a review of the literature. **International Journal of Remote Sensing**, London, v. 29, n. 13, p. 3753-3767, July 2008. DOI: <http://dx.doi.org/10.1080/01431160701874603>. Disponível em:

<https://www.tandfonline.com/doi/epdf/10.1080/01431160701874603?needAccess=true>. Acesso em: 13 ago. 2024.

AGGARWAL, S. Principles of remote sensing. In: SIVAKUMAR, M. V. K; ROY, P. S.; HARMSEN, K.; SAHA, S. **Satellite remote sensing and GIS applications in agricultural meteorology and wmo satellite activities**. Switzerland: World Meteorological Organisation, 2004, p. 1- 21. Disponível em:

[https://www.unisdr.org/files/1682\\_9970.pdf](https://www.unisdr.org/files/1682_9970.pdf). Acesso em: 13 ago. 2024.

AHMAD, A; ORDOÑEZ, J.; CARTUJO, P.; MARTOS, V. Remotely Piloted Aircraft (RPA) in Agriculture: a pursuit of sustainability. **Agronomy**, Switzerland, v. 11, n. 1, e7, p. 1-25. Dec. 2020. DOI: <http://dx.doi.org/10.3390/agronomy11010007>.

Disponível em: <https://www.mdpi.com/2073-4395/11/1/7>. Acesso em: 13 ago. 2024.

BANNARI, A.; MORIN, D.; BONN, F.; HUETE, A. R. A review of vegetation indices. **Remote Sensing Reviews**, London, v. 13, n. 1-2, p. 95-120, Aug. 1995.

DOI: <http://dx.doi.org/10.1080/02757259509532298>. Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/02757259509532298>. Acesso em: 13 ago. 2024.

CHERUBIN, M. R.; FRANCO, A. L. C.; CERRI, C. E. P.; KARLEN, D. L.; PAVINATO, P.S.; RODRIGUES, M.; DAVIES, C.A.; CERRI, C.C. Phosphorus pools responses to land-use change for sugarcane expansion in weathered Brazilian soils. **Geoderma**, Amsterdã, v. 265, p. 27-38, mar. 2016. DOI:

<https://doi.org/10.1016/j.geoderma.2015.11.017>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0016706115301324>. Acesso em: 13 set. 2024.

CLIMATE-DATA (Brasil). **Clima: Minas Gerais 2022**. Elaborado por Köppen e Geiger. Disponível em: <https://pt.climate-data.org/america-do-sul/brasil/minas-gerais203/>. Acesso em: 13 set. 2022.

CORDEIRO, N. K.; SOUZA, D. H. G.; BERNARDI, D.; CARDOSO, K. P. S.; LAZARETTI, N. S.; ABRAÃO, P. C.; MATA, T. C da.; MACEDO JÚNIOR, E. K.

Analysis of regression and correlation on production of sugarcane in the states of Paraná, São Paulo and Minas Gerais, Brazil. **Journal of Experimental Agriculture International**, India, v. 36, n. 5, p. 1-8, May 2019.

<http://dx.doi.org/10.9734/jeai/2019/v36i530246>. Disponível em:

<https://journaljeai.com/index.php/JEAI/article/view/1452/2907>. Acesso em: 13 set. 2024.

CUI, B.; ZHAO, Q.; HUANG, W.; SONG, X.; YE, H.; ZHOU, X. A New Integrated Vegetation index for the estimation of winter wheat leaf chlorophyll content. **Remote Sensing**, Switzerland, v. 11, n. 8, p.1-18, Apr. 2019.

<http://dx.doi.org/10.3390/rs11080974>. Disponível em: <https://www.mdpi.com/2072-4292/11/8/974>. Acesso em: 13 set. 2024.

DALCHIAVON, F. C.; CARVALHO, M. P.; MONTANARI, R.; ANDREOTTI, M.; PANOSSO, A. R. Produtividade da cana - de - açúcar: variabilidade linear e espacial entre componentes tecnológicos e da produção. **Bioscience Journal**, Uberlândia, v. 30, supl. 1, p. 390–400, jun. Disponível em:

<https://seer.ufu.br/index.php/biosciencejournal/article/view/18096>. Acesso em: 13 set. 2024.

GRAHAM, S. **Remote sensing**: feature articles. 1999. Disponível em:

[https://padlet-](https://padlet-uploads.storage.googleapis.com/31269024/f4cfdb94eeb130ab28f7c9934c1049db/Remote_Sensing___Feature_Articles.pdf)

[uploads.storage.googleapis.com/31269024/f4cfdb94eeb130ab28f7c9934c1049db/Remote\\_Sensing\\_\\_\\_Feature\\_Articles.pdf](https://padlet-uploads.storage.googleapis.com/31269024/f4cfdb94eeb130ab28f7c9934c1049db/Remote_Sensing___Feature_Articles.pdf). Acesso em: 13 set. 2024.

GODOY, A. P. de. **Modelagem de processos de acumulação de biomassa e de açúcar da cana - de - açúcar via sistemas nebulosos**. 2007. 253 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2007. Disponível em: <https://repositorio.unicamp.br/acervo/detalhe/409159>. Acesso em: 13 set. 2024.

GOLDEMBERG, J. The Brazilian biofuels industry. **Biotechnology for Biofuels and Bioproducts**, London, v. 1, n. 6, p. 1-7, May, 2008. DOI:10.1186/1754-6834-1-6.

Disponível em:

<https://biotechnologyforbiofuels.biomedcentral.com/articles/10.1186/1754-6834-1-6>. Acesso em: 13 set. 2024.

GUSSO, A.; ARVOR, D.; DUCATI, J. R. Model for soybean production forecast based on prevailing physical conditions. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 52, n. 2, p. 95-103, fev. 2017. DOI: <http://dx.doi.org/10.1590/s0100-204x2017000200003>. Disponível em:

<https://www.scielo.br/j/pab/a/mSvd3K8BvMbX96hXGyddBLp/?lang=en>. Acesso em:

<https://www.scielo.br/j/pab/a/mSvd3K8BvMbX96hXGyddBLp/?lang=en>. Acesso em: 13 set. 2024.

