

**Universidade de São Paulo  
Escola Superior de Agricultura “Luiz de Queiroz”**

**Uso de sensoriamento remoto para aplicações de agricultura digital em  
cana-de-açúcar**

**Daniel Garbellini Duft**

Tese apresentada para obtenção do título de Doutor em  
Ciências. Área de concentração: Engenharia de  
Sistemas Agrícolas

**Piracicaba  
2022**

**Daniel Garbellini Duft**  
**Engenheiro Agrícola**

**Uso de sensoriamento remoto para aplicações de agricultura digital em cana-de-  
açúcar**

versão revisada de acordo com a Resolução CoPGr 6018 de 2011

Orientador:  
Prof. Dr. **PETERSON RICARDO FIORIO**

Tese apresentada para obtenção do título de Doutor em  
Ciências. Área de concentração: Engenharia de  
Sistemas Agrícolas

**Piracicaba**  
**2022**

**Dados Internacionais de Catalogação na Publicação**  
**DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP**

Duft, Daniel Garbellini

Uso de sensoriamento remoto para aplicações de agricultura digital em cana-de-açúcar / Daniel Garbellini Duft. - - versão revisada de acordo com a Resolução CoPGr 6018 de 2011. - - Piracicaba, 2022.

69 p.

Tese (Doutorado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Variáveis agrometeorológicas 2. Zoneamento 3. Índice de vegetação 3. Cultivares 4. Random forest 5. Imagem de satélite I. Título

## **DEDICATÓRIA**

Dedico esta Tese aos meus pais, Solange e Roberto que sempre apostaram na educação como força transformadora e fizeram de tudo para que eu tivesse a oportunidade de chegar nessa etapa da minha vida.

Também a minha esposa Ana Paula pelo cuidado e carinho e paciência durante a elaboração desta.

## AGRADECIMENTOS

Ao orientador e amigo, Prof. Dr. Peterson Ricardo Fiorio, pela competência e respeito com que conduziu este processo, do alvorecer da ideia, até a sua síntese.

Aos Professores Dr. Jansle Vieira Rocha e Dr. Leandro Maria Gimenez e Dr<sup>a</sup> Erica Silva Nakai pelas valiosas contribuições no Exame de Qualificação.

Aos meus colegas de laboratório que ajudaram de alguma forma durante todo esse tempo, Pedro, Luiz, Michaela e Natalia.

A Davilmar Colevatti por todo o apoio na Secretaria de Pós-graduação durante os momentos mais complicados.

Ao Centro de Tecnologia Canavieira (CTC) que sempre apoiou minha jornada e em especial ao meu gerente Mauro Henrique Salgueiro Rodrigues Violante, que acreditou e apoiou cada etapa do processo.

Aos dados em grade da NASA que foram obtidos do Projeto POWER do NASA Langley Research Center (LaRC), financiado pelo Programa de Ciências da Terra/Ciências Aplicadas da NASA.

***É durante os nossos momentos mais escuros que temos de nos concentrar para vermos a luz.***

*Aristóteles*

## SUMÁRIO

RESUMO.....	8
ABSTRACT.....	9
LISTA DE FIGURAS.....	10
LISTA DE TABELAS.....	12
1. INTRODUÇÃO.....	13
1.1. Objetivos.....	16
Referências.....	16
2. REVISÃO DA LITERATURA.....	19
2.1 Agricultura digital.....	19
2.2 Cana-de-açúcar.....	20
2.2.1 Fisiologia.....	20
2.2.2 Produção.....	23
2.2.3 Sensoriamento remoto na cana-de-açúcar.....	25
2.3 Técnicas de classificação e aprendizado de máquina.....	26
2.4 Estimativa de produtividade.....	30
2.5 Monitoramento da disponibilidade de nutrientes.....	31
2.6 Monitoramento de doenças.....	31
2.7 Monitoramento de anomalias.....	32
2.8 Discussão.....	32
Referências.....	33
3. REGIONALIZAÇÃO DAS ÁREAS PRODUTORAS DE CANA-DE-AÇÚCAR NO CENTRO-SUL DO BRASIL ATRAVÉS DE ZONEAMENTO AGROCLIMÁTICO E COMPORTAMENTO DE ÍNDICE DE VEGETAÇÃO.....	39
Resumo.....	39
Abstract.....	39
3.1. Introdução.....	39
3.2. Materiais e Métodos.....	40
3.3. Resultados e Discussão.....	45
3.4. Conclusão.....	52
Referências.....	53

4. POTENCIAL DO ALGORITMO RANDOM FOREST PARA SEPARAÇÃO DE CARACTERÍSTICAS MORFOLÓGICAS DE CANA-DE-AÇÚCAR ATRAVÉS DE IMAGENS DO SATÉLITE SENTINEL-2.....	55
Resumo.....	55
Abstract.....	55
4.1 Introdução.....	55
4.2 Revisão Bibliográfica.....	57
4.3 Metodologia.....	60
4.3.1 Área de estudo.....	60
4.3.2 Imagens de satélite.....	61
4.3.3 Modelagem estatística.....	62
4.3.4 Aplicação do modelo.....	63
4.4 Resultados e Discussão.....	64
4.5 Conclusão.....	66
Referências.....	67



## RESUMO

### Uso de sensoriamento remoto para aplicações de agricultura digital em cana-de-açúcar

A agricultura digital é uma abordagem multidisciplinar que diz respeito ao uso de informações digitais detalhadas para orientar a tomada de decisão ao longo da cadeia agrícola. Seu uso é cada vez mais necessário e deve trazer muitos benefícios para a segurança alimentar e energética nos próximos anos. O grande ponto é a aquisição de dados de maneira contínua para gerar informações e guiar processos. Como a agricultura, principalmente no Brasil, é feita em grandes escalas de área e por conta disso, a aquisição de dados com o uso de sensores na propriedade é dificultada, o sensoriamento remoto aparece como uma ferramenta importante para a obtenção de dados e validação de operações. O sensoriamento remoto é utilizado de forma contínua desde a década de 80, porém tem ganhado mais força com o aparecimento da computação de alta performance e com o barateamento dela. Embora em algumas culturas estejam bastante desenvolvidas no uso de sensoriamento remoto para geração de informações, a cana-de-açúcar ainda possui poucos trabalhos e em escala local. A cana-de-açúcar é a principal cultura para a produção de açúcar e etanol no Brasil. O país é responsável por mais da metade da produção mundial dessa planta e hoje ela é cultivada no Nordeste e na região Centro-Sul. Devido à extensa área de cultivo, existem diversas condições edafoclimáticas em que a cultura da cana-de-açúcar se desenvolve e desta forma, separar essas regiões é extremamente importante para poder aplicar modelos em escala homogênea. Além disso, fazer uma separação morfológica dos canaviais é importante para não gerar modelos sem essa variável e conseqüentemente trazer incertezas ao processo. No intuito de criar regiões homogêneas foi feito um trabalho de zoneamento e regionalização levando-se em conta as variáveis agrometeorológicas, solo e produtividade histórica da cana planta. Criou-se três regiões de alto, médio e baixo potencial de produção de cana para o Centro-Sul do país. Em seguida, avaliando-se o comportamento histórico de índices de vegetação da área de estudo, fez-se uma regionalização levando em conta o potencial de produção e o comportamento do índice de vegetação. Foram propostas dezessete regiões com comportamento homogêneo para aplicações de modelos baseados em sensoriamento remoto. Outra abordagem foi identificar características morfológicas da cana-de-açúcar que podem levar a falhas em modelagens de áreas contínuas. Para isso, foi utilizado o modelo *Random Forest* e imagens do satélite Sentinel-2 para criar um modelo que identifica diferentes cultivares. O modelo teve uma precisão global de 86% e índice kappa de 81%. Quando aplicado para 4 cultivares em uma região maior, apresentou a precisão variando de 91% a 96%. Desta forma, foi possível concluir que modelos se adaptam com a mesma precisão que o conjunto de treino, se a região de aplicação é homogênea em relação a solo, clima e manejo. Além disso, o trabalho é base para futuras aplicações em agricultura digital para a cultura da cana-de-açúcar que precisem gerar modelos para a região Centro-Sul.

Palavras-chave: Variáveis agrometeorológicas, Zoneamento, Índice de vegetação, Cultivares, Random forest, Imagem de satélite

## ABSTRACT

### **Remote sensing as a tool for digital agriculture usage in sugarcane**

Digital agriculture is a multidisciplinary approach that concerns the use of detailed digital information to guide decision making along the agricultural chain. Its use is increasingly and should bring many benefits to food and energy security in the next years. The big point is the data acquisition in a continuous way to generate information and guide processes. As agriculture, mainly in Brazil, is carried out on large scales of area and because of this, the acquisition of data with the use of sensors on the farm level is difficult, remote sensing appears as an important tool for obtaining data and validating field operations. Remote sensing has been used continuously since the 1980s, but it has gained more strength with the emergence of high-performance computing and its low-price tendency. Although in some cultures they are quite developed in the use of remote sensing to generate information, sugarcane still has few works and on a local scale. Sugarcane is the main crop to produce sugar and ethanol in Brazil. The country is responsible for more than half of the world production of this plant and today it is cultivated in the Northeast and in the Center-South region. Due to the extensive cultivation area, there are several edaphoclimatic conditions in which the sugarcane crop develops and, therefore, separating these regions is extremely important to be able to apply models on a homogeneous scale. In addition, making a morphological separation of the sugarcane fields is important not just to generate models without this variable and consequently bring uncertainties to the process. To create homogeneous regions, a zoning and regionalization work was carried out, considering the agrometeorological variables, soil and historical productivity of sugarcane first stage. Three regions of high, medium and low potential for sugarcane production were created for the Center-South of the country. Then, evaluating the historical behavior of vegetation indices in the study area, a regionalization was carried out taking into account the production potential and the behavior of the vegetation index. Seventeen regions with homogeneous behavior were proposed for application of models based on remote sensing. Another approach was to identify morphological characteristics of sugarcane that can lead to failures in continuous area modeling. For this, the Random Forest model and Sentinel-2 satellite images were used to create a model that identifies different cultivars. The model had an overall accuracy of 86% and a kappa index of 81%. When applied to 4 cultivars in a larger region, the accuracy ranged from 91% to 96%. In this way, it was possible to conclude that models adapt with the same precision as the training set, if the application region is homogeneous in relation to soil, climate, and management. In addition, the work is the basis for future applications in digital agriculture for the cultivation of sugarcane that need to generate models for the Center-South region.

**Keywords:** Agrometeorological variables, Zoning, Vegetation index, Cultivars, Random forest, Satellite image

## LISTA DE FIGURAS

Figura 1: Estádios vegetativos da cana-de-açúcar para cana planta e cana soca.....	21
Figura 2: Produção e produtividade de cana-de-açúcar no Brasil.....	24
Figura 3: Complexidade das análises à esquerda e variáveis agronômicas de interesse à direita.....	26
Figura 4: Área de estudo do trabalho.....	41
Figura 5: CAD calculada para cada ponto do estudo. Nos pontos sem a presença de cana, adotou-se uma CAD fixa de 75mm.....	42
Figura 6: Fluxograma de operações de mapas para obtenção do potencial de produção regional.....	44
Figura 7: Perdas de produção percentuais por classes divididas por desvio padrão.....	46
Figura 8: Mapa de produtividade de cana-de-açúcar em estágio cana planta segmentado em classes por um desvio padrão.....	47
Figura 9: Mapa de zoneamento de produção com os mesmos pesos e divididos em classes com um desvio padrão.....	48
Figura 10: Mapa de zoneamento de produção com os pesos de 0,75 para o déficit de evapotranspiração e 0,25 para a produtividade da cana planta e dividido em classes com um desvio padrão.....	49
Figura 11: Distribuição mensal das médias de índices de vegetação EVI por região proposta.....	51
Figura 12: Mapa das 17 regionais propostas pelo estudo.....	52
Figura 13: Área de treino do modelo.....	61
Figura 14. Área de aplicação do modelo.....	63
Figura 15: Identificação visual de variedades através de descritores morfológicos em campo.....	64
Figura 16. Avaliação dos modelos.....	65

Figura 17: Importância de cada fator para o modelo (Gini).....	65
Figura 18. Precisão por classes (13/8/19).....	66

**LISTA DE TABELAS**

Tabela 1. Condições necessárias ao desenvolvimento da cana-de-açúcar.....	23
Tabela 2. Área de cana atual nas zonas de produção propostas.....	49
Tabela 3. Comprimentos de onda das bandas do Sentinel-2B.....	62
Tabela 4. Índices de vegetação.....	62
Tabela 5. Precisão das avaliações em campo.....	66

## 1. INTRODUÇÃO

O uso de sensoriamento remoto por satélite é uma abordagem importante na agricultura para monitorar as condições das plantas e do solo e subsidiar suporte à tomada de decisão dos agricultores. Nos últimos anos, vários tipos de ferramentas e índices por imagens de satélite foram desenvolvidos para monitorar o estresse hídrico, mudanças no uso da terra e relações hídricas entre a cultura e o solo. Embora essas técnicas sejam ferramentas poderosas, especialmente em países e regiões em desenvolvimento onde dados precisos de produtividade e estatísticas para avaliação de safras não são acessíveis, ainda existe bastante desenvolvimento que precisa ser feito (JINDO; KOZAN; ISEKI, 2021).

Como as lavouras de cana-de-açúcar fornecem colmos de cana matéria-prima para a produção de açúcar e biocombustível (etanol). É fundamental analisar a fenologia e produção primária bruta das lavouras de cana-de-açúcar, o que ajudaria a entender melhor e monitorar a condição de cultivo da cana-de-açúcar e o ciclo do carbono acumulado (DUFT *et al.*, 2013).

Dessa forma, a fenotipagem de alto rendimento tem atraído grande atenção nos últimos anos, levando a o desenvolvimento de vários novos protocolos para registrar várias características de plantas de interesse. Fenotipagem de plantas para reprodução e para agricultura de precisão têm requisitos diferentes devido aos diferentes tamanhos das parcelas e campos, as diferentes finalidades e a urgência da ação necessária após a fenotipagem. Enquanto no melhoramento de plantas a fenotipagem é feita em vários milhares de pequenas parcelas principalmente para avaliar para várias características, no cultivo de plantas, a fenotipagem é feita em grandes campos para detectar ocorrência de estresses de plantas e ervas daninhas em um estágio inicial (CHAWADE *et al.*, 2019).

Muitos algoritmos para balanço de energia de superfície baseados em sensoriamento remoto foram desenvolvidos para determinar a evapotranspiração. Esses algoritmos foram desenvolvidos para condições específicas (por exemplo, sensores, uso e manejo de culturas) em que funções e parâmetros empíricos dentro de seus algoritmos concordam com aquelas condições (ALVES *et al.*, 2020). Ainda assim, vê-se que a integração entre modelos espectrais e variáveis agrometeorológicas é pouco explorada na literatura.

A estimativa confiável da produtividade das culturas regionalmente é um componente vital da avaliação da segurança alimentar, especialmente em regiões em desenvolvimento e os métodos tradicionais de previsão de safras precisam de tempo e mão de obra para coletar e processar dados de campo e para liberar relatórios oficiais de produção. Os dados de sensoriamento remoto por satélite são considerados uma solução alternativa que trazem

economia e precisão ao prever o rendimento da colheita em nível de pixel. Neste contexto, as imagens de radar de abertura sintética (SAR) de domínio público, particularmente do Sentinel-1, ampliaram as possibilidades do monitoramento diurno e noturno da vegetação, mesmo quando a cobertura de nuvens limita a visão óptica observação da Terra. No entanto, é um desafio combinar imagens SAR adquiridas em diferentes ângulos de incidência e das órbitas ascendentes e descendentes devido à dependência de calibração do retroespalhamento e da incidência angular (ORÉ, *et al.*, 2022).

A maioria dos estudos de sensoriamento remoto tem usado imagens de satélite para prever a produtividade da cana-de-açúcar, mas esses tiveram sucesso relativo. Até o momento, os estudos que investigam a previsão da produtividade da cana usando imagens de satélite foram limitados em seu escopo; muitas vezes apenas detectando forte correlações entre imagens de satélite e produção de cana ao considerar produtividade e imagens de média resolução espacial em grandes regiões (DUVEILLER; LÓPEZ-LOZANO; BARUTH, 2013). Alta precisão para previsões de produção de cana com sensores de campo também foram relatadas por Rahman e Robson (2020) ao usar séries temporais de índices de vegetação derivados de imagens multiespectrais de satélite (por exemplo, Sentinel-2 e Landsat-8). No entanto, outros estudos encontraram apenas correlações limitadas entre dados multiespectrais de satélite e a produtividade da cana medida em campo (MUIR; ROBSON; RAHMAN, 2018). Além disso, imagens SAR derivadas de satélite mostraram ter relação com a biomassa da vegetação, densidade e altura (MOLIJN *et al.*, 2019). No entanto, o valor bruto das imagens SAR na previsão de produtividade da cana-de-açúcar permanece em grande parte sem solução na literatura. Até o momento, a análise de regressão foi a mais método popular para prever a produtividade da cana-de-açúcar usando imagens de satélite e seus índices de vegetação derivados enquanto as abordagens de aprendizado de máquina ainda aparecem em poucos estudos.

É bastante complexo para usuários sem experiência selecionar a ferramenta ou índice mais adequado para seus objetivos. As principais dificuldades estão na especificidade da terminologia utilizada, diferenças entre os sensores (por exemplo, sensores ativos ou passivos), interpretação de dados e tópicos com multidisciplinares que exigem conhecimentos em mais de uma área do conhecimento (CHAWADE *et al.*, 2019).

Dentre os tópicos multidisciplinares, está a agricultura digital que evoluiu significativamente nos últimos anos devido aos desenvolvimentos tecnológicos em automação e inteligência computacional aplicada ao setor agrícola, incluindo grandes culturas com menor valor agregado ao produto (BARROS *et al.*, 2022). Entende-se que a agricultura digital é

uma agricultura mais conectada e remota que será essencial no levantamento e no processamento dessa grande quantidade de dados coletados em todas as partes das cadeias produtivas, desde antes da colheita, produção e depois da colheita. Dessa maneira, utiliza-se de diferentes tipos de tecnologias digitais tais como sensores embarcados em satélites, aerotransportados ou sistemas autônomos (drones, máquinas agrícolas), instalados diretamente no campo ou em diferentes equipamentos (IoT) ao longo das cadeias produtivas, sistemas de telecomunicação, posicionamento global, software de controle, gestão e análise (*data analytics*) e atuadores (SOUZA *et al.*, 2020).

Segundo Luciano *et al.* (2021), a cana-de-açúcar desempenha um papel importante na produção de alimentos e energia no Brasil assim como no mundo. A grande disponibilidade de sensores em satélite e técnicas avançadas de processamento de dados melhoraram a previsão de produtividade da cana-de-açúcar em escala local e global, mas são necessários mais trabalhos para explorar a sinergia entre sensoriamento remoto, dados meteorológicos e agronômicos.

Sabe-se que a oferta de cana-de-açúcar de uma região varia de acordo com a área de cultivo, condições climáticas, pragas e doenças, bem como o manejo adotado. Infelizmente, na maioria dos países produtores, as previsões de produtividade da cana-de-açúcar muitas vezes ainda são realizadas por meio de métodos tradicionais que são específicos do local e desta forma, levam muito tempo para serem feitos. No sistema tradicional, a produtividade da cana-de-açúcar é estimada com base nos registros de plantio ou modelos alométricos. Essas abordagens geralmente exigem interpretação visual por um profissional experiente, conhecimento dos agricultores sobre a produção histórica e as condições ambientais (BOCCA; RODRIGUES; ARRAES, 2015). Além disso, a produção de açúcar é atualmente estimada a partir de previsões de produtividade de cana de médio e longo prazo. Portanto, o sensoriamento remoto tem sido proposto como uma abordagem alternativa de larga escala para prever produtividade da cana-de-açúcar (WALTER *et al.*, 2014).

