

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**MODELAGEM AGROMETEOROLÓGICA APLICADA À
PREVISÃO DE PARÂMETROS ECOFISIOLÓGICOS E DA
PRODUTIVIDADE DE CANA-DE-AÇÚCAR**

**João Paulo Balbino da Silva
Engenheiro Agrônomo**

2026

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**MODELAGEM AGROMETEOROLÓGICA APLICADA À
PREVISÃO DE PARÂMETROS ECOFISIOLÓGICOS E DA
PRODUTIVIDADE DE CANA-DE-AÇÚCAR**

João Paulo Balbino da Silva

Orientador: Prof. Dr. Glauco de Souza Rolim

Coorientador: Prof. Dr. Lucas Eduardo de Oliveira Aparecido

**Dissertação apresentada à Faculdade de
Ciências Agrárias e Veterinárias - UNESP,
Câmpus de Jaboticabal, como parte das
exigências para a obtenção do título de
Mestre em Agronomia (Produção Vegetal).**

S586m

Silva, João Paulo Balbino da

Modelagem agrometeorológica aplicada à previsão de parâmetros ecofisiológicos e da produtividade de cana-de-açúcar / João Paulo Balbino da Silva. -- Jaboticabal, 2026

90 p. : tabs., fotos, mapas

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Glauco de Souza Rolim

Coorientador: Lucas Eduardo de Oliveira Aparecido

1. Agronomia. 2. Saccharum spp. 3. Previsão de Safra. 4. Modelagem Agrometeorológica. 5. Machine Learning. I. Título.

Impacto potencial desta pesquisa

O estudo utiliza a modelagem não linear para caracterizar parâmetros ecofisiológicos, viabilizando manejos que otimizam o uso de insumos e elevam a produção. A previsão por *Machine Learning* oferece suporte estratégico ao setor sucroenergético, promovendo eficiência operacional e resiliência climática, em aderência aos ODS 7, 9, 12 e 13.

Potential impact of this research

The study uses nonlinear modeling to characterize ecophysiological parameters, enabling management practices that optimize the use of inputs and increase production. Machine learning prediction offers strategic support to the sugarcane and energy sector, promoting operational efficiency and climate resilience, in line with SDGs 7, 9, 12, and 13.

CERTIFICADO DE APROVAÇÃO


TÍTULO DA DISSERTAÇÃO: MODELAGEM AGROMETEOROLÓGICA APLICADA À PREVISÃO DE PARÂMETROS ECOFISIOLÓGICOS E DA PRODUTIVIDADE DE CANA-DE-AÇÚCAR

AUTOR: JOÃO PAULO BALBINO DA SILVA

ORIENTADOR: GLAUCO DE SOUZA ROLIM

COORIENTADOR: COORIENTADOR: LUCAS EDUARDO DE OLIVEIRA APARECIDO


Aprovado como parte das exigências para obtenção do Título de Mestre em Agronomia (Produção Vegetal), pela Comissão Examinadora:

 Documento assinado digitalmente
GLAUCO DE SOUZA ROLIM
Data: 18/03/2026 16:43:24-0300
Verifique em <https://validar.j6.gov.br>

Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Presencial)
Departamento de Ciências Exatas / FCAV UNESP Jaboticabal

 Documento assinado digitalmente
GUILHERME BOTEGA TORSONI
Data: 18/03/2026 20:05:35-0300
Verifique em <https://validar.j6.gov.br>

Prof. Dr. GUILHERME BOTEGA TORSONI (Participação Virtual)
Departamento de Agronomia / Instituto Federal do Mato Grosso do Sul (IFMS) - Naviraí/MS

 Documento assinado digitalmente
THAIS RAYANE GOMES DA SILVA
Data: 18/03/2026 16:44:28-0300
Verifique em <https://validar.j6.gov.br>

Pós-Doutoranda THAIS RAYANE GOMES DA SILVA (Participação Presencial)
Departamento de Ciências Exatas / FCAV UNESP Jaboticabal

Jaboticabal, 25 de fevereiro de 2026.

DADOS CURRICULARES DO AUTOR

João Paulo Balbino da Silva – Filho de João Balbino da Silva e Valdeci Vicente da Silva, nasceu no dia 02 de outubro de 2001, no município de Guaxupé, estado de Minas Gerais. Possui formação técnica em Agropecuária Integrada ao Ensino Médio (2020) e em Administração (2022), ambas pelo Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais – Campus Muzambinho (IFSULDEMINAS). Graduiu-se em Engenharia Agrônoma pelo IFSULDEMINAS – Campus Muzambinho, onde realizou intercâmbio no Instituto Politécnico de Santarém, em Portugal, desenvolvendo pesquisas nas áreas de olericultura e enologia. Em 2024, concluiu pós-graduação lato sensu em Agricultura de Precisão e em Docência na Educação Profissional de Nível Técnico, pelo Instituto Facuminas. No mesmo ano, ingressou no Programa de Pós-Graduação em Agronomia (Produção Vegetal) da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal. Desenvolve pesquisa na linha de agricultura digital, com enfoque no uso de técnicas de machine learning para modelagem da produtividade de cultivos agrícolas. Possui experiência e interesse em tecnologias aplicadas à agricultura, extensão rural e sustentabilidade em sistemas produtivos, com foco na integração de inovações tecnológicas para aprimoramento do desempenho agrícola e socioeconômico.

“Porque sou eu que conheço os planos que tenho para vocês, diz o Senhor, planos de fazê-los prosperar e não de causar dano, planos de dar a vocês esperança e um futuro.”

Jeremias 29:11, Bíblia Sagrada

Em especial, à minha mãe, **Valdeci Vicente da Silva**, pelo apoio incondicional, carinho e exemplo de força. Sua presença e ensinamentos foram e continuam sendo fundamentais para cada conquista em minha vida.

E à memória de meu pai, **João Balbino da Silva**, cuja dedicação, valores e ensinamentos permanecem como inspiração constante em minha trajetória.

Dedico

AGRADECIMENTOS

Primeiramente, elevo meu agradecimento a Deus, por todas as bênçãos derramadas em minha vida e por ser luz e guia diante de todos os desafios e decisões. Sem Sua presença constante, orientação e proteção, nada disso seria possível.

Ao Programa de Pós-Graduação em Agronomia (Produção Vegetal) da Faculdade de Ciências Agrárias e Veterinárias – FCAV/UNESP, pelas oportunidades, apoio acadêmico. Aos docentes, técnicos e colaboradores, parte fundamental desta instituição.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pelo fomento concedido para a realização deste Mestrado Acadêmico.

À minha mãe, Valdeci Vicente da Silva, exemplo de força e superação, sempre presente em todos os momentos, apoiando-me incondicionalmente e lutando ao meu lado para que eu pudesse realizar cada um dos meus sonhos. Você é, sem dúvida, minha maior inspiração; todas as minhas conquistas também são suas, pois sem seu amor e dedicação eu não teria chegado até aqui.

À memória de meu pai, João Balbino da Silva, cuja presença sinto em cada passo que dou. Sua dedicação, valores e lições de vida permanecem vivos em mim e me inspiram continuamente a buscar o melhor. Mesmo ausente fisicamente, está sempre comigo, iluminando e fortalecendo minha jornada.

À minha namorada, Bruna C. C. Carvalho, pela confiança em me acompanhar com amor e carinho para que eu alcance todos os meus sonhos; pelo suporte, companheirismo e compreensão. Nossa história será repleta de aventuras e desafios, e ter você ao meu lado é gratificante.

Agradeço também às minhas irmãs Adrielle Tamaira Vicente da Silva, Franciele Luci Vicente da Silva, Rafaele Cristina Vicente da Silva, Vitória Almeida e Sthefany Balbino Vicente da Silva. Cada uma de vocês foi fundamental para a construção da minha trajetória, seja pelo apoio ou incentivo e pela amizade ao longo de todos esses anos. Sou muito grato por tê-las ao meu lado.

Ao professor Dr. Glauco de Souza Rolim, expressei minha profunda gratidão pela orientação, pela confiança depositada no meu trabalho e pelo constante incentivo ao longo desta jornada. Sua expertise e dedicação foram essenciais para a realização deste trabalho e para a minha formação como profissional.

Ao professor Dr. Lucas Eduardo de Oliveira Aparecido, agradeço pela orientação desde a graduação e pela amizade ao longo de toda a trajetória acadêmica. Seu apoio e companheirismo foram fundamentais para meu desenvolvimento pessoal e profissional.

Aos amigos que conquistei em Jaboticabal, especialmente Rafael Fausto de Lima, Luís Miguel da Costa, e a todos os demais amigos e colegas do Departamento de Ciências Exatas, agradeço pelas conversas, risadas, parceria e aprendizado compartilhados ao longo desta jornada.

Aos meus amigos de Muzambinho, Guilherme Teixeira Simões, João Augusto Vilas Boas dos Santos Gonçalves e Ruan Carlos Correa, e às suas famílias, agradeço pela amizade e pelas experiências compartilhadas ao longo do curso técnico, da graduação e até os dias atuais.

Aos meus amigos de Guaxupé, minha terra natal, Paulo Marcelo, Carlos Felipe, Genivaldo, Júnior, e às famílias de cada um, expresso minha gratidão pela amizade e companheirismo que, independentemente do tempo, permanecem inabaláveis.

A todos os professores e professoras que fizeram parte da minha trajetória, meu mais sincero obrigado pelos ensinamentos.

Agradeço aos membros da Comissão de Avaliação de Defesa e do Exame Geral de Qualificação, pelos apontamentos e contribuições para o enriquecimento desta dissertação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Meu mais sincero agradecimento a todos que fizeram parte desta jornada, contribuindo de alguma forma para a realização deste trabalho e para meu crescimento pessoal e profissional.

SUMÁRIO

CAPÍTULO 1 – Considerações gerais.....	6
1.1 Introdução	6
1.2 Revisão de literatura	8
1.2.1. Economia do setor sucroalcooleiro	8
1.2.2. Variáveis ambientais e o desenvolvimento da cana-de-açúcar	11
1.2.3. Modelos de regressão não linear	12
1.2.4. <i>Machine learning</i> na agricultura.....	13
Referências	13
CAPÍTULO 2 - Parâmetros ecofisiológicos de desenvolvimento de cultivares de cana-de-açúcar estimados por modelos não lineares	20
Resumo:.....	20
Abstract:	21
2.1 Introdução	22
2.2 Material e métodos.....	23
2.2.1 Local de estudo	23
2.2.2 Implantação e delineamento experimental	23
2.2.3 Cultivares e características fenológicas.....	24
2.2.4 Obtenção de dados biométricos	26
2.2.5 Determinação do tempo térmico.....	27
2.2.6 Regressões não lineares	28
2.2.7 Avaliação dos modelos	29
2.3 Resultados	30
2.3.1 Condições meteorológicas durante o ciclo experimental.....	30
2.3.2 Seleção do modelo de regressão não linear	31
2.3.3 Dinâmica do crescimento em altura	32
2.3.4 Dinâmica do comprimento médio de entrenós.....	33
2.3.5 Definição do número de entrenós.....	34
2.3.6 Emissão e estabilização de perfilhos.....	35
2.3.7 Análise do diâmetro médio do colmo	37
2.3.8 Dinâmica do índice de área foliar (LAI).....	38

2.3.9 Dinâmica de acúmulo de produtividade (TCH)	39
2.3.10 Síntese das cultivares e parâmetros	40
2.4 Discussões	41
2.4.1 A Relação entre parâmetros biométricos e TCH.....	41
2.4.2 Estratégias genóticas reveladas pelos parâmetros do modelo	42
2.4.3 Impacto do ambiente e as limitações da modelagem	43
2.4.4 Implicações para o manejo agrônômico e o melhoramento genético	44
2.4.5 Limitações do estudo e perspectivas futuras.....	45
2.5 Considerações finais	46
Referências	47
CAPÍTULO 3 – Previsão de produtividade de cana-de-açúcar com seis meses de antecedência através de <i>machine learning</i>	51
Resumo:.....	51
Abstract:	52
3.1 Introdução	53
3.2 Material e métodos.....	54
3.2.1 Área de estudo.....	54
3.2.2 Aquisição e processamento de dados	55
3.2.3 Algoritmos de machine learning e treinamentos.....	58
3.2.4 Otimização de hiperparâmetros	59
3.2.5 Métricas de desempenho dos modelos	60
3.3 Resultados	61
3.3.1 Desempenho de previsão dos modelos.....	61
3.3.2 <i>Random Forest feature importance</i>	62
3.3.3 Variabilidade espacial do desempenho preditivo.....	63
3.4 Discussões.....	64
3.4.1 Superioridade dos modelos baseados em árvores.....	64
3.4.2 Determinantes ambientais da produtividade	66
3.4.3 Regionalização e fatores limitantes	66
3.4.4 Gestão e sustentabilidade.....	67
3.5 Considerações finais	68

Referências	68
APÊNDICES	71
Apêndice 1.	71
Apêndice 2.	78

MODELAGEM AGROMETEOROLÓGICA APLICADA À PREVISÃO DE PARÂMETROS ECOFISIOLÓGICOS E DA PRODUTIVIDADE DE CANA-DE-AÇÚCAR

Resumo - A cana-de-açúcar (*Saccharum spp.*) desempenha um papel central na economia e na matriz energética brasileira, exigindo ferramentas precisas para o monitoramento do seu desenvolvimento e a previsão de safra frente às variabilidades climáticas. Esta dissertação teve como objetivo aprofundar o entendimento da interação entre variáveis ambientais e o cultivo através de duas abordagens distintas: a modelagem ecofisiológica não linear e a aplicação de algoritmos de aprendizado de máquina (*Machine Learning*). O trabalho foi estruturado em dois estudos principais. O primeiro analisou a dinâmica de crescimento biométrico de sete cultivares de cana-de-açúcar (ciclo de 18 meses) em função de graus-dia acumulados (SDD). Foram testados os modelos de Richards, Gompertz e Michaelis-Menten, sendo o modelo de Richards o mais robusto (R^2_{adj} de 0,96 para altura), permitindo identificar estratégias genotípicas distintas de crescimento ("Lento/Alto Potencial" vs. "Rápido/Baixo Potencial") e correlacionar parâmetros biométricos com o potencial produtivo. O segundo estudo focou na previsão da produtividade em escala nacional com seis meses de antecedência, utilizando uma série histórica de 30 anos (1992–2022). Foram treinados seis algoritmos de *Machine Learning*, dentre os quais o *Random Forest* apresentou o melhor desempenho ($R_{adj}^2=0,63$), superando modelos lineares e de redes neurais. A análise de importância das variáveis indicou que a produtividade é definida majoritariamente entre o 16º e o 29º decêndio do ciclo, sendo o armazenamento de água no solo e a umidade relativa do ar os preditores mais críticos. Conclui-se que a integração de modelos não lineares para caracterização fenotípica e de *Machine Learning* para predição de safra oferece ferramentas estratégicas para o manejo agrônômico de precisão, o melhoramento genético e o planejamento logístico do setor sucroenergético.

Palavras-chave: *Saccharum spp.*; Graus-Dia; *Machine learning*; Previsão de Safra; Modelagem Agrometeorológica.

AGROMETEOROLOGICAL MODELING APPLIED TO THE PREDICTION OF ECOPHYSIOLOGICAL PARAMETERS AND SUGARCANE PRODUCTIVITY

Abstract - Sugarcane (*Saccharum spp.*) plays a central role in the Brazilian economy and energy matrix, requiring precise tools for monitoring its development and forecasting yields in the face of climatic variability. This dissertation aimed to deepen the understanding of the interaction between environmental variables and the crop through two distinct approaches: nonlinear ecophysiological modeling and the application of Machine Learning algorithms. The work was structured into two main studies. The first analyzed the biometric growth dynamics of seven sugarcane cultivars (18-month cycle) as a function of accumulated degree-days (SDD). Richards, Gompertz, and Michaelis-Menten models were tested, with the Richards model proving to be the most robust (R_{adj}^2 of 0.96 for height), allowing for the identification of distinct genotypic growth strategies ("Slow/High Potential" vs. "Fast/Low Potential") and the correlation of biometric parameters with yield potential. The second study focused on forecasting productivity on a national scale six months in advance, using a 30-year historical series (1992–2022). Six Machine Learning algorithms were trained, among which Random Forest presented the best performance ($R_{adj}^2=0,63$), outperforming linear and neural network models. Variable importance analysis indicated that productivity is largely defined between the 16th and 29th ten-day periods of the cycle, with soil water storage and relative humidity being the most critical predictors. It is concluded that integrating nonlinear models for phenotypic characterization and Machine Learning for crop forecasting offers strategic tools for precision agronomic management, genetic breeding, and logistical planning in the sugar-energy sector.

Keywords: *Saccharum spp.*; Degree-Days; Machine learning; Crop Forecast; Agrometeorological Modeling.

CAPÍTULO 1 – Considerações gerais

1.1 Introdução

A cana-de-açúcar (*Saccharum spp.*) é a terceira commodity mais produzida no mundo, com relevância econômica e estratégica no cenário global (Toscano Miranda et al., 2021) e ocupando papel central na produção de açúcar e bioenergia, especialmente etanol (De Matos; Santos; Eichler, 2020; Vandenberghe et al., 2022). A produção do cultivo se concentra nas regiões tropicais e subtropicais, onde contribui para a segurança energética e a economia de países como Brasil, Índia, China e Tailândia (Cheesman et al., 2023; Fioranelli; Bizzo, 2023).

No Brasil, maior produtor mundial de cana-de-açúcar, o cultivo é encontrado em todos os estados (Bordonal et al., 2018). Essa amplitude geográfica de distribuição da produção resulta em diferentes produtividades para cada uma das localidades onde o cultivo se encontra. As variações na produção decorrem de fatores tecnológicos, logísticos e edáficos, mas são principalmente motivadas pelas condições climáticas (Grandis et al., 2024). O clima influencia diretamente a produtividade ao afetar o desenvolvimento e o ciclo fisiológico da planta, a ocorrência de pragas e doenças, a disponibilidade hídrica e o acúmulo de sacarose (Verma; Srivastava; Singh, 2019).

Essas relações demonstram a importância de se compreender e monitorar a forma como as variações climáticas podem determinar a produtividade e o desenvolvimento da cana-de-açúcar (Zhao; Li, 2015). Flutuações climáticas, como condições de elevada temperatura e estresse hídrico, exercem efeitos negativos no desenvolvimento do cultivo, principalmente nas fases de crescimento (brotação e perfilhamento) (Verma; Srivastava; Singh, 2019).

Com isso, a identificação dessa relação entre as fases de desenvolvimento da cana-de-açúcar e os padrões climáticos possibilita a otimização da produtividade e qualidade dos produtos finais (Jaiswal et al., 2023). Sendo essencial o entendimento da influência dos fatores climáticos nas diferentes fases do desenvolvimento fenológico da cana-de-açúcar (Grandis et al., 2024).

Uma ferramenta que pode ser utilizada para esse entendimento é o uso de modelos de regressão não lineares. Estes modelos pressupõem uma relação não linear entre as variáveis independentes (clima) e dependentes (desenvolvimento), permitindo a captura de relações complexas (Jones, 2004; Jones et al., 2019). As regressões não lineares desempenham um papel fundamental na modelagem de cultivos agrícolas, conhecida como *Crop Modeling*, essas regressões são utilizadas para entender e prever o comportamento das plantas em resposta a variáveis ambientais (Jones et al., 2019).

Do ponto de vista econômico, a visualização da resposta da cana-de-açúcar aos diferentes elementos climáticos não apenas permite um melhor planejamento das etapas de período de plantio, colheita e demais práticas agrícolas (Jatuporn; Takeuchi, 2023), como também possibilita antecipar os cenários de produtividade e desenvolver estratégias que garantam a sustentabilidade e a eficiência da produção (Tyagi; Chandra; Tyagi, 2023).

A busca por métodos precisos de prever a produtividade da cana-de-açúcar é essencial para a tomada de decisão ao longo de toda a cadeia produtiva, desde o plantio até a colheita (Casaroli et al., 2023). Isso não apenas confere resiliência às operações agrícolas, mas também contribui para a estabilidade econômica do setor, evitando perdas significativas associadas a condições climáticas adversas (Bhatt et al., 2023). Sendo necessária a utilização de diversas ferramentas para garantir a melhor compreensão desses aspectos.

Com isso, o *Machine Learning (ML)* ou aprendizado de máquina, uma das abordagens da inteligência artificial (Wang; Yao, 2023), surge como uma ferramenta a ser utilizada no setor agrícola. Seu funcionamento na agricultura baseia-se em processos complexos de análise de dados e aprendizado (Reyana et al., 2023).

Em essência, os algoritmos são treinados para reconhecer padrões nos dados coletados, sejam eles relacionados ao clima, ao solo ou ao manejo dos cultivos (Panigrahi; Kathala; Sujatha, 2023). Esses algoritmos são capazes de aprender com os dados disponíveis e gerar previsões e recomendações, permitindo uma tomada de decisão mais precisa e informada em diversas áreas da agricultura (Bowden; Foster; Parkes, 2023; Cock et al., 2023).

Dessa forma, percebe-se que tanto a compreensão sobre a interação entre variáveis climáticas e estádios fenológicos da cana-de-açúcar quanto o aprimoramento da previsão de produtividade são estratégicos para o desenvolvimento de práticas agrícolas no Brasil, especialmente diante da diversidade de cultivares e regimes edafoclimáticos do território nacional. Assim, esta dissertação tem dois objetivos principais: (i) aprofundar o entendimento da relação entre variáveis climáticas e o desenvolvimento fenológico de sete cultivares de cana-de-açúcar com ciclo de 18 meses, por meio de modelos de regressão não lineares; e (ii) avaliar a robustez de diferentes modelos de *Machine Learning* para a previsão de produtividade.

1.2 Revisão de literatura

1.2.1. Economia do setor sucroalcooleiro

Em 2023, a produção global atingiu 2.025.797.465 toneladas, de acordo com dados da FAO, refletindo sua importância entre as commodities agrícolas tropicais (Figura 1) (Food and Agriculture Organization [FAO], 2023). A distribuição geográfica do cultivo é marcada por elevada concentração em regiões de clima tropical e subtropical, com as Américas registrando um volume de 1.020.317.517 toneladas, seguidas pela Ásia com 875.830.430 toneladas. Juntas, essas regiões respondem por mais de 90% da produção mundial, demonstrando a grande dependência global desses polos produtivos. A África (95.168.375 toneladas) e Oceania (34.481.143 toneladas) apresentam participações menos expressivas, refletindo limitações de ordem climática, tecnológica e estrutural. Na Europa, a produção de açúcar está quase exclusivamente associada à beterraba, tornando a contribuição continental para a cana-de-açúcar praticamente irrelevante.