HEIRINCHS, R. O. R., MAGALHÃES, A.; MEIRELLES, G. C. Importance of sugarcane in brazilian and world bioeconomy. *In*: DABBERT, S.; LEWANDOWSKI, I.; WEISS, J.; PYKA, A. (ed). **Knowledge-driven developments in the bioeconomy: technological and economic perspectives**. Springer Cham. 2017. p. 205-217. (Série Economic Complexity and Evolution) *E-book*. Disponível em:

[https://link.springer.com/chapter/10.1007/978-3-319-58374-7\\_11#citeas](https://link.springer.com/chapter/10.1007/978-3-319-58374-7_11#citeas). Acesso em: 13 set. 2024.

HOPKINS, W.G., **A new view of statistics**. Internet Society for Sport Science, 2000. Disponível em: <https://www.sportsci.org/resource/stats/effectmag.html#cohen>. Acesso em: 13 set. 2024.

HU, S.; SHI, L.; HUANG, K.; ZHA, Y.; HU, X.; YE, H.; YANG, Q. Improvement of sugarcane crop simulation by SWAP-WOFOST model via data assimilation. **Field Crops Research**, Amsterdã, v. 232, p. 49-61, Feb. 2019. DOI: <http://dx.doi.org/10.1016/j.fcr.2018.12.009>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378429018311420?via%3Dihub>. Acesso em: 13 set. 2024.

HUETE, A.R. HUENNRICH, K.F.; MIURA, T.; XIAO, X.; DIDAN, K.; LEEUWEN, W. Vegetation index greenness global data set. **NASA ESDR/CDR**, 2006. Disponível em: [https://www.academia.edu/122720360/Vegetation\\_Index\\_greenness\\_global\\_data\\_set\\_White\\_Paper\\_for\\_NASA\\_ESDR\\_CDR\\_April\\_2006\\_](https://www.academia.edu/122720360/Vegetation_Index_greenness_global_data_set_White_Paper_for_NASA_ESDR_CDR_April_2006_). Acesso em: 13 set. 2024.

KUHN, M. Building predictive models in R using the caret package. **Journal of Statistical Software**, Austria, v. 28, n. 5, p. 1-26, Nov. 2008. DOI: doi:10.18637/jss.v028.i05. Disponível em: <https://www.jstatsoft.org/article/view/v028i05>. Acesso em: 20 set. 2024.

LAMBERS, H; COSTA, P. de B.; OLIVEIRA, R. S.; SILVEIRA, F. A. O. Towards more sustainable cropping systems: lessons from native cerrado species. **Theoretical And Experimental Plant Physiology**, London, v. 32, n. 3, p. 175-194, July 2020. DOI: <http://dx.doi.org/10.1007/s40626-020-00180-z>. Disponível em: <https://link.springer.com/article/10.1007/s40626-020-00180-z>. Acesso em: 20 set. 2024.

LEDA, V. C.; GOLÇALVES, A. K.; LIMA, N. da S. Sensoriamento remoto aplicado a modelagem de produtividade da cultura da cana - de - açúcar. **Energia na Agricultura**, Botucatu, v. 34, n. 2, p. 263-270, abr./ jun. 2019. DOI: <http://dx.doi.org/10.17224/energagric.2019v34n2p263-270>. Disponível em: <https://revistas.fca.unesp.br/index.php/energia/article/view/3720/2546>. Acesso em: 20 set. 2024.

LIU, Y.; REN, C.; LIANG, J.; ZHOU, Y.; XUE, X.; DING, C.; LU, J. A robust index based on phenological features to extract sugarcane from multisource remote sensing data. **Remote Sensing**, Switzerland, v. 15, n. 24, p. 1- 22, Dec. 2023. <http://dx.doi.org/10.3390/rs15245783>. Disponível em: <https://www.mdpi.com/2072-4292/15/24/5783>. Acesso em: 20 set. 2024.

LOPES, R. J. C.; SANTOS, A. M. dos.; ZLATAR, T.; LIMA JÚNIOR, C. de. Uso de índices de vegetação por sensoriamento remoto para estudos da Caatinga: uma revisão sistemática. **Gaia Scientia**, João Pessoa, v. 14, n. 1, p. 104-116, mar. 2020.

DOI: <https://doi.org/10.22478/ufpb.1981-1268.2020v14n1.48862>. Disponível em: <https://periodicos.ufpb.br/index.php/gaia/article/view/4886>. Acesso em: 20 set. 2024.

LUCIANO, A. C. dos 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**, Amsterdã, v. 184, e106093, p. 1-10, May 2021. DOI: <https://doi.org/10.1016/j.compag.2021.106063>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921000818>. Acesso em: 20 set. 2024.

LUMLEY, T. Regression subset selection. **Pacote 'leaps**. p. 1-8, June 2024. Disponível em: <https://cran.r-project.org/web/packages/leaps/leaps.pdf>. Acesso em: 20 set. 2024.

MARCUSSI, A. B.; BUENO, C. R. P.; MIQUELONI, D. P.; ARRAES, C. L. Utilização de índices de vegetação para os sistemas de informação geográfica. **Caminhos de Geografia**, Uberlândia, v. 11, n. 35, p. 41-53, set. 2010. DOI: <http://dx.doi.org/10.14393/rcg113516000>. Disponível em: <https://seer.ufu.br/index.php/caminhosdegeografia/article/view/16000>. Acesso em: 20 set. 2024.

MARION, F. A.; ANDRES, J.; HENDGES, E. R. Evolução dos índices de vegetação e sua relação com o estresse hídrico: uma revisão. **GEOFRONTER**, Campo Grande, v. 7, p. 1- 18, dez. 2021. DOI:<https://doi.org/10.61389/geofronter.v7.6758>. Disponível em: <https://periodicosonline.uems.br/index.php/GEOF/article/view/6758>. Acesso em: 10 out. 2024.

MARTINEZ URIBE, R. A. **Produtividade e estimativa de acúmulo da biomassa em soqueira de cana - de - açúcar irrigada por gotejamento subsuperficial com diferentes doses de N fertilizantes**. 2010. 75 f. Tese (Doutorado em Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2010. Disponível em: <https://repositorio.unesp.br/items/bd67b4d6-f6c2-4c58-8598-854878c43b19>. Acesso em: 10 out. 2024.

MERCANTE, E.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A.; ROCHA, J. V. Modelos de regressão lineares para estimativa de produtividade da soja no oeste do Paraná, utilizando dados espectrais. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 3, p. 504-517, jun. 2010. DOI: <http://dx.doi.org/10.1590/s0100-69162010000300014>. Disponível em: <https://www.scielo.br/j/eagri/a/5zHjK83X6Qzh9rXFzrkv6xF/?lang=pt>. Acesso em: 10 out. 2024.