A gestão eficiente dos processos de colheita também leva a uma utilização mais eficaz dos equipamentos de transporte e expedição. Para um planejamento do produtor, as previsões de safra são necessárias para o planejamento da colheita, decisões de manejo, seleção de variedades, planejamento de irrigação e decisões de fluxo de caixa. Além disso, os agricultores podem planejar quanto adubar e qual vai ser a expectativa de produção de cana, desta forma, trazendo benefícios de melhorar a lucratividade da fazenda e reduzir a descarga de fertilizantes em águas superficiais e subterrâneas. Saber a estimativa de açúcar bem antes da data de colheita é também importante para a indústria da cana-de-açúcar. Para as usinas,



essas informações são usadas para desenvolver estratégias de venda a valores que melhor correspondam aos rendimentos de açúcar previstos e para alinhar melhor as estratégias de marketing, preços e de embarque (EVERINGHAM *et al.*, 2007). Previsões de açúcar também são necessários para indicar o potencial de produção industrial de etanol e outros produtos valiosos de açúcares fermentescíveis (BOCCA; RODRIGUES; ARRAES, 2015).

É notado que para estudar-se e aplicar-se diferentes metodologias de sensoriamento remoto é preciso identificar-se localmente onde calibrar e aplicar modelos. Isso faz com que os resultados da literatura para áreas com condições edafoclimáticas semelhantes sejam respeitados. Desta forma, toda aplicação terá resultados mais adequados desde que se respeite a regionalização da área de estudo.

## 1.2 Objetivos

O objetivo deste trabalho é identificar aplicações de sensoriamento remoto em agricultura digital para a cultura da cana-de-açúcar e indicar maneiras de aplicação de metodologias em regiões homogêneas, com os objetivos específicos de:

- i) Criar zonas agroclimáticas homogêneas para aplicação de modelos em cana-de-açúcar;
- ii) Criar modelo de segmentação morfológica através de imagens de satélite para cana-de-açúcar;

## Referências

- ALVES, E. D. S. et al. Water stress coefficient determined by orbital remote sensing techniques. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 24, n. 12, p. 847-853, 2020.
- BARROS, T. et al. Multispectral vineyard segmentation: A deep learning comparison study. **Computers and Electronics in Agriculture**, v. 195, p. 106782, 2022.
- BOCCA, F. F.; RODRIGUES, L. H. A.; ARRAES, N. A. M. When do I want to know and why? Different demands on sugarcane yield. **Agricultural Systems**, v. 135, p. 48-56, 2015.
- CHAWADE, A. et al. High-Throughput Field-Phenotyping Tools for Plant Breeding and Precision Agriculture. **Agronomy**, v. 9, n. 5, p. 258, 2019.
- DUFT, D. G. et al. **Estimação da produtividade dos resíduos da cana-de-açúcar por meio do sensor MODIS**. Foz do Iguaçu: Simposio Brasileiro de Sensoriamento Remoto. 2013.
- DUVEILLER, G.; LÓPEZ-LOZANO, R.; BARUTH, B. Enhanced processing of 1-km spatial resolution fAPAR time series for sugarcane yield forecasting and monitoring. **Remote Sensing**, v. 5, p. 1091-1116, 2013.

- EVERINGHAM, Y. et al. Advanced satellite imagery to classify sugarcane crop characteristics. **Agronomy for Sustainable Development** volume, v. 27, p. 111-117, 2007.
- JINDO, K.; KOZAN, O.; ISEKI, K. Potential utilization of satellite remote sensing for field-based agricultural studies. **Chemical and Biological Technologies in Agriculture**, v. 8, n. 58, 2021.
- LUCIANO, A. C. D. S. et al. Empirical model for forecasting sugarcane yield on a local scale in Brazil using Landsat imagery and random forest algorithm. **Computers and Electronics in Agriculture**, v. 184, p. 106063, 2021.
- MOLIJN, R. A. et al. Sugarcane productivity mapping through C-band and L-band SAR and optical satellite imagery. **Remote Sensing**, v. 11, p. 1109, 2019.
- MUIR, J.; ROBSON, A.; RAHMAN, M. M. Using Satellite Imagery to Predict Cane Yield and Variability. **Research UNE**, 2018.
- ORÉ, G. et al. Predicting Sugarcane Harvest Date and Productivity with a Drone-Borne Tri-Band SAR. **Remote Sensing**, v. 1734, p. 147, 2022.
- RAHMAN, M. M.; ROBSON, A. Integrating Landsat-8 and Sentinel-2 Time Series Data for Yield Prediction of Sugarcane Crops at the Block Level. **Remote Sensing**, v. 12, p. 1313, 2020.
- SOUZA, K. X. S. D. et al. Agricultura digital: definições e tecnologias. In: CNPTIA **Introdução. Tecnologias digitais. Organização, representação e acesso à informação. Modelagem matemática e estatística. Inteligência artificial. Sensores e estudo da terra. Tecnologias convergentes. Considerações finais.** [S.l.]: [s.n.], 2020.
- WALTER, A. et al. Brazilian sugarcane ethanol: developments so far and challenges for the future. **WIREs Energy and Environment**, v. 3, n. 1, p. 70-92, 2014.



## 2. REVISÃO DA LITERATURA

### 2.1 Agricultura digital

Agricultura digital é o uso de informações digitais detalhadas para orientar as decisões ao longo da cadeia agrícola. Isso pode incluir o uso de grande volume de dados ('big data'), para produzir conhecimento. É importante ressaltar que não se restringe à unidade de produção agrícola ou animal, mas pode abranger toda ou parte da cadeia de valor; de fato, um dos aspectos transformacionais de um mundo digitalizado é o potencial de uma ligação quase direta entre consumidor e produtor de alimentos. O conceito de digitalização da agricultura encaixa-se com a definição padrão de digitalização de negócios que é habilitar, melhorar e/ou transformar operações de negócios; funções de negócios; ou processos e atividades, alavancando tecnologias digitais e um uso mais amplo de dados digitalizados, transformados em conhecimento (SHEPHERD *et al.*, 2020).

A também chamada de agricultura inteligente é, portanto, mais do que Agricultura de Precisão, pois vincula informações de agricultores, consumidores e outras partes interessadas da cadeia de valor. Isso significa que os consumidores podem fazer compras com base em informações sobre a fazenda que produz os alimentos, e os agricultores podem tomar decisões de produção com base nas informações sobre as compras dos consumidores (WOLFERT *et al.*, 2017).

O ganho da agricultura digital será em grande parte na forma de novas tecnologias, incluindo capacidade aprimorada de sensores, conectividade de dados aprimorada e suporte de inteligência artificial ou aumentada (IA) tomada de decisão. O potencial de transformação surge da evolução, convergência e integração de uma ampla gama dessas tecnologias existentes, emergentes e futuras. Os sensores são as tecnologias que provavelmente terão o maior impacto no que diz respeito à facilitação da futura coleta de dados com boa relação custo-benefício. A taxa de desenvolvimento de sensores está aumentando, enquanto seu preço está diminuindo. Custo e miniaturização combinados significam que sensores acessíveis têm o potencial de se tornar em breve comum no ambiente agrícola. Além disso, atender aos requisitos de energia torna-se um desafio para dispositivos portáteis, como sensores GPS de alta frequência altamente precisos, necessários para operar em situações em que as trocas de bateria não podem ocorrer (KLAUS, 2021).

Nos sistemas de cultivo, os sensores nas colheitadeiras são usados há muito tempo para gerar mapas de produtividade quando vinculados ao GPS. Esses dados, muitas vezes de várias fontes, que podem ser capturados, analisados e usados para a tomada de decisões, são fundamentais para realizar todo o potencial da agricultura digital. A disponibilidade de

sensores de baixo custo reduz o custo de montagem desses grandes conjuntos de dados. O próximo desafio é gerenciar os dados. O custo de transferência e armazenamento de dados está diminuindo rapidamente, tornando a tecnologia baseada em dados ainda mais acessível para os agricultores. As considerações de armazenamento de dados incluem o local de armazenamento (jurisdição legal); privacidade e acessibilidade; backup e segurança de dados; a divisão entre armazenamento baseado em nuvem e local e por quanto tempo os dados precisam ser mantidos (GUO *et al.*, 2015).

O acesso à banda larga rápida e confiável, para conexão à Internet das Coisas e capacidade de transferir rapidamente grandes quantidades de dados, é essencial para que as comunidades rurais participem da agricultura digital. No entanto, as áreas rurais estão entre as mais excluídas dos rápidos desenvolvimentos de banda larga. No entanto, levará tempo para solucionar todo o problema de conectividade, e este é talvez o maior desafio técnico que limitará a aceitação da agricultura digital (TOWNSEND *et al.*, 2013).

É possível identificar que dessa maneira, o sensoriamento remoto pode ser a principal fonte de informação para a agricultura por algum tempo e assim, ferramentas que possibilitem a digitalização de processos são necessárias.

## **2.2 Cana-de-açúcar**

### **2.2.1 Fisiologia**

A cana-de-açúcar é uma gramínea semiperene alta do gênero *Saccharum*, utilizada para a produção de açúcar. As plantas geralmente têm entre 2 e 6 m de altura com caules robustos, articulados e fibrosos, ricos em sacarose, que se acumula nos entrenós. A cana-de-açúcar é nativa do clima temperado a regiões tropicais do Sudeste Asiático e Papua-Nova Guiné e atualmente é produzida principalmente em regiões tropicais e subtropicais. Economicamente, a cana-de-açúcar é uma das culturas mais importantes que contribuem para a produção de alimentos para a população mundial (MORAES; OLIVEIRA; DIAZ-CHAVEZ, 2015).

Por ser uma cultura semiperene e seu ciclo de crescimento ser de geralmente de 12 a 18 meses até a colheita, existem diversas variáveis que influenciam no seu porte e crescimento durante o ano. O ciclo de crescimento varia em cada país dependendo da variedade, condições culturais locais e parâmetros geográficos (RUDORFF *et al.*, 2010).

Os sete principais estágios de crescimento e desenvolvimento da cana-de-açúcar incluem germinação e estabelecimento (plantio/rebrota e vegetativo), perfilhamento, grande crescimento (alongamento e desenvolvimento dos colmos) e amadurecimento (início do

florescimento e florescimento pleno). As fases fenológicas são mostradas na Figura 1. Além das condições climáticas favoráveis, cada fase requer atividades específicas de manejo da cultura, fornecimento de diferentes nutrientes e água, para uma ótima produtividade (WIEDENFELD, 1995).




Figura 1: Estádios vegetativos da cana-de-açúcar para cana planta e cana soca  
Fonte: adaptado de Spark (2021)

O cultivo da cana-de-açúcar faz com que a planta seja exposta a muitos problemas principalmente devido a fatores ambientais (chuva, temperatura e radiação) que estão fora do controle humano. Na fase de estabelecimento, as ervas daninhas são uma ameaça crítica, pois competem por nutrientes com as novas raízes da cana-de-açúcar (USABORISUT, 2019). Temperaturas e volumes de chuva anormais contribuem para um solo mais seco ou úmido resultam em um crescimento reduzido dos colmos e raízes por estarem altamente vulneráveis a doenças e pragas (ZHAO; LI, 2015). Durante a fase de perfilhamento, o estresse por déficit hídrico é um grande problema que causa menor crescimento da parte aérea e redução da produtividade, enquanto plantas daninhas e pragas permanecem como ameaças neste ciclo. Além disso, o estresse nutricional também desempenha um papel significativo no crescimento da cana-de-açúcar (SMEETS *et al.*, 2008). Já na fase de grande crescimento, o aumento da

frequência e intensidade de eventos climáticos extremos, como secas, inundações e tempestades, afetam a produtividade com menor altura do caule (1,2 a 1,5 m) e diâmetro reduzido, enquanto a temperatura do ar e a luz solar também são importantes para o crescimento da biomassa. Durante a fase final, o crescimento da cana-de-açúcar é fortemente afetado por variáveis meteorológicas, como temperatura do ar, precipitação, umidade do solo e radiação solar. A variabilidade climática causa danos como redução do acúmulo de sacarose nos colmos e menor qualidade do caldo (CARDOZO; SENTELHAS, 2013).

No Brasil, a cana planta é plantada durante todo o ano, sendo o maior volume de setembro a março. A cana-de-açúcar tem alto crescimento entre outubro e fevereiro. Após a primeira colheita, a cana-de-açúcar cresce a partir do mesmo sistema radicular por cinco a sete anos, levando a subseqüentes perdas de produtividade devido à diminuição da população de colmos. As áreas de cana-de-açúcar geralmente são rotacionadas com culturas de verão, como soja e amendoim (MELLO, 2012).

As condições climáticas apresentam o desafio mais importante para a produtividade da cana-de-açúcar. Tanto a produção quanto a produtividade são significativamente afetadas por fatores climáticos, incluindo chuva, temperatura, radiação solar e umidade relativa (ZHAO; LI, 2015). O crescimento homogêneo da cana-de-açúcar durante as diferentes fases requer condições climáticas específicas (CARDOZO e SENTELHAS, 2013).

O acúmulo de graus-dia controla o desenvolvimento fenológico da cana-de-açúcar (LOFTON *et al.*, 2012). O modelo de cálculo de graus-dia aceito é baseado no acúmulo de temperatura média diária, desde o primeiro dia de plantio, (simplificada como a média dos valores de temperatura máxima e mínima) (TERUEL; BARBIERI; JR, 1997).

Monitorar os graus-dia permite prever as taxas usuais de desenvolvimento da cultura necessárias para o crescimento da cana-de-açúcar nas diferentes fases. O graus-dia varia geralmente entre 0 e 250°C durante o primeiro período de plantio e afeta a brotação do caule. Na segunda fase, o aparecimento dos perfilhos requer graus-dia acumulados de 250 a 60°C. Em aproximadamente 500°C graus-dia acumulados, uma alta densidade de colmos aparece. O terceiro grande estágio de crescimento requer graus-dia acumulados de 600 a 900°C influenciando fortemente a produção, o perfilhamento, alongamento do caule, o acúmulo de biomassa e produção de folhas para crescimento rápido e maior produtividade (CUADRA *et al.*, 2011). A última fase de maturação requer graus-dia acumulados de 900 a 1400°C para acúmulo de sacarose antes da colheita (SCARPARI; BEAUCLAIR, 2004).

Dentro dos quatro principais estágios de desenvolvimento da cana-de-açúcar, as condições climáticas ideais necessárias são as mostradas na Tabela 1.

Tabela 1: Condições necessárias ao desenvolvimento da cana-de-açúcar

<b>Estágio</b>	<b>Precipitação</b>	<b>Temperatura</b>	<b>Radiação</b>	<b>Umidade</b>
Germinação	1100 a 1500 mm	32 a 38°C	18 a 36 MJ/m <sup>2</sup>	80 a 85%
Perfilhamento	Controlado	32 a 38°C	18 a 36 MJ/m <sup>2</sup>	80 a 85%
Crescimento	750 e 1100 mm	28 a 32°C	10 a 18 MJ/m <sup>2</sup>	80 a 87%.
Maturação	Pouca	-	10 a 14hs sol	40 a 65%

Fonte: (SIMÕES; ROCHA; LAMPARELLI, 2009)

Para a primeira fase de crescimento da cana-de-açúcar, novas soqueiras brotam caules, enquanto a biomassa e índice de área foliar são ligeiramente aparentes. A capina e a aplicação no combate de pragas e daninhas devem ser implementados para aumentar o número de socas (SOUZA *et al.*, 2017). A fase de perfilhamento requer um controle rigoroso de água e nutrientes suficientes para o crescimento dos novos colmos. Durante esta fase, as folhas brotam e o índice de área foliar pode ser medido. Insetos e doenças (fungos e vírus) podem ter impactos negativos severos (LUNA; LOBO, 2016). O estresse por déficit hídrico pode ocorrer nesta fase devido à seca (ZHAO; LI, 2015), com morte de colmos jovens e diminuição da população de colmos.

O estágio de crescimento envolve rápido alongamento do caule, aumento da biomassa, desenvolvimento vigoroso do dossel e índice de área foliar máximo (TERUEL; BARBIERI; JR, 1997). Além disso, desastres naturais como secas e inundações podem atrapalhar o cultivo da cana-de-açúcar (ZHAO; LI, 2015). Durante a última fase, o índice de área foliar e o teor de clorofila diminuem porque a água da folha é usada para acumular sacarose nos colmos, enquanto o crescimento da biomassa do colmo é quase completamente interrompido, pois o tamanho do estágio de maturação é semelhante ao estágio de crescimento (CARDOZO; SENTELHAS, 2013). A intensidade da floração da cana-de-açúcar reduz a produção de sacarose ao diminuir a qualidade do caldo e diminui o rendimento da cana-de-açúcar. A floração depende do fotoperíodo, condições climáticas, estado nutricional, umidade do solo e variedade; portanto, a seleção da cultivar ideal é necessária para o manejo adequado da cultura (PEREIRA; BARBIER; NOVA, 1983).

### **2.2.2 Produção**



A produção global de cana-de-açúcar aumentou rapidamente de 1994 a 2018 devido à crescente demanda pelo consumo de açúcar (BORDONAL *et al.*, 2018). Em 2018, o Brasil registrou a maior contribuição para a produção global de açúcar com 37,04%, seguido pela Índia (18,69%), China (5,39%) e Tailândia (5,36%) (FAO, 2021).

Embora a cana-de-açúcar contenha elementos nutricionais, ainda existem estudos que ligam o seu consumo excessivo a problemas de saúde como obesidade, cáries dentárias, síndrome metabólica e qualidade da dieta (RUXTON; GARDNER; MCNULTY, 2010). O bagaço da cana-de-açúcar também pode ser moído e transformado em etanol para produção de energia (SAHU, 2018). As fibras da cana-de-açúcar também podem ser usadas para fazer canecas, telas e coberturas. Em alguns países, a flor é utilizada como alimento (STEVENSON; RANDS, 2013).

Em regiões favoráveis, a produção de cana-de-açúcar é economicamente rentável e traz prosperidade para a população local (MORAES; OLIVEIRA; DIAZ-CHAVEZ, 2015). No entanto, o manejo da cana-de-açúcar é trabalhoso e requer uma quantidade adequada de água. A produtividade é altamente dependente do clima (ZHAO; LI, 2015). As mudanças climáticas recentes aumentaram a frequência de eventos extremos e conseqüentemente a gravidade das secas e inundações, afetando negativamente as condições de cultivo (CHARLES *et al.*, 2010). Embora as políticas governamentais, agências relacionadas e usinas de cana-de-açúcar tenham tentado resolver esses problemas, a produção da cultura da cana-de-açúcar sofreu nos últimos anos em especial pelos anos secos de 2020 e 2021, a Figura 2 mostra a evolução da produção e produtividade de cana-de-açúcar nas últimas safras (CONAB, 2021).




Figura 2: Produção e produtividade de cana-de-açúcar no Brasil  
Fonte: (CONAB, 2021)

### 2.2.3 Sensoriamento remoto na cana-de-açúcar

O sensoriamento remoto pode fornecer informações relacionadas à cana-de-açúcar e outras culturas em grandes áreas de maneira oportuna e econômica e, assim, gerar dados de pelo menos uma parte das informações da indústria global de açúcar (MORAN; INOUE; BARNES, 1997). Desde a década de 1980, o sensoriamento remoto por satélite tornou-se uma fonte de dados relevante para detectar, mapear e monitorar o crescimento das culturas, para apoiar o manejo sanitário e a produtividade das culturas. Os benefícios do sensoriamento remoto estão relacionados à sua capacidade de capturar dados de imagens espectro-temporais de um número cada vez maior de sensores e satélites (HOSSAIN; CHEN, 2019). Paralelamente ao desenvolvimento de sensores, os últimos anos também viram um enorme progresso no campo do aprendizado de máquina (ABDEL-RAHMAN; ISMAIL, 2012), bem como uma crescente acessibilidade da infraestrutura de TI necessária. Vários grupos de pesquisa demonstraram com sucesso o potencial de novos algoritmos de aprendizado de máquina com dados de imagem de resolução fina para mapear plantações e florestas em diferentes escalas e em diferentes ambientes (BELGIU; DRĂGUȚ, 2016) e (LUCIANO *et al.*, 2018). Seus resultados provaram que técnicas e dados altamente satisfatórios estão disponíveis para o monitoramento rápido e preciso da vegetação.