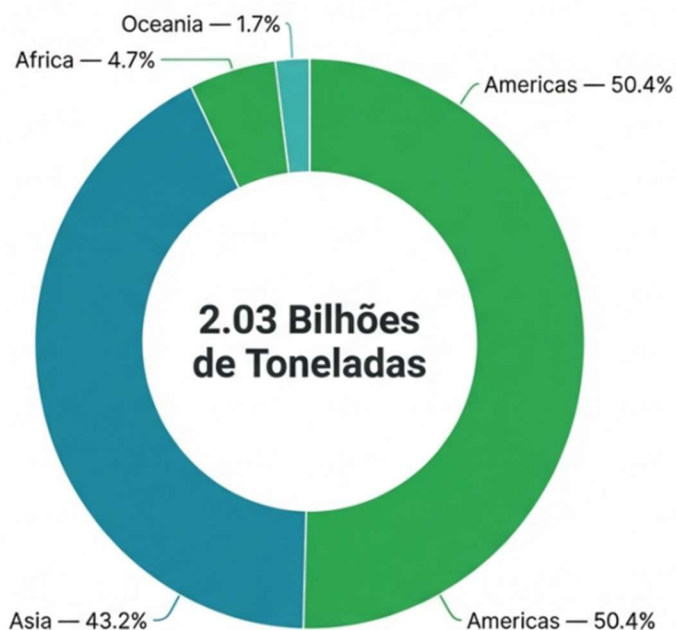


Figura 1: Produção global de cana-de-açúcar em 2023 (FAO, 2023).

A distribuição da produção por país (Figura 2) revela uma concentração do cultivo, liderada pelo Brasil, que respondeu sozinho por cerca de 783 milhões de toneladas, consolidando-se como o maior produtor mundial de cana-de-açúcar. A Índia ocupa a segunda posição, com aproximadamente 491 milhões de toneladas, destacando-se como o principal produtor asiático, seguida pela China, que, somada às suas regiões continentais, atinge cerca de 210 milhões de toneladas.

Tailândia emerge como quarto, maior produtor, embora com volume substancialmente inferior aos líderes. A concentração nos quatro maiores países abarca cerca de 80% da produção global, evidenciando a extrema concentração produtiva em poucos países, predominantemente nas regiões tropicais das Américas e da Ásia. Este cenário demonstra a importância do Brasil no fornecimento mundial de matéria-prima para a indústria açucareira e de biocombustíveis.




Figura 2: Principais países produtores de cana-de-açúcar em 2023 (FAO, 2023).

A cana-de-açúcar representa um dos pilares econômicos do setor agrícola no Brasil, refletindo significativa contribuição para o produto interno bruto agropecuário e para mercados de açúcar, etanol e derivados. Em 2023, o valor total da produção nacional atingiu aproximadamente 101.97 bilhões de reais, com uma produção expressiva de 782.6 milhões de toneladas colhidas em cerca de 10 milhões de hectares, distribuídos em mais de 171 mil propriedades rurais, com rendimento médio nacional de 77.749 kg ha⁻¹.

O estado de São Paulo é o principal polo produtor no país, respondendo por cerca de 56.7 bilhões de reais em produção e 439 milhões de toneladas (Figura 3), equivalentes a mais da metade da produção brasileira. Esta região concentra uma área colhida de aproximadamente 5.5 milhões de hectares em 15 mil propriedades rurais, e rendimento médio de 80.066 kg ha⁻¹.

Minas Gerais posiciona-se como o segundo maior produtor, com valor de produção superior a 11,4 bilhões de reais e geração de 82,5 milhões de toneladas em cerca de 1 milhão de hectares, distribuídos em mais de 49 mil propriedades. O rendimento médio é de 78.004 kg ha⁻¹. Em seguida, na terceira colocação o estado de Goiás com aproximadamente 10.6 bilhões de reais em valor de produção, cerca de 81.6 milhões de toneladas produzidas e rendimento médio de 83.407 kg ha⁻¹.

O Paraná, quarta maior unidade federativa no setor sucroalcooleiro, contribui com pouco mais de 4.6 bilhões de reais em valor de produção e 38.6 milhões de toneladas fabricadas, refletindo rendimento médio de 74.217 kg ha⁻¹ em seus quase 520 mil hectares cultivados.

A diversificação geográfica do cultivo no Brasil vai além desses estados, tendo a presença de cana-de-açúcar em todas as unidades da federação. Sendo um cultivo importante para a produção de açúcar e etanol.

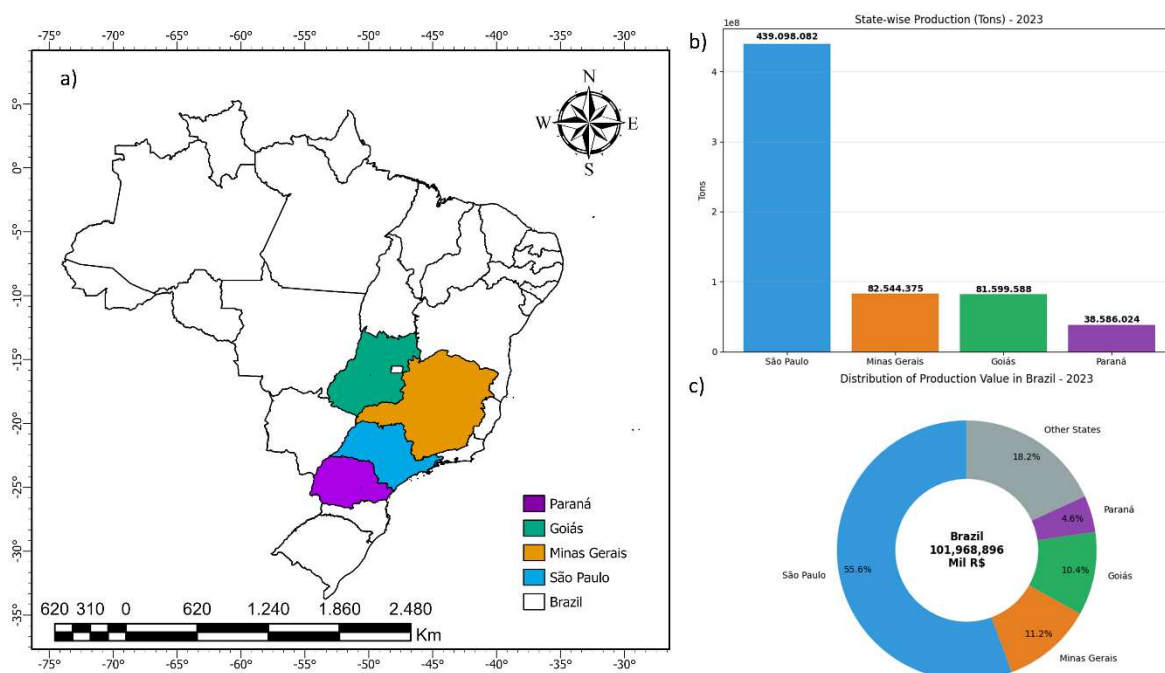


Figura 3: Distribuição espacial, produção e valor econômico da cana-de-açúcar nos principais estados brasileiros em 2023. a) Localização geográfica; b) Produção estadual (toneladas); c) Participação no valor total da produção.

1.2.2. Variáveis ambientais e o desenvolvimento da cana-de-açúcar

O crescimento da cana-de-açúcar é regulado pelo balanço energético e hídrico do ambiente, onde a radiação solar e a temperatura atuam como os principais vetores da fotossíntese e das taxas metabólicas (Sage; Peixoto; Sage, 2013). Complementarmente, a disponibilidade hídrica no sistema, umidade relativa e a velocidade do vento modulam o déficit de pressão de vapor, influenciando a condutância estomática e a eficiência no uso da água, fatores que definem o teto

produtivo sob diferentes tendências climáticas (Ngobese; Ramburan; Labuschagne, 2018).

O impacto dessas variáveis se dá conforme os estádios fenológicos, determinando desde o estande inicial até a produtividade final (Zhao; Li, 2015). Enquanto a fase de grande crescimento exige alta disponibilidade hídrica e radiação para a expansão do dossel, a fase de maturação requer um estresse térmico ou hídrico moderado (Ngobese; Ramburan; Labuschagne, 2018). Essa transição fisiológica é fundamental para cessar o crescimento vegetativo e promover o acúmulo de sacarose nos colmos, onde alterações climáticas podem comprometer a qualidade do produto final (Sage; Peixoto; Sage, 2013).

No território brasileiro, a interação entre as variáveis ambientais e planta impõe desafios distintos ao planejamento varietal devido à vasta amplitude latitudinal (Corbellini et al., 2024). A resposta das cultivares ao fotoperíodo e às flutuações térmicas varia significativamente entre o Centro-Sul e o Norte-Nordeste, tornando o estudo da interação Genótipo x Ambiente, indispensável para a seleção de materiais com maior estabilidade fenotípica e adaptação regional (Fanourakis; Heuvelink; Carvalho, 2013).

Os desafios impostos pela variabilidade climática, como secas e geadas, direcionam a agricultura para o aprimoramento do manejo através soluções inovadoras (Salinger; Stigter; Das, 2000). A integração de modelos de simulação e o uso de cultivares tolerantes ao estresse abiótico permitem uma gestão de riscos mais assertiva. Assim, a antecipação de cenários climáticos deixa de ser um obstáculo para se tornar um diferencial estratégico na manutenção da longevidade e produtividade do canavial.

1.2.3. Modelos de regressão não linear

Os modelos não lineares podem ser utilizados na descrição da relação clima-fenologia por refletirem a natureza sigmoideal dos processos biológicos (Archontoulis; Miguez, 2015). Diferente das funções lineares, que assumem um crescimento infinito e constante, as respostas fisiológicas dos cultivos, como a cana-de-açúcar, variáveis como temperatura e soma térmica apresentam comportamentos de saturação e limites críticos (Bonnett, 2013; Dormer, 1965). Modelos como o Logístico de Gompertz

permitem capturar as fases inicial, crescimento exponencial e estabilização, descrevendo com maior precisão o acúmulo de biomassa e a dinâmica de maturação do cultivo (Archontoulis; Miguez, 2015).

A aplicação desses modelos em ambiente de simulação e previsão de safra é fundamental para converter dados agrometeorológicos em previsões reais de produtividade agrícola (Hoque et al., 2025). As principais vantagens desses modelos residem na interpretabilidade biológica de seus parâmetros, como a taxa máxima de crescimento e o ponto de inflexão da curva, o que facilita a comparação entre diferentes genótipos ou regimes hídricos.

1.2.4. Machine learning na agricultura

O *Machine Learning* na agricultura é baseado no uso de algoritmos computacionais capazes de identificar padrões complexos em grandes volumes de dados sem a necessidade de programação explícita de regras biológicas (Panigrahi; Kathala; Sujatha, 2023). No contexto da previsão agrícola, o *ML* atua na identificação de relações não lineares entre variáveis, como índices de vegetação, dados meteorológicos e atributos do solo, permitindo que o modelo "aprenda" a dinâmica do sistema produtivo a partir de dados históricos para realizar inferências precisas sobre a produtividade de safras futuras (Wang; Yao, 2023).

Entre os algoritmos mais utilizados para a previsão de produtividade, destacam-se os métodos de conjunto *ensemble learning*, como o *Random Forest (RF)* e o *Gradient Boosting (XGBoost)*. Paralelamente, as *Artificial Neural Networks (RNA)*, especialmente modelos de *Deep Learning*, oferecem uma capacidade superior de no processamento de grandes séries temporais e dados de sensoriamento remoto (Gupta et al., 2021).

Referências

ALVARES, Clayton Alcarde *et al.* Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

ARCHONTOULIS, Sotirios V.; MIGUEZ, Fernando E. Nonlinear Regression Models and Applications in Agricultural Research. **Agronomy Journal**, v. 107, n. 2, p. 786–798, 2015.

- BEZUIDENHOUT, C. N. *et al.* A process-based model to simulate changes in tiller density and light interception of sugarcane crops. **Agricultural Systems**, v. 76, n. 2, p. 589–599, 1 maio 2003.
- BHATT, Rajan *et al.* Climate-Smart Technologies for Improving Sugarcane Sustainability in India—A Review. **Sugar Tech**, v. 25, n. 1, p. 1–14, 1 fev. 2023.
- BOLLERO, Germán A.; BULLOCK, Donald G.; HOLLINGER, Steven E. Soil Temperature and Planting Date Effects on Corn Yield, Leaf Area, and Plant Development. **Agronomy Journal**, v. 88, n. 3, p. 385–390, 1996.
- BONNETT, Graham D. Developmental Stages (Phenology). *In*: **Sugarcane: Physiology, Biochemistry, and Functional Biology**. [S.l.]: John Wiley & Sons, Ltd, 2013. p. 35–53.
- BORDONAL, Ricardo de Oliveira *et al.* Sustainability of sugarcane production in Brazil. A review. **Agronomy for Sustainable Development**, v. 38, n. 2, p. 13, 27 fev. 2018.
- BOWDEN, Christopher; FOSTER, Timothy; PARKES, Ben. Identifying links between monsoon variability and rice production in India through machine learning. **Scientific Reports**, v. 13, n. 1, p. 2446, 10 fev. 2023.
- CASAROLI, Derblai *et al.* Using crop models, a decline factor, and a “multi-model” approach to estimate sugarcane yield compared to on-farm data. **Theoretical and Applied Climatology**, 29 nov. 2023.
- CHEESMAN, Alexander W. *et al.* Impacts of ground-level ozone on sugarcane production. **Science of The Total Environment**, v. 904, p. 166817, 15 dez. 2023.
- COCK, James *et al.* Operations research and machine learning to manage risk and optimize production practices in agriculture: good and bad experience. **Current Opinion in Environmental Sustainability**, v. 62, p. 101278, 1 jun. 2023.
- CORBELLINI, Marcos *et al.* Geographical adaptability for optimizing the recommendation of soybean cultivars in the Brazilian Cerrado. **Scientific Reports**, v. 14, n. 1, p. 13076, 6 jun. 2024.
- CUADRA, S. V. *et al.* A biophysical model of Sugarcane growth. **GCB Bioenergy**, v. 4, n. 1, p. 36–48, 2012.
- CURSI, Danilo Eduardo *et al.* Origin, Genetic Diversity, Conservation, and Traditional and Molecular Breeding Approaches in Sugarcane. *In*: PRIYADARSHAN, P. M.; JAIN, S. Mohan (Orgs.). **Cash Crops: Genetic Diversity, Erosion, Conservation and Utilization**. Cham: Springer International Publishing, 2022. p. 83–116.
- DA SILVA, Cesar J. *et al.* Growth and production of sugarcane varieties under supplementary irrigation and no irrigation. **Revista Caatinga**, v. 36, n. 4, p. 885–896, 2023.

DE CASTRO, Sérgio Gustavo Quassi *et al.* Optimizing Nitrogen Fertilizer Rates at Distinct In-season Application Moments in Sugarcane. **International Journal of Plant Production**, v. 16, n. 1, p. 137–152, 2022.

DE MATOS, Mario; SANTOS, Fernando; EICHLER, Paulo. Chapter 1 - Sugarcane world scenario. *In: SANTOS, Fernando et al. (Orgs.). Sugarcane Biorefinery, Technology and Perspectives. [S.l.]: Academic Press, 2020. p. 1–19.*

DE MIRANDA, Evaristo E.; FONSECA, Marcelo F. Chapter 4 - Sugarcane: food production, energy, and environment. *In: SANTOS, Fernando et al. (Orgs.). Sugarcane Biorefinery, Technology and Perspectives. [S.l.]: Academic Press, 2020. p. 67–88.*

DORMER, K. J. Correlations in plant development: general and basic aspects. *In: ALLSOPP, Allan et al. (Orgs.). Differentiation and Development / Differenzierung und Entwicklung: Part 1 / Teil 1. Berlin, Heidelberg: Springer, 1965. p. 452–478.*

DOS SANTOS WANDERLEY, Luan Rafael *et al.* Nutritional Requirement by Irrigated Brazilian Sugarcane Varieties. **Sugar Tech**, v. 23, n. 4, p. 762–775, 1 ago. 2021.

ENDRES, Lauricio *et al.* Morphological changes recorded in different phenophases of sugarcane plants subjected to water stress in tropical field conditions. **Australian Journal of Crop Science**, v. 12, n. 7, p. 1041–1050, 2018.

FEWKES, Derek W.; GREATHEAD, David J. Progress towards the integrated control of sugar cane pests. **Pesticide Science**, v. 9, n. 5, p. 445–457, 1978.

FIORANELLI, Anselmo; BIZZO, Waldir A. Generation of surplus electricity in sugarcane mills from sugarcane bagasse and straw: Challenges, failures and opportunities. **Renewable and Sustainable Energy Reviews**, v. 186, p. 113647, 1 out. 2023.

GRANDIS, Adriana *et al.* Biotechnologies to Improve Sugarcane Productivity in a Climate Change Scenario. **BioEnergy Research**, v. 17, n. 1, p. 1–26, 1 mar. 2024.

GUPTA, Rohan *et al.* Artificial intelligence to deep learning: machine intelligence approach for drug discovery. **Molecular diversity**, v. 25, p. 1315–1360, 2021.

HOQUE, M. N. *et al.* Agro-meteorological Crop Yield Modeling: A Comprehensive Review. **Journal of Environmental Science and Natural Resources**, p. 55–64, 2025.

INMAN-BAMBER, N. G.; LAKSHMANAN, P.; PARK, S. Sugarcane for water-limited environments: Theoretical assessment of suitable traits. **Field Crops Research**, v. 134, p. 95–104, 12 ago. 2012.

Instituto Agrônômico (IAC) - Cultivares. Disponível em: <<https://www.iac.sp.gov.br/cultivares/inicio/resultados.php>>. Acesso em: 23 out. 2025.

JAIPHONG, Thanankorn *et al.* Effects of duration and combination of drought and flood conditions on leaf photosynthesis, growth and sugar content in sugarcane. **Plant Production Science**, v. 19, n. 3, p. 427–437, 2 jul. 2016.

JAISWAL, Rohit *et al.* Indian sugarcane under warming climate: A simulation study. **European Journal of Agronomy**, v. 144, p. 126760, 1 mar. 2023.

JAMES, Gareth *et al.* Linear Regression. *In*: JAMES, Gareth *et al.* (Orgs.). **An Introduction to Statistical Learning: with Applications in Python**. Cham: Springer International Publishing, 2023. p. 69–134.

JATUPORN, Chalermpon; TAKEUCHI, Kenji. Estimating the potential impact of climate change on energy crop productivity in Thailand: an empirical study of sugarcane, cassava, and oil palm using panel data analysis. **Environment, Development and Sustainability**, 31 mar. 2023.

JONES, Antonia J. New tools in non-linear modelling and prediction. **Computational Management Science**, v. 1, n. 2, p. 109–149, 1 jul. 2004.

JONES, M. R. *et al.* Exploring process-level genotypic and environmental effects on sugarcane yield using an international experimental dataset. **Field Crops Research**, v. 244, p. 107622, 1 dez. 2019.

KANG, M. S.; MILLER, J. D.; TAI, P. Y. P. Genetic and Phenotypic Path Analyses and Heritability in Sugarcane. **Crop Science**, v. 23, n. 4, p. cropsci1983.0011183X002300040010x, 1983.

KAPUR, Raman; DUTTAMAJUMDER, S. K.; RAO, K. Krishna. A breeder's perspective on the tiller dynamics in sugarcane. **Current Science**, v. 100, n. 2, p. 183–189, 2011.

KOHILA, S.; GOMATHI, R. Adaptive physiological and biochemical response of sugarcane genotypes to high-temperature stress. **Indian Journal of Plant Physiology**, v. 23, n. 2, p. 245–260, 1 jun. 2018.

KUIJPER, J. DeGroeï van Bladschijf, Bladscheede em Stengel van het suikerriet. **Arch Suikerind Ned Indië**, v. 23, n. 1, p. 528–556, 1915.

KUMAR, Tanweer *et al.* Genetic Engineering for Enhancing Sugarcane Tolerance to Biotic and Abiotic Stresses. **Plants**, v. 13, n. 13, p. 1739, jan. 2024.

LAZARINI, Marco A.; ZAMBROSI, Fernando C. B. Propagation Materials do not Affect Nutrient Absorption of Sugarcane During the Plant-Cane Cycle. **Sugar Tech**, v. 27, n. 2, p. 559–565, 1 abr. 2025.

LEITE, Emily Aquino *et al.* Assessing climate change impacts on sugarcane yield, crop water productivity, and nitrous oxide emissions across Brazil's bioenergy using the CSM-SAMUCA-sugarcane model. **Agricultural Systems**, v. 231, p. 104494, 1 jan. 2026.

LI, Yang-Rui. Growth and Development of Sugarcane (*Saccharum* spp. Hybrid) and Its Relationship with Environmental Factors. *In: VERMA, Krishan K. et al. (Orgs.). Agro-industrial Perspectives on Sugarcane Production under Environmental Stress*. Singapore: Springer Nature, 2022. p. 1–11.

LIU, D. L.; KINGSTON, G.; BULL, T. A. A new technique for determining the thermal parameters of phenological development in sugarcane, including suboptimum and supra-optimum temperature regimes. **Agricultural and Forest Meteorology**, v. 90, n. 1, p. 119–139, 1 mar. 1998.

LOUREIRO, Marcelo E. *et al.* Sugarcane Breeding and Selection for more Efficient Biomass Conversion in Cellulosic Ethanol. *In: BUCKERIDGE, Marcos Silveira; GOLDMAN, Gustavo H. (Orgs.). Routes to Cellulosic Ethanol*. New York, NY: Springer, 2011. p. 199–239.

MARCHIORI, Paulo E. R. *et al.* Plant growth, canopy photosynthesis and light availability in three sugarcane varieties. **Sugar Tech**, v. 12, n. 2, p. 160–166, 1 jun. 2010.