MOLIJN, R. A.; IANNINI, L.; ROCHA, J. V.; HANSEN, R. F. Sugarcane productivity mapping through c-band and l-band sar and optical satellite imagery. **Remote Sensing**, Switzerland, v. 11, n. 9, e1109, p. 1-27, May 2019. DOI: <http://dx.doi.org/10.3390/rs11091109>. Disponível em: <https://www.mdpi.com/2072-4292/11/9/1109>. Acesso em: 10 out 2024.

MOLIJN, R. A. **Space-based SAR and optical remote sensing for productivity monitoring and mapping of sugarcane**. 2020. 135 f. Dissertação (Mestrado em

Engenharia Agrícola) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2020. Disponível em:  
<https://repositorio.unicamp.br/acervo/detalhe/1149017>. Acesso em: 10 out. 2024.

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**, Switzerland, v. 14, n. 5, e1140, p. 1- 22, Feb. 2022. DOI:  
<http://dx.doi.org/10.3390/rs14051140>. Disponível em: <https://www.mdpi.com/2072-4292/14/5/1140>. Acesso em: 10 out. 2024.

NDUKU, L.; MUNGHEMEZULU, C.; MASHABA-MUNGHEMEZULU, Z.; KALUMBA, A. M.; CHIRIMA, G. J.; MASIZA, W.; VILLIERS, C. de. Global research trends for unmanned aerial vehicle remote sensing application in wheat crop monitoring. **Geomatics**, Switzerland, v. 3, n. 1, p. 115-136, Jan. 2023. DOI:  
<http://dx.doi.org/10.3390/geomatics3010006>. Disponível em:  
<https://www.mdpi.com/2673-7418/3/1/6>. Acesso em: 10 out. 2024.

NOLASCO, M.; OVANDO, G.; SAYAGO, S.; MAGARIO, I.; BOCCO, M. Estimating soybean yield using time series of anomalies in vegetation indices from MODIS. **International Journal of Remote Sensing**, London, v. 42, n. 2, p. 405-421, Nov. 2020. DOI: <http://dx.doi.org/10.1080/01431161.2020.1809736>. Disponível em:  
<https://www.tandfonline.com/doi/full/10.1080/01431161.2020.1809736>. Acesso em: 10 out. 2024.

OLIVEIRA, E. G.; FERREIRA, M. E.; ARAÚJO, F. M. de. Diagnóstico do uso da terra na região centro-oeste de Minas Gerais, Brasil: a renovação da paisagem pela cana - de - açúcar e seus impactos socioambientais. **Sociedade & Natureza**, Uberlândia, v. 24, n. 3, p. 545-555, dez. 2012. DOI: <http://dx.doi.org/10.1590/s1982-45132012000300013>. Disponível em:  
<https://www.scielo.br/j/sn/a/hZgDN3pFrwZ4Qds9SCwRS5h/?lang=pt>. Acesso em: 10 out. 2024.

OLIVEIRA, R. A.; SANTOS, R. S. dos.; RIBEIRO, A.; ZOLNIER, S.; BARBOSA, M. H. P. Estimativa da produtividade da cana - de - açúcar para as principais regiões produtoras de Minas Gerais usando-se o método ZAE I. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 16, n. 5, p. 549-557, maio 2012. DOI: <http://dx.doi.org/10.1590/s1415-43662012000500011>. Disponível em:  
<https://www.scielo.br/j/rbeaa/a/Lsf4zSSQBjQsgGTtMCpFwkk/?format=pdf&lang=pt>. Acesso em: 10 out. 2024.

PENA, E. A.; SLATE, E. H. Global validation of linear model assumptions. **Journal of the American Statistical Association**, London, v.101, n. 473, e341, p. 1-30, Mar. 2006. DOI: <http://dx.doi.org/10.1198/016214505000000637>. Disponível em:  
[https://www.researchgate.net/publication/41436001\\_Global\\_Validation\\_of\\_Linear\\_Model\\_Assumptions](https://www.researchgate.net/publication/41436001_Global_Validation_of_Linear_Model_Assumptions). Acesso em: 10 out. 2024.

PETERSEN, K. Measuring and predicting software productivity: a systematic map and review. **Information and Software Technology**, Amsterdã, v. 53, n. 4, p. 317-

343, Apr. 2011. DOI: <http://dx.doi.org/10.1016/j.infsof.2010.12.001>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950584910002156?via%3Dihub>. Acesso em: 10 out. 2024.

PIGNÈDE, E.; ROUDIER, P.; DIEDHIOU, A.; BI, V. H. N.; KOBEA, A.T.; KONATÉ, D.; PÉNÉ, C. B. Sugarcane yield forecast in Ivory Coast (West Africa) based on weather and vegetation index data. **Atmosphere**, Switzerland, v. 12, n. 11, e1459, p. 1-22, nov. 2021. DOI: <http://dx.doi.org/10.3390/atmos12111459>. Disponível em: <https://www.mdpi.com/2073-4433/12/11/1459>. Acesso em: 10 out. 2024.

PONTES, P. P. B.; ROCHA, J. V.; LAMPARELLI, R. A. C. Análise temporal de índices de vegetação como subsídio à previsão de safras de cana - de - açúcar. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais** [...]. Goiânia: INPE, 2005. p. 217–224. Disponível em: <http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.21.21.12/doc/217.pdf>. Acesso em: 10 Jan. 2023.

READ, J. M.; CHAMBERS, C.; TORRADO, M. Remote sensing. *In*: KOBAYASHI, A. **International encyclopedia of human geography**. 2. ed. Amsterdã: Elsevier, 2020. p. 411-422. *E-book*. DOI: <http://dx.doi.org/10.1016/b978-0-08-102295-5.10589-x>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/B978008102295510589X?via%3Dihub>. Acesso em: 20 out. 2024.

RODRIGUES, H. S. M. de C.; CASTRO, S. S. de. A expansão da cana - de - açúcar e a aptidão agrícola das terras da microrregião do Vale do Rio dos Bois-GO. **Geografia**, Rio Claro, v. 43, n. 2, p. 237-253, maio/ ago. 2018. DOI: <http://dx.doi.org/10.5016/geografia.v43i2.13703>. Disponível em: <https://www.periodicos.rc.biblioteca.unesp.br/index.php/ageteo/article/view/13703/8682>. Acesso em: 20 out. 2024.