Diversos sensores com várias propriedades espectrais, espaciais e temporais estão se mostrando eficazes para aplicações relacionadas à cana-de-açúcar (por exemplo, mapeamento em tempo quase real, monitoramento de crescimento, ultra resolução para previsão de rendimento e gerenciamento de desastres) (ENNOURI; KALLEL, 2019). Nos últimos dois anos, novos sensores foram implantados, como o radar de abertura sintética (SAR) de banda C Sentinel-1 e o instrumento multiespectral Sentinel-2 (S2 MSI), detecção e alcance de luz (LiDAR) e sensores hiperespectrais (TSOUROS; BIBI; SARIGIANNIDIS, 2019). Além disso, imagens de veículos aéreos não tripulados (RPA) têm sido usadas para monitorar as lavouras de cana-de-açúcar (XU *et al.*, 2020). Ao fornecer dados de resolução fina de baixo custo em tempo quase real, o sensoriamento remoto tornou-se uma ferramenta importante para melhorar o mapeamento da cana-de-açúcar e seu gerenciamento (MOLIJN *et al.*, 2019). A Figura 3 mostra a representação esquemática do nível de complexidade entre observações de sensoriamento remoto e características agronômicas de interesse.

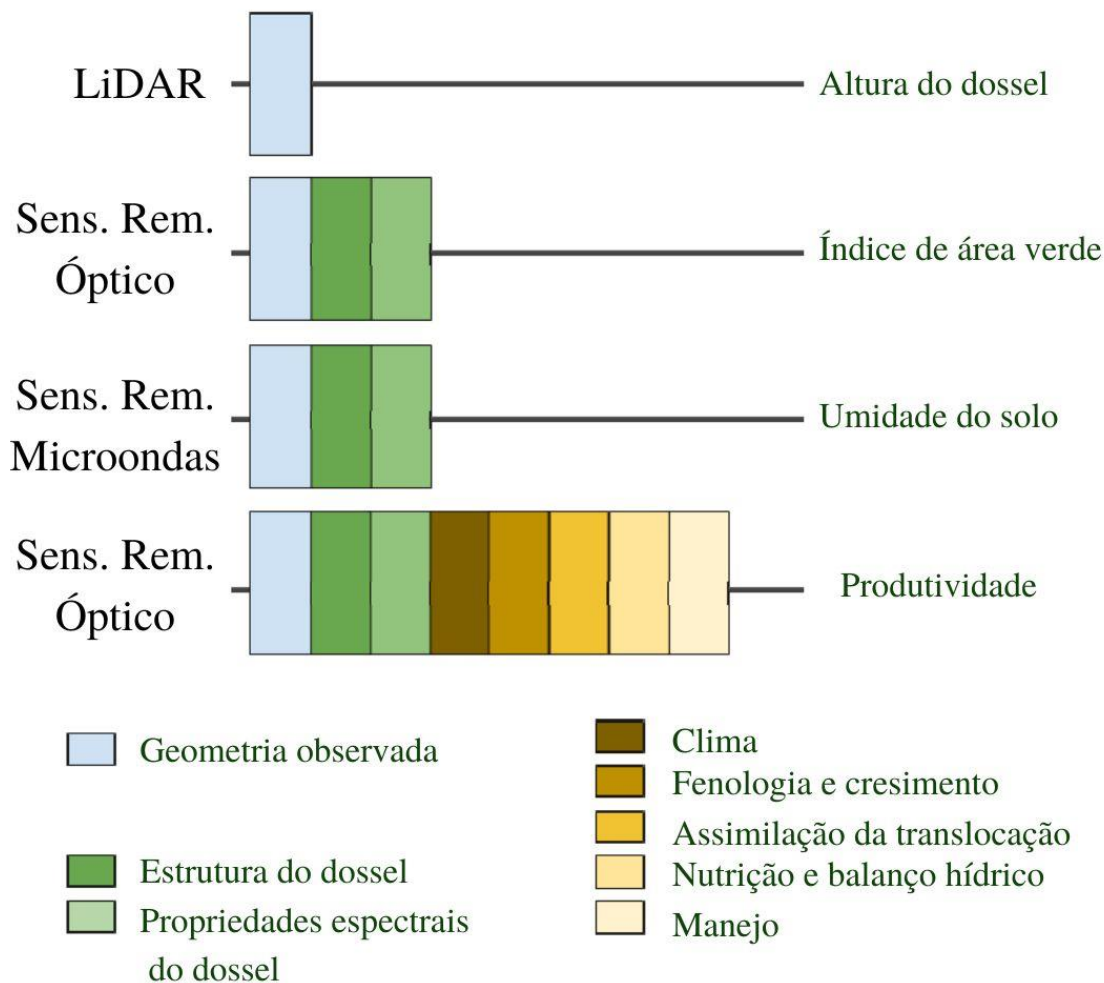


Figura 3: Complexidade das análises à esquerda e variáveis agronômicas de interesse à direita.

Fonte: adaptado de (WEISS; JACOB; DUVEILLER, 2020)

### 2.3 Técnicas de classificação e aprendizado de máquina

As constelações europeias Sentinel-1 e Sentinel-2, juntamente com o rico arquivo de imagens Landsat, são as mais populares para monitorar áreas de cana-de-açúcar. Devido ao progresso no acesso a dados e avanços contínuos no fornecimento de dados prontos para análise, o rico conteúdo de informações fornecido pelas imagens de satélite multitemporais agora pode ser mais bem aproveitada em ambientes únicos (DWYER *et al.*, 2018). Além disso, métodos inovadores de aprendizado de máquina estão amplamente disponíveis e foram aplicados com sucesso para gerenciamento rápido de campo, mapeamento de cana-de-açúcar e monitoramento. Técnicas como *random forest* (RF), *classification and regression tree*

(CART), *support vector machine* (SVM) e uma rede neural artificial (RNA) têm sido aplicadas para auxiliar na tomada de decisão (VIRNODKAR *et al.*, 2020).

Em termos de técnica de classificação, a maioria das classificações de cana-de-açúcar foi feita usando técnicas comuns de sensoriamento remoto, incluindo técnicas de classificação supervisionada (por exemplo, classificação de máxima verossimilhança, classificação de mínima distância e classificação de mapeador de ângulo espectral) usados por Demattê *et al.* (2016) e Vicente *et al.* (2012), juntamente com algoritmos de classificação não supervisionados (por exemplo, classificador ISODATA) usado por Ferreira, Alves e Shimabukuro (2014) em seus trabalhos. Na maioria dos casos, as informações espectrais de pixels individuais são consideradas vetores de recursos preditivos dentro de um espaço n-dimensional para identificar campos de cultivo (JENSEN, 1996).

Muitos estudos compararam ISODATA e árvores de decisão (DT) como Vicente *et al.* (2012) e usando o *Indian Remote Sensing Satellite-6* (IRS-P6, ResourceSat-1), um *autoscanner* de imagem linear de alta resolução (LISS-IV), Hyperion e dados Landsat-5 TM (com resolução espacial de 5 a 30m) para classificar áreas de cana-de-açúcar e não-cana (DELGADO *et al.*, 2012). O método DT demonstrou o melhor desempenho para separar cana-de-açúcar de outras culturas que índices específicos (por exemplo, NDVI e EVI) usados com DT podem efetivamente discriminar canaviais de outros tipos de cultivo com precisão em cerca de 90%. Imagens multiespectrais do IRS-P6, um *autoscanner* de imagem linear de média resolução (LISS-III) e satélite WorldView-2 lite, tiveram classificação de culturas eficaz utilizando *Possibilistic C-Mean* (PCM) aplicado com abordagens *fuzzy*. As bandas espectrais do Worldview-2 (amarelo, vermelho, *red-edge*, NIR1 e NIR2) resultaram em alta capacidade de identificação de plantações e alcançaram uma precisão de cerca de 90-93% para a classificação da cana-de-açúcar (UPADHYAY *et al.*, 2012). Em estudo recente, o uso e cobertura do solo, incluindo a cana-de-açúcar, no Estado de São Paulo, foi analisada usando dois conjuntos de dados multitemporais Landsat (L5 TM e L8 OLI) com o algoritmo. A precisão média foi de 84% (SILVA; ALVES; FERREIRA, 2018).

Algoritmos de aprendizado de máquina como RF, SVM, e DT têm sido usados com dados de sensoriamento remoto para monitoramento de cana-de-açúcar com excelente precisão por WANG *et al.* (2019). Eles compararam os métodos classificadores RF, SVM e CART com o índice de vegetação NDVI multitemporal de imagens Sentinel-2 MSI para mapear plantações de cana-de-açúcar. SVM demonstrou potencial para mapeamento de cana-de-açúcar em paisagens complexas na China. Johnson, Scheyvens e Shivakoti (2014) conduziram estudos com Landsat8 OLI fusionada e SVM, enquanto Rede Neural

Convolutacional (CNN), Análise Discriminante Penalizada (PDA) e Análise Discriminante Linear (LDA) também foram avaliadas como técnicas alternativas para o mapeamento. A CNN obteve uma precisão muito boa de 95% (CEVALLOS; VILLAGOMEZ; ANDRYSHCHENKO, 2019). No entanto, esses autores analisaram apenas uma imagem de data única de um único sensor para mapeamento de cana-de-açúcar. Atualmente, dados de sensoriamento remoto multitemporais e de diversas fontes estão disponíveis, desta forma, os resultados das classificações são melhores em comparação com a entrada de dados de uma única data (WANG *et al.*, 2019).

Wang *et al.* (2019) classificaram com sucesso áreas de cana-de-açúcar em paisagens complexas usando o índice NDVI multitemporal de imagens Sentinel-2 e vários métodos de aprendizado de máquina. Os autores construíram uma imagem de NDVI de três bandas com base em diferentes estágios fenológicos produzindo um espaço tridimensional. O espaço tridimensional permitiu entender melhor o comportamento espectral da cana-de-açúcar em comparação com outras classes. Isso confirma o valor das imagens multitemporais no sensoriamento remoto para separar os canaviais de outras culturas e classes de cobertura do solo.

RF é uma abordagem baseada no conjunto de árvores de decisão (DT) para realizar uma previsão para classificações e regressões. A abordagem usa *bootstrapping* para gerar diferentes conjuntos de dados de treino e teste e para obter resultados imparciais com base nos chamados dados *out-of-bag* (OOB). Para a agregação das predições específicas das DT e para avaliação de precisão e aplicação do modelo, é usado o voto majoritário (BREIMAN, 2001). Ao longo da última década, o classificador de RF tem sido cada vez mais utilizado pela comunidade de sensoriamento remoto devido à sua simplicidade e velocidade, juntamente com resultados satisfatórios de classificação (PAL, 2004). Vários estudos aplicaram o classificador RF para identificar plantações de cana-de-açúcar e produziram alta precisão de classificação para mapeamento de cana-de-açúcar. Dados de imagens de satélite multiespectrais incluindo Hyperion, Landsat-5 TM, Landsat-7 ETM+, Landsat-8 OLI, Sentinel-1, Sentinel-2 MSI e RapidEye têm sido usados para classificar cana-de-açúcar e outras culturas usando RF (LUCIANO *et al.*, 2018).

Schultz *et al.* (2015) utilizaram o método RF e estatísticas OOB para avaliar automaticamente várias segmentações alternativas a fim de inferir automaticamente os melhores parâmetros de segmentação para mapeamento de cana-de-açúcar. Os resultados do RF mostraram classificação de alta precisão de 80-98%.

Uma vantagem do classificador de RF é sua flexibilidade para lidar com muitas variáveis de entrada diferentes (sensoriamento remoto e dados geográficos). Vários estudos relataram a aplicação de índices de vegetação para identificar as variáveis e estações mais adequadas para o mapeamento do uso do solo (PAL, 2004). Vários autores incentivaram a análise de mais fontes de dados de sensoriamento remoto, em particular para usar o classificador RF para mapeamento de áreas de cana-de-açúcar (LUCIANO *et al.*, 2018).

Sensores de última geração, como o Sentinel-2 MSI, fornecem informações de alta resolução em termos de resolução espacial, espectral, radiométrica e temporal com alto potencial para classificação de culturas (IMMITZER; VUOLO; ATZBERGER, 2016). A análise orientada a objeto (OBIA) foi desenvolvida para alavancar a variabilidade dos pixels dentro dos objetos como informações adicionais (espectral, textura e métricas estatísticas) para a classificação (BLASCHKE, 2010). O OBIA primeiro agrupa pixels em objetos homogêneos que são idealmente relacionados a objetos na natureza, como campos ou talhões. Vários artigos empregaram a abordagem OBIA juntamente com uma configuração de técnicas de mineração de dados (DM) para mapeamento de cana-de-açúcar. OBIA e DM foram, por exemplo, aplicados com DT usando dados de Landsat-5 TM, Landsat-7 ETM+ e Landsat-8 OLI para identificar cana-de-açúcar e outras classes. Tais combinações de algoritmos foram consideradas muito eficientes com precisão de 94% para mapeamento da cana-de-açúcar (BLASCHKE, 2010). Além disso, as características polarimétricas do RADARSAT-2 provaram ser úteis dentro de uma abordagem OBIA, enquanto a análise de dados monotemporais teve apenas um baixo potencial para identificar a cana-de-açúcar. Souza *et al.* (2017) testaram dados com resolução espacial alta de 0,2–0,4 m obtidos por voos de RPAs em uma abordagem OBIA para identificação de linhas de plantio em cana-de-açúcar. Imagens de resolução espacial de 2 m no RGB, LiDAR e dados hiperespectrais foram usadas para gerar mapas de cana-de-açúcar. O classificador OBIA demonstrou um desempenho muito bom ao analisar imagens de altíssima resolução, não apenas para mapeamento de cana-de-açúcar, mas também para outras culturas (SUMESH; NINSAWAT; SOM-ARD, 2021). No entanto, as configurações de parâmetros ideais requerem um longo tempo de configuração para fornecer resultados de segmentação adequados que podem afetar a precisão do mapa final.

Apesar do sucesso dos estudos acima, eles também revelaram alguns pontos de atenção que levam a variações na precisão da classificação. Os principais fatores que impactaram negativamente a precisão da classificação foi a aquisição de dados de baixa qualidade, máscaras de nuvens imperfeitas, sobreposição espectral e confusão entre diferentes classes de uso do solo, dificuldades para identificar áreas de treinamento adequadas e

incerteza em relação aos dados de treinamento disponíveis. Como problema geral, a transferibilidade das abordagens desenvolvidas para outras regiões permanece uma questão não resolvida por conta da não homogeneidade geográfica.

## 2.4 Estimativa de produtividade

A biomassa da cana-de-açúcar é relação direta do dossel da planta e o tamanho desses colmos são questões que, juntas, determinam a produção e a produtividade da cultura (CASTRO-NAVA *et al.*, 2016). Diversos trabalhos estudaram a estimativa de produtividade com base em técnicas de sensoriamento remoto e dados de campo. A maioria dos trabalhos de previsão de produtividade da cana-de-açúcar trouxe a produção de cana.

Vários estudos usaram valores e índices espectrais, como NDVI, índice de área foliar, análise de componentes principais (PCA) de vários sensores (SPOT-HRV, ASTER, Landsat, CBERS-4, IRS -P6 LISS-IV e espectrorradiômetro) juntamente com dados históricos de produtividade para estimativa da produção (ALMEIDA; FILHO; ROSSETTO, 2007).

Almeida, Filho e Rossetto (2007) e Lisboa *et al.* (2018) coletaram dados reais de rendimento usando parcelas de amostra, dados de satélite de várias datas e um espectrorradiômetro de campo. Além disso, Simões, Rocha e Lamparelli (2009) analisaram o crescimento e o rendimento da cana-de-açúcar usando parâmetros biofísicos como biomassa total, produtividade, índice de área foliar e número de plantas por metro linear de dados temporais do Landsat. Esses dados foram integrados por meio de regressões lineares simples e múltiplas stepwise para produzir os modelos. O método de validação usou a raiz do erro quadrático médio (RMSE) e outras estatísticas para avaliar a melhor variável e o modelo ideal para estimativa de produtividade. Os resultados mostraram boa precisão usando NDVI e índice de área foliar provenientes de imagens de satélite para a variação na produtividade da cana-de-açúcar para uma grande área. No entanto, em áreas menores algumas limitações quanto aos detalhes da plantação e outras vegetações foram notadas.

Os dados de imagens de RPA foram analisadas para a estimativa da produtividade das culturas em pequenas fazendas. É uma ferramenta de baixo custo e pode fornecer rapidamente imagens de alta resolução que podem identificar a estrutura do dossel e as condições da área não cultivada (TSOUROS; BIBI; SARIGIANNIDIS, 2019). Sanches *et al.* (2018) e Souza *et al.* (2017) avaliaram vários índices de dados de imagens de RPA, que incluíram índice de vegetação verde-vermelho (GRVI), índices de vegetação de razão (RVI), NDVI, índice de pigmento de razão simples (SRPI), índices de clorofila verde (CIgreen), índices de clorofila borda vermelha (CIrededge) e GNDVI juntamente com o índice de área foliar para determinar

o índice ótimo para estimativa de produtividade. Os modelos de regressão avaliaram esses índices em relação à produtividade efetiva da colheita. GRVI e CÍrededge foram capazes de prever com precisão a produtividade da cana-de-açúcar.

Vários estudos utilizaram o LiDAR em um RPA para extrair a altura da planta da cana-de-açúcar e utilizaram essa variável em conjunto com outros preditores para estimar a produtividade da cana-de-açúcar. Os modelos alcançaram uma precisão de mais de 90% e a altura de planta do RPA teve uma alta consistência em relação às medições de pesquisa de campo em escala de campo. O uso da altura derivada do LiDAR foi um bom fator para a estimativa de produtividade em comparação com as observações da altura das plantas no campo. Além disso, a combinação do modelo RF com dados derivados do LiDAR funcionou melhor do que os modelos de regressão geral e foi a abordagem mais apropriada para a estimativa da produtividade da cana-de-açúcar (XU *et al.* 2020).

## 2.5 Monitoramento da disponibilidade de nutrientes

A maioria dos estudos detectou níveis de nitrogênio em folhas de cana-de-açúcar usando espectros de refletância de sensoriamento remoto e espectroscopia de campo (WIEGAND *et al.*, 1996). Dados de NDVI multitemporal de Landsat-5 TM e Hyperion foram usados juntamente com espectroscopia no local para a quantificação da concentração de nitrogênio foliar (YANG; ZHOU; MELVILLE, 1997). Foram usados para calibrar e validar modelos de nitrogênio foliar diversos modelos ao longo dos estudos de nutrientes em folhas de cana (ABDEL-RAHMAN; AHMED; ISMAIL, 2013 ). Os resultados mostraram uma forte relação entre o NDVI e o teor de nutrientes nas folhas e indicaram um alto potencial de RF e SVM para prever as concentrações de nitrogênio nas folhas.

## 2.6 Monitoramento de doenças

Apan *et al.* (2003) usaram dados do Hyperion para medir o impacto do risco da doença fúngica 'ferrugem alaranjada' através de dados espectrais. Eles usaram o índice de estresse hídrico das doenças (DWSI) para aumentar a sensibilidade para monitorar a doença. Embora útil, algumas ineficiências foram notadas, bem como uma confusão com certas plantações devido à sensibilidade à umidade do solo. ABDEL-RAHMAN *et al.* (2010) usaram dados de espectrorradiômetro de campo para detectar danos causados por *thrips* da cana-de-açúcar. Usando análise de variância unidirecional (ANOVA), eles demonstraram que a região da borda vermelha fornece o mais alto nível de discriminação das classes de dano. Johansen *et al.* (2018) usaram imagens multitemporais GeoEye-1 juntamente com o índice NDVI para



detecção de doenças. A técnica OBIA foi realizado para monitorar os danos com precisão em torno de 87%. Eles acharam a OBIA útil para melhorar a tomada de decisão dos produtores afetados por esta doença.