MARIN, Fabio R. *et al.* Sugarcane Yield and Yield Components as Affected by Harvest Time. **Sugar Tech**, v. 23, n. 4, p. 819–826, 1 ago. 2021.

MOORE, Paul H.; MARETZKI, Andrew. Sugarcane. *In: Photoassimilate Distribution Plants and Crops Source-Sink Relationships*. [S.l.]: Routledge, 1996.

NGOBESE, Immaculate; RAMBURAN, Sanesh; LABUSCHAGNE, Maryke. Quantifying sugarcane cultivar differences in tiller and stalk phenology: identifying traits suited to crop model-assisted breeding. **Journal of Crop Improvement**, v. 32, n. 6, p. 847–860, 2 nov. 2018.

PANIGRAHI, Bharati; KATHALA, Krishna Chaitanya Rao; SUJATHA, M. A Machine Learning-Based Comparative Approach to Predict the Crop Yield Using Supervised Learning With Regression Models. **Procedia Computer Science**, International Conference on Machine Learning and Data Engineering. v. 218, p. 2684–2693, 1 jan. 2023.

RAMBURAN, S.; ZHOU, M.; LABUSCHAGNE, M. Interpretation of genotype × environment interactions of sugarcane: Identifying significant environmental factors. **Field Crops Research**, v. 124, n. 3, p. 392–399, 20 dez. 2011.

REYANA, A. *et al.* Accelerating Crop Yield: Multisensor Data Fusion and Machine Learning for Agriculture Text Classification. **IEEE Access**, v. 11, p. 20795–20805, 2023.

RIDESA: Variedades RB. Disponível em: <<https://www.ridesa.com.br/variedades>>. Acesso em: 23 out. 2025.

SAGE, Rowan F.; PEIXOTO, Murilo Melo; SAGE, Tammy L. Photosynthesis in Sugarcane. *In: Sugarcane: Physiology, Biochemistry, and Functional Biology*. [S.l.]: John Wiley & Sons, Ltd, 2013. p. 121–154.

SALINGER, M. J.; STIGTER, C. J.; DAS, H. P. Agrometeorological adaptation strategies to increasing climate variability and climate change. **Agricultural and Forest Meteorology**, v. 103, n. 1, p. 167–184, 1 jun. 2000.

SANDHU, Karansher Singh *et al.* Integrated Approach in Genomic Selection to Accelerate Genetic Gain in Sugarcane. **Plants**, v. 11, n. 16, p. 2139, jan. 2022.

SHRIVASTAVA, A. K. *et al.* Physiological Interventions for Enhancing Sugarcane and Sugar Productivity. **Sugar Tech**, v. 17, n. 3, p. 215–226, 1 set. 2015.

SIANSI, Frederico Luiz [UNESP. Emissão de co2 do solo e indicadores de produtividade e suas relações com características espectrais da cana - de - açúcar sob diferentes épocas de plantio. 5 fev. 2024.

SINGELS, A.; SMIT, M. A. Sugarcane response to row spacing-induced competition for light. **Field Crops Research**, v. 113, n. 2, p. 149–155, 3 ago. 2009.

TOSCANO MIRANDA, Nahieh *et al.* Sugarcane bagasse pyrolysis: A review of operating conditions and products properties. **Renewable and Sustainable Energy Reviews**, v. 149, p. 111394, 1 out. 2021.

TYAGI, Sanjay; CHANDRA, Shalini; TYAGI, Gargi. Climate Change and its Impact on Sugarcane Production and Future Forecast in India: A Comparison Study of Univariate and Multivariate Time Series Models. **Sugar Tech**, v. 25, n. 5, p. 1061–1069, 1 out. 2023.

VANDENBERGHE, L. P. S. *et al.* Beyond sugar and ethanol: The future of sugarcane biorefineries in Brazil. **Renewable and Sustainable Energy Reviews**, v. 167, p. 112721, 1 out. 2022.

Variedades CTC. Disponível em: <<https://ctc.com.br/produtos/>>. Acesso em: 23 out. 2025.

VERMA, R. R.; SRIVASTAVA, T. K.; SINGH, P. Climate change impacts on rainfall and temperature in sugarcane growing Upper Gangetic Plains of India. **Theoretical and Applied Climatology**, v. 135, n. 1–2, p. 279–292, 2019.

WAGIH, M. E.; ALA, A.; MUSA, Y. Evaluation of sugarcane varieties for maturity earliness and selection for efficient sugar accumulation. **Sugar Tech**, v. 6, n. 4, p. 297–304, 1 dez. 2004.

WANG, Hannah Szu-Han; YAO, Yuan. Machine learning for sustainable development and applications of biomass and biomass-derived carbonaceous materials in water and agricultural systems: A review. **Resources, Conservation and Recycling**, v. 190, p. 106847, 1 mar. 2023.

ZHAO, Duli *et al.* Sugarcane Plant Growth and Physiological Responses to Soil Salinity during Tillering and Stalk Elongation. **Agriculture**, v. 10, n. 12, p. 608, dez. 2020.

ZHAO, Duli; LI, Yang-Rui. Climate Change and Sugarcane Production: Potential Impact and Mitigation Strategies. **International Journal of Agronomy**, v. 2015, n. 1, p. 547386, 2015.

ZHAO, Duli; ZHU, Kai; LABORDE, Chris. Sugarcane Growth, Physiological and Yield Responses to Application of Trinexapac-ethyl (Moddus™) in Grand Growth Phase. **Journal of Plant Growth Regulation**, v. 42, n. 5, p. 2813–2826, 1 maio 2023.

CAPÍTULO 2 - Parâmetros ecofisiológicos de desenvolvimento de cultivares de cana-de-açúcar estimados por modelos não lineares

Resumo:

O desenvolvimento da cana-de-açúcar (*Saccharum spp.*), uma cultura C4, é intrinsecamente dependente do tempo térmico acumulado (ΣDD), tornando os modelos de regressão não linear, ferramentas ideais para descrever sua curva sigmoideal de crescimento. Este estudo objetivou aplicar a modelagem não linear para quantificar a dinâmica do crescimento biométrico (altura da planta, número de entrenós, comprimento de entrenós, diâmetro médio, número de perfilhos, índice de área foliar e produtividade) de sete cultivares de cana-de-açúcar (ciclo de 18 meses, "cana planta") em função do ΣDD , visando extrair parâmetros biológicos interpretáveis (valor máximo em y (assíntota) ' α ', taxa ' κ ', ponto de inflexão ' γ ') para caracterizar a variabilidade genotípica. O experimento foi conduzido no nordeste do Estado de São Paulo (clima Aw), em delineamento de blocos casualizados, acumulando 3076,71 ΣDD (T_{base} 16°C). Os modelos de Richards, Gompertz e Michaelis-Menten foram comparados utilizando os critérios de RMSE e R^2_{adj} . O modelo de Richards foi selecionado como o mais robusto e acurado, apresentando ajuste superior para variáveis de acúmulo estrutural, como altura da planta (R^2_{adj} médio de 0,96) e produtividade estimada (TCH) (R^2_{adj} médio de 0,95). Uma forte correlação positiva foi encontrada entre o potencial de altura (α) e o potencial de produtividade (αTCH). A análise dos parâmetros revelou duas estratégias genotípicas distintas de resposta ao tempo térmico: "Crescimento Lento/Alto Potencial" identificado pela IACCTC07-7207, com picos de crescimento (γ) tardios, alinhada ao ciclo longo; e "Crescimento Rápido/Baixo Potencial" identificado pela CTC4, com picos precoces, sugerindo maior adequação a ciclos curtos. O modelo mostrou limitações para variáveis fisiologicamente dinâmicas como número de perfilhos ($R^2_{adj} = 0,58$). Conclui-se que os parâmetros α , κ e γ do modelo de Richards são indicadores quantitativos eficazes para otimizar o manejo agrônomo de precisão, como a sincronização da fertilização com o γ específico de cada cultivar, contribuindo com métricas para quantificar o melhoramento genético.

Palavras-chave: *Saccharum spp.*; Graus-Dia, *Richards*; Variabilidade Genotípica.

CHAPTER 2 - Ecophysiological development parameters of sugarcane cultivars estimated by nonlinear models

Abstract:

The development of sugarcane (*Saccharum* spp.), a C4 crop, is intrinsically dependent on accumulated thermal time (ΣDD), making nonlinear regression models (NLMs) ideal tools to describe its sigmoidal growth curve. This study aimed to apply nonlinear modeling to quantify the dynamics of biometric growth (plant height, number of internodes, internode length, average diameter, number of tillers, leaf area index, and productivity) of seven sugarcane cultivars (18-month cycle, "plant cane") as a function of ΣDD , aiming to extract interpretable biological parameters (maximum value in y (asymptote) ' α ', rate ' κ ', inflection point ' γ ') to characterize genotypic variability. The experiment was conducted in the northeast of the State of São Paulo (Aw climate), in a randomized block design, accumulating 3076.71 ΣDD (Tbase 16°C). The Richards, Gompertz, and Michaelis-Menten models were compared using the RMSE and R2adj criteria. The Richards model was selected as the most robust and accurate, showing superior fit for structural accumulation variables, such as plant height (mean R2adj of 0.96) and estimated productivity (TCH) (mean R2adj of 0.95). A strong positive correlation was found between height potential (α) and productivity potential (αTCH). The analysis of the parameters revealed two distinct genotypic strategies of response to thermal time: "Slow Growth/High Potential" identified by IACCTC07-7207, with late growth peaks (γ), aligned with the long cycle; The "Rapid Growth/Low Potential" characteristic identified by CTC4, with early peaks, suggests greater suitability for short cycles. The model showed limitations for physiologically dynamic variables such as tiller number (R2adj = 0.58). It is concluded that the parameters α , κ , and γ of the Richards model are effective quantitative indicators for optimizing precision agronomic management, such as synchronizing fertilization with the specific γ of each cultivar, contributing metrics to quantify genetic improvement.

Keywords: *Saccharum* spp.; Degree-Days, *Richards*; Genotypic Variability.

2.1 Introdução

A cana-de-açúcar (*Saccharum spp.*) é uma commodity estratégica para a segurança energética e alimentar global, com o Brasil liderando a produção, respondendo por aproximadamente 37% da produção global (cerca de 746 milhões de toneladas anuais) (Da Silva et al., 2023; Zhao; Zhu; LaBorde, 2023). No entanto, a maximização sustentável da produtividade enfrenta desafios, como as mudanças climáticas, que impactam o crescimento de forma significativa (Leite et al., 2026). Isso exige um entendimento preciso de como o cultivo responde ao ambiente em que está inserido, otimizando a eficiência no uso de recursos (Lazarini; Zambrosi, 2025).

Para cultivos do tipo C4 como a cana-de-açúcar, que utiliza um mecanismo especializado que concentra o CO₂ nas células, reduzindo a fotorrespiração (Sage; Peixoto; Sage, 2013), o tempo térmico acumulado (ΣDD) é um preditor de desenvolvimento mais robusto do que os dias após o plantio (Bollero; Bullock; Hollinger, 1996) podendo ser relacionado a características biométricas de desenvolvimento, como a altura da planta, que segue um padrão sigmoidal, refletindo as fases fenológicas de brotação, crescimento exponencial e maturação (Bonnett, 2013; Dormer, 1965).

Modelos de regressão lineares simples, embora fáceis de aplicar, não conseguem capturar com precisão essa complexidade, limitando a capacidade preditiva e a compreensão dos mecanismos subjacentes ao crescimento (James et al., 2023). A solução, por sua vez, reside na adoção de modelos de regressão não linear (NLMs), que incluem funções sigmoides clássicas como a de Gompertz (Gompertz, 1825), Richards (Richards, 1959) e cinética de Michaelis-Menten (Archontoulis; Miguez, 2015). Estes modelos de regressão não linear são ideais para capturar essa dinâmica complexa, pois, ao contrário dos modelos lineares, seus parâmetros possuem interpretação biológica direta, como a assíntota de crescimento máximo (α), a taxa de crescimento (κ) e o momento de ponto de inflexão (γ) (Archontoulis; Miguez, 2015).

Apesar de existirem estudos demonstrando o crescimento de cultivares de cana-de-açúcar (Bonnett, 2013; Da Silva et al., 2023; Zhao; Zhu; LaBorde, 2023), e

que a fenologia do cultivo seja altamente influenciada pelo genótipo e pela temperatura (Jones et al., 2019), a literatura carece de ferramentas que isolem e quantifiquem a variabilidade genética inerente ao uso eficiente do tempo térmico. Diferentes cultivares de cana-de-açúcar exibem respostas fisiológicas e de desenvolvimento distintas a condições ambientais e de manejo (Kohila; Gomathi, 2018).

Embora o conceito de graus-dia seja amplamente consolidado na modelagem de cultivos, ainda são escassas as investigações que apliquem modelos não lineares associados ao acúmulo térmico para descrever o desenvolvimento dos cultivos. Relacionando o efeito da variabilidade dos graus-dia sobre os parâmetros de ajuste desses modelos.

O objetivo deste estudo foi aplicar a modelagem não linear para quantificar a dinâmica de crescimento biométrico de sete cultivares de cana-de-açúcar em função dos graus-dia acumulados (ΣDD), determinando e comparando os parâmetros biológicos (assíntota, ponto de inflexão e taxa de crescimento) para caracterizar a variabilidade genotípica na resposta ao ΣDD .

2.2 Material e métodos

2.2.1 Local de estudo

A área localiza-se no nordeste do Estado de São Paulo, região sudeste do Brasil, no município de Barrinha. As coordenadas geográficas são 21°11'38" de latitude sul e 48°09'50" de longitude oeste. O clima da região é do tipo megatérmico, tropical com estação seca de inverno (Aw) e precipitação anual média de 1.400 mm, com chuvas concentradas no período de novembro a fevereiro (Alvares et al., 2013).

2.2.2 Implantação e delineamento experimental

O plantio foi realizado em outubro de 2021. Com base na análise química do solo, aplicou-se 3 t ha⁻¹ de calcário dolomítico em área total, não sendo necessária a gessagem. Adotou-se o preparo de solo reduzido, consistindo na destruição química da soqueira anterior, seguida de subsolagem apenas na linha de plantio.

O experimento foi conduzido em delineamento de blocos casualizados (DBC) com sete tratamentos e três repetições (blocos). Os tratamentos consistiram nas

seguintes cultivares de cana-de-açúcar: RB005014, CTC9006, CT02-2994, RB855156, IACCTC07-7207, CTC4 e RB985476.

Cada parcela experimental foi composta por cinco linhas de 10 metros de comprimento, espaçadas a 1,5 m. A área útil para avaliação correspondeu aos 8 metros centrais da terceira linha (linha central) de cada parcela, minimizando o efeito de bordadura.

O plantio foi realizado com mudas pré-brotadas (PSS), plantadas manualmente a um espaçamento de 0,65 m entre plantas dentro da linha. O experimento foi conduzido em condições de sequeiro. O controle de plantas daninhas foi realizado com herbicidas pré-emergentes e pós emergentes seletivo, a depender da necessidade de campo.

2.2.3 Cultivares e características fenológicas

O experimento foi conduzido com sete cultivares de cana-de-açúcar, selecionadas por apresentarem diferentes características genéticas (Tabela 1). O plantio foi realizado em 25/11/2021 e a colheita em 13/06/2023, totalizando um ciclo de 570 dias (18 meses), caracterizado como "cana planta". Todos os genótipos foram submetidos simultaneamente às mesmas datas de plantio e colheita, permitindo a comparação de seu desenvolvimento sob as mesmas condições ambientais e período de cultivo.

Tabela 1: Cultivares de cana-de-açúcar utilizadas, conforme programas de melhoramento, CTC (*Variedades CTC*, 2025), IAC (*Instituto Agrônomo (IAC) - Cultivares*, 2025) e Ridesa (*RIDESA*, 2025), adaptado de Siansi, (2024).

Cultivar	Brotação	Isoporização	Florescimento	Produtividade (TCH)
CTC2994	Boa	Ausente	Ausente	Muito Alta
CTC4	Muito Boa	Ausente	Ausente	Muito Alta
CTC9006	Boa	Média	Média	Alta
IACCTC07-7207	Muito Boa	Ausente	Ausente	Muito Alta
RB005014	Muito Boa	Ausente	Ausente	Muito Alta

RB855156	Muito Boa	Intensa	Intenso	Alta
RB985476	Muito Boa	Ausente	Ausente	Alta

O ciclo iniciou-se com o plantio de mudas pré-brotadas (PSS), que estabelece o estande inicial. Subsequentemente, ocorre a fase de perfilhamento, período crítico onde se define a população final de colmos por área (Ngobese; Ramburan; Labuschagne, 2018). Após o estabelecimento dos perfilhos, inicia-se a fase de crescimento expansivo, caracterizada pelo rápido alongamento dos colmos, máxima expansão da área foliar (dossel) e intenso acúmulo de fotoassimilados (Marchiori et al., 2010). Por fim, geralmente induzida por estímulos como déficit hídrico moderado ou redução da temperatura, o cultivo entra na fase de maturação, na qual o crescimento vegetativo é reduzido e o armazenamento de sacarose nos colmos é maximizado (Moore; Maretzki, 1996) (Figura 1).

A fenologia do cultivo é regida primordialmente pelo acúmulo de tempo térmico (SDD), superando a cronologia em dias como variável explicativa (Liu; Kingston; Bull, 1998). O acúmulo térmico modula a cinética enzimática e metabólica, determinando características biométricas como a alongação de colmos e a expansão foliar (Bonnett, 2013). Para o ciclo de cana-planta (Figura 1), as fases fenológicas podem ser categorizadas da seguinte forma: a brotação ocorre até os 60 dias após o plantio (DAP), demandando cerca de 420 SDD; o perfilhamento estende-se de 61 a 210 DAP (421–1250 SDD); o crescimento vegetativo, fase de maior demanda energética, ocorre entre 211 e 480 DAP (1251–2760 SDD); culminando na maturação, que finaliza o ciclo entre 481 e 570 DAP (2761–3076 SDD) (Bonnett, 2013; Da Silva et al., 2023; Dos Santos Wanderley et al., 2021; Endres et al., 2018; Kohila; Gomathi, 2018; Lazarini; Zambrosi, 2025; Zhao; Zhu; LaBorde, 2023).

Dependendo da sensibilidade da cultivar ao fotoperíodo e das condições ambientais, pode ocorrer o florescimento, um evento que cessa o desenvolvimento apical do colmo (Bonnett, 2013).




Figura 1: Representação esquemática dos estádios fenológicos da cana-de-açúcar, desde o plantio (*Pre-Sprouted Seedlings - PSS*) até a Maturação. Cada estádio é associado a um intervalo de tempo em *Days After Planting* (DAP) e ao acúmulo de Graus-Dia (Σ DD).

2.2.4 Obtenção de dados biométricos

Os colmos, na parte central das parcelas, foram identificados com fita, deixando espaços suficientes para que não ocorresse o estrangulamento das fitas a estes colmos. Todas as leituras eram feitas nestes mesmos locais, com as mesmas referências de colmos, exceção feita a poucos colmos desta área útil das últimas leituras, posto que alguns colmos tombados foram substituídos pelo vizinho mais próximo.

As avaliações biométricas foram realizadas em cinco colmos por tratamento, totalizando 110 colmos. Em cada colmo, mediam-se a altura da planta, determinada mensurando-se a distância da superfície do solo até a aurícula visível (colarinho) da folha +1, conforme o sistema de numeração de Kuijper (1915), o comprimento do entrenó médio (cm), o diâmetro médio (cm), número de perfilhos e índice de área foliar (LAI) determinado pelo método indireto com o uso do equipamento AccuPAR LP 80 (METER Group, Pullman, WA, USA).

As medidas realizadas com o equipamento AccuPAR LP 80 foram feitas no centro da parcela experimental compreendendo uma medida da radiação fotossinteticamente ativa (PAR) acima do dossel e próximo ao solo (10 cm acima do solo). Os dados obtidos em escala temporal de dias após o plantio (DAP), com

intervalos de 30 dias, com a primeira coleta iniciada em 25/12/2021 até a data de colheita dos cultivos.

A partir dos dados coletados, foi feito o cálculo da quantidade de toneladas de cana por hectare estimado utilizando as variáveis: altura média dos colmos, diâmetro médio dos colmos e número de perfilho (Equação 1).

$$TCHe = \frac{d^2 \times C \times h (0,007854)}{E} \quad (1)$$

sendo d: diâmetro médio dos colmos (cm); C: perfilhamento (nº de colmos por metro); h: altura média dos colmos (cm); E: espaçamento entre sulcos (m).

2.2.5 Determinação do tempo térmico

O tempo térmico, expresso em graus-dia (DD), foi calculado para estimar o desenvolvimento fenológico da cana-de-açúcar. Para isso, foram utilizados dados meteorológicos de uma estação automática (Campbell Scientific, Inc., Logan, UT, EUA), composta por um sistema de aquisição de dados (Datalogger modelo CR1000) e sensores de temperatura e umidade relativa do ar, radiação solar global, velocidade do vento e precipitação pluviométrica, instalada na área central do estudo. A aquisição dos dados foi configurada para registrar as variáveis a cada 60 segundos, gerando médias a cada 20 minutos, com transmissão automática via modem 3G. As variáveis diárias utilizadas para o cálculo foram a temperatura máxima (T_{max}) e a temperatura mínima (T_{min}) do ar, em graus Celsius (°C).

O cálculo dos graus-dia diários (DD) foi realizado através do método da média, utilizando a Equação 2:

$$DD = \frac{(T_{max} + T_{min})}{2} - T_b \quad (2)$$

sendo: T_{max} : temperatura máxima diária do ar (°C); T_{min} : temperatura mínima diária do ar (°C); T_b : temperatura base inferior (°C).

Para o cultivo da cana-de-açúcar, adotou-se uma temperatura base (T_b) de 16 °C (Bonnett, 2013; Casaroli et al., 2023). Adicionalmente, foi estabelecida uma temperatura base superior (T_{bs}) de 42 °C (Bonnett, 2013; Casaroli et al., 2023). Em

dias que a T_{max} excedeu a T_{bs} , o valor de T_{max} na equação 2 foi substituído pelo valor de T_{bs} , para evitar a contabilização de estresse térmico como acúmulo para o desenvolvimento.