RODRIGUES, L. de S.; PEREIRA, D. R. Aprendizado de máquina aplicado em imagem NDVI para previsão da produtividade da cana - de - açúcar. **Colloquium Exactarum**, Presidente Prudente, v. 13, n. 4, p. 82-98, out./ dez. 2021. DOI: <http://dx.doi.org/10.5747/ce.2021.v13.n4.e378>. Disponível em: <https://journal.unoeste.br/index.php/ce/article/view/4023>. Acesso em: 20 out. 2024.

RUDORFF, B. F. T.; AGUIAR, D. A.; SILVA, W. F.; SUGAWARA, L. M.; ADAMI, M.; MOREIRA, M. A. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo State (Brazil) using Landsat data. **Remote sensing**, London, v. 2, n. 4, p. 1057-1076, Apr. 2010. DOI: <https://doi.org/10.3390/rs2041057>. Disponível em: <https://www.mdpi.com/2072-4292/2/4/1057>. Acesso em: 20 out. 2024.

SAINI, P.; NAGPAL B.; GARG, P.; KUMAR, S. Evaluation of remote sensing and meteorological parameters for yield prediction of sugarcane (*Saccharum officinarum* L.) crop. **Brazilian Archives of Biology and Technology**, Curitiba, v. 66, e23220781, p. 1- 15. 2023. DOI: <https://doi.org/10.1590/1678-4324-2023220781>. Disponível em:

<https://www.scielo.br/j/babt/a/hGcr4mCBhHbnL8bzwwBCbDt/?lang=en>. Acesso em: 20 out. 2024.

SANTOS, J. de B. G. dos; HACON, S. de S.; NEVES, S. M. A. da S. Índice de Vegetação por Diferença Normalizada (NDVI) e seu uso no estudo da saúde humana: uma revisão de escopo. **Revista Brasileira de Geografia Física**, Recife, v. 16, n. 3, p. 1115-1144, jun. 2023. DOI: <http://dx.doi.org/10.26848/rbgf.v16.3.p1115-1144>. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/255899>. Acesso em: 02 nov. 2024.

SANTOS, M. S. M. dos; MADALENA, J. A.; SOARES, L.; FERREIRA, P. V.; BARBOSA, G. V. S. Repetibilidade de características agroindustriais em cana - de - açúcar. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 39, n. 4, p. 301-306, abr. 2004. DOI: <http://dx.doi.org/10.1590/s0100-204x2004000400001>. Disponível em: <https://www.scielo.br/j/pab/a/cyFYybLwSfsHGx47VDnc43z/?format=pdf&lang=pt>. Acesso em: 02 nov. 2024.

SILVA, A. S. da; MOURA, G. B. de A.; LOPES, P. M. O.; GUIMARÃES, M. J. M.; BEZERRA, A. C.; GOMES, A. W. A. predição da produtividade de cana - de - açúcar com base em modelo agrometeorológico no semiárido brasileiro. **Nativa**, Sinop, v. 10, n. 4, p. 515-524, nov. 2022. DOI: <http://dx.doi.org/10.31413/nativa.v10i4.13773>. Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/nativa/article/view/13773>. Acesso em: 02 nov. 2024.

SILVA, N. R. de F. e; CHAVES, M. E. D.; LUCIANO, A. C. dos S.; SANCHES, I. D.; ALMEIDA, C. M. de; ADAMI, M. Sugarcane yield estimation using satellite remote sensing data in empirical or mechanistic modeling: a systematic review. **Remote Sensing**, London, v. 16, n. 5, e863, p. 1- 26, Feb. 2024. DOI: <http://dx.doi.org/10.3390/rs16050863>. Disponível em: <https://www.mdpi.com/2072-4292/16/5/863>. Acesso em: 02 nov. 2024.

SILVESTRE, N.G.; VIEIRA, G. H. S.; NASCIMENTO, D. P. Estimativa da melhor época de plantio e produtividade de cana - de - açúcar com o modelo agrometeorológico Aquacrop. **Revista Ifes Ciência**, Vitória, v. 5, n. 1, p. 197-207, 2019. DOI: <https://doi.org/10.36524/ric.v5i1.279>. Disponível em: <https://ojs.ifes.edu.br/index.php/ric/article/view/279/252>. Acesso em: 02 nov. 2024.

SIMÕES, M. dos S.; ROCHA, J. V.; LAMPARELLI, R. A. C. Growth indices Ans productivity in sugarcane. **Scientia Agrícola**, Piracicaba, v. 62, n. 1, p. 23-30, jan./ fev. 2005. DOI: <http://dx.doi.org/10.1590/s0103-90162005000100005>. Disponível em: <https://www.scielo.br/j/sa/a/ZwCtksGNMyKpydJTWypWpCb/?format=pdf&lang=en>. Acesso em: 02 nov. 2024.

SINGLA, S. K.; GARG, R. D.; DUBEY, O. P. Machine learning models to estimate the sugarcane brix values from multitemporal vegetation indices. *In: INTERNATIONAL CONFERENCE ON COMPUTATION, AUTOMATION AND KNOWLEDGE MANAGEMENT*, 2020, Dubai. **Anais [...]**. Dubai: IEEE, 2020. p. 177-183. DOI:

<http://dx.doi.org/10.1109/iccakm46823.2020.9051545>. Disponível em:  
<https://ieeexplore.ieee.org/document/9051545>. Acesso em: 02 nov. 2024.

SIQUEIRA, G. M.; SILVA, Ê. F. de F. e; DAFONTE, J. Distribuição espacial da condutividade elétrica do solo medida por indução eletromagnética e da produtividade de cana - de - açúcar. **Bragantia**, Campinas, v. 74, n. 2, p. 215-223, jun. 2015. DOI: <http://dx.doi.org/10.1590/1678-4499.0234>. Disponível em: <https://www.scielo.br/j/brag/a/hdmTGsnS3XPfSyG88jcVsDL/?format=pdf&lang=pt>. Acesso em: 02 nov. 2024.

SOARES, A. L.; AMARAL, L. de P.; AMADO, T. J. C. Índices de vegetação aplicados a diferentes doses de nitrogênio no período de 2016 a 2020: uma revisão. **Revista Multidisciplinar de Educação e Meio Ambiente**, Fortaleza, v. 2, n. 3, p. 23, 2021. DOI: <https://doi.org/10.51189/rema/1612>. Disponível em: <https://editoraime.com.br/revistas/index.php/rema/article/view/1612>. Acesso em: 16 nov. 2024.