## 2.7 Monitoramento de anomalias

Picoli, Duft e Machado (2017) avaliaram a capacidade de vários índices de vegetação de dados do sensor MODIS para monitorar os efeitos da seca em plantações de cana-de-açúcar. Foi realizada uma análise de correlação para identificar os melhores índices. O índice padronizado de precipitação-*evapotranspiração* (SPEI) foi utilizado para avaliar os índices. O SPEI foi altamente correlacionado com o índice global de umidade da vegetação (GVMI), índice de condição da vegetação (VCI), índice de diferença normalizada no infravermelho (NDII), SWIR1 e NDWI. Com base nesses índices de dados do MODIS, foi encontrado um alto potencial para o monitoramento da seca da cana-de-açúcar.

Mais tarde, Picoli *et al.* (2019) detectaram o efeito da seca da cana-de-açúcar usando índices espectrais de imagens Landsat, incluindo NDVI, VCI, NDWI, GVMI e NDII para monitorar as áreas afetadas. O modelo climatológico de balanço hídrico solo (CSWB) também foi aplicado para avaliar os índices seguindo a abordagem LDA.

## 2.8 Discussão

É possível verificar que existem muitos trabalhos que endereçam para temas importantes na cultura da cana-de-açúcar ligados ao sensoriamento remoto, porém ainda existem grandes áreas que estão descobertas. Foi possível observar que muitos estudos endereçam o problema do mapeamento de áreas cultivadas pela classificação de uso do solo, trazem a dinâmica da previsão de produtividade, avançam para monitoramento de nutrientes, doenças e desastres, porém sempre os estudos trazem o caráter local como um problema a ser considerado nas análises.

É possível observar que para trabalhos de sensoriamento remoto e culturas agrícolas e em especial a cana-de-açúcar encontrar regiões homogêneas para aplicações metodológicas são mandatórias e desta forma, é preciso de esforços e trabalhos que enderecem a problemática de regionalizar áreas que possuam caráter homogêneo para estudos. Isso pode ser feito através de caracterização edafoclimática e fisiológica ou modelagem estatística.

Primeiramente é necessário um estudo de categorização das regiões produtoras a partir do aspecto de clima, solo e comportamento do desenvolvimento vegetativo. Em um segundo momento é preciso dentro dessas regiões classificar as áreas de produção pelas características

fenológicas, uma vez que cada fenótipo pode trazer uma resposta diferente aos sensores. Por fim, é ainda preciso classificar o comportamento do desenvolvimento da biomassa na escala de unidade mínima de produção. Pela cana-de-açúcar ser uma cultura semiperene é bastante comum ela ir perdendo estande ao longo dos cortes seja por arranquio de soqueiras, seja por ocorrência de pragas, doenças, daninhas ou compactação do solo.

Desta forma, é possível concluir que aplicar qualquer metodologia que seja em grandes áreas sem levar em consideração os fatores locais, faz com que seja quase impossível comparar resultados entre locais e entre safras.

O sensoriamento remoto aplicado a cana-de-açúcar tem evoluído muito nos últimos anos e é possível observar que ainda existe espaço para evoluir ainda mais levando-se em consideração os fatores expostos nesse trabalho.

## Referências

- ABDEL-RAHMAN, E. M.; AHMED, F. B.; BERG, M. V.; WAY, M. Potential of spectroscopic data sets for sugarcane thrips (*Fulmekiola serrata* Kobus) damage detection. **International Journal of Remote Sensing**, v. 31, 2010.
- ABDEL-RAHMAN, E. M.; AHMED, F. B.; ISMAIL, R. Random forest regression and spectral band selection for estimating sugarcane leaf nitrogen concentration using EO-1 Hyperion hyperspectral data. **Int. J. Remote Sens.**, v. 712-728, n. 34, 2013.
- ABDEL-RAHMAN, E. M.; ISMAIL, R. Random forest regression and spectral band selection for estimating sugarcane leaf nitrogen concentration using EO-1 Hyperion hyperspectral data. **International Journal of Remote Sensing**, v. 34, n. 2, p. 712-728, 2012.
- ALMEIDA, T. I. R.; FILHO, C. R. D. S.; ROSSETTO, R. ASTER and Landsat ETM+ images applied to sugarcane yield forecast. **International Journal of Remote Sensing**, p. 4057-4069, 2007.
- ALVES, E. D. S. et al. Water stress coefficient determined by orbital remote sensing techniques. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 24, n. 12, p. 847-853, 2020.
- APAN, A. et al. Detecting sugarcane 'orange rust' disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, p. 489-498, 2003.
- BARROS, T. et al. Multispectral vineyard segmentation: A deep learning comparison study. **Computers and Electronics in Agriculture**, v. 195, p. 106782, 2022.
- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016.
- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, n. 65, p. 2-16, 2010.
- BOCCA, F. F.; RODRIGUES, L. H. A.; ARRAES, N. A. M. When do I want to know and why? Different demands on sugarcane yield. **Agricultural Systems**, v. 135, p. 48-56, 2015.

- BORDONAL, R. D. O. et al. Sustainability of sugarcane production in Brazil. A review. **Agronomy for Sustainable Development**, v. 38, n. 13, 2018.
- BREIMAN, L. Random Forests. **Machine Learning**, n. 45, p. 5-32, 2001.
- CARDOZO, N. P.; SENTELHAS, P. C. Climatic effects on sugarcane ripening under the influence of cultivars and crop age. **Sci. agric.**, v. 70, n. 6, 2013.
- CASTRO-NAVA, S. et al. Leaf Growth and Canopy Development of Three Sugarcane Genotypes under High Temperature Rainfed Conditions in Northeastern Mexico. **International Journal of Agronomy**, v. 16, 2016.
- CEVALLOS, J. P. C.; VILLAGOMEZ, J. M. A.; ANDRYSHCHENKO, I. S. Convolutional Neural Network in the Recognition of Spatial Images of Sugarcane Crops in the Troncal Region of the Coast of Ecuador. **Procedia Computer Science**, v. 150, 2019.
- CHARLES, H. et al. Food Security: The Challenge of Feeding 9 Billion People. **SCIENCE**, v. 5967, p. 327, 2010.
- CHAWADE, A. et al. High-Throughput Field-Phenotyping Tools for Plant Breeding and Precision Agriculture. **Agronomy**, v. 9, n. 5, p. 258, 2019.
- CONAB, C. N. de (2022) 'Acompanhamento da Safra Brasileira Cana-de- açúcar', V. 4 - SAFRA 2021/22 N.4 - Quarto levantamento | ABRIL 2022.
- CUADRA, S. V. et al. A biophysical model of Sugarcane growth. **GCB Bioenergy**, 2011.
- DELGADO, R. C. et al. Spectral classification of planted area with sugarcane through the decision tree. **Rev. Bras. Eng. Agric**, n. 32, p. 369-380, 2012.
- DEMATTÊ, J. A. M. et al. Assessment of sugarcane harvesting residue effects on soil spectral behavior. **Scientia Agricola**, v. 73, n. 2, 2016.
- DUFT, D. G. et al. **Estimação da produtividade dos resíduos da cana-de-açúcar por meio do sensor MODIS**. Foz do Iguaçu: Simposio Brasileiro de Sensoriamento Remoto. 2013.
- DUVEILLER, G.; LÓPEZ-LOZANO, R.; BARUTH, B. Enhanced processing of 1-km spatial resolution fAPAR time series for sugarcane yield forecasting and monitoring. **Remote Sensing**, v. 5, p. 1091-1116, 2013.
- DWYER, J. L. et al. Analysis Ready Data: Enabling Analysis of the Landsat Archive. **Remote Sens.**, v. 9, n. 1363, p. 10, 2018.
- ENNOURI, K.; KALLEL, A. Remote Sensing: An Advanced Technique for Crop Condition Assessment. **Mathematical Problems in Engineering**, v. 19, 2019.
- EVERINGHAM, Y. et al. Advanced satellite imagery to classify sugarcane crop characteristics. **Agronomy for Sustainable Development volume**, v. 27, p. 111-117, 2007.
- FAO. FAOSTAT - CROPS. Disponível em: <<http://www.fao.org/faostat/>>. Acesso em: 02 jan. 2022.
- FERREIRA, M. P.; ALVE, D. S.; SHIMABUKURO, Y. E. Forest dynamics and land-use transitions in the Brazilian Atlantic Forest: the case of sugarcane expansion. **Regional Environmental Change**, v. 15, p. 365-377, 2014.
- GUO, W. et al. Data-driven precision agriculture, in Soil-Specific Farming. **Precision Agriculture**, p. 353– 372, 2015.

- HOSSAIN, M. D.; CHEN, D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 150, p. 115-134, 2019.
- IMMITZER, M.; VUOLO, F.; ATZBERGER, C. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. **Remote Sens.**, v. 8, n. 3, 2016.
- JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. New York: Pearson, 1996.
- JINDO, K.; KOZAN, O.; ISEKI, K. Potential utilization of satellite remote sensing for field-based agricultural studies. **Chemical and Biological Technologies in Agriculture**, v. 8, n. 58, 2021.
- JOHANSEN, K. et al. Using GeoEye-1 Imagery for Multi-Temporal Object-Based Detection of Canegrub Damage in Sugarcane Fields in Queensland, Australia. **GIScience & Remote Sensing**, v. 55, 2018.
- JOHNSON, B.; SCHEYVENS, H.; SHIVAKOTI, B. R. An ensemble pansharpening approach for finer-scale mapping of sugarcane with Landsat 8 imagery. **Int. J. Appl. Earth Obs. Geoinformation**, v. 6, n. 3, 2014.
- KLAUS, S. The Fourth Industrial Revolution. **WEF**, 2021. Disponível em: <<https://www.weforum.org/about/the-fourth-industrial-revolution-by-klaus-schwab>>. Acesso em: 2021 dez. 21.
- LISBOA, I. P. et al. Prediction of Sugarcane Yield Based on NDVI and Concentration of Leaf-Tissue Nutrients in Fields Managed with Straw Removal. **Agronomy**, v. 8, n. 9, p. 196, 2018.
- LOFTON, J. et al. Estimating sugarcane yield potential using an in-season determination of normalized difference vegetative index. **Sensors**, v. 12, n. 6, 2012.
- LUCIANO, A. C. D. S. et al. Generalized space-time classifiers for monitoring sugarcane areas in Brazil. **Remote Sensing of Environment**, v. 215, p. 438-451, 2018.
- LUCIANO, A. C. D. S. et al. Empirical model for forecasting sugarcane yield on a local scale in Brazil using Landsat imagery and random forest algorithm. **Computers and Electronics in Agriculture**, v. 184, p. 106063, 2021.
- LUNA, I.; LOBO, A. Mapping Crop Planting Quality in Sugarcane from UAV Imagery: A Pilot Study in Nicaragua. **Remote Sens.**, v. 8, n. 6, p. 500, 2016.
- MELLO, M. A. V. A. R. F. C. D. R. C. A. D. A. A. M. P. Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, v. 123, p. 553-562, 2012.
- MOLIJN, R. A. et al. Sugarcane productivity mapping through C-band and L-band SAR and optical satellite imagery. **Remote Sensing**, v. 11, p. 1109, 2019.
- MORAES, M. A. F. D.; OLIVEIRA, F. C. R.; DIAZ-CHAVEZ, R. A. Socio-economic impacts of Brazilian sugarcane industry. **Environmental Development**, v. 16, p. 31-43, 2015.
- MORAN, M. S.; INOUE, Y.; BARNES, E. M. Opportunities and limitations for image-based remote sensing in precision crop management. **Remote Sensing of Environment**, v. 61, n. 3, 1997.
- MUIR, J.; ROBSON, A.; RAHMAN, M. M. Using Satellite Imagery to Predict Cane Yield and Variability. **Research UNE**, 2018.

- ORÉ, G. et al. Predicting Sugarcane Harvest Date and Productivity with a Drone-Borne Tri-Band SAR. **Remote Sensing**, v. 1734, p. 147, 2022.
- PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, p. 217-222, 2004.
- PEREIRA, A. R.; BARBIER, V.; NOVA, I. A. V. Climatic conditioning of flowering induction in sugarcane. **Agricultural Meteorology**, v. 29, n. 2, p. 103-110, 1983.
- PICOLI, M. C. A. et al. Sugarcane drought detection through spectral indices derived modeling by remote-sensing techniques. **Modeling Earth Systems and Environment**, v. 5, p. 1679-1688, 2019.
- PICOLI, M. C. A.; DUFT, D. G.; MACHADO, P. G. Identifying drought events in sugarcane using drought indices derived from Modis sensor. **Pesquisa Agropecuária Brasileira**, v. 5, n. 11, 2017.
- RAHMAN, M. M.; ROBSON, A. Integrating Landsat-8 and Sentinel-2 Time Series Data for Yield Prediction of Sugarcane Crops at the Block Level. **Remote Sensing**, v. 12, p. 1313, 2020.
- RUDORFF, B. F. T. et al. Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using Landsat Data. **Remote Sens.**, v. 2, n. 4, p. 1057-1076, 2010.
- RUXTON, C. H. S.; GARDNER, E. J.; MCNULTY, H. M. Is sugar consumption detrimental to health? A review of the evidence 1995-2006. **Crit Rev Food Sci Nutr**, v. 50, p. 1-19, 2010.
- SANCHES, G. M. et al. The potential for RGB images obtained using unmanned aerial vehicle to assess and predict yield in sugarcane fields. **International Journal of Remote Sensing**, p. 5402-5414, 2018.
- SCARPARI, M. S.; BEAUCLAIR, E. G. F. D. Sugarcane maturity estimation through edaphic-climatic parameters. **Scientia Agricola**, v. 61, n. 5, 2004.
- SCHULTZ, B. et al. Self-Guided Segmentation and Classification of Multi-Temporal Landsat 8 Images for Crop Type Mapping in Southeastern Brazil. **Remote Sens.**, v. 7, n. 11, p. 14482-14508, 2015.
- SHEPHERD, M. et al. Priorities for science to overcome hurdles thwarting the full promise of the 'digital agriculture' revolution. **Journal of the Science of Food and Agriculture**, p. 5083-5092, 2020.
- SILVA, A. L.; ALVES, D. S.; FERREIRA, M. P. Landsat-Based Land Use Change Assessment in the Brazilian Atlantic Forest: Forest Transition and Sugarcane Expansion. **Remote Sens**, v. 10, n. 7, p. 996, 2018.
- SIMÕES, M. D. S.; ROCHA, J. V.; LAMPARELLI, R. A. C. Orbital spectral variables, growth analysis and sugarcane yield. **Scientia Agricola**, v. 66, n. 4, 2009.
- SMEETS, E. et al. The sustainability of Brazilian ethanol—An assessment of the possibilities of certified production. **Biomass and Bioenergy**, v. 32, n. 8, p. 781-813, 2008.
- SOUZA, C. H. W. D. et al. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture**, v. 143, p. 49-56, 2017.
- STEVENSON, J. A.; RANDS, R. D. annotated list of the fungi and bacteria associated with sugarcane and its products. **Hawaiian planters' record**, v. 42, n. 4, p. 247, 2013.

- TERUEL, D. A.; BARBIERI, V.; JR, L. A. F. Sugarcane leaf area index modeling under different soil water conditions. **Scientia Agricola**, v. 54, 1997.
- TOWNSEND, L. et al. Enhanced broadband access as a solution to the social and economic problems of the rural digital divide. **Local Economy**, v. 28, p. 580-595, 2013.
- TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A Review on UAV-Based Applications for Precision Agriculture. **Information**, v. 10, n. 11, p. 349, 2019.
- UPADHYAY, P. et al. Effect on specific crop mapping using WorldView-2 multispectral add-on bands: soft classification approach. **Journal of Applied Remote Sensing**, v. 6, n. 1, 2012.
- USABORISUT, P. Progress in Mechanization of Sugarcane Farms in Thailand. **Sugar Tech**, v. 20, p. 116-121, 2019.
- VICENTE, L. E. et al. NDVI temporal series from the SPOT Vegetation sensor and SAM algorithm applied to sugarcane mapping. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, 2012.
- VIRNODKAR, S. S. et al. Application of Machine Learning on Remote Sensing Data for Sugarcane Crop Classification: A Review. **Lecture Notes in Networks and Systems**, v. 93, 2020.
- WANG, M. et al. Mapping sugarcane in complex landscapes by integrating multi-temporal Sentinel-2 images and machine learning algorithms. **Land Use Policy**, v. 88, p. 104109, 2019.
- WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, 2020.
- WHITE, J. W. et al. Evaluation of Satellite-Based, Modeled-Derived Daily Solar Radiation Data for the Continental United States. **Agronomy Journal**, p. 1242-1251, 2011.
- WIEDENFELD, R. P. Effects of irrigation and N fertilizer application on sugarcane yield and quality. **Field Crops Research**, v. 43, n. 3, p. 101-108, 1995.
- WIEGAND, C. et al. Soil Salinity Effects on Crop Growth and Yield - Illustration of an Analysis and Mapping Methodology for Sugarcane. **Journal of Plant Physiology**, v. 148, p. 418-424, 1996.
- WOLFERT, S. et al. Big data in smart farming – a review. **Agric Syst**, v. 153, p. 69– 80, 2017.
- XU, J.-X. et al. Estimation of Sugarcane Yield Using a Machine Learning Approach Based on UAV-LiDAR Data. **Remote Sens.**, v. 12, n. 17, p. 2823, 2020.
- YANG, X.; ZHOU, Q.; MELVILLE, M. Estimating local sugarcane evapotranspiration using Landsat TM image and a VITT concept. **International Journal of Remote Sensing**, v. 18, 1997.
- ZHAO, D.; LI, Y.-R. Climate Change and Sugarcane Production: Potential Impact and Mitigation Strategies. **International Journal of Agronomy**, v. 15, 2015.



### **3. REGIONALIZAÇÃO DAS ÁREAS PRODUTORAS DE CANA-DE-AÇÚCAR NO CENTRO-SUL DO BRASIL ATRAVÉS DE ZONEAMENTO AGROCLIMÁTICO E COMPORTAMENTO DE ÍNDICE DE VEGETAÇÃO**

#### **Resumo**

A cana-de-açúcar tem tido uma dinâmica espacial bastante grande nos últimos vinte anos, essa dinâmica fez com que fosse necessária a ocupar áreas marginais além das tradicionais já produtivas. A produtividade das áreas depende do clima do solo e do manejo e entender o máximo potencial é importante para tomada de decisão para investimentos assertivos sobre aquisição de áreas ou expansão. Além das variáveis tradicionais, as mudanças climáticas vêm alterando a dinâmica dos zoneamentos tradicionais da cultura no país. Diante desse contexto, o objetivo desse trabalho foi criar um zoneamento agroclimático para a cana-de-açúcar utilizando dois cenários com o objetivo de garantir áreas homogêneas para futuros estudos. Como principal resultado, foi possível criar 17 regiões no Centro Sul do Brasil que possuem características semelhantes para aplicação de modelos.

**Palavras-chave:** SIG, Balanço Hídrico, produtividade

#### **Abstract**

Sugarcane has had a very large spatial dynamic in the last twenty years, this dynamic has made it necessary to occupy marginal areas in addition to the traditional ones that are already productive. Area productivity depends on soil climate and management, and understanding the maximum potential is important for decision making for assertive investments on land acquisition or expansion. In addition to traditional variables, climate change has been altering the dynamics of traditional crop zoning in the country. Given this context, the objective of this work was to create an agroclimatic zoning for sugarcane using two scenarios with the objective of guaranteeing homogeneous areas for future studies. As a main result, it was possible to create 17 regions in the Center South of Brazil that have similar characteristics for the application of models.