Para dias em que a temperatura média ($(T_{max} + T_{min})/2$), foi inferior à T_b , o valor de DD foi considerado zero (0), pois não há acúmulo de tempo térmico abaixo da temperatura base. Os graus-dia acumulados (SDD) foram obtidos pelo somatório dos DD diários, iniciando a contagem a partir do dia do plantio (25/11/2021) até a colheita (13/06/2023).

2.2.6 Regressões não lineares

Para a identificação dos padrões de resposta biométricos em relação ao graus-dia acumulados (SDD), foram aplicados 3 diferentes modelos de regressão não linear, com projeção de curvas sigmoidais como, *Gompertz* e *Richards* e o modelo de regressão não linear *Michaelis-Menten*, com curva sem formato sigmoidal. Como medida temporal para conduzir as análises, foi adotado o tempo térmico acumulado (SDD), considerando as fases fenológicas específicas da cana-de-açúcar, nomeadamente brotação, perfilhamento, crescimento expansivo e maturação (Endres et al., 2018).

O modelo de regressão não linear de *Gompertz*, desenvolvido por Benjamin Gompertz em 1825, é caracterizado por três diferentes parâmetros representados por 'α', 'k' e 'γ'. Sendo utilizado na projeção de curva de crescimento sigmoidal que representa a variação da taxa de crescimento em função do tempo (Equação 3).

$$Y = \alpha(e^{-e[-k(x-\gamma)]}) \quad (3)$$

sendo α: capacidade de sustentação do meio (ou valor máximo de Y); k: taxa de crescimento; γ: ponto de inflexão (no eixo x).

O modelo de *Richards* produz uma curva sigmoidal que descreve o crescimento ao longo do tempo, com maior robustez, sendo caracterizado por possuir quatro parâmetros, ele oferece uma maior flexibilidade na modelagem da curva (Equação 4).

$$Y = \alpha[1 + (\delta - 1)e^{-k(x-\gamma)}] \frac{1}{(1-\delta)} \quad (4)$$

na qual α : capacidade de sustentação do meio (ou valor máximo de Y); δ : formato em que o crescimento de Y ocorre antes e após o ponto de inflexão (também chamado de assimetria); k: taxa de crescimento intrínseco; γ : ponto de inflexão (no eixo X).

O modelo *Michaelis-Menten* (Equação 5), projeta uma curva de crescimento sem formato sigmoidal, com somente um ponto de concavidade, sem ponto de inflexão.

$$Y = \frac{\alpha X}{k + X} \quad (5)$$

sendo α : capacidade de sustentação do meio (ou valor máximo de Y); k: a constante de Michaelis que representa o valor da variável independente (X) em que Y atinge metade do seu valor máximo ($\alpha/2$).

2.2.7 Avaliação dos modelos

Para avaliar a acurácia do ajuste dos modelos de regressão não-linear em descrever os fenômenos biométricos da cana-de-açúcar, foram utilizados dois indicadores estatísticos principais. A seleção do modelo mais adequado foi baseada na combinação do menor valor da raiz do erro quadrático médio (RMSE) e do maior valor do coeficiente de determinação ajustado (R^2_{adj}).

O RMSE mede a magnitude média dos erros entre os valores observados e os valores preditos pelo modelo. É um indicador de acurácia absoluta, pois é expresso na mesma unidade da variável resposta. Valores mais próximos de zero indicam um erro de predição menor e, conseqüentemente, um modelo mais acurado (Equação 6).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{obs_i} - Y_{pr_i})^2}{n}} \quad (6)$$

sendo: Y_{pred_i} : o resultado previsto pelo modelo; Y_{obs_i} : o resultado observado; e n: número de observações.

O R^2_{adj} representa a proporção da variabilidade total dos dados observados que é explicada pelo modelo, ajustada pelo número de parâmetros utilizados. Diferente do RMSE, é uma medida de precisão (adimensional, de 0 a 1). Foi utilizado o R^2_{adj}

(Equação 7) por ser mais robusto que o R^2 comum ao comparar modelos com diferentes números de parâmetros.

$$R^2 \text{ ajustado} = \left[1 - \frac{(1-R^2) \times (n-1)}{n-k-1} \right] \quad (7)$$

sendo, R^2 : Coeficiente de determinação tradicional; n: número de observações; e k: número de parâmetros (coeficientes) do modelo.

2.3 Resultados

2.3.1 Condições meteorológicas durante o ciclo experimental

Durante os 570 dias do ciclo experimental, a precipitação total acumulada foi de 2229 mm, apresentando uma distribuição bimodal (Figura 2). O primeiro período de maior precipitação ocorreu nas fases de brotação e perfilhamento (30-150 DAP). O segundo período chuvoso concentrou-se na fase de crescimento expansivo e início da maturação (330-510 DAP).

Um período de baixa precipitação ocorreu entre o final do perfilhamento e o início do crescimento expansivo, aproximadamente aos 180-300 DAP. Uma segunda redução na precipitação ocorreu ao final do ciclo (540-570 DAP), coincidindo com a fase de maturação, condição benéfica para o acúmulo de sacarose.

As temperaturas durante o ciclo foram favoráveis ao desenvolvimento do cultivo. A temperatura máxima variou de 26,8 °C a 32,3 °C (média de 29,6 °C), e a mínima de 12,9 °C a 19,7 °C (média de 16,3 °C). Este regime térmico resultou em um somatório térmico total acumulado de 3076,71 Σ DD.

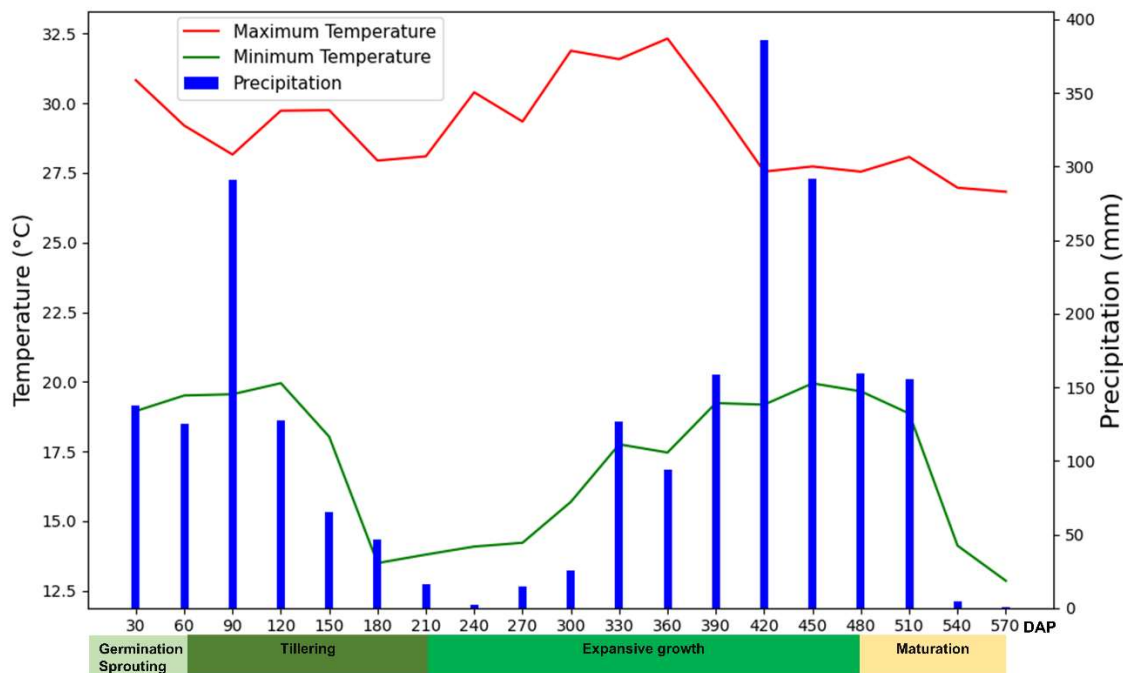


Figura 2: Condições meteorológicas registradas ao longo do ciclo experimental, em dias após o plantio (DAP), e suas respectivas fases fenológicas.

2.3.2 Seleção do modelo de regressão não linear

Para determinar o modelo mais adequado para descrever o acúmulo biométrico das cultivares em função do somatório de graus-dia (ΣDD), foi realizada uma avaliação estatística comparativa dos três modelos não lineares (Tabela 2). A seleção baseou-se nos critérios de maior coeficiente de determinação ajustado (R^2_{adj}) e menor raiz do erro quadrático médio (RMSE).

O modelo de Michaelis-Menten apresentou, o desempenho mais baixo, com o menor R^2_{adj} médio (0,72) e o maior RMSE médio (7,595). Já os modelos sigmóides de Richards e Gompertz mostraram-se altamente competitivos. Embora Gompertz tenha apresentado um R^2_{adj} médio ligeiramente superior (0,79 vs. 0,76), o modelo de Richards obteve o menor erro médio (RMSE = 4,602) e, mais importante, demonstrou uma superioridade clara no ajuste das características biométricas-chave de produção, como a altura da planta (Plant height) (RMSE de 17,19 vs. 20,65 do Gompertz) e produtividade estimada (Estimated tons of cane per hectare -TChE) (RMSE de 10,35 vs. 10,84 do Gompertz).

Considerando a performance superior do modelo de Richards nos parâmetros biométricos e sua maior flexibilidade biológica, por ser um modelo de 4 parâmetros que acomoda curvas assimétricas, ele foi selecionado para a subsequente discussão das características biométricas das cultivares. Já os resultados e gráficos de ajuste dos modelos de Gompertz e Michaelis-Menten foram alocados ao material suplementar (Apêndice 1).

Tabela 2: Avaliação estatística dos modelos não lineares (Richards, Gompertz, Michaelis-Menten) aplicados a diferentes características biométricas entre cultivares de cana-de-açúcar.

CARACTERÍSTICAS BIOMÉTRICAS	Richards		Gompertz		Michaelis Menten		Média	
	R ² _{adj}	RMSE	R ² _{adj}	RMSE	R ² _{adj}	RMSE	R ² _{adj}	RMSE
Altura da planta (cm)	0,96	17,189	0,95	20,650	0,93	26,101	0,95	21,313
Comprimento médio do entrenó (cm)	0,85	0,811	0,86	0,803	0,85	0,891	0,85	0,835
Número de entrenós	0,94	1,400	0,94	1,517	0,80	2,960	0,89	1,959
Número de perfilhos	0,58	0,933	0,59	0,957	0,50	1,098	0,55	0,996
Diâmetro médio do colmo (mm)	0,46	0,904	0,59	0,847	0,53	0,957	0,52	0,903
Índice de área foliar (LAI)	0,60	0,628	0,63	0,632	0,61	0,683	0,61	0,647
Toneladas estimadas de cana por hectare (TCHe)	0,95	10,351	0,95	10,836	0,83	20,478	0,91	13,888
Média	0,76	4,602	0,79	5,177	0,72	7,595	0,76	5,792

2.3.3 Dinâmica do crescimento em altura

A análise dos parâmetros do modelo de Richards (Figura 3) revela diferenças significativas nas estratégias de crescimento entre as cultivares. Em média, as cultivares apresentaram uma altura máxima potencial (parâmetro α) de 557,0 cm, com o ponto de máxima taxa de crescimento (parâmetro γ) ocorrendo aos 451,1 Σ DD. O modelo proporcionou um bom ajuste para a variável altura da planta (*Plant height*) em função do Σ DD, como evidenciado pelo R²_{adj} médio de 0,96 e um RMSE médio de 17,19 cm.

A cultivar RB005014 destacou-se com o maior potencial de crescimento, apresentando a assíntota mais elevada ($\alpha = 688,3$ cm). Este alto potencial está associado a um crescimento mais lento, pois a mesma cultivar registrou o ponto de

inflexão (γ) mais atrasado, aos 551,6 Σ DD. Em contraste, a cultivar CTC4 apresentou o menor potencial de altura, com uma assíntota de apenas 425,0 cm.

Quanto à velocidade de crescimento, a CT02-2994 foi a mais responsiva ao acúmulo térmico (Σ DD), exibindo maior taxa de crescimento ($\kappa = 0,0007 \text{ cm } \Sigma\text{DD}^{-1}$), o que indica uma curva de crescimento mais acentuada. Este comportamento é oposto ao de cultivares com crescimento relativo mais lento, como a RB855156 e a própria RB005014, ambas com $\kappa = 0,0003 \text{ cm } \Sigma\text{DD}^{-1}$.




Figura 3: Ajuste do modelo de Richards para altura da planta (cm) em função do acúmulo térmico (Σ DD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

2.3.4 Dinâmica do comprimento médio de entrenós

O modelo de Richards (Figura 4) apresentou um bom ajuste para o comprimento médio de entrenós, com R^2_{adj} médio de 0,85 e RMSE de 0,811. A qualidade do ajuste foi mais variável entre as cultivares do que a observada para altura da planta, variando de R^2_{adj} igual a 0,97 (CT02-2994) a 0,72 (IACCTC07-7207), sugerindo uma maior complexidade nesta variável. Em média, o potencial máximo de comprimento (α) foi de 28,4 cm, com o pico de crescimento (γ) ocorrendo aos 1644,8 Σ DD, já na fase fenológica de crescimento expansivo.

A análise dos parâmetros expôs duas estratégias de crescimento contrastantes, confirmando a separação visual dos grupos. As cultivares CTC4 e RB985476

demonstraram um padrão de crescimento rápido e curto, ou seja, essas cultivares atingem o ponto de inflexão (γ) muito cedo, aproximadamente 895 Σ DD, no final do perfilhamento e apresentando as maiores taxas (κ) sendo 0,0029 e 0,0018 $\text{cm } \Sigma\text{DD}^{-1}$, respectivamente. Contudo, este desenvolvimento rápido resultou no menor potencial de comprimento final com a de 16,3 e 15,5 cm, respectivamente.

Inversamente, cultivares como RB005014 e CTC9006 seguiram uma estratégia de crescimento lento e longo. Essas cultivares exibiram os maiores potenciais de comprimento com a de 42,0 e 40,0 cm, respectivamente, mas com taxas (κ) muito menores 0,0002 e 0,0003 $\text{cm } \Sigma\text{DD}^{-1}$, respectivamente, e picos de crescimento (γ) mais tardios com 1433,6 e 1670,5 Σ DD, respectivamente. Já a cultivar RB855156 se destacou por ter o ponto de inflexão mais tardio de todas ($\gamma = 3076,7 \Sigma\text{DD}$), indicando um alongamento de entrenó que ocorre até o final do ciclo do cultivo.




Figura 4: Ajuste do modelo de Richards para comprimento médio do entrenó (cm) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

2.3.5 Definição do número de entrenós

O início da emissão de entrenós (Figura 5) se mostrou similar até aproximadamente 1750 ΣDD , na fase de crescimento expansivo para todas as cultivares. Já as estratégias de definição do número final de entrenós variaram entre as cultivares, o que é evidenciado pela ampla faixa do ponto de inflexão (γ), que variou

de 749 a 2296 Σ DD. O ajuste do modelo demonstrou um valor médio de 0,94 para R^2_{adj} e de 1,4 para RMSE, apresentando um potencial máximo (α) de 44,4 entrenós.

A cultivar RB985476 apresentou o menor potencial ($\alpha = 16,9$) e o pico de crescimento (γ) mais precoce de todos (749 Σ DD), ocorrendo já na fase de perfilhamento. Isso, combinado a maior taxa de κ ($0,0014 \text{ N}^\circ \Sigma\text{DD}^{-1}$), indica uma definição rápida e antecipada do número de entrenós, levando a uma estabilização precoce da curva.

De forma inversa a CTC4 demonstrou a estratégia mais tardia, com seu pico de emissão de entrenós (γ) ocorrendo com 2296 Σ DD, bem avançado na fase de crescimento expansivo. Já a cultivar CT02-2994 destacou-se pelo maior potencial máximo (α) de número de entrenós com 62 entrenós, com taxa de crescimento $\kappa = 0,0003 \text{ N}^\circ \Sigma\text{DD}^{-1}$, atingindo seu pico de crescimento (γ) aos 994 Σ DD, indicando um lento e elevado potencial de formação de entrenós.

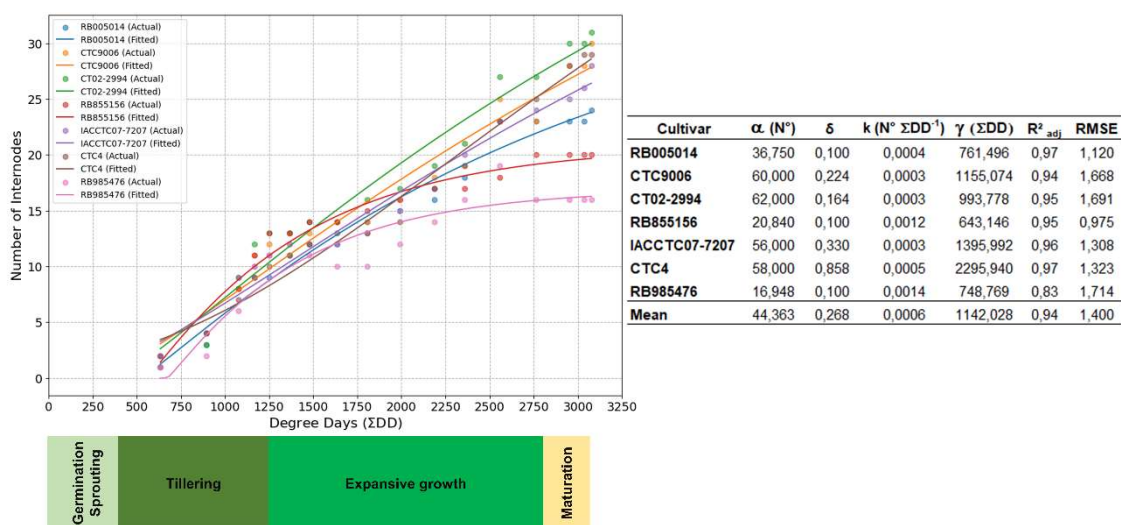


Figura 5: Ajuste do modelo de Richards para número de entrenós em função do acúmulo térmico (Σ DD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

2.3.6 Emissão e estabilização de perfilhos

A modelagem do número de perfilho em função do Σ DD (Figura 6) sugere uma alta variabilidade biológica intrínseca ao perfilhamento, que inclui processos de emissão e mortalidade de perfilhos não capturados por um modelo sigmoide simples,

como evidenciado pelo baixo R^2_{adj} médio de 0,58. No entanto, o RMSE médio foi baixo (0,93 perfilhos), indicando que o erro absoluto do modelo permaneceu pequeno.

Apesar da variabilidade, a análise dos parâmetros revelou duas estratégias de perfilhamento distintas. A maioria das cultivares demonstrou um padrão de rápida emissão e estabilização do número de perfilhos. Seus picos de crescimento (γ) ocorreram entre 321 e 414 ΣDD (início da fase de perfilhamento), com taxas κ (variando de 0,0104 a 0,0208 $N^\circ \Sigma DD^{-1}$). Levando à estabilização do número de perfilhos por volta de 750 ΣDD .

Em oposição, a cultivar RB985476 seguiu uma estratégia de desenvolvimento lento e contínuo. A cultivar apresentou a menor taxa onde k é igual a 0,0011 $N^\circ \Sigma DD^{-1}$ e o ponto de inflexão mais precoce $\gamma = 218 \Sigma DD$, resultando em uma curva que continuou a ascender lentamente durante quase todo o ciclo, sem atingir uma assíntota clara.

Já em termos de potencial máximo (α), foi possível identificar os dois grupos. O primeiro sendo um grupo de alto potencial onde α varia entre 9,6 e 10,3 perfilhos, composto por CTC4, RB855156, RB005014 e IACCTC07-7207. E o segundo grupo de menor potencial varia entre 8,4 e 9,3 perfilhos, composto por RB985476, CTC9006 e CT02-2994. Tendo como média geral do potencial máximo (α) entre cultivares o valor de 9,4 perfilhos.

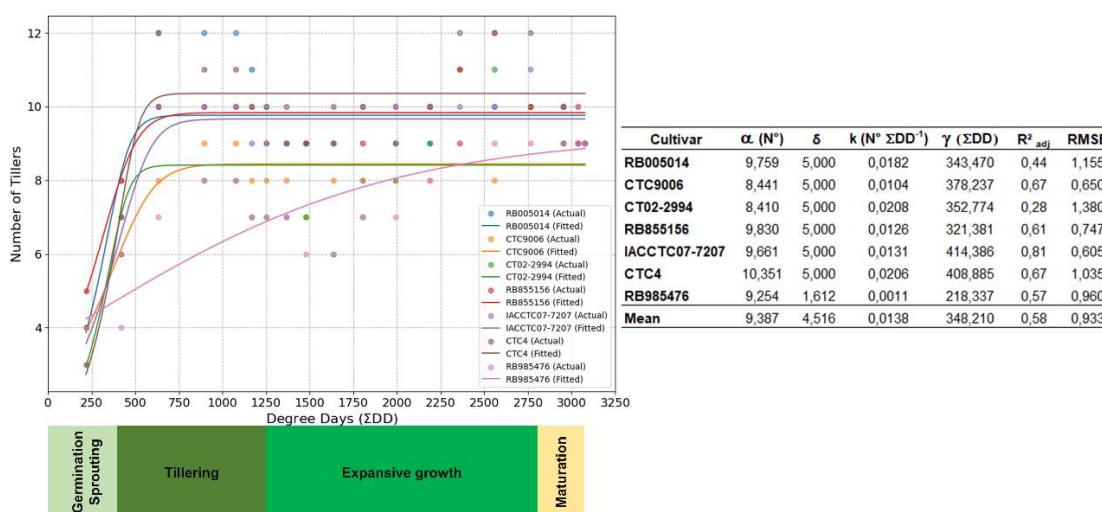


Figura 6: Ajuste do modelo de Richards para número de perfilho em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

2.3.7 Análise do diâmetro médio do colmo

A modelagem do diâmetro médio do colmo (Figura 7) foi a que apresentou maior dificuldade de ajuste, com um R^2_{adj} médio de apenas 0,46. O modelo de Richards falhou em convergir adequadamente para as cultivares CTC9006 ($R^2_{adj} = 0,03$), CT02-2994 ($R^2_{adj} = 0,05$), RB855156 ($R^2_{adj} = 0,38$) e IACCTC07-7207 ($R^2_{adj} = 0,35$). A alta dispersão dos dados e a aparente falta de um padrão sigmoide claro para esta variável sugerem que o diâmetro do colmo pode ser menos diretamente governado pelo acúmulo térmico em comparação com outras variáveis. Por essa razão, a interpretação dos parâmetros α , κ e γ foi restrita às três cultivares onde o modelo obteve ajuste satisfatório ($R^2_{adj} > 0,72$).