SOM-ARD, J.; ATZBERGER, C.; IZQUIERDO-VERDIGUIER, E.; VUOLO, F.; IMMITZER, M. remote sensing applications in sugarcane cultivation: a review. **Remote Sensing**, London, v. 13, n. 20, e4040, p.1-46, Oct. 2021. DOI: <http://dx.doi.org/10.3390/rs13204040>. Disponível em: <https://www.mdpi.com/2072-4292/13/20/4040>. Acesso em: 16 nov. 2024.

SOUZA JR., C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A. reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, London, v. 12, n. 17, e2735, p.1-27, Aug. 2020. DOI: <http://dx.doi.org/10.3390/rs12172735>. Disponível em: <https://www.mdpi.com/2072-4292/12/17/2735>. Acesso em: 16 nov. 2024.

SCHULTZ, M; CLEVERS, J. G. P. W.; CARTER, S.; VERBESSELT, J.; AVITABILE, V.; QUANG, H. V.; HEROLD, M. Performance of vegetation indices from Landsat time series in deforestation monitoring. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdã, v. 52, p. 318-327, Oct. 2016. DOI: <http://dx.doi.org/10.1016/j.jag.2016.06.020>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0303243416301040?via%3Dihub>. Acesso em: 16 nov. 2024.

SHUKLA, S. K.; SHARMA, L.; AWASTHI, S. K.; PATHAK, A. D. **Sugarcane in India: package of practices for different agro-climatic zones**. Lucknow: ICAR-Indian Institute of Sugarcane Research, 2017. (AICRP (S) Technical Bulletin, 1). Disponível em: [https://iisr.icar.gov.in/iisr/aicrp/download/Sugarcane\\_in\\_India.pdf](https://iisr.icar.gov.in/iisr/aicrp/download/Sugarcane_in_India.pdf). Acesso em: 12 nov. 2024.

SUKYAI, P.; YINGKAMHAENG, N.; LAM, N. T.; TANGSATIANPAN, V.; WATCHARINRAT, C.; VANIJINDA, G.; VANICHSRISATANA, W ; SRIROTH, K. Research and development prospects for sugarcane and sugar industry in Thailand. **Sugar Tech**, London, v. 18, p. 583-587, nov. 2016. DOI: <https://doi.org/10.1007/s12355-016-0495-1>. Disponível em: <https://link.springer.com/article/10.1007/s12355-016-0495-1>. Acesso em: 16 nov. 2024.

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**, Amsterdã, v.180, e105903, p.1- 19, Jan. 2021. DOI: <http://dx.doi.org/10.1016/j.compag.2020.105903>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169920331082?via%3Dihub>. Acesso em: 16 Nov. 2024.

SUWANLEE, S. R.; PINASU, D.; SOM-ARD, J.; BORGOGNO-MONDINO, E.; SARVIA, F. Estimating sugarcane aboveground biomass and carbon stock using the combined time series of sentinel data with machine learning algorithms. **Remote Sensing**, London, v. 16, n. 5, e750, p. 1-22, Feb. 2024. DOI: <http://dx.doi.org/10.3390/rs16050750>. Disponível em: <https://www.mdpi.com/2072-4292/16/5/750>. Acesso em: 16 Nov. 2024.

TAUBINGER, L.; AMARAL, L. R. do; MOLIN, J. P. Vegetation indices from active crop canopy sensor and their potential interference factors on sugarcane. *In*: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 11., 2012. Indianapolis USA. **Anais [...]**. Indianapolis USA, 2012. p. 1-13. Disponível: [https://www.agriculturadeprecisao.org.br/wp-content/uploads/2020/01/cgr-2012\\_13.pdf](https://www.agriculturadeprecisao.org.br/wp-content/uploads/2020/01/cgr-2012_13.pdf). Acesso em: 30 nov. 2024.

UNIÃO NACIONAL DA BIOENERGIA (UDOP). **Cana**: pesquisa aponta que áreas de cultivo poderão crescer 45% até 2030. Araçatuba: UDOP, 2021. Disponível em: <https://www.udop.com.br/noticia/2021/07/08/cana-pesquisa-aponta-que-areas-de-cultivo-poderao-crescer-45-ate-2030.html>. Acesso em: 19 out. 2024.

VASCONCELOS, J. C. S.; SPERANZA, E. A.; ANTUNES, J. F. G.; BARBOSA, L. A. F.; CHRISTOFOLETTI, D.; SEVERINO, F. J.; CANÇADO, G. M. de A. Development and validation of a model based on vegetation indices for the prediction of sugarcane yield. **Agriengineering**, London, v. 5, n. 2, p. 698-719, Apr. 2023. DOI: <http://dx.doi.org/10.3390/agriengineering5020044>. Disponível em: <https://www.mdpi.com/2624-7402/5/2/44>. Acesso em: 30 Nov. 2024.

XUE, J.; SU, B. Significant remote sensing vegetation indices: a review of developments and applications. **Journal of Sensors**, Nova Jersey, v. 2017, p. 1-17, May, 2017. DOI: <http://dx.doi.org/10.1155/2017/1353691>. Disponível em: <https://onlinelibrary.wiley.com/doi/epdf/10.1155/2017/1353691>. Acesso em: 30 nov. 2024.

ZHU, L.; LIU, X.; WANG, Z.; TIAN, L. High-precision sugarcane yield prediction by integrating 10-m Sentinel-1 VOD and Sentinel-2 GRVI indexes. **European Journal of Agronomy**, Amsterdã, v. 149, e126889, p. 1-15, Sep. 2023. DOI: <http://dx.doi.org/10.1016/j.eja.2023.126889>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1161030123001570?via%3Dihub>. Acesso em: 30 Nov. 2024.

WU, B.; MIAO Z.; HOGWEI Z.; FUYOU T.; ANDRIES B. P.; XINGLI Q.; NANA Y. Challenges and opportunities in remote sensing-based crop monitoring: A

review. **National Science Review**, Oxford, v. 10, n. 4, enwac290, p. 1-17, Apr. 2023.  
DOI: <https://doi.org/10.1093/nsr/nwac290>. Disponível em:  
<https://academic.oup.com/nsr/article/10/4/nwac290/6939854>. Acesso em: 30 nov.  
2024.