**Keywords:** GIS, water balance, yield

#### **3.1 Introdução**

A produção de cana-de-açúcar no Brasil aumentou de maneira bastante intensa nos últimos vinte anos por conta da expansão dos motores flex e o aumento da mistura do etanol na gasolina de maneira constante (PICOLI; MACHADO, 2021). Esse aumento na produção deveu-se a uma grande expansão na área plantada e esse aumento da área plantada em um curto espaço de tempo não garantiu que os canaviais ocupassem os melhores solos e zonas climáticas favoráveis (SPERA; VANWEYA; JACK, 2017).

A produtividade máxima potencial da cana-de-açúcar varia de acordo com o clima, o solo e os fatores de manejo (DIAS; SENTELHAS, 2018). A modelagem é capaz de simular de forma bastante fiel o clima e o solo, porém o manejo é uma variável não tão simples de se



capturar em escala regional, desta forma, encontrar alternativas para tal é essencial para um melhor aproveitamento do mesmo (DIAS *et al.*, 2021).

O entendimento dos potenciais produtivos é algo muito importante para os produtores, investidores, tomadores de decisão e governantes para poderem guiar investimentos e subsidiar as produções com as melhores práticas para cada região (SPAROVEK *et al.*, 2007). Antes de implantar um novo projeto é necessário que se conheça o potencial de produção daquela área e o histórico de produção dela, desde que essa já tenha um histórico produtivo na área.

Ao longo dos últimos anos as mudanças climáticas globais vêm trazendo alguns eventos climáticos extremos e alterações na dinâmica climática em patamares não registrados historicamente. Para cana-de-açúcar é preciso revisitar os modelos e zoneamentos históricos da cultura e entender se as mudanças climáticas foram responsáveis por uma alteração na dinâmica espacial da produção (SILVA *et al.*, 2021).

O zoneamento de áreas não somente para fins legais e políticos como o ZAE (Zoneamento Agroecológico de Cana-de-Açúcar), mas também para um olhar mais sustentável como de Hernandez *et al.* (2021) são essenciais para o desenvolvimento da cultura de maneira organizada, porém economicamente ainda faltam materiais que organizem o território de forma a garantir a produção o retorno que ele precisa.

A forma com que a cana-de-açúcar se desenvolve é crucial identificar quando esse canavial é plantado, colhido e quando atinge seu pico vegetativo. Utilizar-se de séries temporais de índices de vegetação de satélites de alta resolução temporal é uma forma eficaz de caracterizar essas diferenças entre plantas e locais de produção (RUDORFF *et al.*, 2009).

Desta forma, o objetivo desse trabalho foi criar regiões para avaliações através de um zoneamento de produção agroclimático com caráter produtivo e séries temporais de índices de vegetação para o Centro-Sul do Brasil e criar áreas homogêneas de produção para futuros estudos.

### **3.2 Materiais e Métodos**

#### Área de estudo:

A área de estudo é toda a área cultivada com cana-de-açúcar na região Centro-Sul e a região entorno dela. No mapa da Figura 4 é possível observar toda a região estudada com os 692 pontos do GRID do NASAPOWER.

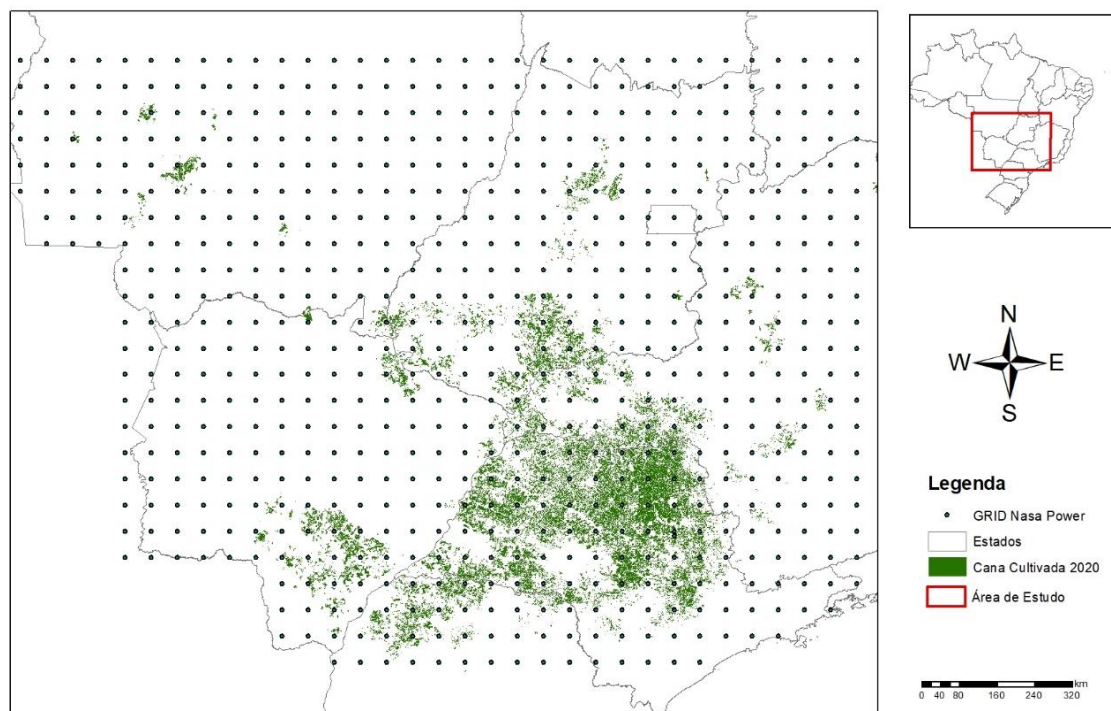


Figura 4: Área de estudo do trabalho

A área de estudo compreende uma área com 10,8Mha cultivados com cana-de-açúcar na safra 2020-21, desta forma, a maior parte da área cultivada e que pode ter expansão de canaviais no país. Esse dado foi obtido através do mapa da plataforma MapBiomas (MAPBIOMAS, 2021).

#### Dados meteorológicos e de solo:

Os dados meteorológicos utilizados nesse trabalho foram obtidos através da plataforma NASA/POWER, que traz um dado proveniente de um modelo de assimilação meteorológica, ou seja, ele faz uma união entre dados de satélites, radares e estações meteorológicas, reanalisa, interpola e reamostra em uma grade de 0,5° para todo o globo terrestre. Dessa forma, é possível ter informação diária para todo o globo, sem dados faltantes em uma longa série temporal em uma malha contínua (WHITE *et al.*, 2011). A possibilidade de ter-se dados contínuos, faz com que seja possível avaliar com maior precisão mesmo que se perca em assertividade. Dessa forma, a utilização de 692 pontos na grade fez com que fosse possível ter uma dimensão das condições atmosféricas de toda a região sem ter perdas locais como é colocado por (BOSILOVICH *et al.*, 2017). Os dados foram coletados de 01/01/2000 a 31/12/2020.

Os dados de solo foram levantados da base de mapas do Sistema Brasileiro de Classificação de Solos (SANTOS *et al.*, 2018) que possui uma base de dados de todo o país. Em cada ponto da grade foi feito um cálculo de qual é a proporção da textura de solo na área envolvente (raio de 0,25°). Dessa maneira, foi calculada uma capacidade de armazenamento de água disponível (CAD) ponderada para cada ponto de acordo com (PRADO, 2013) e (MONTEIRO; SENTELHAS, 2014). A Figura 5 mostra a variação da CAD em cada um dos pontos da grade analisados.

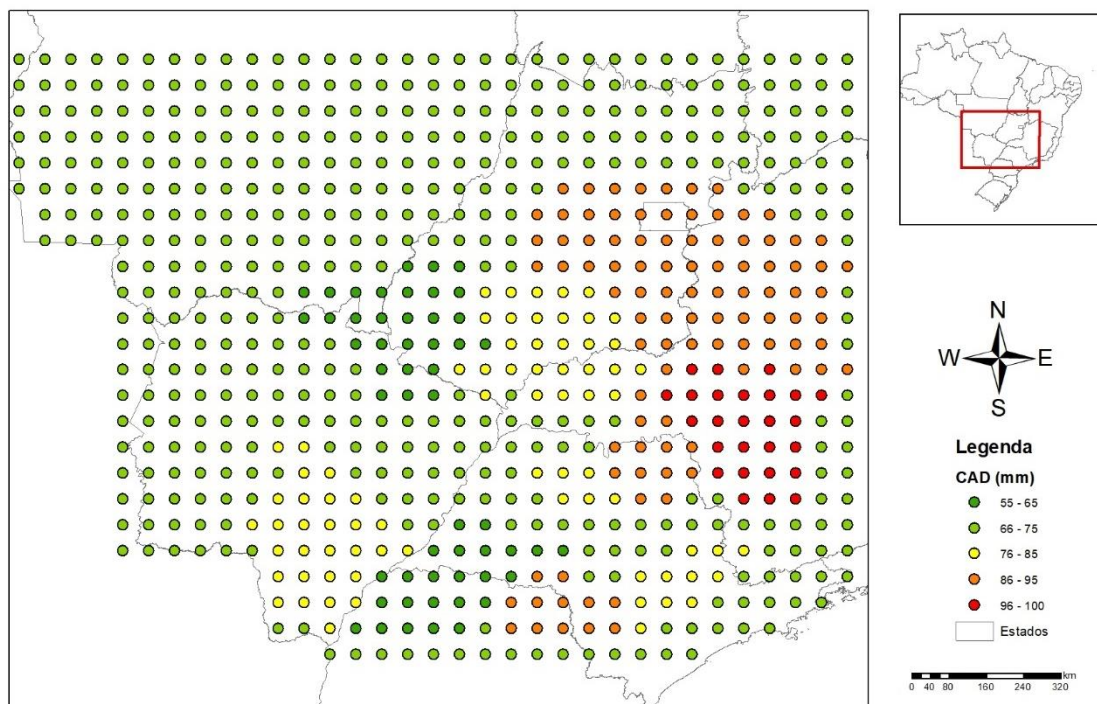


Figura 5: CAD calculada para cada ponto do estudo. Nos pontos sem a presença de cana, adotou-se uma CAD fixa de 75mm

#### Dados de produtividade:

Os dados de produtividade utilizados nesse estudo são oriundos do Benchmark CTC®. O Benchmark é um banco de dados auto declaratório em que as usinas inserem todos os meses a produtividade atual e visualizam sua posição em relação às demais. Para o estudo foram usadas 184 usinas com 5 anos de dados (safra 2015-16 a 2019-20) e a produtividade média da cana planta. Dessa forma, avalia-se o maior potencial produtivo independente de manejo, trazendo para a análise o potencial edafoclimático como o principal fator. Esses dados foram anonimizados e regionalizados para o ponto do grid mais próximos à área da usina para que sejam mantidos os padrões de confidencialidade da fonte.

### Balanço hídrico:

Por ser o hídrico um dos fatores que mais atuam na produtividade das culturas, faz-se necessário incluir esta variável nos modelos de estimativa da produtividade associando, assim, os elementos chuva e evapotranspiração sobre a produtividade, para fases fenológicas da cultura (DELGADO-ROJAS; BARBIERI, 1999).

Para a estimativa do balanço hídrico sequencial diário adotou-se o procedimento proposto por Thornthwaite (1955), utilizando-se o valor variável por ponto para o valor da capacidade de água disponível no solo (CAD) (DOORENBOS; KASSAM, 1979).

Quando as necessidades hídricas da cultura são atendidas plenamente, a evapotranspiração real (ET<sub>r</sub>) é igual à evapotranspiração da cultura (ET<sub>c</sub>). Todavia, quando o suprimento é insuficiente tem-se que ET<sub>r</sub> < ET<sub>c</sub> e a perda de produtividade é proporcional ao estresse hídrico sofrido pela cultura. A produtividade real (PR) é a produtividade penalizada (GAP) pelo estresse hídrico pode ser chamada de gap de produtividade (1 - ET<sub>r</sub>/ET<sub>c</sub>), em função da sua sensibilidade ao déficit hídrico (K<sub>y</sub>), utilizando-se a Eq. 1.

$$PR = GAP * [1 - k_y * (1 - \frac{ET_r}{ET_c})] \quad (1)$$

em que: k<sub>y</sub> - 1,20 para todo o ciclo da cultura da cana-de-açúcar (DOORENBOS; KASSAM, 1979).

Foi criado um modelo computacional para calcular o GAP para todos os 692 pontos do Centro-Sul do Brasil no acumulado e na média da série dos 20 anos-safra analisados para poder entender qual é a interação de déficit de evapotranspiração e de produtividade par as áreas produtivas de cana-de-açúcar no país.

### Fluxograma de operação dos mapas:

A operacionalização dos processos de cruzamentos dos mapas está descrita na Figura 6.

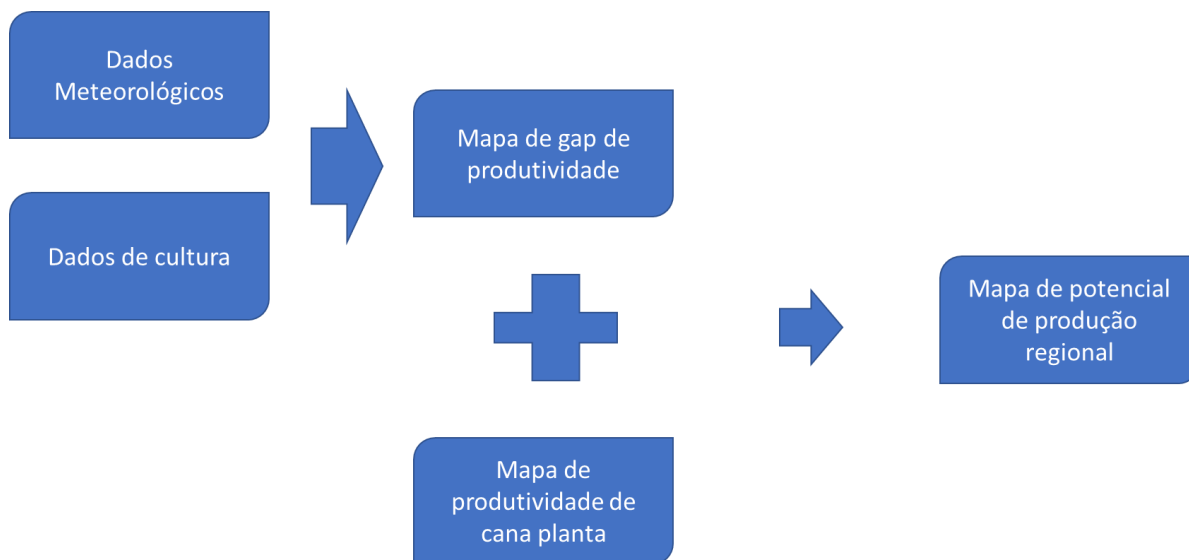


Figura 6: Fluxograma de operações de mapas para obtenção do potencial de produção regional

#### Metodologia de criação dos mapas:

Para a criação do mapa de Gap de produtividade, foi utilizada a saída do modelo ZAE (1-ETr/ETc). Foi utilizada a função de distribuição de intervalos por 1 desvio padrão de diferença. Foi invertido o valor de maior valor para menor déficit.

Para o mapa de produtividade de cana planta, foi especializada a produtividade de 184 usinas do Centro-Sul através da interpolação do Inverso do Quadrado da Distância e a malha interpolada foi classificada através da função de distribuição de intervalos por 1 desvio padrão de diferença.

Os mapas classificados foram normalizados para um novo mapa variando de 0 a 1 através da função Fuzzy Membership com caracterização linear no ArcMap 10.8.

Os mapas normalizados de cana plantam e de gap de produtividade foram somados com a finalidade de garantir maiores valores para melhores áreas e menores valores para piores áreas. Usou-se a média e um desvio padrão para classificar as áreas em boas, médias e ruins para a produção de cana-de-açúcar.

#### Índice de Vegetação Melhorado (EVI):

As imagens dos sensores TERRA e AQUA do satélite MODIS são adequadas para monitoramento agrícola devido à alta resolução temporal e resolução espacial moderada (SAKAMOTO *et al.*, 2005).

As imagens MODIS têm sido usadas tanto no mapeamento quanto no monitoramento de culturas agrícolas (GRZEGOZEWSKI *et al.*, 2016), e especificamente para a cana-de-açúcar que é uma cultura semiperene (ADAMI *et al.*, 2012). O uso de produtos de índices de vegetação MODIS, como EVI (Enhanced Vegetation Index) e NDVI (Normalized Difference Vegetation Index), permite estabelecer os dados espectro temporais padrão para identificar diferentes culturas agrícolas e mapear grandes extensões territoriais com repetitividade e baixo custo. As séries temporais dos índices de vegetação, utilizadas em mapeamentos, também podem ser utilizadas para examinar as mudanças na superfície da Terra, encontrar evidências de mudanças no desenvolvimento da vegetação e demonstrar padrões de dinâmica temporal (JIA *et al.*, 2011).

Foram extraídas séries temporais para toda a área de cana mapeada para cada município canavieiro do país das imagens de EVI do sensor MODIS de 2000 a 2020 e feito um tratamento nos dados para filtrar dados nulos e com problemas de nuvens.

### **3.3 Resultados e Discussão**

É possível observar que a perda de produtividade devido a fatores climáticos varia de 28 a 74% dentro das áreas produtoras de cana-de-açúcar no Brasil. As áreas mais ao sul possuem as menores perdas por déficit de evapotranspiração, enquanto as áreas mais ao norte possuem os maiores déficits. Esse comportamento é diretamente ligado ao comportamento da chuva, radiação e temperaturas. A Figura 7 mostra o mapa de classes de perdas de produção percentuais.

Comparando-se com o trabalho de Monteiro e Sentelhas (2014), é possível observar que existem algumas diferenças que provavelmente são devidas a quantidade de dados meteorológicos utilizados e aos dados de solos serem mais robustos do que a fonte utilizada naquele trabalho. Quando comparado ao trabalho de (MARIN *et al.*, 2016), é possível observar uma tendência um pouco maior de regionalização norte-sul enquanto lá é de leste-oeste, porém os valores são semelhantes.

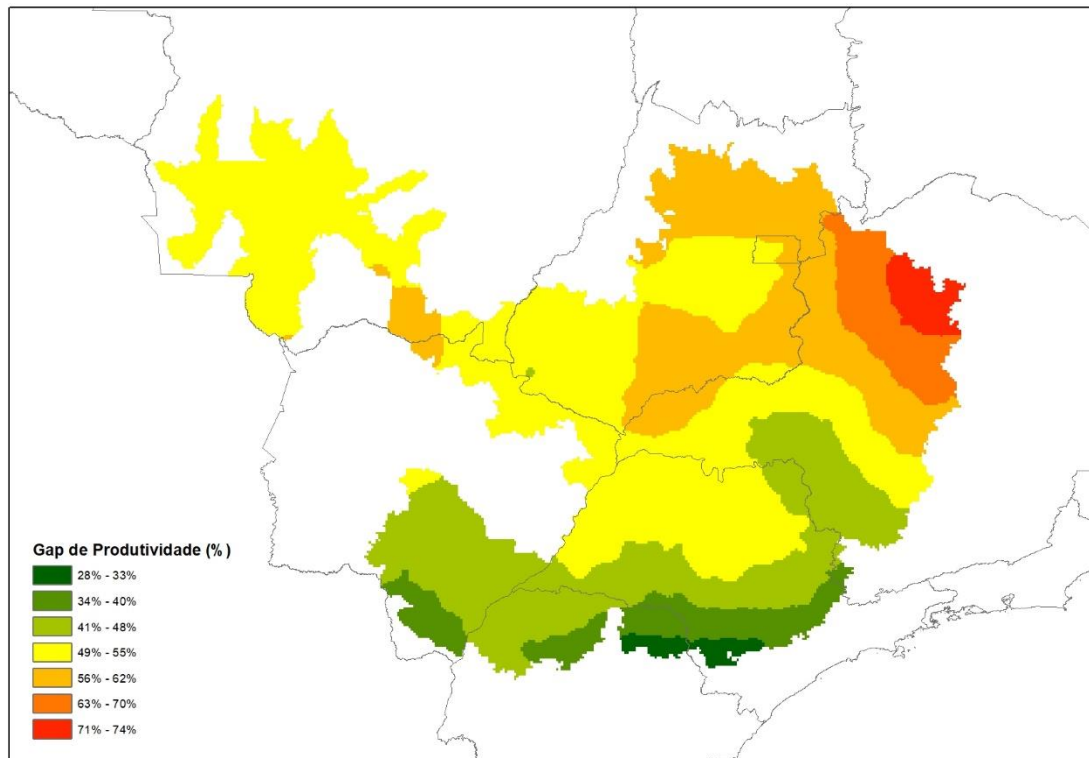


Figura 7: Perdas de produção percentuais por classes divididas por desvio padrão.