Para as cultivares com ajuste válido, ocorreu uma relação inversa, onde CTC4 e RB005014 apresentaram os menores potenciais máximos de diâmetro (α) de 37,9 mm e 36,4 mm, respectivamente. Mas, em contrapartida, exibiram as maiores taxas relativas de crescimento (k) de 0,0006 e 0,0007 mm ΣDD^{-1} . Isso contrasta com a RB985476, que apresentou um potencial de diâmetro médio maior (α) de 40,7 mm, mas com uma taxa de crescimento (κ) de 0,0003 mm ΣDD^{-1} , consideravelmente mais lenta.




Figura 7: Ajuste do modelo de Richards para diâmetro médio do colmo (mm) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

2.3.8 Dinâmica do índice de área foliar (LAI)

A modelagem do Índice de Área Foliar (LAI) (Figura 8) apresentou alta variabilidade devido à complexidade biológica desta variável, que integra número de perfilhos e tamanho foliar. O ajuste médio do modelo apresentou R^2_{adj} igual à 0,60, com valores individuais variando de 0,38 (RB855156) a 0,80 (IACCTC07-7207). Em média, as cultivares apresentaram um LAI máximo potencial (α) de 5,82, com o pico de crescimento (γ) ocorrendo aos 2039 ΣDD .

A cultivar CTC4 assim como para a característica biométrica de diâmetro médio do colmo, novamente exibiu um comportamento de rápido desenvolvimento inicial, atingindo seu ponto de inflexão (γ) mais cedo que todas (895 ΣDD), mas resultando no menor potencial de dossel (α) com valor de 4,46.

A RB855156 demonstrou desenvolvimento mais prolongado, com o ponto de inflexão (γ) ocorrendo ao final do ciclo (3077 ΣDD), o que permite a construção de um dossel com alto potencial (α) com valor de 6,45. Já a cultivar CT02-2994 destacou-se com o maior potencial de formação de dossel entre todas as cultivares, apresentando uma assíntota a de 7,33, combinada com uma taxa de crescimento (k) de 0,002 LAI ΣDD^{-1} .

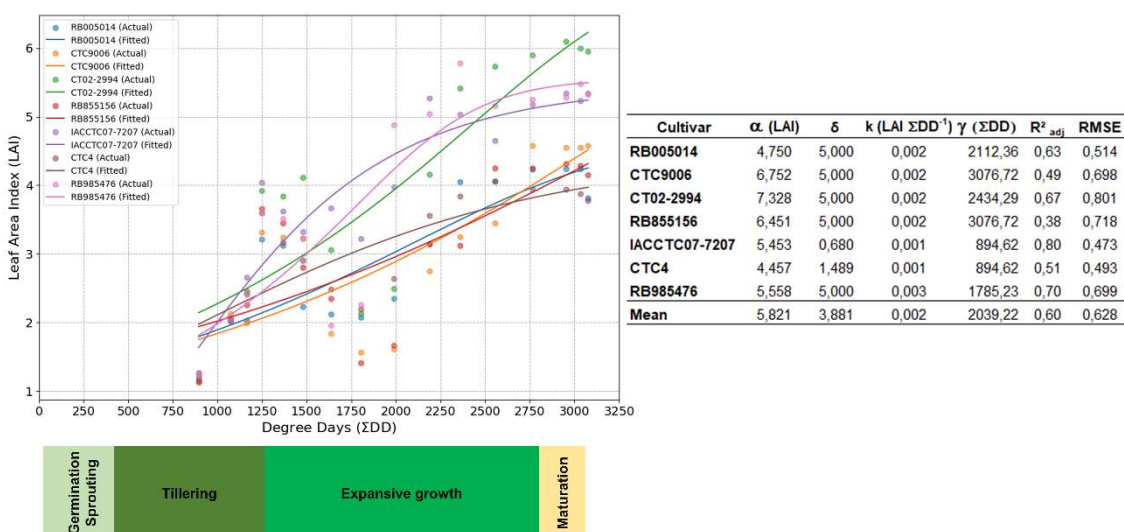


Figura 8: Ajuste do modelo de Richards para índice de área foliar (LAI) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

2.3.9 Dinâmica de acúmulo de produtividade (TCH)

O acúmulo de toneladas de cana por hectare (TCH) (Figura 9) foi a variável mais bem explicada pelo modelo de Richards, alcançando um R^2_{adj} médio de 0,95 e um RMSE de 10,35 t ha⁻¹ (Figura 10). Em média, o potencial de produtividade (α) foi de 306,0 t ha⁻¹, com o pico de acúmulo (γ) ocorrendo aos 1553,9 ΣDD .

Os resultados confirmam uma forte correlação entre o potencial de altura da planta e o potencial de produtividade. As três cultivares que se destacaram com maior potencial de altura (IACCTC07-7207, RB855156 e RB005014) também apresentaram os maiores potenciais de produtividade (α). Sendo a cultivar IACCTC07-7207 a que demonstrou a maior assíntota (α) no valor de 382,5 t ha⁻¹. Seguida pela cultivar RB855156 com a de 341,7 t ha⁻¹ e RB005014 com a de 323,9 t ha⁻¹.

A cultivar CT02-2994 apresentou o menor potencial produtivo com a de 177,1 t ha⁻¹, menos da metade da cultivar de maior produtividade. Curiosamente, esta cultivar foi a que exibiu a maior taxa relativa de acúmulo (k) de 0,0043 t ha⁻¹ ΣDD^{-1} , indicando uma estratégia de crescimento rápido, mas baixo potencial produtivo.

A análise do ponto de inflexão (γ) identificou CTC9006 (665 ΣDD) e CTC4 (694 ΣDD) como as de acúmulo mais precoce. Por outro lado, a RB005014 confirmou seu perfil de ciclo longo, com o pico de acúmulo de TCH ocorrendo mais tarde (γ) aos 2514 ΣDD .

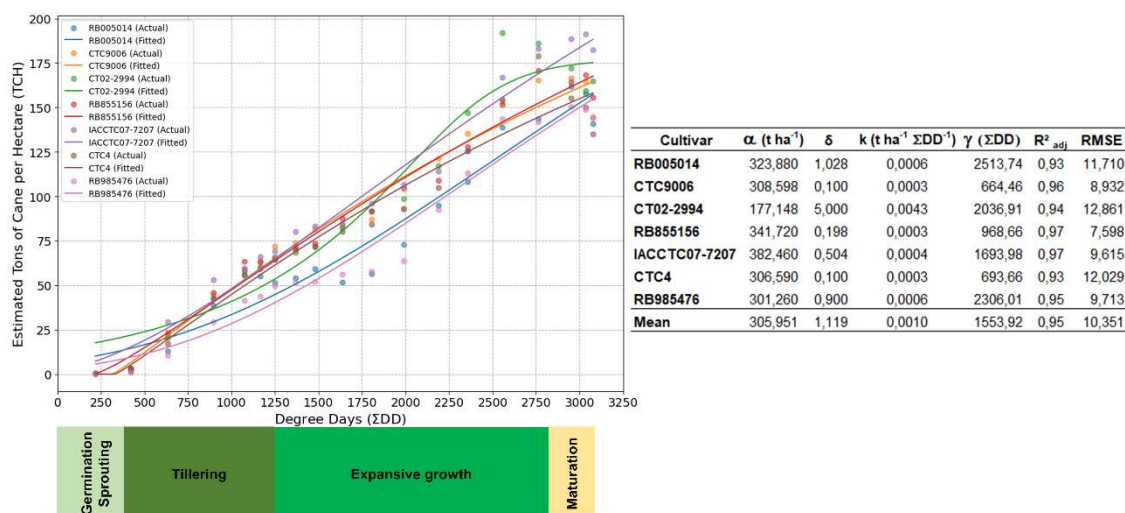


Figura 9: Ajuste do modelo de Richards para produtividade estimada (TCH) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar

2.3.10 Síntese das cultivares e parâmetros

A categorização morfofisiológica, baseada nos parâmetros de máximo potencial (α) e taxa de crescimento (κ), revelou estratégias distintas de acúmulo de biomassa entre os genótipos (Tabela 3). A cultivar IACCTC07-7207 destacou-se por apresentar um balanço arquitetural superior, combinando 'Alto' potencial de perfilhamento e diâmetro de colmo com uma taxa de crescimento 'Lenta', resultando na classificação de 'Alto TCH'. Este comportamento indica uma fenologia de ciclo longo com enchimento de colmos constante. Em contraste, a cultivar CT02-2994 demonstrou que embora classificada com 'Alto' potencial para estatura e área foliar (LAI) e altura da planta, sua rápida taxa de desenvolvimento para TCH culminou em um baixo potencial produtivo, sugerindo baixa eficiência na conversão de tecidos vegetativos em biomassa.

Tabela 3: Padrões morfofisiológicos de desenvolvimento de cultivares de cana-de-açúcar baseados no máximo potencial (α) (alto/médio/baixo) e na taxa de crescimento (κ) (rápido/médio/lento).

CULTIVAR	POTENCIAL DE CARACTERÍSTICAS BIOMÉTRICAS						
	Altura da Planta	Comp. médio do entrenó	Número de Entrenós	Número de Perfilhos	Diâmetro médio do colmo	LAI	TCHe
RB005014	Alto- lento	Alto- lento	Médio- lento	Alto- rápido	Baixo- rápido	Baixo- lento	Médio- lento

CTC9006	Alto- lento	Alto- lento	Alto- lento	Médio- médio	Alto- lento	Médio- lento	Médio- lento
CT02-2994	Alto- lento	Alto- lento	Alto- lento	Médio- rápido	Alto- lento	Alto- lento	Baixo- rápido
RB855156	Médio- médio	Médio- médio	Baixo- rápido	Alto- médio	Alto- lento	Médio- lento	Médio- lento
IACCTC07-7207	Médio- médio	Médio- médio	Alto- lento	Alto- médio	Alto- lento	Médio- lento	Alto- lento
CTC4	Baixo- rápido	Baixo- rápido	Alto- lento	Alto- rápido	Baixo- rápido	Baixo- lento	Médio- lento
RB985476	Baixo- rápido	Baixo- rápido	Baixo- rápido	Alto- lento	Médio- lento	Médio- lento	Médio- lento

2.4 Discussões

2.4.1 A Relação entre parâmetros biométricos e TCH

Os resultados demonstram uma relação positiva entre as assíntotas (parâmetro a) estimadas para a altura e as assíntotas para o TCH. As cultivares que se destacaram com o maior potencial produtivo, notadamente a IACCTC07-7207 (382,5 t ha⁻¹) e a RB855156 (341,7 t ha⁻¹), estão entre as que também apresentaram o maior potencial de altura. Essa correlação é fisiologicamente esperada (Bonnett, 2013; Kang; Miller; Tai, 1983), mas raramente quantificada através de parâmetros de modelos não lineares. O TCH é, em essência, o produto final da biomassa acumulada nos colmos, e a altura da planta é um dos principais vetores arquitetônicos para esse acúmulo (Loureiro et al., 2011).

O número de perfilhos embora fundamental para o estabelecimento inicial do estande, indicou que o potencial máximo de perfilhamento (α) é uma métrica "ruidosa" e um preditor fraco do TCH. A explicação para isso reside no processo dinâmico de competição e mortalidade de perfilhos (Kapur; Duttamajumder; Rao, 2011). Onde o modelo captura a emissão de perfilhos, mas não a senescência e a mortalidade que ocorrem após o fechamento do dossel, um processo que é ampliado pela competição por luz e recursos (Shrivastava et al., 2015). Assim, uma cultivar pode ter um alto número de perfilhos, mas se uma grande proporção desses perfilhos não sobreviver, eles não contribuem para o TCH final (Bezuidenhout et al., 2003).

Na prática é possível afirmar que o monitoramento e a previsão de produtividade em cana-de-açúcar de ciclo longo denominada cana-planta, a altura da planta e, secundariamente, o IAF em função do tempo térmico (ΣDD) é um indicador muito mais robusto do que a contagem de perfilhos. Já para programas de

melhoramento genético que buscam maximizar a produtividade, o foco deve estar em genótipos que combinem uma alta assíntota de altura (α) com uma arquitetura de dossel (IAF) que minimize o auto sombreamento e, por consequência, a mortalidade de perfilhos (Singels; Smit, 2009).

2.4.2 Estratégias genóticas reveladas pelos parâmetros do modelo

A análise dos parâmetros da regressão em conjunto revela que as sete cultivares não diferenciam apenas em seus valores finais, mas em suas estratégias de acúmulo de biomassa. Sendo possível identificar dois perfis principais de resposta ao tempo térmico (ΣDD).

2.4.2.1 Crescimento lento

As cultivares de maior potencial de THC, notadamente IACCTC07-7207, RB855156 e RB005014, exemplificam uma estratégia de crescimento lento. Estas cultivares se caracterizam por taxas de crescimento relativo (κ) mais baixas, associadas a pontos de inflexão (γ) significativamente mais tardios. Fisiologicamente, isso representa um genótipo que particiona recursos de forma constante e prolongada, alinhado com o potencial de um ciclo longo (Inman-Bamber; Lakshmanan; Park, 2012; Moore; Maretzki, 1996).

Isso pode trazer implicações econômicas como uma colheita antecipada que poderia resultar em perdas de produtividade (Marin et al., 2021), ou ganhos através de uma partição constante de insumos, estando mais resiliente a intemperes climáticas podendo se recuperar ao longo do ciclo (Moore; Maretzki, 1996). Esses genótipos podem apresentar grande potencial para maximizar a produtividade em ambientes sem restrições.

2.4.2.2 Crescimento rápido

As cultivares como CTC4 e RB985476 demonstraram uma estratégia de crescimento rápido. A CTC4, por exemplo, atingiu seu pico de acúmulo de TCH (γ) muito cedo, aos 694 ΣDD . Da mesma forma, a RB985476 definiu seu número de entrenós ($\gamma = 749 \Sigma DD$) e comprimento de entrenós ($\gamma = 895 \Sigma DD$) precocemente, ainda na fase de perfilhamento. Essa precocidade, caracterizada pelo baixo ponto de

inflexão (γ) está ligada a taxas (κ) mais altas, e também, a um potencial máximo (α) significativamente menor.

A cultivar CTC4, também apresentou um a de TCH 30% menor que a média geral. Isso sugere que esses genótipos são programados para um ciclo de vida rápido, eles crescem cedo, mas também atingem a senescência ou o potencial máximo muito antes do final do ciclo de 18 meses. Na prática, elas poderiam ser genótipos superiores para sistemas de cana-soca (12 meses), onde a capacidade de atingir a maturação rapidamente é uma característica desejada (Li, 2022; Wagih; Ala; Musa, 2004).

2.4.3 Impacto do ambiente e as limitações da modelagem

Os resultados revelam que o poder preditivo do modelo de Richards, baseado unicamente no somatório de graus-dia (ΣDD), foi altamente dependente da variável biométrica analisada. O modelo teve bom desempenho para descrever variáveis de acúmulo estrutural de longo prazo, como altura ($R^2_{adj} = 0,96$) e produtividade final ($R^2_{adj} = 0,95$). No entanto, sua eficácia foi baixa para variáveis fisiologicamente mais "ruidosas" e dinâmicas, como o diâmetro do colmo ($R^2_{adj} = 0,46$) e o número de perfilhos ($R^2_{adj} = 0,58$).

Esta não é uma falha do estudo, mas sim uma descoberta. Embora o ΣDD , seja o principal vetor de desenvolvimento, não é o único (Kumar et al., 2024; Liu; Kingston; Bull, 1998). O baixo ajuste para o diâmetro do colmo, apresentando R^2_{adj} variando de 0,03 a 0,86 é um indicativo de que este parâmetro biométrico sofre pouca influência do acúmulo térmico e é mais influenciado por outras variáveis (Li, 2022). O diâmetro pode flutuar diária e semanalmente com base no turgor celular, um processo que um modelo baseado em ΣDD não pode capturar, explicando a alta dispersão dos dados (Jaiphong et al., 2016; Zhao et al., 2020).

Além disso, a natureza determinística do modelo suaviza os impactos de estresses abióticos pontuais. Conforme os dados meteorológicos (Figura 2), o experimento foi submetido a uma redução nos índices de precipitação entre 180 e 300 DAP. Este período coincidiu exatamente com o final da fase de perfilhamento e o início do crescimento expansivo.

2.4.4 Implicações para o manejo agrônômico e o melhoramento genético

Os parâmetros α , κ e γ não descrevem apenas o crescimento, mas fornecem parâmetros quantitativos que podem redefinir as estratégias de manejo e seleção de cultivares. Esses parâmetros podem ser utilizados como indicadores diretos de como um genótipo deve ser manejado no campo e o que ele pode oferecer a um programa de melhoramento.

2.4.4.1 Implicações para o manejo agrônômico

Tradicionalmente, decisões de manejo, como a adubação de cobertura e o controle de pragas e doenças, são baseadas em um calendário fixo (Fewkes; Greathead, 1978). Nossos resultados oferecem uma abordagem de precisão muito superior, baseada no tempo térmico (ΣDD) e nos parâmetros genótipo-específicos. O parâmetro γ (ponto de inflexão), que marca o momento que ocorre a taxa máxima de crescimento, pode ser compreendido também como o ponto de máxima demanda nutricional (Dos Santos Wanderley et al., 2021).

Os resultados mostram que esta demanda pode variar a depender da cultivar utilizada. A cultivar CTC4, por exemplo, atingiu seu pico de acúmulo de TCH (γ) aos 694 ΣDD . Já a cultivar RB005014 atingiu o mesmo pico apenas aos 2514 ΣDD . Isso significa que um manejo agrônômico como uma adubação nitrogenada e potássica de cobertura para a cultivar CTC4, deve ser aplicada antes dos 600 ΣDD para sincronizar a oferta de nutrientes com o pico de demanda (Dos Santos Wanderley et al., 2021).

Já realizar a adubação nesta mesma janela para a RB005014 seria ineficiente, pois sua demanda máxima só ocorrerá 1800 ΣDD depois, podendo levar a perdas por lixiviação ou volatilização (De Castro et al., 2022). Da mesma forma, os parâmetros de assíntota (α) demonstram o manejo da colheita, ou seja, tentar colher a cultivar RB005014 que possui um a tardio no mesmo ponto que a CTC4 resultaria em uma penalidade de produtividade, pois ela ainda estaria em plena fase de acúmulo. Dessa maneira, o manejo de fertilização e colheita de precisão, pode ser otimizado e personalizado através de ΣDD específicos para cada cultivar.

2.4.4.2 Implicações para o melhoramento genético

Para programas de melhoramento, a produtividade final (TCH) é o alvo. Neste presente trabalho separamos a produtividade em seus parâmetros quantitativos, o potencial (α), a taxa (κ) e o tempo (γ). Isso permite uma seleção genética mais específica da característica desejada pelo melhorista, tornando a identificação de doadores de genes mais fácil (Sandhu et al., 2022).

A cultivar IACCTC07-7207 pode se apresentar como uma doadora de genes para alto potencial de THC (α). Por outro lado, a CT02-2994, apesar de seu baixo potencial de TCH (α) final, é uma fonte de genes para vigor inicial demonstrando uma alta taxa de resposta (κ). Neste cenário uma boa opção para o melhoramento seria um cruzamento que combine o α da IACCTC07-7207 com o k da CT02-2994.

A seleção tradicional exige que o melhorista espere o ciclo completo do cultivo para medir o TCH final (Cursi et al., 2022; Sandhu et al., 2022). Com esta metodologia é possível ajustar o modelo de Richards aos dados coletados nos primeiros 1000 Σ DD e projetar qual será a assíntota final (α) daquele genótipo. Isso permite ao melhorista otimizar a escolha de genótipos logo no primeiro ano, acelerando o tempo de seleção.

2.4.5 Limitações do estudo e perspectivas futuras

Embora este estudo tenha quantificado com sucesso as diferentes estratégias de desenvolvimento de sete cultivares de cana-de-açúcar, é importante citar que os parâmetros α , κ e γ estimados não devem ser interpretados como constantes genéticas universais, mas sim como o resultado da interação Genótipo x Ambiente, específica deste ensaio (Ramburan; Zhou; Labuschagne, 2011). O estudo foi conduzido em um único local e em um ciclo de 18 meses, que incluiu períodos de precipitação e de escassez hídrica. É certo que esta condição pode influenciar a expressão do potencial genético, possivelmente alterando as taxas de crescimento (κ) e os momento dos picos de crescimento (γ) (De Miranda; Fonseca, 2020).

Outro fator constatado é que, a natureza determinística do modelo de Richards, embora poderosa, é uma simplificação. A sua dificuldade em descrever adequadamente o diâmetro do colmo (R^2_{adj} médio de 0,46) e o número de perfilhos (R^2_{adj} médio de 0,58) são evidências de que o somatório de graus-dia (Σ DD) não é o

único fator que determina o crescimento (Li, 2022). Estas variáveis são fortemente influenciadas por processos dinâmicos, como o balanço hídrico e a competição interespecífica, que um modelo baseado apenas em temperatura não captura (Cuadra et al., 2012).

Estas limitações, no entanto, pavimentam o caminho para pesquisas futuras. As implicações práticas sugeridas nesta discussão devem agora ser validadas como hipóteses de campo. Propomos ensaios futuros para testar ativamente se o manejo da adubação de cobertura baseado nos alvos γ específicos de cada cultivar, como 694 ΣDD para a CTC4 e 2514 ΣDD para a RB005014, resulta em um aumento comprovado na eficiência do uso de fertilizantes.

2.5 Considerações finais

O modelo de regressão não linear de Richards foi o mais robusto e acurado para descrever a resposta das sete cultivares de cana-de-açúcar ao acúmulo de índice térmico (ΣDD), apresentando um bom ajuste para as variáveis agronômicas como altura da planta e produtividade estimada (TCH). O acúmulo térmico (ΣDD) é um preditor eficaz do desenvolvimento do cultivo, mas a resposta a ele é genótipo-específica.