## APÊNDICES

### APÊNDICE A – Características químicas do solo nas áreas de estudo

Quanto à fertilidade nas áreas do Novo Mundo de 2º e 3º ano para a camada superficial (0 - 0,20 m) apresenta: pH (H<sub>2</sub>O) = 5,93; P-resina = 21,35 mg; K = 2,58 cmolc dm<sup>-3</sup>; Ca = 29,10 cmolc dm<sup>-3</sup>; Mg = 9,35 cmolc dm<sup>-3</sup>; S = 5,51 mg dm<sup>-3</sup>; Acidez potencial (H+Al) = 18,02 cmolc dm<sup>-3</sup>; CTC (pH 7,0) = 59,05 cmolc dm<sup>-3</sup>; matéria orgânica (MOS) = 19,93dag kg<sup>-1</sup> e V% = 68,79. Em relação aos micronutrientes, teores de B = 0,61 mg dm<sup>-3</sup>; Cu = 1,40 mg dm<sup>-3</sup>; Fe = 13,07mg dm<sup>-3</sup>; Mn = 3,64 mg dm<sup>-3</sup> e Zn = 0,40 mg dm<sup>-3</sup> foram encontrados.

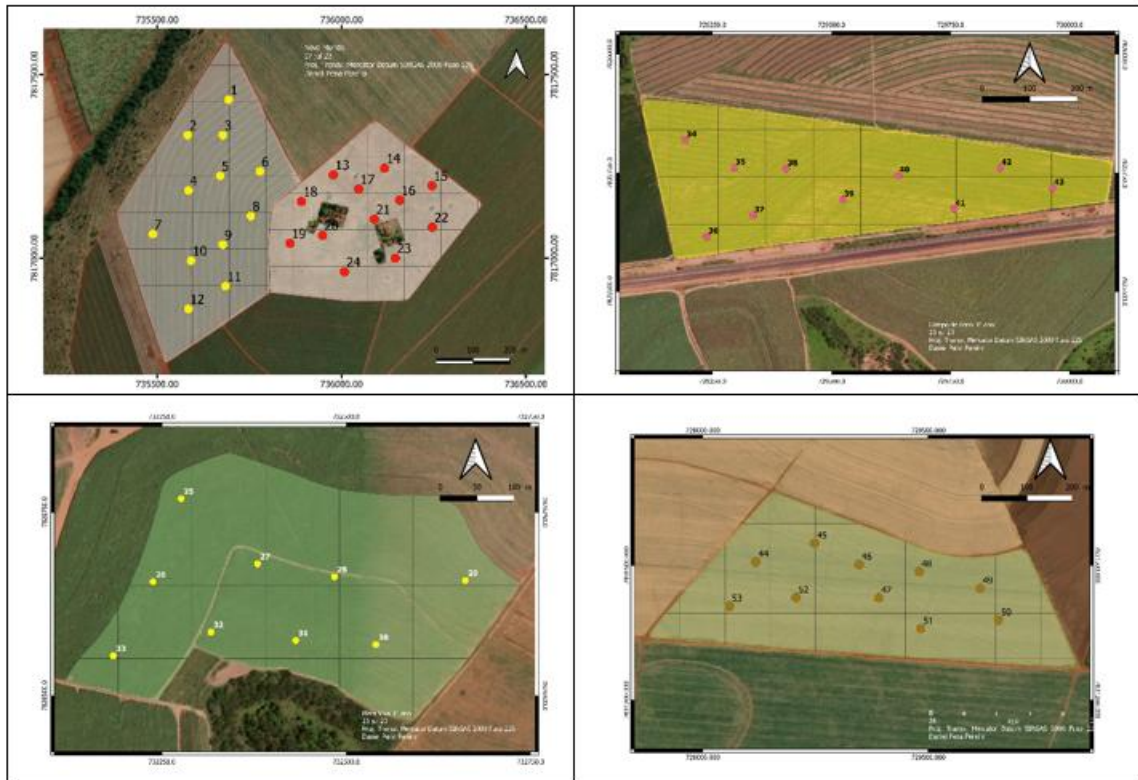
Quanto à fertilidade nas áreas do Mata Viva 3º ano para a camada superficial (0 - 0,20 m) apresenta: pH (H<sub>2</sub>O) = 4,57; Presina = 12,54 mg dm<sup>-3</sup>; K = 0,73 cmolc dm<sup>-3</sup>; Ca = 13,67 cmolc dm<sup>-3</sup>; Mg = 2,87 cmolc dm<sup>-3</sup>; S = 4,73 mg dm<sup>-3</sup>; Al = 4,67 cmolc dm<sup>-3</sup>; Acidez potencial (H+Al) = 25,97 cmolc dm<sup>-3</sup> ; CTC (pH 7,0) = 43,23 cmolc dm<sup>-3</sup>; matéria orgânica (MOS) = 13,67dag kg<sup>-1</sup> e V% = 68,79. Em relação aos micronutrientes, teores de B = 0,53 mg dm<sup>-3</sup>; Cu = 0,56 mg dm<sup>-3</sup>; Fe = 41,00 mg dm<sup>-3</sup>; Mn = 9,27 mg dm<sup>-3</sup> e Zn = 0,66 mg dm<sup>-3</sup> foram encontrados.

Quanto à fertilidade nas áreas do Campo de Feno 3º ano para a camada superficial (0 - 0,20 m) apresenta: pH (H<sub>2</sub>O) = 5,93; Presina = 21,35 mg dm<sup>-3</sup>; K = 2,58 cmolc dm<sup>-3</sup>; Ca = 29,10 cmolc dm<sup>-3</sup> ; Mg = 9,35 cmolc dm<sup>-3</sup>; S = 5,51 mg dm<sup>-3</sup>; Acidez potencial (H+Al) = 18,02 cmolc dm<sup>-3</sup>; CTC (pH 7,0) = 59,05 cmolc dm<sup>-3</sup>; matéria orgânica (MOS) = 19,93dag kg<sup>-1</sup> e V% = 68,79. Em relação aos micronutrientes, teores de B = 0,61 mg dm<sup>-3</sup>; Cu = 1,40 mg dm<sup>-3</sup>; Fe = 13,07mg dm<sup>-3</sup>; Mn = 3,64 mg dm<sup>-3</sup> e Zn = 0,40 mg dm<sup>-3</sup> foram encontrados.