Para tanto, entende-se que para levar em consideração demais fatores na produção atual como o manejo e as condições da área atualmente é necessário fazer uma análise também da produção de cada área para balizar os resultados potenciais. Desta forma, optou-se por utilizar-se os dados históricos máximos de cana planta de cinco safras para identificar o real potencial das áreas em produzir cana-de-açúcar naquele local. A Figura 8 mostra o mapa da distribuição de produtividade de cana-de-açúcar em estágio cana planta entre as safras 2015-16 até 2019-20.

No mapa da Figura 8 a classe 1 representa as áreas com as menores produtividades e a classe 6 as áreas com as maiores produtividades. Essa variável é bastante importante para mostrar o potencial do manejo associado ao clima e solo das regiões associadas. Ao unir essa informação com o déficit de evapotranspiração, é possível identificar qual é de fato a zone relevante de alta e baixa produção em cada região.

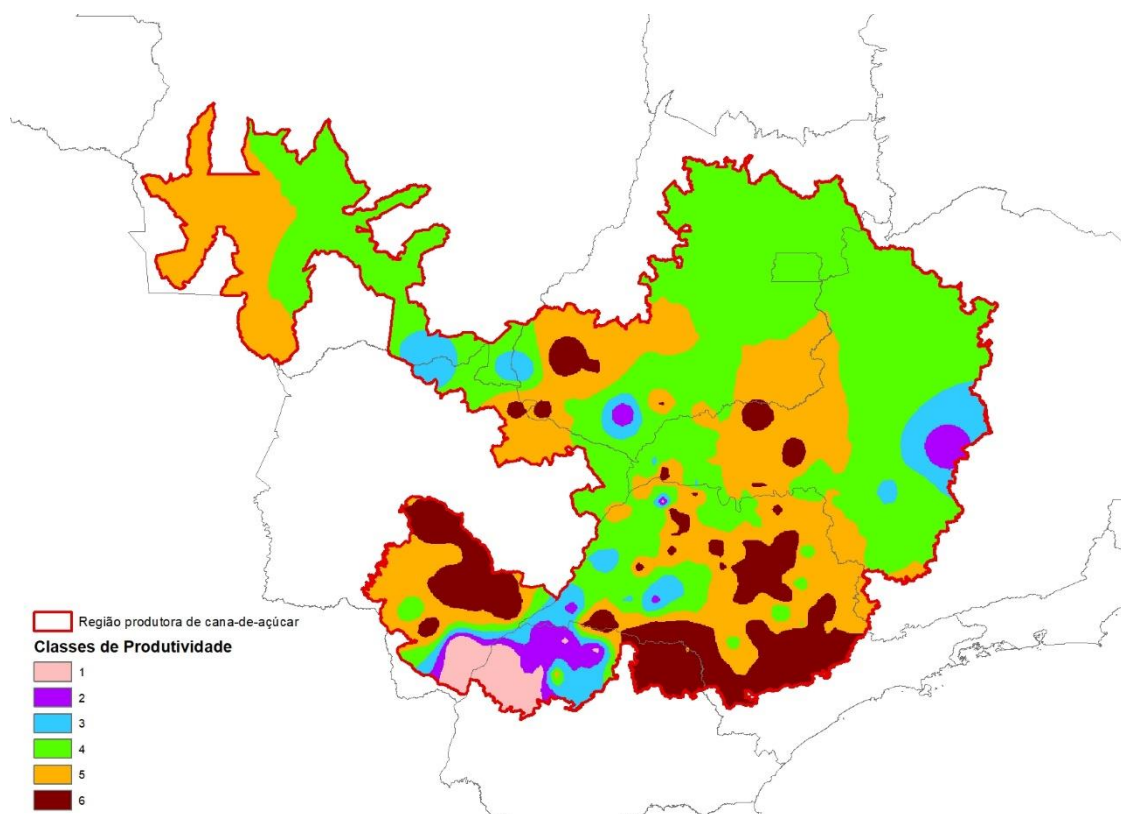


Figura 8: Mapa de produtividade de cana-de-açúcar em estágio cana planta segmentado em classes por um desvio padrão.

Na sequência os mapas foram normalizados através da ferramenta “Fuzzy Membership” com a função linear no ArcMap 10.8. Essa linearização trouxe todos os dados para a mesma base, não importando que o mapa de déficit de evapotranspiração tinha sete classes e o mapa de produtividade tinha seis classes quando divididos pelo desvio padrão. Foi feita então a união dos mapas usando dois diferentes parâmetros. No primeiro, ambos com o mesmo peso e no segundo, considerando que o fator climático é responsável por dois terços da produção (MONTEIRO; SENTELHAS, 2017), o mapa de déficit teve um peso de 0,75 (75%) enquanto o mapa de produtividade da cana planta teve um peso de 0,25 (25%). Esses mapas foram gerados e comparados, sendo a Figura 9 o mapa com pesos iguais e o mapa da Figura 10 o mapa com pesos de 0,75 para o déficit e 0,25 para produtividade.



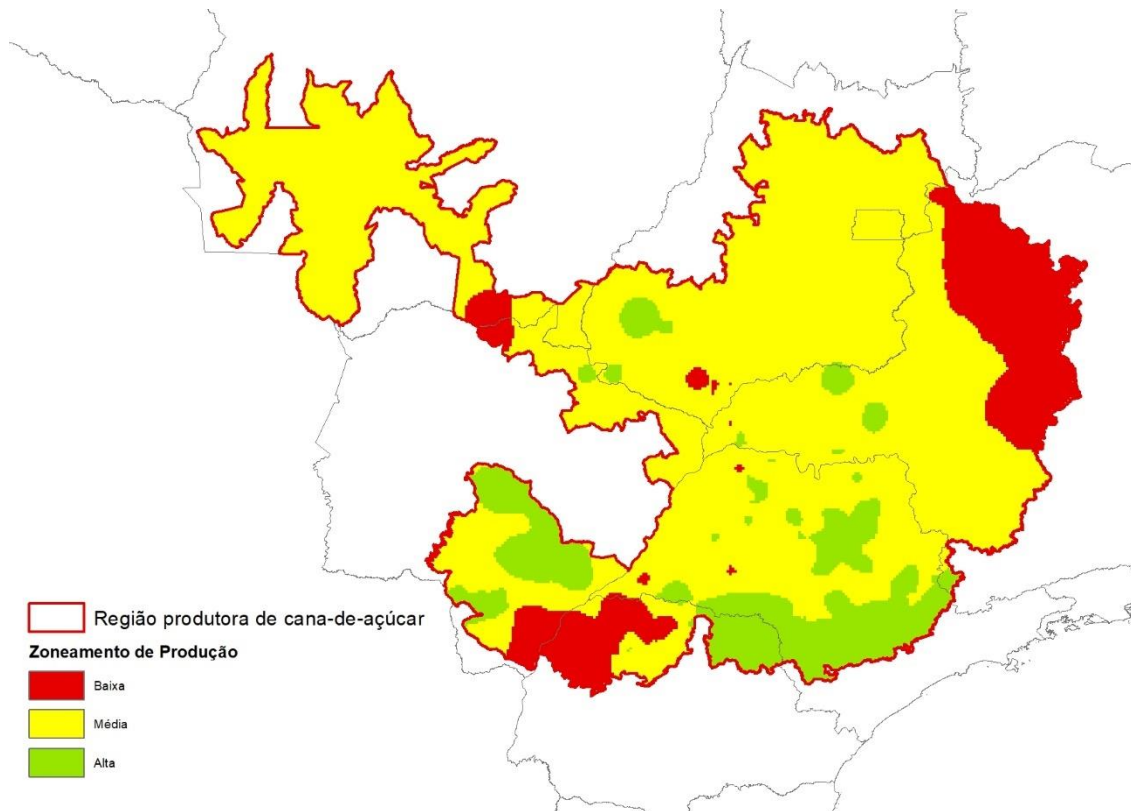


Figura 9: Mapa de zoneamento de produção com os mesmos pesos e divididos em classes com um desvio padrão.

Ao comparar o mapa da Figura 9 com o mapa da Figura 10, é possível entender que existe uma maior contribuição das menores e maiores produtividades nas regiões com menor e maior déficit, consecutivamente, na Figura 9. Ao utilizar a produtividade da cana planta como uma variável de mesmo peso, é possível ver a criação de mais zonas ligadas ao manejo local que advém dessa variável resposta que é a produtividade média da cana planta em 5 safras. Já quando é utilizado o dado da literatura que mostra que o clima é responsável por dois terços da produtividade na modelagem para o Centro-Sul do Brasil, foi possível verificar uma tendência muito mais semelhante aos mapas modelados em função exclusiva do clima e solo da região (Figura 10).

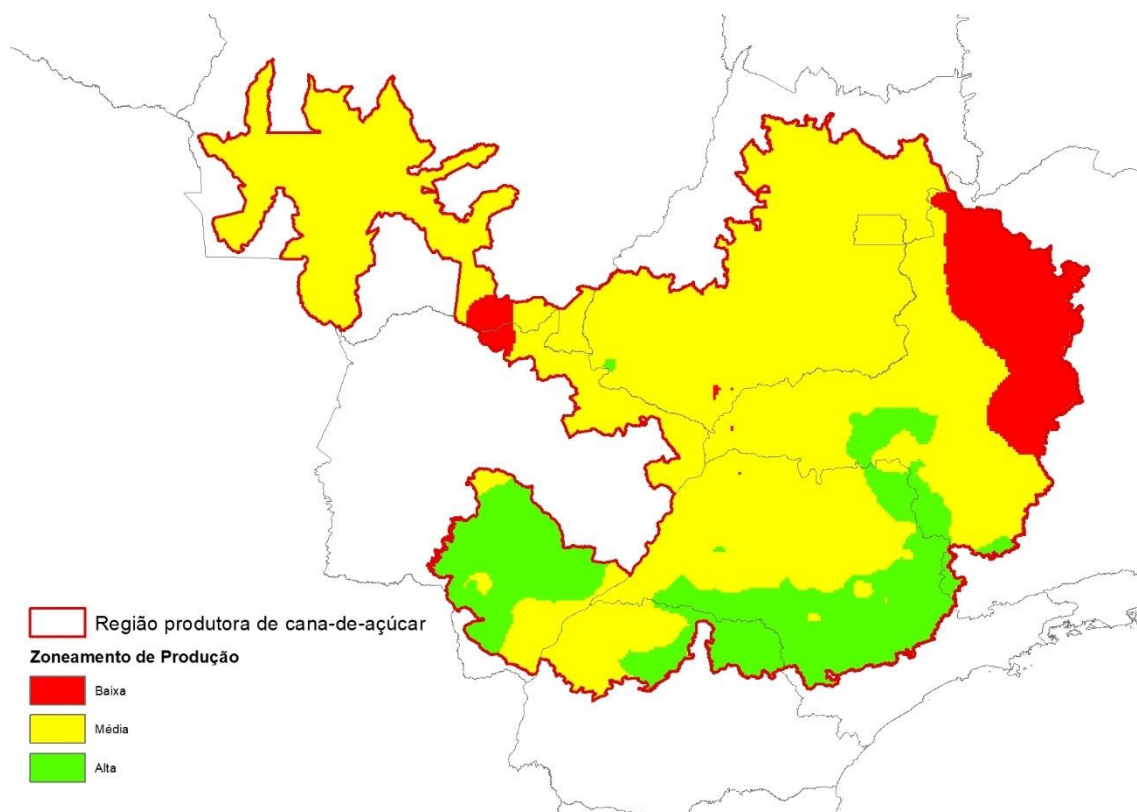


Figura 10: Mapa de zoneamento de produção com os pesos de 0,75 para o déficit de evapotranspiração e 0,25 para a produtividade da cana planta e dividido em classes com um desvio padrão.

Ao avaliar a cana-de-açúcar já cultivada hoje em cada uma dessas regiões é possível identificar as diferenças entre as classes e qual é o principal desvio por região. A Tabela 2 mostra a área em hectares por estado dividida em cada uma das classes das zonas de produção.

Tabela 2. Área de cana atual nas zonas de produção propostas

	Baixo		Médio		Alto	
	Iguais	Diferentes	Iguais	Diferentes	Iguais	Diferentes
GO	22.542	11.152	1.159.626	1.212.895	45.903	4.024
MG	70.328	70.328	964.030	847.956	77.365	193.439
MS	68.109	18.882	445.195	305.453	356.001	544.970
MT	8.710	8.710	262.791	262.791		
PR	440.010		172.270	553.726	66.266	124.820
SP	39.116	2.460	4.391.212	4.446.035	1.579.249	1.561.083

É possível notar que em Goiás enquanto a classe baixo cai em 50% entre os mapas com pesos iguais e diferentes, para a classe alto o residual é de 10%. Em Minas Gerais a classe alto teve um aumento de quase três vezes. Em Mato Grosso do Sul uma queda da classe baixo de 70% e um aumento de 30% na classe alto. No Mato Grosso não houve alteração. No Paraná, a classe baixo deixa de existir com pesos diferentes enquanto médio e alto sobem. E em São Paulo existe uma queda de 90% da classe baixo.

Dessa forma fica claro que com pesos diferentes e a variável climática sendo mais importante, mesmo as regiões que possuem problemas de manejo já consolidados não são penalizadas com menores potenciais de produção, da mesma forma, regiões com manejos diferenciados, como por exemplo irrigação, não colaboram positivamente para um maior potencial de produção de uma região.

Usando a abordagem de pesos iguais, é possível ter essas conclusões e embora o clima seja responsável por dois terços da produção, as práticas locais de manejo já consagradas por algum tempo, podem ser consideradas variáveis importantes para o zoneamento da produção de cana-de-açúcar no Centro-Sul do Brasil.

Ao avaliar a média do índice de vegetação melhorado (EVI) para os anos de 2000-2020, foi possível agrupar os municípios que possuíam um comportamento semelhante. Além disso, usou-se o mapa da Figura 10 como um fator na análise e através da análise spatial-linkage em um pacote no ArcMap 10.8 foi possível criar 17 regiões homogêneas. O gráfico da Figura 11 mostra essa distribuição nas regiões criadas com os nomes arbitrariamente dados.

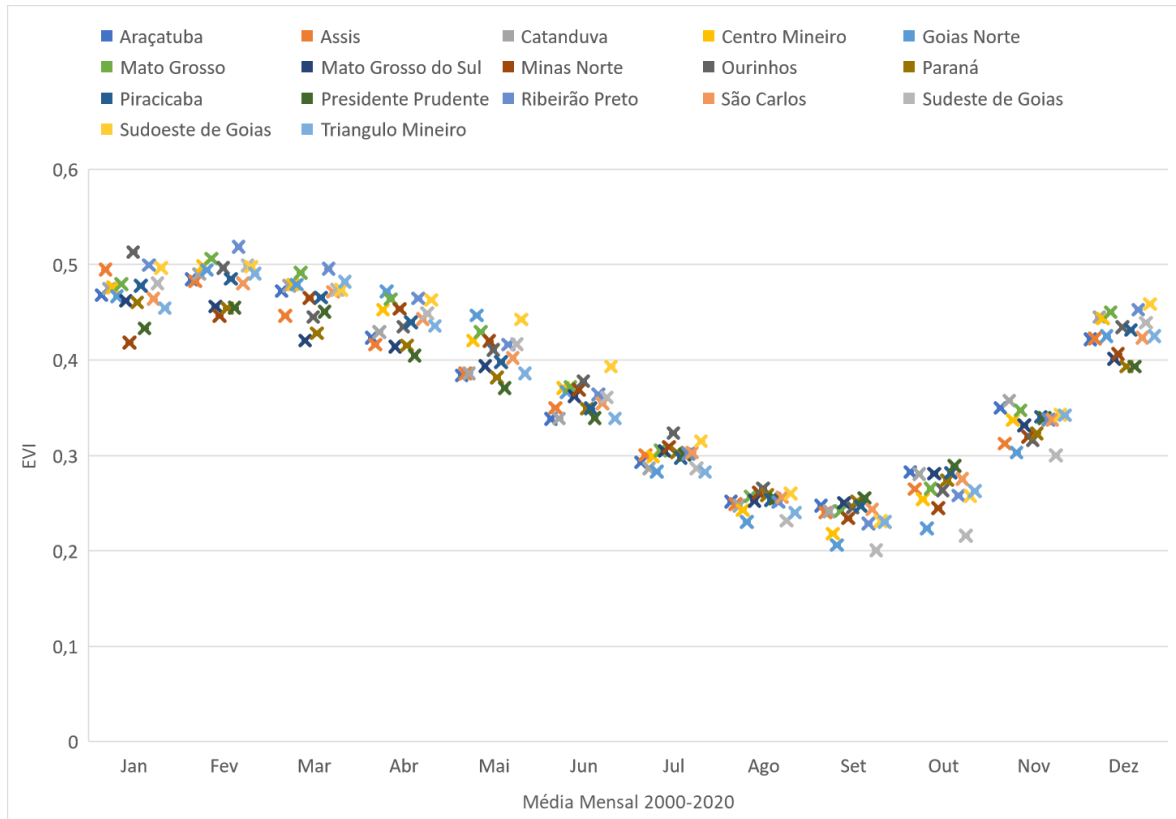


Figura 11: Distribuição mensal das médias de índices de vegetação EVI por região proposta

Especialmente as regiões ficaram dispostas de forma que atendam ao critério de ambas as entradas. A Figura 12 mostra o mapa das regiões propostas.

Com base nessas análises é possível observar que existem locais com mais e menos presença de cana-de-açúcar em cada região e em diferentes potenciais de produção.