A análise paramétrica do modelo de Richards permitiu quantificar duas estratégias de desenvolvimento principais. O crescimento lento, como ocorre nas cultivares IACCTC07-7207 e RB855156, que maximiza o potencial produtivo (α) através de um ciclo mais longo (γ). E o crescimento rápido, como o caso da cultivar CTC4, que cresce rapidamente (k) e atinge um pico precoce (γ), sendo possivelmente mais adaptada a ciclos curtos.

O potencial de altura da planta (a) foi validado como o parâmetro biométrico de maior correlação com o potencial de produtividade final (α_{TCH}), consolidando-o como um indicador-chave para seleção em programas de melhoramento.

Já os parâmetros biométricos com alta variabilidade como número de perfilhos e diâmetro de colmo, não tiveram grande sucesso ao serem explicados pelo ΣDD ,

indicando que possivelmente possuem interações maiores com outros fatores como competição entre plantas ou déficit hídrico.

Conclui-se que os parâmetros a (potencial), κ (taxa) e γ (ponto de inflexão) são ferramentas quantitativas funcionais para a agricultura de precisão. O parâmetro γ , em particular, pode atuar como um indicador do pico de demanda nutricional, permitindo que o manejo da fertilização de cobertura seja customizado para a fenologia específica de cada cultivar, otimizando o uso de insumos e o retorno econômico.

Referências

ALVARES, Clayton Alcarde *et al.* Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

ARCHONTOULIS, Sotirios V.; MIGUEZ, Fernando E. Nonlinear Regression Models and Applications in Agricultural Research. **Agronomy Journal**, v. 107, n. 2, p. 786–798, 2015.

BEZUIDENHOUT, C. N. *et al.* A process-based model to simulate changes in tiller density and light interception of sugarcane crops. **Agricultural Systems**, v. 76, n. 2, p. 589–599, 1 maio 2003.

BOLLERO, Germán A.; BULLOCK, Donald G.; HOLLINGER, Steven E. Soil Temperature and Planting Date Effects on Corn Yield, Leaf Area, and Plant Development. **Agronomy Journal**, v. 88, n. 3, p. 385–390, 1996.

BONNETT, Graham D. Developmental Stages (Phenology). *In*: **Sugarcane: Physiology, Biochemistry, and Functional Biology**. [S.l.]: John Wiley & Sons, Ltd, 2013. p. 35–53.

CASAROLI, Derblai *et al.* Using crop models, a decline factor, and a “multi-model” approach to estimate sugarcane yield compared to on-farm data. **Theoretical and Applied Climatology**, 29 nov. 2023.

CUADRA, S. V. *et al.* A biophysical model of Sugarcane growth. **GCB Bioenergy**, v. 4, n. 1, p. 36–48, 2012.

CURSI, Danilo Eduardo *et al.* Origin, Genetic Diversity, Conservation, and Traditional and Molecular Breeding Approaches in Sugarcane. *In*: PRIYADARSHAN, P. M.; JAIN, S. Mohan (Orgs.). **Cash Crops: Genetic Diversity, Erosion, Conservation and Utilization**. Cham: Springer International Publishing, 2022. p. 83–116.

DA SILVA, Cesar J. *et al.* Growth and production of sugarcane varieties under supplementary irrigation and no irrigation. **Revista Caatinga**, v. 36, n. 4, p. 885–896, 2023.

DE CASTRO, Sérgio Gustavo Quassi *et al.* Optimizing Nitrogen Fertilizer Rates at Distinct In-season Application Moments in Sugarcane. **International Journal of Plant Production**, v. 16, n. 1, p. 137–152, 2022.

DE MIRANDA, Evaristo E.; FONSECA, Marcelo F. Chapter 4 - Sugarcane: food production, energy, and environment. *In*: SANTOS, Fernando *et al.* (Orgs.). **Sugarcane Biorefinery, Technology and Perspectives**. [S.l.]: Academic Press, 2020. p. 67–88.

DORMER, K. J. Correlations in plant development: general and basic aspects. *In*: ALLSOPP, Allan *et al.* (Orgs.). **Differentiation and Development / Differenzierung und Entwicklung: Part 1 / Teil 1**. Berlin, Heidelberg: Springer, 1965. p. 452–478.

DOS SANTOS WANDERLEY, Luan Rafael *et al.* Nutritional Requirement by Irrigated Brazilian Sugarcane Varieties. **Sugar Tech**, v. 23, n. 4, p. 762–775, 1 ago. 2021.

ENDRES, Lauricio *et al.* Morphological changes recorded in different phenophases of sugarcane plants subjected to water stress in tropical field conditions. **Australian Journal of Crop Science**, v. 12, n. 7, p. 1041–1050, 2018.

FEWKES, Derek W.; GREATHEAD, David J. Progress towards the integrated control of sugar cane pests. **Pesticide Science**, v. 9, n. 5, p. 445–457, 1978.

INMAN-BAMBER, N. G.; LAKSHMANAN, P.; PARK, S. Sugarcane for water-limited environments: Theoretical assessment of suitable traits. **Field Crops Research**, v. 134, p. 95–104, 12 ago. 2012.

Instituto Agrônômico (IAC) - Cultivares. Disponível em: <<https://www.iac.sp.gov.br/cultivares/inicio/resultados.php>>. Acesso em: 23 out. 2025.

JAIPHONG, Thanankorn *et al.* Effects of duration and combination of drought and flood conditions on leaf photosynthesis, growth and sugar content in sugarcane. **Plant Production Science**, v. 19, n. 3, p. 427–437, 2 jul. 2016.

JAMES, Gareth *et al.* Linear Regression. *In*: JAMES, Gareth *et al.* (Orgs.). **An Introduction to Statistical Learning: with Applications in Python**. Cham: Springer International Publishing, 2023. p. 69–134.

JONES, M. R. *et al.* Exploring process-level genotypic and environmental effects on sugarcane yield using an international experimental dataset. **Field Crops Research**, v. 244, p. 107622, 1 dez. 2019.

KANG, M. S.; MILLER, J. D.; TAI, P. Y. P. Genetic and Phenotypic Path Analyses and Heritability in Sugarcane. **Crop Science**, v. 23, n. 4, p. crops1983.0011183X002300040010x, 1983.

KAPUR, Raman; DUTTAMAJUMDER, S. K.; RAO, K. Krishna. A breeder's perspective on the tiller dynamics in sugarcane. **Current Science**, v. 100, n. 2, p. 183–189, 2011.

KOHILA, S.; GOMATHI, R. Adaptive physiological and biochemical response of sugarcane genotypes to high-temperature stress. **Indian Journal of Plant Physiology**, v. 23, n. 2, p. 245–260, 1 jun. 2018.

KUIJPER, J. DeGroeij van Bladschijf, Bladscheede em Stengel van het suikerriet. **Arch Suikerind Ned Indië**, v. 23, n. 1, p. 528–556, 1915.

KUMAR, Tanweer *et al.* Genetic Engineering for Enhancing Sugarcane Tolerance to Biotic and Abiotic Stresses. **Plants**, v. 13, n. 13, p. 1739, jan. 2024.

LAZARINI, Marco A.; ZAMBROSI, Fernando C. B. Propagation Materials do not Affect Nutrient Absorption of Sugarcane During the Plant-Cane Cycle. **Sugar Tech**, v. 27, n. 2, p. 559–565, 1 abr. 2025.

LEITE, Emily Aquino *et al.* Assessing climate change impacts on sugarcane yield, crop water productivity, and nitrous oxide emissions across Brazil's bioenergy using the CSM-SAMUCA-sugarcane model. **Agricultural Systems**, v. 231, p. 104494, 1 jan. 2026.

LI, Yang-Rui. Growth and Development of Sugarcane (*Saccharum* spp. Hybrid) and Its Relationship with Environmental Factors. *In*: VERMA, Krishan K. *et al.* (Orgs.). **Agro-industrial Perspectives on Sugarcane Production under Environmental Stress**. Singapore: Springer Nature, 2022. p. 1–11.

LIU, D. L.; KINGSTON, G.; BULL, T. A. A new technique for determining the thermal parameters of phenological development in sugarcane, including suboptimum and supra-optimum temperature regimes. **Agricultural and Forest Meteorology**, v. 90, n. 1, p. 119–139, 1 mar. 1998.

LOUREIRO, Marcelo E. *et al.* Sugarcane Breeding and Selection for more Efficient Biomass Conversion in Cellulosic Ethanol. *In*: BUCKERIDGE, Marcos Silveira; GOLDMAN, Gustavo H. (Orgs.). **Routes to Cellulosic Ethanol**. New York, NY: Springer, 2011. p. 199–239.

MARCHIORI, Paulo E. R. *et al.* Plant growth, canopy photosynthesis and light availability in three sugarcane varieties. **Sugar Tech**, v. 12, n. 2, p. 160–166, 1 jun. 2010.

MARIN, Fabio R. *et al.* Sugarcane Yield and Yield Components as Affected by Harvest Time. **Sugar Tech**, v. 23, n. 4, p. 819–826, 1 ago. 2021.

MOORE, Paul H.; MARETZKI, Andrew. Sugarcane. *In*: **Photoassimilate Distribution Plants and Crops Source-Sink Relationships**. [S.l.]: Routledge, 1996.

NGOBESE, Immaculate; RAMBURAN, Sanesh; LABUSCHAGNE, Maryke. Quantifying sugarcane cultivar differences in tiller and stalk phenology: identifying traits suited to crop model-assisted breeding. **Journal of Crop Improvement**, v. 32, n. 6, p. 847–860, 2 nov. 2018.

RAMBURAN, S.; ZHOU, M.; LABUSCHAGNE, M. Interpretation of genotype × environment interactions of sugarcane: Identifying significant environmental factors. **Field Crops Research**, v. 124, n. 3, p. 392–399, 20 dez. 2011.

RIDESA: Variedades RB. Disponível em: <<https://www.ridesa.com.br/variedades/>>. Acesso em: 23 out. 2025.

SAGE, Rowan F.; PEIXOTO, Murilo Melo; SAGE, Tammy L. Photosynthesis in Sugarcane. *In: Sugarcane: Physiology, Biochemistry, and Functional Biology*. [S.l.]: John Wiley & Sons, Ltd, 2013. p. 121–154.

SANDHU, Karansher Singh *et al.* Integrated Approach in Genomic Selection to Accelerate Genetic Gain in Sugarcane. **Plants**, v. 11, n. 16, p. 2139, jan. 2022.

SHRIVASTAVA, A. K. *et al.* Physiological Interventions for Enhancing Sugarcane and Sugar Productivity. **Sugar Tech**, v. 17, n. 3, p. 215–226, 1 set. 2015.

SIANSI, Frederico Luiz [UNESP]. Emissão de co2 do solo e indicadores de produtividade e suas relações com características espectrais da cana - de - açúcar sob diferentes épocas de plantio. 5 fev. 2024.

SINGELS, A.; SMIT, M. A. Sugarcane response to row spacing-induced competition for light. **Field Crops Research**, v. 113, n. 2, p. 149–155, 3 ago. 2009.

Variedades CTC. Disponível em: <<https://ctc.com.br/produtos/>>. Acesso em: 23 out. 2025.

WAGIH, M. E.; ALA, A.; MUSA, Y. Evaluation of sugarcane varieties for maturity earliness and selection for efficient sugar accumulation. **Sugar Tech**, v. 6, n. 4, p. 297–304, 1 dez. 2004.

ZHAO, Duli *et al.* Sugarcane Plant Growth and Physiological Responses to Soil Salinity during Tillering and Stalk Elongation. **Agriculture**, v. 10, n. 12, p. 608, dez. 2020.

ZHAO, Duli; ZHU, Kai; LABORDE, Chris. Sugarcane Growth, Physiological and Yield Responses to Application of Trinexapac-ethyl (Moddus™) in Grand Growth Phase. **Journal of Plant Growth Regulation**, v. 42, n. 5, p. 2813–2826, 1 maio 2023.

CAPÍTULO 3 – Previsão de produtividade de cana-de-açúcar com seis meses de antecedência através de *machine learning*

Resumo:

A modelagem agrometeorológica através de algoritmos de *Machine Learning* (ML) surge como uma estratégia para identificar interações não lineares complexas entre variáveis ambientais e a produtividade da cana-de-açúcar. Este estudo teve o objetivo de treinar e testar seis diferentes modelos para a previsão da produtividade da cana-de-açúcar no Brasil com seis meses de antecedência. Foram avaliados os algoritmos: *Multiple Linear Regression (RLM)*, *Multilayer Perceptron (MLP)*, *Support Vector Regression (SVR)*, *Random Forest Regression (RF)*, *Extreme Gradient Boosting Regression (XGBoost)* e *Gradient Boosting Regressor (GBR)*, utilizando uma série histórica de 30 anos (1992–2022) de 100 municípios representativos, integrando 432 variáveis agrometeorológicas. Os resultados demonstraram a superioridade do algoritmo *Random Forest (RF)*, que apresentou o melhor desempenho estatístico ($R^2_{\text{adj}} = 0,63$). A análise de importância de variáveis revelou que a produtividade é majoritariamente definida em uma janela crítica entre o 16º e o 29º decêndio do ciclo, sendo o armazenamento de água no solo e a umidade relativa os principais preditores. Espacialmente, o modelo apresentou maior acurácia nas regiões Sudeste e Centro-Oeste, evidenciando sua eficácia nos polos de alta produtividade e relevância econômica. A previsão com antecedência, fornecida pelo modelo é uma ferramenta estratégica de suporte à decisão para o setor sucroenergético, permitindo a otimização logística e o planejamento antecipado, contribuindo para a resiliência do setor frente às variabilidades climáticas.

Palavras-chave: *Saccharum officinarum*; *Random Forest*; Previsão de safra; Agrometeorologia.

CHAPTER 3 – Predicting sugarcane productivity six months in advance through machine learning

Abstract:

Agrometeorological modeling using Machine Learning (ML) algorithms emerges as a strategy to identify complex nonlinear interactions between environmental variables and sugarcane productivity. This study aimed to train and test six different models for predicting sugarcane productivity in Brazil six months in advance. The following algorithms were evaluated: Multiple Linear Regression (RLM), Multilayer Perceptron (MLP), Support Vector Regression (SVR), Random Forest Regression (RF), Extreme Gradient Boosting Regression (XGBoost), and Gradient Boosting Regressor (GBR), using a 30-year historical series (1992–2022) from 100 representative municipalities, integrating 432 agrometeorological variables. The results demonstrated the superiority of the Random Forest (RF) algorithm, which presented the best statistical performance ($R^2_{adj} = 0.63$). The analysis of variable importance revealed that productivity is largely defined within a critical window between the 16th and 29th ten-day periods of the cycle, with soil water storage and relative humidity being the main predictors. Spatially, the model showed greater accuracy in the Southeast and Midwest regions, demonstrating its effectiveness in areas of high productivity and economic relevance. The forward forecast provided by the model is a strategic decision support tool for the sugarcane and ethanol sector, allowing for logistical optimization and advance planning, contributing to the sector's resilience in the face of climate variability.

Keywords: *Saccharum officinarum*; Random Forest; Crop forecast; Agrometeorology.

3.1 Introdução

A utilização de algoritmos de Machine Learning (ML) na agricultura permite que interações não lineares complexas entre variáveis ambientais e o ganho de produtividade possam ser identificadas e interpretadas (Almeida et al., 2021). Esses algoritmos possuem uma estrutura robusta para processar grandes volumes de dados, com capacidade de integrar informações históricas e em tempo real, eles demonstram bom desempenho quando aplicados em grande ou pequena escala (Attri; Awasthi; Sharma, 2024).

Essas ferramentas podem ser aplicadas na agricultura de forma estratégica, para fornecer informações importantes como a previsão de safra, doenças e clima (Pallathadka et al., 2023). Informações como essa possibilita que o setor agrícola possa ser resiliente e tome decisões que auxiliem a mitigar os impactos das mudanças climáticas (Almeida et al., 2021). Para a agricultura, a capacidade de antecipar quedas na produtividade permite o ajuste antecipado de manejos agronômicos e a otimização do uso de insumos (Alam; Israr; Kumar, 2024). Sendo fundamental para a manutenção da estabilidade produtiva de alimento, frente ao aumento da frequência de eventos extremos, como secas prolongadas e oscilações térmicas.

Para o cultivo da cana-de-açúcar, a utilização de algoritmos de machine learning para a modelagem da produtividade, auxilia o setor no cumprimento dos objetivos de desenvolvimento sustentável (ODS) da agenda 2030 da ONU. A possibilidade de garantir a previsibilidade da produção de bioenergia, contribui para aumento de fontes de energia limpa e acessível (ODS 7). Essa previsibilidade promove uma agricultura de baixo carbono e alta eficiência tecnológica (ODS 12 e ODS 13).

Para os países que ocupam a liderança mundial na produção desse cultivo que é a terceira commodity mais produzida no mundo (Toscano Miranda et al., 2021). A cana-de-açúcar, representa uma parcela significativa do PIB agropecuário, como o caso do Brasil, maior produtor mundial, seguido da Índia, China e Tailândia (Fioranelli; Bizzo, 2023). Além da relevância econômica, o cultivo também possui um papel social, gerando milhões de empregos e sustentando a matriz de biocombustíveis (Brunner, 2023; Silva; Perico; Santana, 2023).

A capacidade de previsão antecipada da produtividade possibilita decisões estratégicas em toda a cadeia produtiva, como o planejamento logístico, o cronograma de moagem nas usinas e até a regulação de preços no mercado internacional de açúcar e etanol. Contudo, apesar da importância do Brasil como maior produtor mundial, estudos que empreguem algoritmos de machine learning para a modelagem da produtividade de cana-de-açúcar em escala nacional, integrando a variabilidade climática de todo o território, ainda são incipientes.

Dessa forma, este estudo tem por objetivo desenvolver e validar modelos agrometeorológicos baseados em *machine learning* para a previsão da produtividade da cana-de-açúcar no Brasil. Busca-se identificar quais algoritmos e variáveis climáticas apresentam maior poder preditivo, fornecendo uma ferramenta de suporte à decisão que auxilie a viabilidade operacional para o setor sucroenergético.

3.2 Material e métodos

3.2.1 Área de estudo

O estudo abrange o território brasileiro, maior produtor mundial de cana-de-açúcar (*Saccharum officinarum*), considerando a diversidade ambiental das principais regiões produtoras. A janela de modelagem compreende o ciclo total de 18 meses da cana-planta. No entanto, o conjunto de preditores é limitado até o 12º mês após o plantio, permitindo uma antecedência de 6 meses em relação à colheita. Para garantir a robustez estatística e a generalização dos modelos de *machine learning*, foi adotado um protocolo de amostragem estratificada em três etapas.

Inicialmente, foram analisados todos os municípios brasileiros com registros de produção de cana-de-açúcar na base de dados do IBGE entre 1992 e 2022. Municípios com séries temporais incompletas ou ausência de dados em qualquer ano do período de 30 anos foram excluídos para evitar viés em algoritmos sensíveis a dados faltantes.

O segundo passo foi caracterizado pela relevância econômica, focando em áreas de consolidada aptidão agrícola para o cultivo. Selecionou-se os 10% dos municípios com maior área colhida em 2022 em cada estado do país. Esse critério

garante que os modelos sejam treinados considerando ambientes onde o cultivo possui relevância produtiva real.

O terceiro passo buscou assegurar a generalidade dos modelos. Nesse momento, 100 municípios (Tabela 1 – Apêndice 2) foram selecionados aleatoriamente (Figura 1) via biblioteca *Pandas* (Python 3.10), permitindo que a amostra representasse diferentes gradientes de latitude, longitude e regimes pluviométricos, mitigando o *overfitting* espacial.

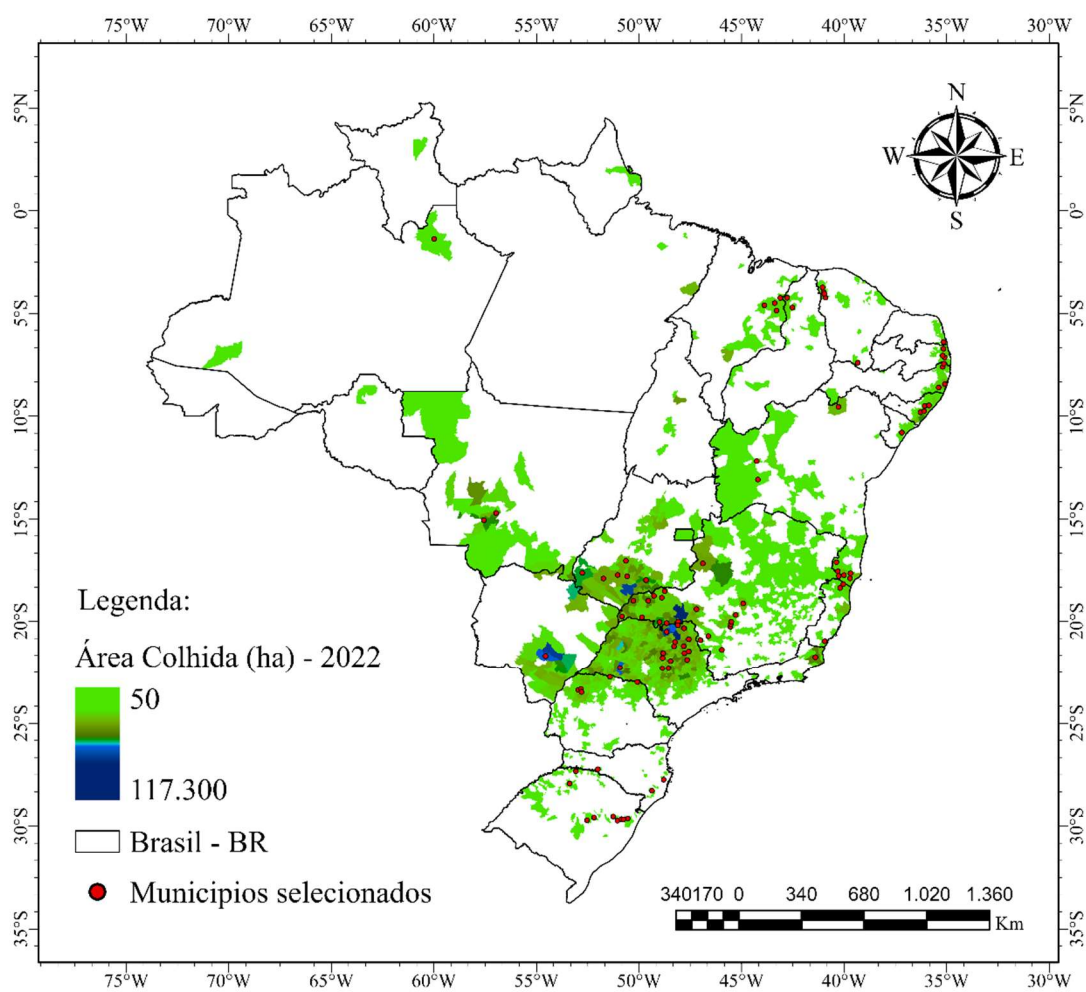


Figura 1: Mapa de localização dos municípios selecionados aleatoriamente.