Quanto à fertilidade nas áreas do Bernau 2º ano para a camada superficial (0 - 0,20 m) apresenta: pH (H<sub>2</sub>O) = 5,80; Presina = 39,67 mg dm<sup>-3</sup>; K = 1,27 cmolc dm<sup>-3</sup>; Ca = 34,07 cmolc dm<sup>-3</sup>; Mg = 7,28 cmolc dm<sup>-3</sup>; S = 4,44 mg dm<sup>-3</sup>; Acidez potencial (H+Al) = 12,09 cmolc dm<sup>-3</sup>; CTC (pH 7,0) = 54,70 cmolc dm<sup>-3</sup>; matéria orgânica (MOS) = 17,44

dag kg<sup>-1</sup> e V% = 77.92. Em relação aos micronutrientes, teores de B = 0,33 mg dm<sup>-3</sup> ; Cu = 0,79 mg dm<sup>-3</sup>; Fe = 22,17 mg dm<sup>-3</sup>; Mn = 1,87 mg dm<sup>-3</sup> e Zn = 1,88 mg dm<sup>-3</sup> foram encontrados.

**APÊNDICE B – Figuras das áreas de estudos e respectivas grades amostrais aleatórias estratificadas.**



## APÊNDICE C - Tabelas dos resultados das análises de regressões múltiplas

### 1) TCH\_L - Fase Planejamento de safra

	Coeficientes	Erro Padrão	t-valor	p-valor
(intercepto)	-154.25	46.04	-3.35	0.00158**
NDVI	307.05	57.83	5.31	2.79e-06***

Códigos de significância: 0 '\*\*\*' 0.01 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Erro padrão residual: 18,48 com 48 graus de liberdade; R-quadrado múltiplo: 0,37; R-quadrado ajustado: 0,3569; Estatística F: 28,19 com 1 e 48 graus de liberdade; e valor p: 2.786e-06.

### PRESSUPOSTOS

ASSESSMENT OF THE LINEAR MODEL ASSUMPTIONS


USING THE GLOBAL TEST ON 4 DEGREES-OF-FREEDOM:

Level of Significance = 0.05

Call:

gvlma(x = modelo)

	Value	p-value	Decision
Global Stat	3.036e+00	0.5517	Assumptions acceptable.
Skewness	2.979e-05	0.9956	Assumptions acceptable.
Kurtosis	4.874e-01	0.4851	Assumptions acceptable.
Link Function	1.039e-02	0.9188	Assumptions acceptable.
Heteroscedasticity	2.539e+00	0.1111	Assumptions acceptable.



Durbin-Watson test

data: modelo TCH\_L ~ NDVI

DW = 1.9614, p-value = 0.4053

alternative hypothesis: true autocorrelation is greater than 0

## CROSS VALIDATION

Resampling: Cross-Validated (10-fold)

Summary of sample sizes: 45, 45, 45, 46, 45, 46, ...

Resampling results:

RMSE	MAPE	R2
18.23512	18.50245	0.5484257

## 2) TCH\_L - Fase Pré - Corte 30 dias

	Coeficientes	Erro Padrão	t-valor	p-valor
(intercepto)	-78.17	32.54	-2.402	0.0202*
NDVI	258.63	44.05	5.872	3.93e-07***

Códigos de significância: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 '' 1

Erro padrão residual: 25,04 com 48 graus de liberdade; R-quadrado múltiplo: 0,418; R-quadrado ajustado: 0,4059; Estatística F: 34,48 com 1 e 48 graus de liberdade; e valor p: 3.933e-07.

## PRESUPOSTOS

### ASSESSMENT OF THE LINEAR MODEL ASSUMPTIONS


USING THE GLOBAL TEST ON 4 DEGREES-OF-FREEDOM:

Level of Significance = 0.05

Call:

```
gvlma(x = modelo)
```

	Value	p-value	Decision
Global Stat	3.47995	0.4809	Assumptions acceptable.
Skewness	1.32576	0.2496	Assumptions acceptable.
Kurtosis	0.09708	0.7554	Assumptions acceptable.
Link Function	1.35189	0.2449	Assumptions acceptable.
Heteroscedasticity	0.70522	0.4010	Assumptions acceptable.



Durbin-Watson test

data: modelo TCH\_L ~ NDVI

DW = 1.6677, p-value = 0.09545

alternative hypothesis: true autocorrelation is greater than 0

## CROSS VALIDATION

No pre-processing

Resampling: Cross-Validated (10 fold)

Summary of sample sizes: 46, 45, 45, 46, 44, 46, ...

Resampling results:

RMSE MAPE R2  
23.76393 19.32907 0.473841

### 3) TCH - Fase Planejamento de safra

	Coeficientes	Erro Padrão	t-valor	p-valor
(intercepto)	-207.84	53.61	-3.877	0.000321***
NDVI	400.96	67.33	5.955	2,94e-07***

Códigos de significância: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Erro padrão residual: 21,51 com 48 graus de liberdade; R-quadrado múltiplo: 0,4249; R-quadrado ajustado: 0,4129; Estatística F: 35,46 com 1 e 48 graus de liberdade; e valor p: 2,936e-07.

### PRESSUPOSTOS

ASSESSMENT OF THE LINEAR MODEL ASSUMPTIONS


USING THE GLOBAL TEST ON 4 DEGREES-OF-FREEDOM:

Level of Significance = 0.05

Call:

gvlma(x = modelo)

	Value	p-value	Decision
Global Stat	4.5184	0.34037	Assumptions acceptable.
Skewness	0.8912	0.34516	Assumptions acceptable.
Kurtosis	0.2637	0.60757	Assumptions acceptable.
Link Function	0.1111 0.73895		Assumptions acceptable.
Heteroscedasticity	3.2524	0.07132	Assumptions acceptable.



Durbin-Watson test, INDEPENDÊNCIA

data: modelo TCH ~ NDVI

DW = 1.8983, p-value = 0.3208

alternative hypothesis: true autocorrelation is greater than 0

### CROSS VALIDATION

Resampling: Cross-Validated (10 fold)

Summary of sample sizes: 46, 45, 45, 46, 44, 46, ...