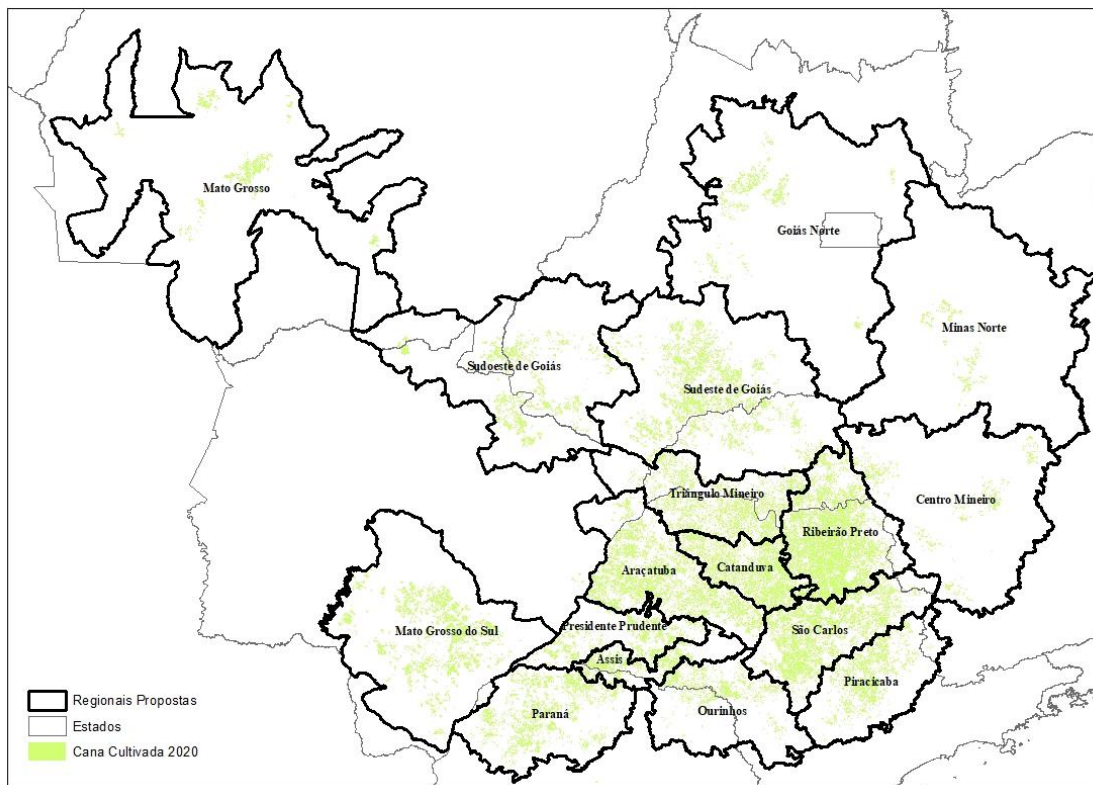


Figura 12: Mapa das 17 regionais propostas pelo estudo

### 3.4 Conclusão

Com esses mapas é possível não somente avaliar a produção atual e a implicação do potencial delas, mas também planejar de maneira mais assertiva a expansão do setor.

Comparando os resultados foi possível observar que para um cenário mais conservador pode-se adotar o mapa com pesos diferentes como o padrão, porém para um cenário mais arrojado o mapa com pesos iguais faz mais sentido porque traz o ponto da discussão do manejo à modelagem tradicional. Utilizar essa variável faz com que seja uma garantia de boas práticas ou não para o jogo. Em decisões financeiras essas práticas muitas vezes não são levadas em conta e podem inviabilizar projetos que podem parecer viáveis à primeira vista.

A regionalização mostra um novo horizonte para futuros trabalhos que precisem aplicar técnicas de aprendizado estatístico através de sensoriamento remoto para a cana-de-açúcar no país.

Este trabalho mostra que é possível entender o potencial de produção regional através de uma modelagem espacial e que essa modelagem pode ser revisitada constantemente usando um histórico mais recente, garantindo que as mudanças climáticas globais não interfiram no zoneamento.

## Referências

- ADAMI, M. et al. A web platform development to perform thematic accuracy assessment of sugarcane mapping in South-Central Brazil. **Remote Sensing**, p. 3201-3214, 2012.
- BOSILOVICH, M. G. et al. Atmospheric Water Balance and Variability in the MERRA-2 Reanalysis. **Journal of Climate**, p. 1177-1196, 2017.
- DELGADO-ROJAS, J. S.; BARBIERI. Modelo agrometeorológico de estimativa da produtividade da cana-de-açúcar. **Revista Brasileira de Agrometeorologia**, 1999.
- DIAS, H. B. et al. Sugarcane yield future scenarios in Brazil as projected by the APSIM-Sugar model. **Industrial Crops and Products**, v. 171, 2021.
- DIAS, H.; SENTELHAS, P. Sugarcane yield gap analysis in Brazil - A multi-model approach for determining magnitudes and causes. **Teh Science of the Total Environment**, v. 638, p. 1127-1136, 2018.
- DOORENBOS, J.; KASSAM, A. H. Yield response to water. **Irrigation and Drainage**, v. FAO 33, p. 172, 1979.
- GRZEGOZEWSKI, D. M. et al. Mapping soya bean and corn crops in the State of Paraná, Brazil, using EVI images from the MODIS sensor. **International Journal of Remote Sensing**, p. 1257-1275, 2016.
- HERNANDES, T. A. D. et al. Identifying suitable areas for expanding sugarcane ethanol production in Brazil under conservation of environmentally relevant habitats. **Journal of Cleaner Production**, v. 292, 2021.
- MAPBIOMAS, P. Coleção 5.0 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil, 2021. Acesso em: 22 jan. 2021.
- MARIN, F. R. et al. Prospects for Increasing Sugarcane and Bioethanol Production on Existing Crop Area in Brazil. **BioScience**, v. 66, p. 307-316, 2016.
- MONTEIRO, L. A.; SENTELHAS, P. C. Potential and Actual Sugarcane Yields in Southern Brazil. **Sugar Tech**, p. 264-276, 2014.
- MONTEIRO, L. A.; SENTELHAS, P. C. Sugarcane yield gap: can it be determined at national level with a simple agrometeorological model? **Crop and Pasture Science**, v. 68, n. 3, 2017.
- PICOLI, M. C. A.; MACHADO, P. G. Land use change: the barrier for sugarcane sustainability. **Biofpr**, 2021.
- PRADO, H. D. **Pedologia Fácil - Aplicações em solos tropicais**. 4a. ed. Piracicaba: Fundag, 2013.
- RUDORFF, B. F. T. et al. Temporal series of EVI/MODIS to identify land converted to sugarcane. **009 IEEE International Geoscience and Remote Sensing Symposium**, p. 252-255, 2009.
- SAKAMOTO, T. et al. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, p. 366-374, 2005.
- SANTOS, H. G. D. et al. **Sistema Brasileiro de Classificação de Solos**. 18. ed. Rio de Janeiro: [s.n.], 2018.
- SILVA, G. J. D. et al. Aptitude of areas planned for sugarcane cultivation expansion in the state of São Paulo, Brazil: a study based on climate change effects. **Agriculture, Ecosystems and Environment**, v. 107, n. 64, p. 305, 2021.

SPAROVEK, G. et al. Sugarcane ethanol production in Brazil: an expansion model sensitive to socioeconomic and environmental concerns. **Biofpr**, v. 1, n. 4, p. 270-282, 2007.

SPERA, S.; VANWEYA, L.; JACK, M. The drivers of sugarcane expansion in Goiás, Brazil. **Land Use Policy**, v. 66, p. 111-119, 2017.

THORNTHWAITE, C. W. A Re-examination of the Concept and Measurement of Potential Evapotranspiration. **Publications in Climatology**, v. 7, p. 200-209, 1955.

WHITE, J. W. et al. Evaluation of Satellite-Based, Modeled-Derived Daily Solar Radiation Data for the Continental United States. **Agronomy Journal**, p. 1242-1251, 2011.

## 4. POTENCIAL DO ALGORITMO RANDOM FOREST PARA SEPARAÇÃO DE CARACTERÍSTICAS MORFOLÓGICAS DE CANA-DE-AÇÚCAR ATRAVÉS DE IMAGENS DO SATÉLITE SENTINEL-2

### Resumo

O uso de sensoriamento remoto para diferenciar variedades de cana-de-açúcar é baseado no fato de que as variedades têm seu próprio padrão espectral devido a características físicas e morfológicas. A identificação de variedades de cana-de-açúcar usando sensoriamento remoto é necessária para reduzir o tempo necessário para identificação em campo e para identificar variedades não contratadas além de monitorar a adoção de novas variedades. Devido a esse cenário, o principal objetivo deste artigo foi avaliar a capacidade do satélite Sentinel-2 identificar variedades de cana-de-açúcar em diferentes datas do ano. Como principal resultado foi possível observar que a técnica se mostrou eficaz com esse tipo de imagem e que o melhor mês para essa discriminação foi agosto.

### Abstract

The use of remote sensing for sugarcane varietal discrimination is based on that the variety need to have its own spectral pattern due to physical and morphological characteristics. The identification of sugarcane varieties using remote sensing is needed to reduce the time taken to identify in the field and identify non-certified varieties also to monitor the adoption of new varieties. Due to this scenario, the main objective of this paper was assessing the capability of Sentinel-2 satellite identify sugarcane varieties in different dates of the year. As the main result, it was possible to observe that the technique proved to be effective with this type of image and that the best month for this discrimination was August.

### 4.1 Introdução

A cana-de-açúcar (*Saccharum officinarum* L.), onde o Brasil atualmente é o maior produtor mundial, com safra 2022/23 estimada em 596,1 milhões de toneladas, fornece os mais variados produtos como açúcar, bagaço, produção de energia e etanol (CONAB, 2022). Para manter a importância e pioneirismo, é realizada pesquisa e desenvolvimento relacionado ao crescimento da produtividade da cana-de-açúcar, incluindo melhoramento genético de variedades para otimizar o teor de sacarose, aumentar a tolerância à seca, e facilitar a aquisição de etanol e biomassa na indústria, resultando em novas variedades que se adaptam a diferentes solos e climas para posteriormente serem disponibilizados para plantios em larga escala, permitindo ao agricultor selecionar a variedade que mais se adequa a sua região e necessidade de resistência a doenças da cultura (MORAIS et al., 2015).

O uso do sensoriamento remoto para discriminação de características morfológicas da cana-de-açúcar é baseado no fato de que a variedade precisa ter um padrão espectral próprio devido às características físicas (SANDOVAL et al., 2011). A identificação de variedades se



expandiu devido à disponibilidade de novos sistemas de satélites capazes de registrar muitas bandas do espectro, potencialmente identificando mudanças sutis na clorofila, teor de água, lignina/celulose, nitrogênio e outros (GALVÃO et al. 2005). A identificação de variedades de cana-de-açúcar por sensoriamento remoto é necessária para reduzir o tempo de identificação em campo e identificar variedades não certificadas também para monitorar a adoção de novas variedades (FORTES; DEMATE, 2005).

Além disso, a importância do monitoramento e discriminação das variedades de cana-de-açúcar, com base na lei n. 9.456, de 25 de abril de 1997, de Proteção às Cultivares do Brasil (LPC) MAPA (1998), possibilita que os especialistas em melhoramento de plantas protejam suas novas variedades com a aquisição de direitos sobre elas. Assim, são desenvolvidos métodos de acompanhamento do desenvolvimento das culturas, proporcionando a vantagem do monitoramento em tempo real sem a necessidade de deslocamento físico. Como exemplo disso temos a popularização dos métodos de sensoriamento remoto, cada vez mais utilizados por especialistas aplicados na agricultura.

Enquanto o sensoriamento remoto tem sido usado principalmente para mapear áreas de cana-de-açúcar (LUCIANO et al., 2019; RUDORFF et al., 2010; XAVIER et al., 2006) e o estado da vegetação da cana-de-açúcar, feito por Atzberger (2013), também pode ser usado na previsão de variedades. Recentemente, a grande variedade de sensores de satélite e as técnicas avançadas de processamento de dados melhoraram o processo de obtenção de informações sobre as culturas, como índice de área foliar, biomassa e dados fenológicos (LUCIANO et al., 2019).

O uso do sensoriamento remoto tem sido amplamente aplicado devido ao fato de poder fornecer dados que permitem a extração de informações atualizadas, além de outros fatores importantes, como salinidade do solo, monitoramento de culturas, aparecimento de queimadas, discriminação entre culturas e variedades, avaliação nutricional, detecção de pragas e doenças, previsões meteorológicas, avaliação das necessidades de água e outros fins (ABDEL-RAHMAN, 2008).

Vários estudos têm sido realizados com o uso de sensoriamento remoto aplicado em lavouras de cana-de-açúcar com o objetivo de identificar, discriminar ou classificar características morfológicas como variedades. Identificar essas variedades é uma tarefa importante, pois permite acompanhar o crescimento das características fitoterápicas, além da previsão de colheita, permitindo ao produtor selecionar a variedade que melhor se adapta às condições climáticas e de solo encontradas, além de reduzir a incidência de doenças das culturas. Devido a isso, este trabalho apresenta uma revisão de literatura, trazendo trabalhos

com pesquisas de discriminação de variedades de cana-de-açúcar, visando verificar o estado da arte para o desenvolvimento de pesquisas futuras.

A variação no desempenho relativo das cultivares entre os ambientes é denominada interação genótipo-ambiente (G x E) e essa interação é um dos três principais componentes da variabilidade em qualquer população. Interações G x E são uma velha questão universal, em todos os organismos vivos, que tem sido mal abordada (KANG, 2002). Essas interações muitas vezes complicam o teste e a seleção de genótipos superiores. A presença de interações G x E causa diferenças na estabilidade entre os genótipos, reduzindo assim o progresso genético em muitos programas de melhoramento. Para avaliar o desempenho de genótipos em diferentes ambientes, a produtividade média desses genótipos pode ser utilizada. Quando as cultivares são cultivadas em vários locais para testar seu desempenho, suas classificações relativas não geralmente permanecem os mesmos. Isso indica a presença da interação G x E (ISSA, 2009). Na reprodução da planta, o tipo mais importante de interação G x E é cruzado ou qualitativo, o que implica mudanças nas classificações dos genótipos entre os ambientes (BAKER, 1988). Com interações não cruzadas, genótipos com médias superiores podem ser recomendados para todos os ambientes. A interação Crossover G x E resulta em complicações quando se trata de melhoramento, seleção e teste de genótipos superiores. As interações cruzadas mostram que diferentes genótipos são adaptados a diferentes ambientes. Esta existência de interações G x E complica a identificação de genótipos superiores para uma variedade de ambientes (ISSA, 2009).

Devido a este cenário, o objetivo principal deste trabalho é avaliar a capacidade do satélite Sentinel-2 em identificar variações morfológicas devido a variedades de cana-de-açúcar em diferentes datas do ano e aplicar o melhor resultado para uma região com as condições ambientais semelhantes como descritas no Capítulo 3.

## **4.2 Revisão Bibliográfica**

Apesar de ser um tema com relevância em outras culturas, na cana-de-açúcar encontra-se poucos trabalhos sobre o tema. É importante entender qual a técnica de análise e imagem utilizada em cada trabalho já publicado para contribuir em uma nova área.

Quanto aos métodos de análise, os trabalhos convergem para uma estratégia de utilização de estatística multivariada. A análise multivariada é composta por métodos estatísticos responsáveis por extrair informações de conjuntos de dados amplamente utilizados na classificação de objetos com medidas simultâneas em muitas variáveis (Johnson et al.,

2002). Os estudos levantados na literatura para identificar variedades de cana-de-açúcar utilizam-se das análises descritas a seguir.

Análise de Componentes Principais (PCA): é um método que visa reduzir a dimensionalidade dos dados, aumentar a variância entre classes, em que variáveis correlacionadas são transformadas em variáveis não correlacionadas. Sempre número de variáveis resultantes do método será menor ou igual à quantidade original.

Análise Discriminante Linear (LDA): é uma generalização do linear discriminante de Fisher, sendo muito semelhante ao método PCA, com técnicas de redução da dimensionalidade dos dados e transformação linear visando separar duas ou mais classes.

Análise Discriminante Canônica (CDA): visa reduzir a dimensionalidade dos dados usando variáveis canônicas, sendo combinações lineares de variáveis originais, a forma de maximizar a variação entre classes, buscando dois conjuntos de combinações lineares, para que sejam o mais correlacionados possível (MURTAGH; HECK, 2012).

Análise Fatorial Discriminante: os fatores são utilizados na análise fatorial para representar variáveis por meio de combinações lineares, variando de indivíduo para indivíduo, visando diminuir o número de fatores e, conseqüentemente, a redundância dos dados (RENCHER, 2005).

Análise Discriminante Penalizada (PDA): foi desenvolvida para situações envolvendo muitas variáveis altamente correlacionadas, aplicando penalidades ao discriminante de Fisher (HASTIE et al., 1995).

Análise Discriminante de Mínimos Quadrados Parciais (PLS-DA): técnica supervisionada que é uma adaptação da regressão de mínimos quadrados parcial (PLS) para redução de dimensionalidade, aplicada a variável com resposta categórica. O método PLS-DA encontra um modelo de regressão linear que faz uma regressão entre as classes e seus descritores.

Stepwise Forward Discriminant Analysis (SFDA): baseado na análise de PCA, este algoritmo utiliza uma análise de discriminação passo a passo selecionando as melhores variáveis. O método inicia sem preditores e cada passo verifica a melhor variável a ser incluída no modelo (BERTRAND et al., 1990).

Support Vector Machine (SVM): é um algoritmo supervisionado que visa encontrar um hiperplano ótimo (limites de decisão) com espaço n-dimensional para a separação entre classes. Os vetores de suporte, correspondentes aos dados próximos dos limites do hiperplano, são usados para maximizar a margem (CORTES; VAPNIK, 1995).

Random Forest (RF): sendo o aprendizado supervisionado, também chamado de floresta de decisão aleatória, combina árvores de decisão para realizar a classificação de um novo indivíduo ou objeto por meio de votos nas árvores. Os votos são baseados em atributos de indivíduos (BREIMAN, 2001).

Foi possível então dentro de cada um dos trabalhos encontrados na literatura determinar qual o método utilizado e a principal conclusão.

Utilizando imagens multiespectrais de alta resolução através de vídeo captura, foi aplicado PCA nos dados multiespectrais de 24 variedades de cana-de-açúcar. Efeitos de borda, acomodação e fatores associados ao estresse hídrico influenciaram a separabilidade entre variedades. Além disso, relatou a necessidade de investigar a assinatura espectral das variedades também com base no estágio de crescimento (SCHIMIDT et al., 2000).

Usando dados Landsat-7 ETM+, não trouxe diferenças significativas entre as cinco principais variedades de cana-de-açúcar. Os resultados de discriminação de variedades podem estar associados à resolução do sensor e à maior influência do estágio de crescimento em contraste com as características físicas das folhas (GERS, 2003).

Com a abordagem hiperespectral, a separação de oito variedades de cana-de-açúcar foi realizada por análise discriminante de 152 bandas e 40 índices de vegetação derivados de outro estudo. Para o pré-processamento dos dados de imagem do sensor Hyperion, foram feitas a recalibração, seleção de bandas de sensor, conversão de valores de refletância usando correção e reparo de valor de pixel. A classificação obtida para 8 variedades foi de 72,4% com melhor separabilidade entre algumas variedades na faixa de 550nm, 680nm, 800nm e 1660nm e 2220nm (APAN et al., 2004).

Utilizando análise discriminante canônica foi possível discriminar uma variedade. Usou-se 198 bandas. Diferenças nos valores de reflectância das variedades foram observadas nas seguintes faixas: 750-1300, 550-690 e 1500-1750nm (GALVÃO et al., 2006).

Utilizando imagens multiespectrais aplicando correção atmosférica (modelo 5S - Simulação de Sinal de Satélite no Espectro Solar), analisando cada banda individualmente, que são: B1, B2, B3, B4, B5 e B7, com método por gráfico de dispersão de pixels e equações de regressão para discriminar quatro variedades de cana-de-açúcar de índices de vegetação com características específicas delas. Usou um método de SFDA para selecionar as melhores variáveis para discriminar variedades. Um percentual de 93,55% foi obtido a partir da classificação das variedades de cana-de-açúcar (FORTES e DEMATE, 2006).

A partir do uso do sensor hiperespectral (EO-1/Hyperion), para classificar 9 variedades de cana localizadas na Austrália utilizou-se LDA, PDA, RF e SVM. Usou 150

bandas do Hyperion. Para as nove variedades de cana-de-açúcar discriminadas, SVM e RF obtiveram as maiores pontuações corretas. LDA e PDA têm mais precisão de variações para diferentes tamanhos de amostra (EVERINGHAM et al., 2007).

Usando um espectrorradiômetro de fibra óptica com faixa de comprimento de onda de 350 - 850nm em intervalos de 0,4nm, investigando pigmento de folhas, esta pesquisa combinou dados de refletância de comprimento de onda (5nm e 20nm) e três índices de vegetação para distinguir sete variedades de cana-de-açúcar por CDA e LDA. As melhores classificações das variedades foram relacionadas aos pigmentos (JOHNSON et al., 2002).