3.2.2 Aquisição e processamento de dados

Os dados de produtividade (kg ha^{-1}) foram obtidos via sistema SIDRA (Sistema IBGE de Recuperação Automática), provenientes da pesquisa de Produção Agrícola

Municipal (PAM). O recorte temporal compreendeu o período de 1992 a 2022, totalizando uma série histórica de 30 anos, essencial para capturar a variabilidade interanual e tendências climáticas de longo prazo.

Dada a amplitude temporal da série, a produtividade observada reflete não apenas as oscilações climáticas, mas também o incremento tecnológico, como melhoramento genético, manejo de solos e mecanização. Para isolar o efeito estritamente meteorológico da variabilidade na produtividade, procedeu-se à remoção da tendência tecnológica. Este procedimento é fundamentado na premissa de que o componente linear da série representa o avanço técnico, enquanto os resíduos da regressão (variabilidade residual) são explicados predominantemente pelas variáveis ambientais. Para cada local analisado, ajustou-se um modelo de regressão linear simples, utilizando o tempo como variável independente (Equação 1).

$$Y_{ct} = \alpha + (\beta \times t) + Et \quad (1)$$

Onde: Y_{ct} : produtividade observada no ano t ; α : intercepto, representando o nível tecnológico basal no início da série; β : coeficiente angular, que quantifica a taxa de ganho tecnológico anual ($\text{kg ha}^{-1} \text{ ano}^{-1}$); t : variável tempo (anos); Et : resíduo do modelo, representando a variabilidade da produtividade (delta) decorrente de fatores não tecnológicos, majoritariamente agrometeorológicos.

Os dados meteorológicos foram extraídos da plataforma *NASA Prediction of Worldwide Energy Resources (POWER)*, com resolução espacial de $0,5^\circ \times 0,5^\circ$. A série temporal (1992–2021) foi processada em escala diária e, posteriormente, agrupada em decêndios (períodos de 10 dias). Essa escala temporal é preferível em estudos agrometeorológicos por capturar a variabilidade intra-sazonal sem o ruído inerente aos dados diários. Cada ano civil foi composto por 36 decêndios.

O balanço hídrico climatológico foi calculado seguindo o método de Thornthwaite & Mather (1955). Adotou-se uma capacidade de água disponível (CAD) fixa de 100 mm, valor representativo para solos de textura média/argilosa em estudos regionais. A partir do balanço hídrico, obteve-se as variáveis, deficiência hídrica (DEF), excedente hídrico (EXC) e armazenamento de água no solo (ARM).

Para atender ao objetivo de previsão com 6 meses de antecedência, a matriz de entrada (*input*) foi estruturada utilizando uma janela preditiva que abrange os primeiros 12 meses do ciclo (36 decêndios iniciais). Para cada ponto amostral de produtividade (*target*) foram atribuídas 432 variáveis preditoras (*features*). As variáveis e suas respectivas formas de agregação estão detalhadas na Tabela 1.

Tabela 1: Variáveis agrometeorológicas utilizadas na modelagem.

<i>Features</i>	Unidade	Agregação
Radiação Solar Global	MJ m ² -1 day ⁻¹	Média
Temperatura Máxima	°C	Média
Temperatura Média	°C	Média
Temperatura Mínima	°C	Média
Velocidade do Vento a 2 metros	m s ⁻¹	Média
Precipitação	mm	Soma
Humidade Relativa	%	Média
Evapotranspiração de Referência (ET _o)	mm	Média
Evapotranspiração Real (ET _r)	mm	Média
Armazenamento de Água no Solo	mm	Média
Deficiência Hídrica	mm	Soma
Excedente Hídrico	mm	Soma

Devido à heterogeneidade das escalas das variáveis agrometeorológicas, os dados foram submetidos à normalização Min-Max, reescalando para um intervalo entre 0 e 1. Este procedimento de *feature scaling* foi utilizado para garantir a estabilidade numérica durante o treinamento, prevenindo que variáveis com maiores magnitudes absolutas dominem o cálculo dos gradientes e enviesem a convergência dos algoritmos de *machine learning*.

O conjunto de dados final, após a integração das 432 *features* preditivas e do *target* (produtividade corrigida), consolidou-se em uma matriz de 3000 linhas e 433 colunas. Esta estrutura amostral compreende a série histórica de 30 anos (1992–2022) distribuída entre as 100 localidades selecionadas no estudo.

3.2.3 Algoritmos de machine learning e treinamentos

Para a previsão da produtividade da cana-de-açúcar, foram selecionados seis algoritmos de machine learning, incluindo *Multiple Linear Regression* (RLM), *Multilayer Perceptron* (MLP), *Support Vector Regression* (SVR), *Random Forest Regression* (RF) e *Extreme Gradient Boosting Regression* (XGBoost) e *Gradient Boosting Regressor* (GBR). Essa diversidade permitiu comparar o desempenho de abordagens, frente à alta dimensionalidade dos dados agrometeorológicos. Todos os modelos foram implementados em ambiente *Python* (v. 3.3), utilizando a biblioteca *Scikit-learn* e *XGBoost* no ambiente *Google Colaboratory*.

A Regressão Linear Múltipla (MLR) foi utilizada como baseline estatístico para capturar associações lineares (Vesey et al., 2011). Em contrapartida, a *Multilayer Perceptron* (MLP) foi aplicada para modelar interações não lineares complexas através de suas camadas ocultas, sendo reconhecida pela eficácia em dados de alta dimensão (Erdem; Bozkurt, 2021).

O *Support Vector Regression* (SVR) foi selecionado por sua capacidade de generalização e robustez em espaços amostrais multivariados, utilizando o mapeamento em dimensões superiores para lidar com padrões ruidosos (Paidipati et al., 2021).

O modelo *Random Forest* foi utilizado por sua resiliência ao overfitting e capacidade de lidar com variáveis altamente correlacionadas através da construção de múltiplas árvores de decisão independentes (Wang; Yao, 2023).

Já o *Gradient Boosting Regressor* (GBR) e *XGBoost*, ambos utilizam o princípio de *boosting*, onde modelos fracos são treinados sequencialmente para minimizar os resíduos dos modelos anteriores. O *XGBoost*, especificamente, foi incluído por sua

eficiência computacional e implementação de regularização avançada, o que previne o *overfitting* (Kiangala; Wang, 2021).

O conjunto de dados consolidado foi dividido em duas frações independentes: 70% para treinamento e 30% para teste. Para assegurar que o desempenho não fosse fruto de uma divisão favorável, utilizou-se a técnica de validação cruzada *k-fold* ($k=5$) dentro do conjunto de treinamento. Este procedimento garante que todos os subconjuntos de dados sejam utilizados tanto para ajuste quanto para validação interna, aumentando a confiabilidade estatística dos parâmetros estimados.

3.2.4 Otimização de hiperparâmetros

Para maximizar a performance de previsão e garantir a generalização dos algoritmos, procedeu-se ao ajuste dos hiperparâmetros por meio de busca exaustiva através do Grid Search com validação cruzada. Este processo buscou identificar a configuração ideal para cada modelo, equilibrando a complexidade do algoritmo com o conjunto de dados (Tabela 2).

Tabela 2: Hiperparâmetros otimizados para os modelos de *machine learning*.

Modelo	Parâmetros	Valores Testados	Valores Definidos
MLP	<i>hidden_layer_sizes</i>	32; 64; 100; 128; 150; 200; 250; 256 3 e 4 neurônios por camada. Ex: (32,32,32,) ... (256,256,256,256,)	150, 100, 256, 150
	<i>activation</i>	relu, identity, tanh	relu
	<i>solver</i>	lbfgs, sgd, adam	adam
	<i>max_iter</i>	100; 200; 300; 400; 500	300
	<i>learning_rate</i>	constant, invscaling, adaptive	constant
	<i>learning_rate_init</i>	0.01; 0.02; 0.03; 0.04; 0.05	0.05
SVR	<i>kernel</i>	rbf, linear, poly	linear
	<i>c</i>	50; 100; 200; 1000	200
	<i>gamma</i>	scale, auto	scale
	<i>max_depth</i>	none; 5; 10; 15; 20; 25	none
RF	<i>n_estimators</i>	100; 150; 200; 250; 300	250
	<i>max_features</i>	sqrt, log2, 0.25; 0.50; 0.75; 1	1

	<i>bootstrap</i>	True, False	True
	<i>tree_method</i>	auto; exact; approx; hist.	auto
XGBoost	<i>learning_rate</i>	0.1; 0.3; 0.05; 0.7	0.1
	<i>max_depth</i>	3;4;5; 6; 7	5
	<i>n_estimators</i>	50; 75; 100; 150; 200; 250	200
	<i>n_estimators</i>	25; 50; 100; 150; 200	200
GBR	<i>learning_rate</i>	0.01; 0.05; 0.1; 0.2	0.1
	<i>max_depth</i>	3; 5; 10; 15; 20	10
	<i>loss</i>	squared_error, absolute_error, quantile	squared_error
	<i>criterion</i>	friedman_mse, squared_error	friedman_mse
	<i>validation_fraction</i>	0.1; 0.2; 0.3	0.2

3.2.5 Métricas de desempenho dos modelos

A acurácia e a capacidade preditiva dos modelos foram avaliadas por meio de quatro métricas estatísticas. O Erro Médio Absoluto (MAE) (Equação 2) e a Raiz do Erro Quadrático Médio (RMSE) (Equação 3) foram utilizados para quantificar a magnitude do erro nas mesmas unidades da variável resposta (kg ha⁻¹). O Erro Quadrático Médio (MSE) (Equação 4) foi incluído para penalizar erros de maior magnitude, dada a sua sensibilidade a *outliers* na produtividade. Utilizou-se também o coeficiente de determinação ajustado (R^2_{adj}) (Equação 5), que incorpora uma penalidade baseada no número de preditores.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{N}} \quad (4)$$

$$R^2_{adj} = \left[1 - \frac{(1-R^2) \times (n-1)}{n-k-1} \right] \quad (5)$$

Onde: y_i : produtividade residual observada; \bar{y}_i : produtividade residual predita pelo modelo; n : número total de observações; k : número de variáveis independentes (atributos).

3.3 Resultados

3.3.1 Desempenho de previsão dos modelos

A modelagem demonstrou que os modelos baseados em árvores de decisão como, *Random Forest Regression* (RF) e *Extreme Gradient Boosting Regression* (XGBoost) e *Gradient Boosting Regressor* (GBR) superaram as abordagens lineares e de redes neurais na previsão da produtividade da cana-de-açúcar (Tabela 2).

O modelo *Random Forest Regression* (RF) apresentou o melhor desempenho estatístico, com o maior coeficiente de determinação ajustado no conjunto de teste, no valor de 0,63 e o menor valor da raiz do erro quadrático médio, com valor de 14.257 kg ha⁻¹. Os modelos GBR e o XGBoost, apresentaram um bom ajuste na fase de treinamento com valores de 0,94 e 0,93 respectivamente, mas ambos demonstraram uma queda de performance na fase de teste, com valores de 0,58 e 0,60 respectivamente, demonstrando uma sensibilidade superior ao ruído dos dados agrometeorológicos.

Já os modelos de *Multiple Linear Regression* (RLM) e *Support Vector Regression* (SVR) apresentaram valores de coeficiente de determinação ajustado de 0,48 e 0,43 respectivamente. Esses modelos apresentaram o menor desempenho entre os seis modelos testados, com pouca capacidade em capturar extremos de produtividade, tendendo a subestimar valores altos e superestimar valores baixos (Figura 3), demonstrando a natureza não linear e complexa das interações entre as variáveis ambientais e a produtividade da cana-de-açúcar.

Tabela 2: Métricas de desempenho para os conjuntos de treinamento e teste.

	Métricas	GBR	MLP	RF	RLM	SVR	XGBoost
Treinamento	MAE	1906,98	11289,61	4984,16	12473,74	13259,85	2556,56
	MSE	29114437,69	20894622,7	50610004,36	255291019,3	306237912,3	33388527,89
	RMSE	5395,77	14454,97	7114,07	15977,82	17499,65	5778,28
	R ² _{adj}	0,94	0,60	0,91	0,51	0,41	0,93

Teste	MAE	11604,24	12338,60	10880,00	13402,98	13526,97	11433,37
	MSE	239610648,9	260647719,2	203289281,0	292007279,5	315969414,0	224442141,2
	RMSE	15479,36	16144,58	14257,95	17088,22	17775,52	14981,39
	R^2_{adj}	0,58	0,53	0,63	0,48	0,43	0,60




Figura 2: Dispersão entre produtividade observada e predita para os modelos testados; a) GBR, b) MLP, c) RF, d) RLM, e) SVR e f) XGBoost.

3.3.2 Random Forest feature importance

A análise da importância das variáveis do modelo Random Forest, que obteve o melhor desempenho preditivo, revelou que um grupo de preditores agrometeorológicos concentrou a maior capacidade de explicação da produtividade. Das 432 variáveis inseridas, as cinco principais contribuíram com aproximadamente 25% do peso total da predição (Figura 4).

A concentração temporal das variáveis mais influentes ocorreu entre o 16º e o 29º decêndio do ciclo da cana-de-açúcar. O armazenamento de água no solo no 20º

decêndio (ARM_20) apresentou o maior score de importância, atingindo o valor de 0,105. Seguido por este, a umidade relativa do ar no 23º decêndio (RH2M_23) como o segundo preditor mais relevante, com um score de 0,092.

As demais variáveis que ficaram entre as cinco mais importantes apresentaram valores menores aos dois primeiros preditores. A velocidade do vento no 29º decêndio (WS2M_29) e no 16º decêndio (WS2M_16) com valor de 0,026 e 0,016 respectivamente. E novamente a variável armazenamento de água no solo no 23º decêndio (ARM_23) com o valor de 0,016.

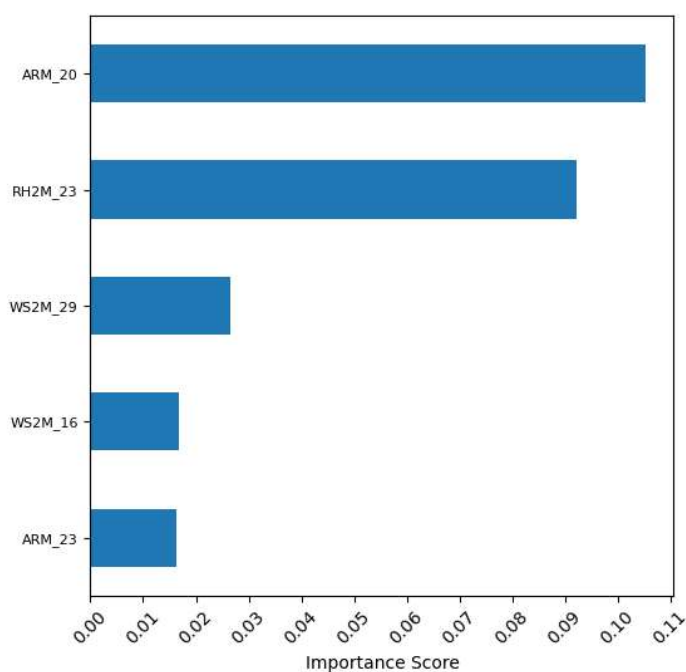


Figura 3: Importância das cinco principais variáveis agrometeorológicas para a previsão da produtividade via Random Forest.

3.3.3 Variabilidade espacial do desempenho preditivo

A análise espacial do coeficiente de determinação ajustado (R^2_{adj}) revelou diferenças na performance do modelo ao longo dos locais estudados (Figura 5). Embora o modelo Random Forest tenha apresentado uma performance global robusta, a capacidade preditiva variou entre as diferentes regiões produtoras de cana-de-açúcar.

Os maiores valores de R^2 , representados pelas tonalidades verde e amarela, com $R^2 > 0,60$ concentraram-se nas regiões Sudeste e Centro-Oeste, com destaque para os estados de São Paulo, Minas Gerais e Goiás. Nestas áreas de expansão e consolidação do setor sucroenergético, o modelo demonstrou bom desempenho em capturar a variabilidade da produtividade, atingindo picos de precisão. O desempenho mais baixo do modelo, representado pelas tonalidades roxas, com $R^2 < 0,40$ foi observado na Região Sul e em pontos isolados no Norte do país.

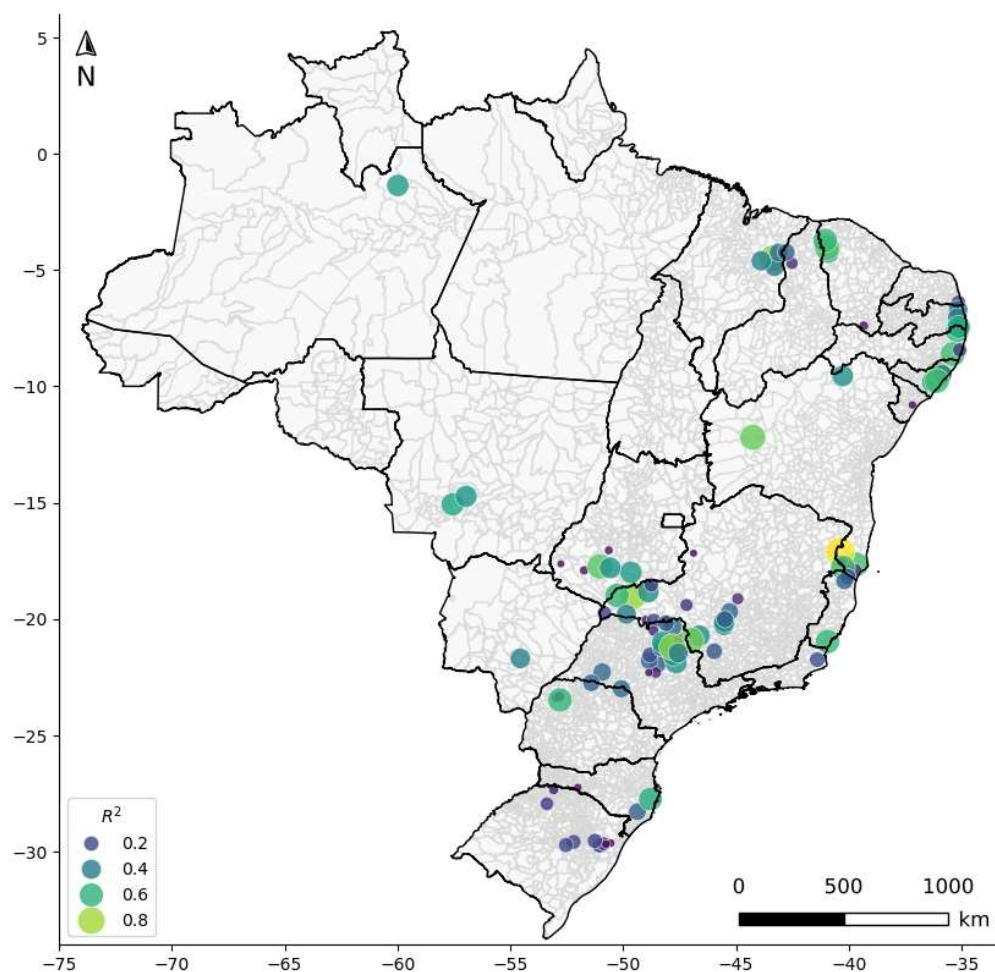


Figura 4: Distribuição espacial do coeficiente de determinação (R^2) para a produtividade da cana-de-açúcar nos municípios selecionados.

3.4 Discussões

3.4.1 Superioridade dos modelos baseados em árvores

A superioridade dos algoritmos baseados em árvores de decisão, especificamente o *Random Forest* (RF), *XGBoost* e *GBR*, em relação às técnicas

lineares e redes neurais (MLP), demonstra como a complexidade não-linear está ligada a interação entre as variáveis ambientais e a produtividade da cana-de-açúcar (Almeida et al., 2021).

O desempenho dos modelos de *boosting* (*XGBoost* e *GBR*) que apresentaram um bom ajuste durante o treinamento e uma queda no momento de teste, esse fenômeno pode ser um indicativo de overfitting, devido ao funcionamento dos modelos de forma sequencial, onde cada árvore tenta corrigir o erro da anterior (Rigatti, 2017). Tendendo a "memorizar" o ruído do treino em vez de aprender o padrão climático geral.

O bom desempenho do modelo Random Forest pode ser explicado pelo uso do princípio de bagging (*Bootstrap Aggregating*), construindo árvores independentes em subconjuntos aleatórios de dados e variáveis (Marcari; De Souza Rolim; De Oliveira Aparecido, 2015). Esse funcionamento permite uma maior capacidade de generalização e menor variância do modelo.

A baixa performance do SVR e da RLM demonstra que modelos que tentam encontrar um hiperplano ou uma relação linear simples não conseguiram processar com a alta dimensionalidade das 432 features (James et al., 2023). A relação entre clima e produtividade da cana não segue uma progressão linear (Bhatt et al., 2023). A resposta a variáveis ambientais como o excesso de chuva (EXC) ou a deficiência hídrica (DEF) pode variar conforme o estágio fenológico da planta. Já os modelos de árvores capazes de capturar essas tendências através de suas ramificações, enquanto modelos lineares tendem a subestimar valores extremos.

O desempenho intermediário da *Multilayer Perceptron* (MLP) demonstra que, para bases de dados tabulares de tamanho moderado (3.000 observações), algoritmos de *Ensemble* baseados em árvores podem superar o *Deep Learning*. Isso ocorre por que as redes neurais exigem um volume de dados massivo (Jiang et al., 2020).