Resampling results:

RMSE	MAPE	R2
20.64398	18.17491	0.6033798

#### 4) TCH - Fase Pré-Corte 30 dias

	Coeficientes	Erro Padrão	t-valor	p-valor
(intercepto)	-113.96	39.77	-2.866	0.00616**
NDVI	343.32	53.83	6.378	6.61e-08***

Códigos de significância: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Erro padrão residual: 30,6 com 48 graus de liberdade; R-quadrado múltiplo: 0,4587; R-quadrado ajustado: 0,4475; Estatística F: 40,68 com 1 e 48 graus de liberdade; e valor p: 6,615e-08

## PRESUPOSTOS

### ASSESSMENT OF THE LINEAR MODEL ASSUMPTIONS

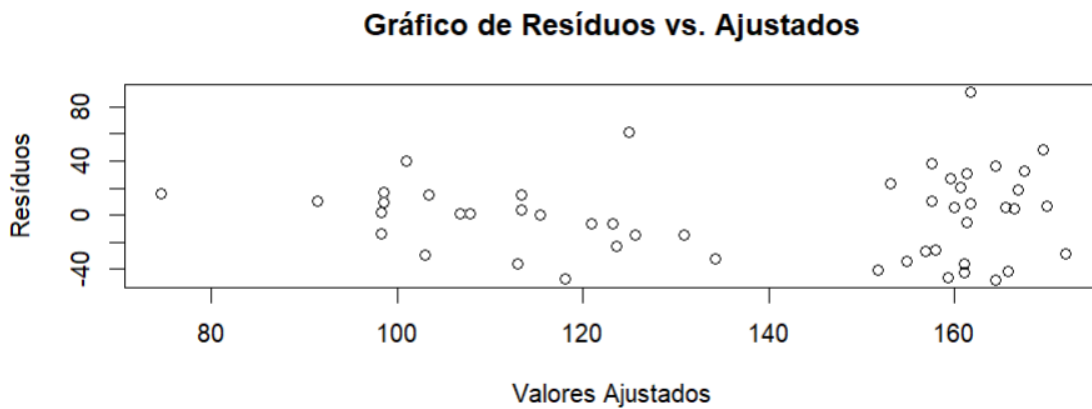
USING THE GLOBAL TEST ON 4 DEGREES-OF-FREEDOM:

Level of Significance = 0.05

Call:

```
gvlma(x = modelo)
```

	Value	p-value	Decision
Global Stat	5.14943	0.2723	Assumptions acceptable.
Skewness	1.58696	0.2078	Assumptions acceptable.
Kurtosis	0.07842	0.7794	Assumptions acceptable.
Link Function	2.01991	0.1552	Assumptions acceptable.
Heteroscedasticity	1.46415	0.2263	Assumptions acceptable.



Durbin-Watson test

data: modelo TCH ~ NDVI

DW = 1.6404, p-value = 0.07958

alternative hypothesis: true autocorrelation is greater than 0

## CROSS VALIDATION

Resampling: Cross-Validated (10-fold)

Summary of sample sizes: 46, 45, 45, 46, 44, 46, ...

Resampling results:

RMSE    MAPE    R2  
24.99181 20.20038 0.4010836

### 5) ATR - Fase Planejamento de safra

	Coeficientes	Erro Padrão	t-valor	p-valor
(intercepto)	233.31	23.85	9.781	8.37e-12 ***
NDVI	-85.16	29.85	-2.853	0.00706 **

Códigos de significância: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Erro padrão residual: 7,504 com 48 graus de liberdade; R-quadrado múltiplo: 0,1803; R-quadrado ajustado: 0,1581; Estatística F: 14.8 com 1 e 48 graus de liberdade; e valor p: 0,007056.

## PRESSUPOSTOS

ASSESSMENT OF THE LINEAR MODEL ASSUMPTIONS


USING THE GLOBAL TEST ON 4 DEGREES-OF-FREEDOM:

Level of Significance = 0.05

Call:

gvlma(x = modelo)

	Value	p-value	Decision
Global Stat	1.943336	0.7462	Assumptions acceptable.
Skewness	0.003986	0.9497	Assumptions acceptable.
Kurtosis	1.335864	0.2478	Assumptions acceptable.
Link Function	0.549779	0.4584	Assumptions acceptable.
Heteroscedasticity	0.053707 0.8167		Assumptions acceptable.



Durbin-Watson test

data: modelo ATR ~ NDVI

DW = 1.998, p-value = 0.4549

alternative hypothesis: true autocorrelation is greater than 0

## CROSS VALIDATION

Linear Regression

39 samples

1 predictor

No pre-processing

Resampling: Cross-Validated (10 fold)

Summary of sample sizes: 36, 35, 35, 35, 35, 35, ...

Resampling results:

RMSE	MAPE	R2
7.339399	3.840892	0.5503083

### 6) ATR - Fase Pré-Corte 30 dias

	Coeficientes	Erro Padrão	t-valor	p-valor
(intercepto)	208.36	18.12	11.500	7.56e-15 ***

NDRE	145.57	64.21	2.267	0.0284 *
NDVI	-163.85	68.26	-2.400	0.0207 *

Códigos de significância: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 '.' 1

Erro padrão residual: 7,496 com 44 graus de liberdade; R-quadrado múltiplo: 0,1189; R-quadrado ajustado: 0,07889; Estatística F: 2,97 com 1 e 44 graus de liberdade; e valor p: 0,06168.

## PRESSUPOSTOS

### ASSESSMENT OF THE LINEAR MODEL ASSUMPTIONS


#### USING THE GLOBAL TEST ON 4 DEGREES-OF-FREEDOM:

Level of Significance = 0.05

Call:

```
gvlma(x = modelo)
```

	Value	p-value	Decision
Global Stat	3.6565	0.4545	Assumptions acceptable.
Skewness	0.5333	0.4652	Assumptions acceptable.
Kurtosis	0.1430	0.7053	Assumptions acceptable.
Link Function	2.4397	0.1183	Assumptions acceptable.
Heteroscedasticity	0.5405	0.4622	Assumptions acceptable.



Durbin-Watson test

data: modelo ATR ~ NDRE+NDVI

DW = 1.8938, p-value = 0.283

alternative hypothesis: true autocorrelation is greater than 0

## **CROSS VALIDATION**

No pre-processing

Resampling: Cross-Validated (10 fold)

Summary of sample sizes: 42, 42, 42, 43, 42, 44, ...

Resampling results:

RMSE	MAPE	R2
7.188855	3.608105	0.5038757