Estudo na Índia por imagem hiperespectral, utilizou-se o Spectral Angle Mapper (SAM), que determina a similaridade espectral entre dois espectros calculando o ângulo entre eles como vetores com dimensionalidade igual ao número de faixas, para identificar e classificar três variedades de cana-de-açúcar (RAO et al., 2007).

Mediu-se a separabilidade espectral de duas variedades de cana-de-açúcar da Colômbia, foi aplicada PCA resultando em precisão global de 80,8% (SANDOVAL et al., 2011).

Através das técnicas de PCA, FDA, SFDA e PLS-DA classificou-se quatro variedades de cana-de-açúcar pela refletância espectral visível/infravermelho próximo obtida dos colmos por um dispositivo portátil. A discriminação pelo FDA com validação cruzada considerando as quatro variedades de cana-de-açúcar ficou entre 80,65% e 100% (NETO et al., 2018).

Desta forma, foi possível observar uma lacuna de trabalhos utilizando imagens dos satélites Sentinel-2 e uma maior exploração do algoritmo RF para regiões homogêneas.

## **4.3 Metodologia**

### **4.3.1 Área de estudo**

A área de estudo de calibração é um recorte dentro da órbita-ponto 22KHA do Sentinel-2B. Esse recorte contém 9.070ha de cana-de-açúcar e 25 variedades de cana-de-açúcar. Todas as áreas são parcelas comerciais e as variedades foram determinadas por inspeção local feita por especialistas em variedades. A Figura 13 mostra a área de estudo. As 25 variedades dentro desta área representam em área 92% do total de cana-de-açúcar do Centro-Sul. Para este artigo, as variedades serão mostradas em letras maiúsculas porque o alvo é avaliar a capacidade de separação das imagens do satélite Sentinel-2, e não o fator de variedade e sua fisiologia.




Figura 13: Área de treino do modelo

### 4.3.2 Imagens de satélite

Todas as imagens vieram do satélite Sentinel-2B nível de processamento Level-2A, com correções radiométricas e geométricas. Foi utilizada a refletância de 10 bandas (Tabela 3) e 3 índices de vegetação (NDBI, RENDWI e RENDVI – Tabela 4). Foram utilizados 3 conjuntos de imagens de: 09/02/2019, 09/06/2019 e 13/08/2019. Todos os dados de refletância dos pixels da cana-de-açúcar foram extraídos e tabulados para análise estatística. Dentro dessa área de estudo foram representadas todas as fases fenológicas da cana-de-açúcar (isso é possível considerando-se canas planta e cana soca e colheitas de início, meio e final de safra).

Tabela 3. Comprimentos de onda das bandas do Sentinel-2B

<b>Banda</b>	<b>Comprimento de onda central (nm)</b>	<b>Resolução (m)</b>
B2	490	10
B3	560	10
B4	665	10
B5	705	20
B6	740	20
B7	783	20
B8	842	10
B8A	865	20
B11	1610	20
B12	2190	20

Tabela 4. Índices de vegetação

<b>Índice</b>	<b>Cálculo</b>	<b>Fonte</b>
NDBI	$(B11-B8)/(B11+B8)$	Zha et al (2001)
RENDVI	$(B8-B6)/(B8+B6)$	Gitelson et al (1994)
RENDWI	$(B3-B5)/(B3+B5)$	Gitelson et al (1994)

### 4.3.3 Modelagem estatística

Foram criados três modelos de regressão diferentes (um para 02/09/2019, um para 06/09/2019 e outro para 08/13/2019). Todos os modelos foram calibrados e testados para predição de variedades de cana-de-açúcar, usando um algoritmo de regressão RF. RF é um método de algoritmo de aprendizado de conjunto baseado em árvores de decisão para regressão e classificação. Foi utilizado o pacote “ranger” de Wright e Ziegler (2017) sob o software R, uma implementação rápida de RF (BREIMAN, 2001). Os parâmetros de FR (o número de variáveis amostradas aleatoriamente como candidatas em cada parcela e o número n árvores de árvores) foram definidos após uma avaliação dos desempenhos estatísticos para estimar variedades de cana-de-açúcar n árvores iguais a 500.

O processo de treinamento e validação foi feito em conjuntos de dados independentes, usando validação cruzada (KOHAVI, 1995). A amostragem foi feita utilizando 70% do conjunto de dados para treinamento e 30% para teste, o que representou aproximadamente 569.488 amostras para treinamento e 244.082 amostras para teste, em cada modelo. Os

modelos foram avaliados com base nos coeficientes de determinação ( $R^2$ ) e no índice de concordância modificado (dmod), com média do conjunto de dados independente. A importância relativa das variáveis preditoras foi calculada pela média da importância (medida de impureza, a variância das respostas) do algoritmo de RF (BREIMAN, 2001).

#### 4.3.4 Aplicação do modelo

A aplicação do modelo proposto foi dentro da mesma região que ele pertence de acordo com a Figura 14 do Capítulo 3. A região de São Carlos possui 1.078.600ha de cana-de-açúcar cultivada. O modelo como é orientado a pixel, foi aplicado para 10 subamostras aleatórias dentro da região com 245.000 pixels (para replicar o tamanho da área de teste do modelo criado), buscando encontrar as mesmas variedades. A verificação de acurácia foi feita com visitas a campo e discriminação das variedades de forma visual com descritores morfológicos. A Figura 15 mostra como é feita a identificação através de descritores em chave combinatória em campo para encontrar a real cultivar.

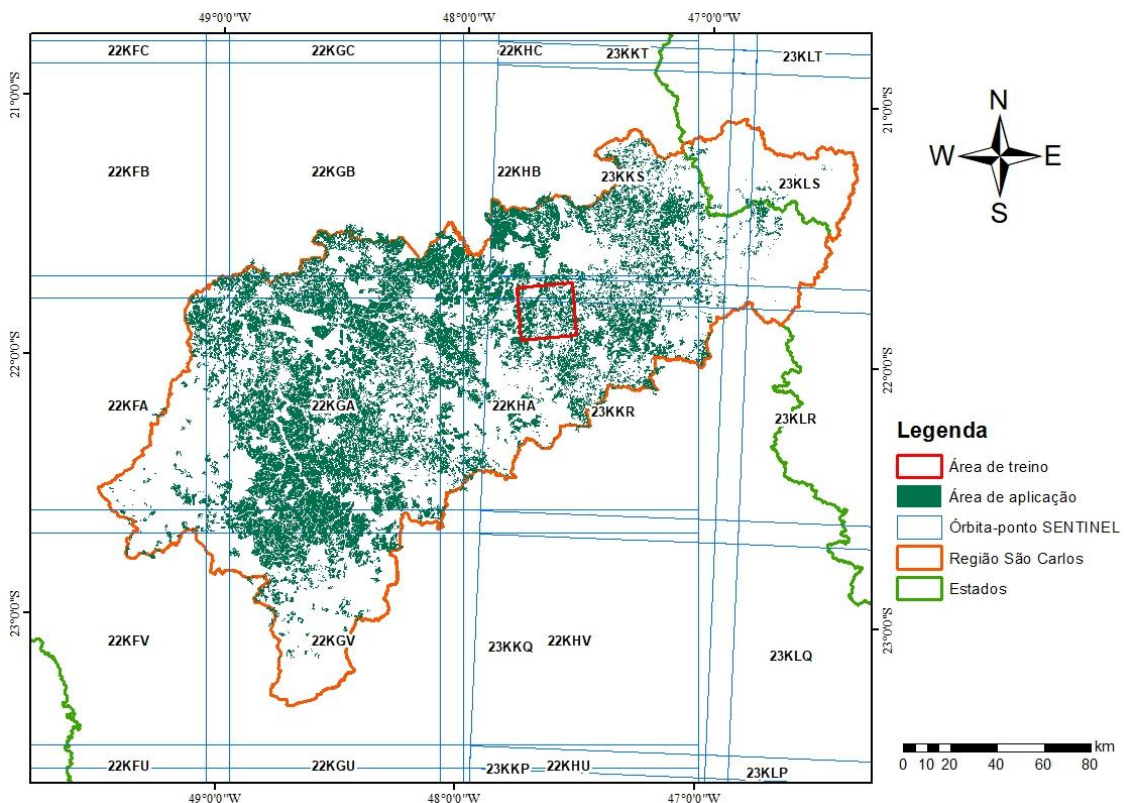


Figura 14. Área de aplicação do modelo






Figura 15: Identificação visual de variedades através de descritores morfológicos em campo

#### 4.4 Resultados e Discussão

Avaliando os resultados foi possível constatar que todos os três modelos apresentaram bom desempenho na previsão da variedade de cana-de-açúcar utilizando imagens Sentinel-2. A Figura 16 mostra a precisão e o índice kappa de cada modelo. É possível ver que o melhor ajuste é o modelo 13/08/2019 com precisão 0,86 e índice kappa 0,81.

Observando a importância de cada banda e índices para o desempenho do modelo, foi possível perceber que apesar do Sentinel-2 possuir mais bandas entre o vermelho e o NIR (infravermelho próximo), a que melhor se ajustou aos modelos foi o SWIR (short-wave infravermelho) B11 e B12. A Figura 17 mostra a diminuição da média de Gini e é possível concluir que para todos os modelos B11 e B12 foram as bandas mais importantes para eles.

No ângulo das variedades, todas as variedades apresentaram precisão acima de 70%, mas quatro delas acima de 90%. Procurando relações entre estas é possível concluir que todas as quatro variedades são boas para fechar a copa mais cedo do que as outras, mas nenhuma delas pertence à mesma família, a não ser que três pertençam ao mesmo dono da empresa. A Figura 18 mostra a precisão para todas as 25 variedades (classes).

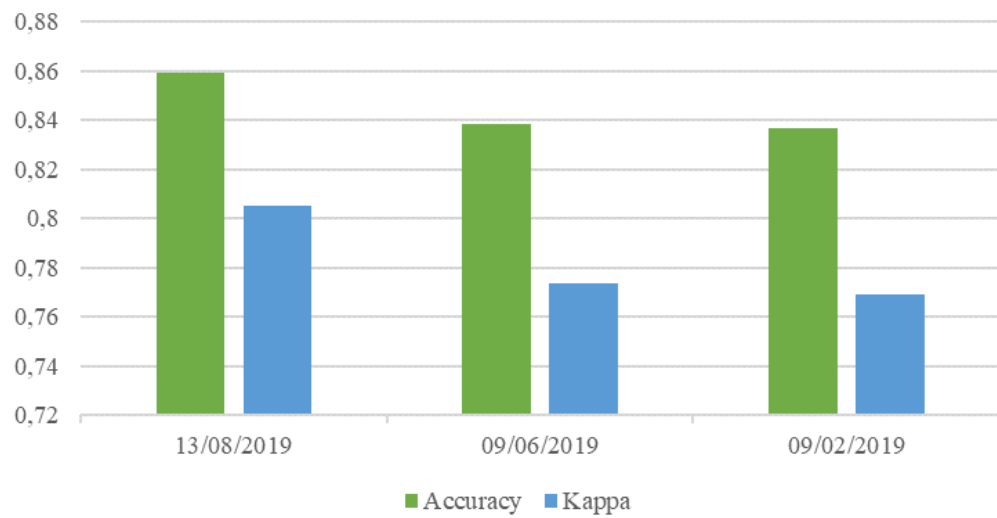


Figura 16: Avaliação dos modelos




Figura 17: Importância de cada fator para o modelo (Gini)




Figura 18. Precisão por classes (13/8/19)

Para a aplicação regional, foi medida apenas a precisão global das classes R, A, O e D. Isso foi feito para deixar o trabalho de campo mais confiável, uma vez que por tratar-se de cultivares conhecidas, sua identificação é facilitada. A Tabela 5 mostra a precisão para cada uma dessas classes e a quantidade de locais avaliados com a indicação do modelo.

Tabela 5: Precisão das avaliações em campo

<b>Classe</b>	<b>Precisão</b>	<b>Número de avaliações</b>
R	96%	111
A	94%	105
O	94%	117
D	91%	101

É possível observar que ao aplicar-se o modelo para uma região com as características edafoclimáticas e de produção semelhantes, a precisão do modelo é mantida.

#### 4.5 Conclusão

Todos esses são resultados preliminares, mas mostram que o Sentinel-2B e o algoritmo RF apresentaram resultados melhores do que estudos anteriores com imagens multiespectrais (SANDOVAL et al., 2011; GALVÃO et al., 2006; FORTES; DEMATE, 2006). Com uma precisão global de 86% e índice kappa de 81%, o modelo de 13/08/2109 teve um desempenho melhor que os demais, mas uma abordagem multitemporal pode trazer resultados ainda melhores. A observação das variedades quatro teve a precisão superior a 90% e sinaliza que expandir a área de estudo procurando variedades que tenham grandes áreas

plantadas a precisão do modelo global pode ser maior. O último ponto é que as bandas 11 e 12 do Sentinel-2 foram as mais importantes para os modelos, o que pode significar que neste comprimento de onda a maioria das variedades tem refletância diferente.

A precisão do modelo aplicado na região de São Carlos manteve o nível dos que foram aplicados na região de treino dele. Isso comprova que utilizar modelos RF em regiões semelhantes às dos treinos traz bons resultados.

O trabalho ainda teve suas limitações por utilizar uma metodologia orientada a pixel. Isso causa uma necessidade computacional bem grande e assim não é possível aplicar para grandes áreas. Como sugestão de trabalhos futuros é possível trazer a metodologia orientada a objeto com as mesmas imagens, datas, bandas e índices que trouxeram os melhores resultados.

Com a definição morfológica dos canaviais, é possível aplicar modelos de estimativa de produtividade mais assertivos, uma vez que a resposta espectral de cada variedade é diferente e interfere nas respostas dos modelos, em especial, os de RF.

## Referências

- Abdel-Rahman, E. M., and 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**. 29, p. 3753-3767. 2008.
- APAN, A. et al. Detecting sugarcane ‘orange rust’ disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing** , p. 489-498, 2003.
- Atzberger, C. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. **Remote Sens.** 5, 949–981. 2013.
- Baker M.J. Differential response to environmental stress. In: Weir, B.S., Eisen, E.J., Goodman, M.M., Namkoong, G. (Eds.). *Proceedings of the Second International Conference on Quantitative Genetics*. Sinauer Associates, Sunderland, Massachusetts, pp. 492-504. 1988.
- Bertrand, D.; P. Courcoux, J.-C. Autran, R. Meritan and P. Robert. "Stepwise canonical discriminant analysis of continuous digitalized signals: application to chromatograms of wheat proteins", **Journal of Chemometrics**, vol. 4, no. 6, pp. 413-427, 1990.
- Breiman, L., 2001. Random forests. **Mach. Learn.** 45, 5–32.
- CONAB, C. N. de (2018) ‘Acompanhamento da Safra Brasileira Cana-de- açúcar’, V. 4 - SAFRA 2017/18 N.4 - Quarto levantamento | ABRIL 2018.
- Cortes, C.; V. Vapnik, "Support-vector networks", **Machine learning**, vol. 20, no. 3, pp. 273-297, 1995.

Everingham, Y; K. Lowe, D. Donald, D. Coomans and J. Markley, "Advanced satellite imagery to classify sugarcane crop characteristics", **Agronomy for sustainable development**, vol. 27, no. 2, pp. 111-117, 2007.

Fortes, C. and Demattê, J. Discrimination of sugarcane varieties using Landsat 7 ETM+ spectral data. **International Journal of Remote Sensing**, 27(7), pp.1395-1412. 2006.

Galvão, L., Formaggio, A. and Tisot, D. The influence of spectral resolution on discriminating Brazilian sugarcane varieties. **International Journal of Remote Sensing**, 27(4), pp.769-777. 2006.

Gers, C. Relating remotely sensed multi-temporal landsat 7 etm+ imagery to sugarcane characteristics, **Proc S Afr Sug Technol Ass.** Citeseer, pp. 7, 2003.

Gitelson, A., and M. Merzlyak. "Spectral Reflectance Changes Associated with Autumn Senescence of Aesculus Hippocastanum L. and Acer Platanoides L. Leaves." **Journal of Plant Physiology** 143,1994.

Hastie, T; A. Buja, and R. Tibshirani, "Penalized discriminant analysis," *The Annals of Statistics*, pp. 73–102, 1995.

Issa, A.B. Genotype by environment interaction and yield stability of maize hybrids evaluated in Ethiopia. MSc. Agric. in the Department of Plant Sciences/Plant Breeding, Faculty of Agriculture and Natural Sciences University of the Free State Bloemfontein, South Africa. 2009.

Johnson, R. A., D. W. Wichern et al., *Applied multivariate statistical analysis*. Prentice hall Upper Saddle River, NJ, vol. 5, no. 8. 2002.

Kang, M. S., 2002. Genotype-Environment interaction: Progress and Prospects. CAB International, Quantitative Genetics, Genomics and Plant Breeding.

Kohavi, R., 1995. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection, in: *Appears in the International Joint Conference on Artificial Intelligence (IJCAI)*.

Luciano, A.C. dos S., Picoli, M.C.A., Rocha, J.V., Duft, D.G., Lamparelli, R.A.C., Leal, M.R.L.V., Le Maire, G., 2019. A generalized space-time OBIA classification scheme to map sugarcane areas at regional scale, using Landsat images time-series and the random forest algorithm. *Int. J. Appl. Earth Obs. Geoinf.* 80, 127–136.

Morais, L. K. de; Cursi, D. E.; Santos, J. M. dos; Sampaio, M.; Camara, T. M. M.; Silva, P. de A.; Barbosa, G. V.; Hoffmann, H. P; Chapola, R. G.; Fernandes, A. R.; Gazaffi, R. Melhoramento genético da cana-de-açúcar. Embrapa Tabuleiros e Costeiros. Documentos, pp. 200, 2015.

Murtagh F.; A. Heck, *Multivariate data analysis*. **Springer Science & Business Media**, 2012, vol. 131.

Neto A. S, D; Lopes, J. Toledo, S. Zolnier and T. Silva, "Classification of sugarcane varieties using visible/near infrared spectral reflectance of stalks and multivariate methods", **The Journal of Agricultural Science**, vol. 156, no. 4, pp. 537-546, 2018.

Rao, N. R., P; Garg ; S. K. Ghosh, "Development of an agricultural crops spectral library and classification of crops at cultivar level using hyperspectral data", **Precision Agriculture**, vol. 8, no. 4–5, pp. 173-185, 2007.

Rencher A. C., “A review of “methods of multivariate analysis, second edition”,” **IIE Transactions**, vol. 37, no. 11, pp. 1083–1085, 2005.

Rudorff, B.F.T., de Aguiar, D.A., da Silva, W.F., Sugawara, L.M., Adami, M., Moreira, M.A., 2010. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo state (Brazil) using Landsat data. **Remote Sens.** 2, 1057–1076.

Sandoval, J.; Gonzales, C.; Murillo, A. Evaluation of Landsat 7 ETM+ Data for Spectral Discrimination and Classification of Sugarcane Varieties in Colombia. **Journal of Agricultural Science and Technology**: 101-107. 2011.

Schmidt, E.J., G. Narciso, P. Frost, and C. Gers. 2000. Application of remote sensing technology in the sa sugar industry review of recent research findings. **Proc. S. Afr. Sug. Technol. Ass.** 74, 192-200.

Xavier, A.C., Rudorff, B.F.T., Shimabukuro, Y.E., Berka, L.M.S., Moreira, M.A., 2006. Multi-temporal analysis of MODIS data to classify sugarcane crop. **Int. J. Remote Sens.** 27, 755–768.

Wright, M.N., Ziegler, A., **Ranger**: A Fast Implementation of Random Forests for High Dimensional Data in C ++ and R 77. 2017.

Zha, Y.; Gao, J.; Ni, S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. **International Journal of Remote Sensing, China**, v. 24, n. 3, p.583-594, 23 out. 2001.