3.4.2 Determinantes ambientais da produtividade

As variáveis de armazenamento de água no solo (ARM) e umidade relativa do ar (RH2M) na hierarquia de importância do modelo demonstra a sensibilidade hídrica do cultivo durante fases fenológicas críticas. O fato do ARM no 20º decêndio (ARM_20) ter sido identificado como o preditor de maior poder explicativo está intrinsecamente ligado ao ciclo biológico da cana-planta.

Este período, situado aproximadamente aos 200 dias após o plantio, coincide com o ápice da fase de grande crescimento vegetativo e alongação dos colmos, momento em que o cultivo atinge seu maior índice de área foliar e apresenta a maior demanda evapotranspirativa (Qin et al., 2023). A disponibilidade hídrica nesta janela é importante para a turgidez celular necessária à expansão dos tecidos (Boyer, 1988). Logo, a ocorrência de déficit hídrico neste estágio prejudica o acúmulo de biomassa e, conseqüentemente, a produtividade final.

Já a variável umidade relativa do ar no 23º decêndio (RH2M_23) complementa essa interpretação ao estar diretamente relacionada na regulação estomática através do déficit de pressão de vapor (Fanourakis; Heuvelink; Carvalho, 2013). A ocorrência de baixos índices de umidade relativa podem induzir o fechamento estomático, sendo um mecanismo de defesa para reduzir a perda de água, o que interrompe o fluxo de CO₂ e reduz a taxa fotossintética líquida (McAdam; Brodribb, 2015).

A ocorrência temporal dos principais preditores entre o 16º e o 29º decêndio demonstra que a produtividade é amplamente definida durante os estádios fenológicos de perfilhamento e grande crescimento vegetativo (Bonnett, 2013). Esses estádios são intermediários dentro do ciclo do cultivo, possibilitando aos produtores em alguns casos a revisão e readequação do manejo do cultivo, visando a manutenção da produtividade.

3.4.3 Regionalização e fatores limitantes

A acurácia observada nas regiões Sudeste e Centro-Oeste, com destaque para os estados de São Paulo, Minas Gerais e Goiás, sugere que, nessas áreas, a variabilidade interanual da produtividade é predominantemente governada pelo regime hídrico.

A redução na capacidade preditiva observada na Região Sul e no Nordeste brasileiro indica que a produtividade da cana-de-açúcar nessas latitudes é influenciada por fatores que o modelo não pode capturar (Flack-Prain et al., 2021). Essa baixa performance do modelo para os municípios situados nessas localidades, pode ser explicada pela maior frequência de eventos extremos e a dependência de manejos específicos dessas regiões (Ghil et al., 2011). Já na Zona da Mata do Nordeste brasileiro, onde a pluviosidade é mais regular e influenciada pela umidade oceânica, o modelo apresentou ajustes satisfatórios.

Dessa forma, a regionalização dos resultados demonstra que o *Random Forest* atua como bom modelo generalista para prever a produtividade no Brasil. A variação do desempenho mostra que apesar dessa capacidade de generalização, as particularidades de cada região produtora podem influenciar de maneira positiva ou negativa no acerto do modelo.

3.4.4 Gestão e sustentabilidade

A capacidade de prever a produtividade com seis meses de antecedência, através de modelos como o *Random Forest*, oferece uma vantagem competitiva para o planejamento operacional dos produtores e das unidades de processamento. Essa antecipação permite a otimização do cronograma de moagem, a gestão eficiente da frota logística e o ajuste de contratos no mercado internacional de açúcar e etanol (Shaikh, 2025).

Ao fornecer um suporte à decisão baseado em dados agrometeorológicos, a modelagem reduz as incertezas inerentes à cadeia produtiva, contribuindo para a estabilidade econômica do setor (Marcari; De Souza Rolim; De Oliveira Aparecido, 2015). O uso de algoritmos de *Machine Learning* promove padrões de produção mais responsáveis (ODS 12) ao otimizar o emprego de recursos naturais e insumos. A identificação de janelas críticas para a produtividade, como o 20º decêndio, permite o direcionamento assertivo de tecnologias como a irrigação suplementar, minimizando desperdícios hídricos e operacionais.

3.5 Considerações finais

Entre as abordagens testadas, o algoritmo *Random Forest (RF)* se mostrou como a ferramenta de maior precisão e capacidade de generalização, superando tanto os modelos lineares tradicionais quanto os algoritmos de *boosting*. Já a análise da importância das variáveis revelou que a produtividade é majoritariamente definida em uma janela crítica situada entre o 16º e o 29º decêndio do ciclo da cana-planta.

O armazenamento de água no solo no 20º decêndio e a umidade relativa no 23º decêndio foram os principais determinantes da produtividade final, refletindo a alta sensibilidade do cultivo ao estresse hídrico durante as fases fenológicas de final de perfilhamento e início do crescimento vegetativo.

A eficiência do modelo em prever a produtividade com seis meses de antecedência, fornece um suporte à decisão estratégica para o planejamento logístico, o cronograma de moagem e a gestão de estoques no mercado de bioenergia e açúcar.

Referências

- ALAM, Shabroz; ISRAR, Juveriya; KUMAR, Ajay. Artificial Intelligence and Machine Learning in Bioinformatics. *In*: SINGH, Vijai; KUMAR, Ajay (Orgs.). **Advances in Bioinformatics**. Singapore: Springer Nature, 2024. p. 321–345.
- ALMEIDA, Gabriela Mourão de *et al.* Machine learning in the prediction of sugarcane production environments. **Computers and Electronics in Agriculture**, v. 190, p. 106452, 1 nov. 2021.
- ATTRI, Ishana; AWASTHI, Lalit Kumar; SHARMA, Teek Parval. Machine learning in agriculture: a review of crop management applications. **Multimedia Tools and Applications**, v. 83, n. 5, p. 12875–12915, 1 fev. 2024.
- BHATT, Rajan *et al.* Climate-Smart Technologies for Improving Sugarcane Sustainability in India—A Review. **Sugar Tech**, v. 25, n. 1, p. 1–14, 1 fev. 2023.
- BONNETT, Graham D. Developmental Stages (Phenology). *In*: **Sugarcane: Physiology, Biochemistry, and Functional Biology**. [S.l.]: John Wiley & Sons, Ltd, 2013. p. 35–53.
- BOYER, John S. Cell enlargement and growth-induced water potentials. **Physiologia Plantarum**, v. 73, n. 2, p. 311–316, 1988.
- BRUNNER, Jan. Agricultural workers and trade unions in the neoliberal food regime: capital–labour relations, conflicts over labour and the agroindustrial transformation of

the sugarcane sector in São Paulo. **Canadian Journal of Development Studies / Revue canadienne d'études du développement**, v. 44, n. 1, p. 58–76, 2 jan. 2023.

ERDEM, Ebru; BOZKURT, Ferhat. A comparison of various supervised machine learning techniques for prostate cancer prediction. **Avrupa Bilim ve Teknoloji Dergisi**, n. 21, p. 610–620, 2021.

FANOURLAKIS, Dimitrios; HEUVELINK, Ep; CARVALHO, Susana M. P. A comprehensive analysis of the physiological and anatomical components involved in higher water loss rates after leaf development at high humidity. **Journal of Plant Physiology**, v. 170, n. 10, p. 890–898, 1 jul. 2013.

FIORANELLI, Anselmo; BIZZO, Waldir A. Generation of surplus electricity in sugarcane mills from sugarcane bagasse and straw: Challenges, failures and opportunities. **Renewable and Sustainable Energy Reviews**, v. 186, p. 113647, 1 out. 2023.

FLACK-PRAIN, Sophie *et al.* The impact of climate change and climate extremes on sugarcane production. **GCB Bioenergy**, v. 13, n. 3, p. 408–424, 2021.

GHIL, M. *et al.* Extreme events: dynamics, statistics and prediction. **Nonlinear Processes in Geophysics**, v. 18, n. 3, p. 295–350, 18 maio 2011.

JAMES, Gareth *et al.* Linear Regression. *In*: JAMES, Gareth *et al.* (Orgs.). **An Introduction to Statistical Learning: with Applications in Python**. Cham: Springer International Publishing, 2023. p. 69–134.

JIANG, Minqi *et al.* An improved Stacking framework for stock index prediction by leveraging tree-based ensemble models and deep learning algorithms. **Physica A: Statistical Mechanics and its Applications**, v. 541, p. 122272, 1 mar. 2020.

KIANGALA, Sonia Kahiomba; WANG, Zenghui. An effective adaptive customization framework for small manufacturing plants using extreme gradient boosting-XGBoost and random forest ensemble learning algorithms in an Industry 4.0 environment. **Machine Learning with Applications**, v. 4, p. 100024, 2021.

MARCARI, Marcos Antônio; DE SOUZA ROLIM, Glauco; DE OLIVEIRA APARECIDO, Lucas Eduardo. Agrometeorological models for forecasting yield and quality of sugarcane. **Australian Journal of Crop Science**, v. 9, n. 11, p. 1049–1056, 2015.

MCADAM, Scott A. M.; BRODRIBB, Timothy J. The Evolution of Mechanisms Driving the Stomatal Response to Vapor Pressure Deficit. **Plant Physiology**, v. 167, n. 3, p. 833–843, 1 mar. 2015.

PAIDIPATI, Kiran Kumar *et al.* Prediction of rice cultivation in india—support vector regression approach with various kernels for non-linear patterns. **AgriEngineering**, v. 3, n. 2, p. 182–198, 2021.

PALLATHADKA, Harikumar *et al.* IMPACT OF MACHINE learning ON Management, healthcare AND AGRICULTURE. **Materials Today: Proceedings**, SI:5 NANO 2021. v. 80, p. 2803–2806, 1 jan. 2023.

QIN, Nianxiu *et al.* Assessing the drought impact on sugarcane yield based on crop water requirements and standardized precipitation evapotranspiration index. **Agricultural Water Management**, v. 275, p. 108037, 1 jan. 2023.

RIGATTI, Steven J. Random Forest. **Journal of Insurance Medicine**, v. 47, n. 1, p. 31–39, 1 jan. 2017.

SHAIKH, Zuber Peermohammed. Artificial Intelligence and Machine Learning in Optimization of Supply Chain Transformation: Digital Operation Through Simulation. *In: Supply Chain Transformation Through Generative AI and Machine Learning. [S.l.]*: IGI Global Scientific Publishing, 2025. p. 409–434.

SILVA, Gabriel MCD; PERICO, Ana Elisa; SANTANA, Naja B. Sustainable Efficiency of Sugarcane Mills in the State of Sao Paulo: A Data Envelopment Analysis. **Journal of Sustainable Development**, v. 16, n. 3, p. 1–63, 2023.

TOSCANO MIRANDA, Nahieh *et al.* Sugarcane bagasse pyrolysis: A review of operating conditions and products properties. **Renewable and Sustainable Energy Reviews**, v. 149, p. 111394, 1 out. 2021.

VESEY, Winona Burt *et al.* Multiple linear regression: A return to basics in educational research. **Multiple Linear Regression Viewpoints**, v. 37, n. 2, p. 14–22, 2011.

WANG, Hannah Szu-Han; YAO, Yuan. Machine learning for sustainable development and applications of biomass and biomass-derived carbonaceous materials in water and agricultural systems: A review. **Resources, Conservation and Recycling**, v. 190, p. 106847, 1 mar. 2023.

APÊNDICES

Apêndice 1.

1.1 Gompertz

1.1.1 Dinâmica do Crescimento em Altura

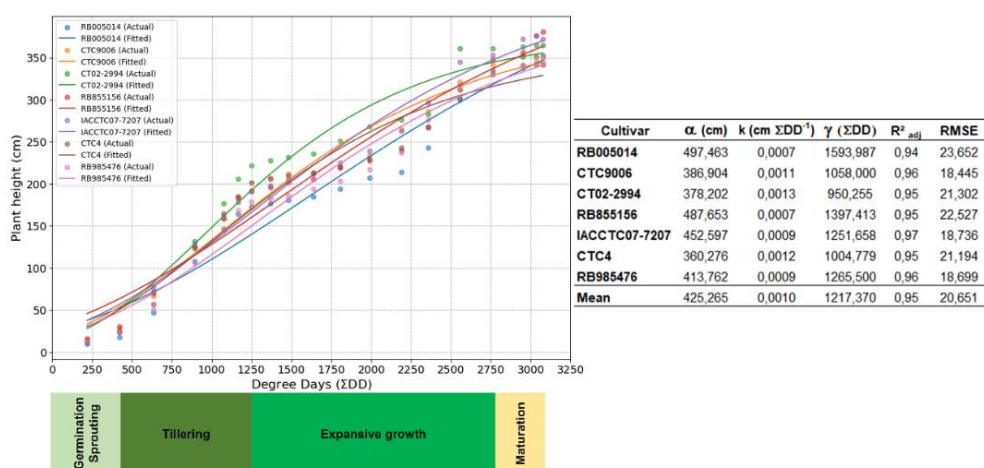


Figura 1: Ajuste do modelo de Gompertz para altura da planta (cm) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.1.2 Dinâmica do Comprimento Médio de Entrenós




Figura 2: Ajuste do modelo de Gompertz para comprimento médio do entrenó (cm) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.1.3 Definição do Número de Entrenós

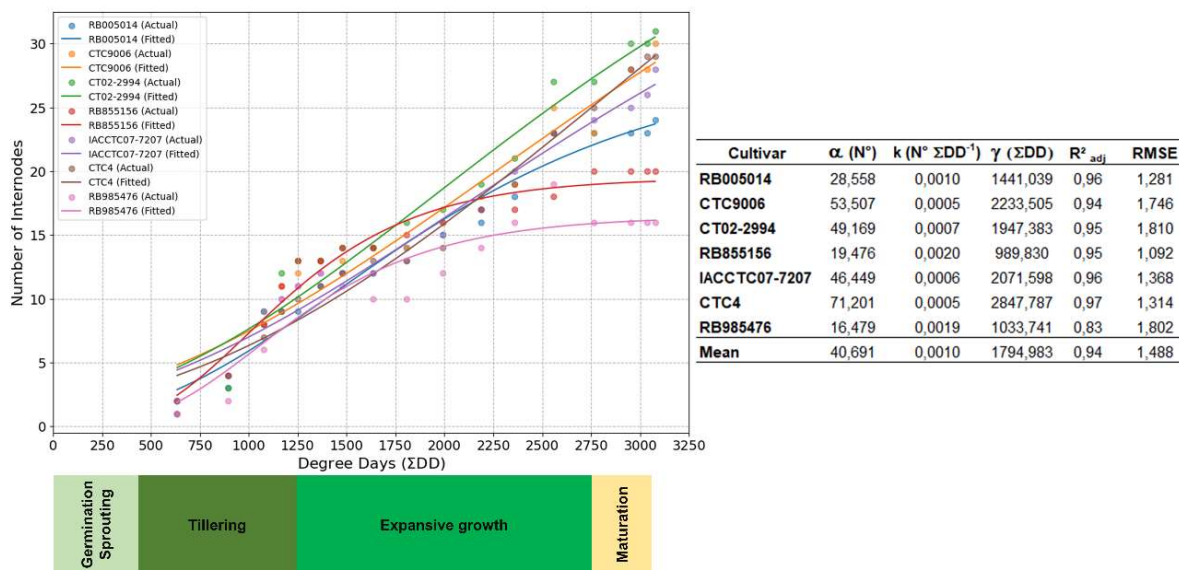


Figura 3: Ajuste do modelo de Gompertz para número de entrenós em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.1.4 Emissão e Estabilização de Perfis




Figura 4: Ajuste do modelo de Gompertz para número de perfilhos em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.1.5 Análise do Diâmetro Médio do Colmo

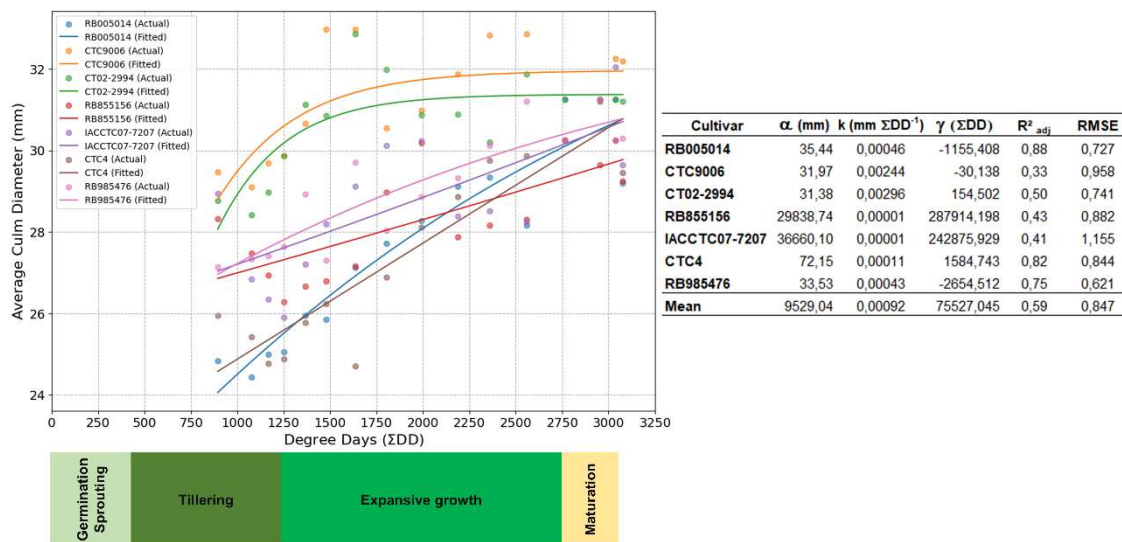


Figura 5: Ajuste do modelo de Gompertz para diâmetro médio do colmo (mm) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.1.6 Dinâmica do Índice de Área Foliar (LAI)

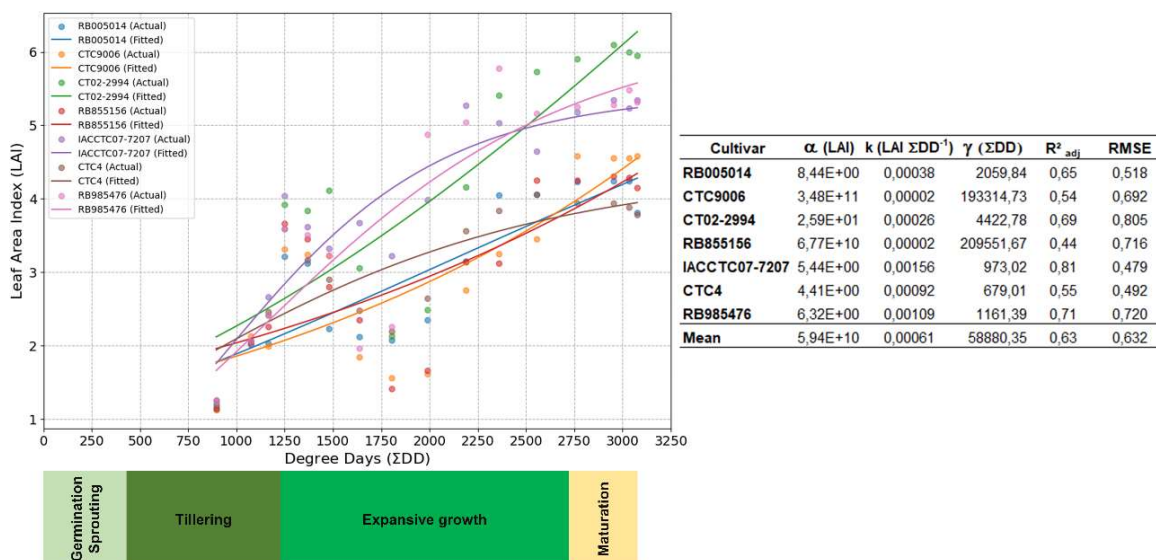


Figura 6: Ajuste do modelo de Gompertz para índice de área foliar (LAI) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.1.7 Dinâmica de Acúmulo de Produtividade (TCH)




Figura 7: Ajuste do modelo de Gompertz para produtividade estimada (TCH) em função do acúmulo térmico (Σ DD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2 Michaelis-Menten

1.2.1 Dinâmica do Crescimento em Altura

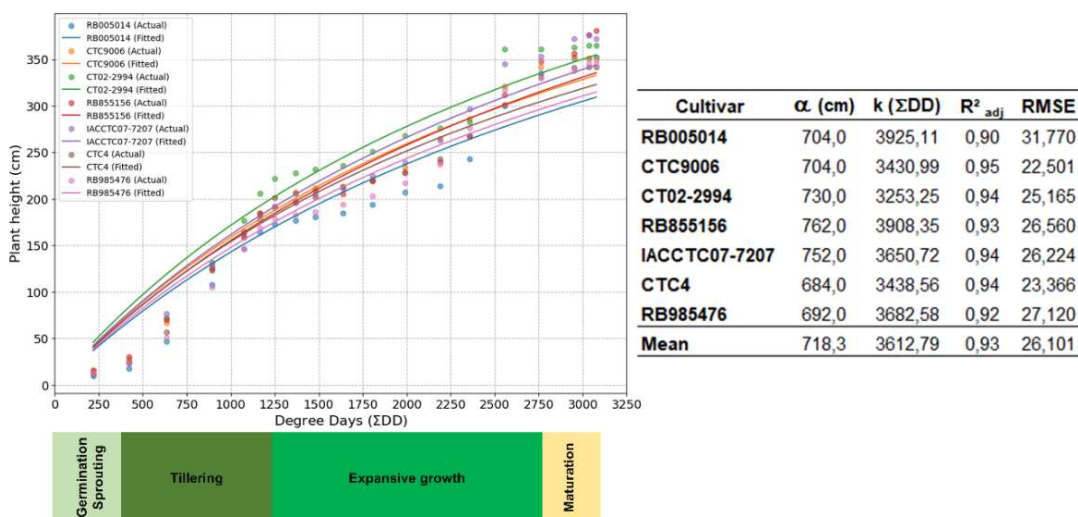


Figura 8: Ajuste do modelo de Michaelis-Menten para altura da planta (cm) em função do acúmulo térmico (Σ DD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2.2 Dinâmica do Comprimento Médio de Entrenós

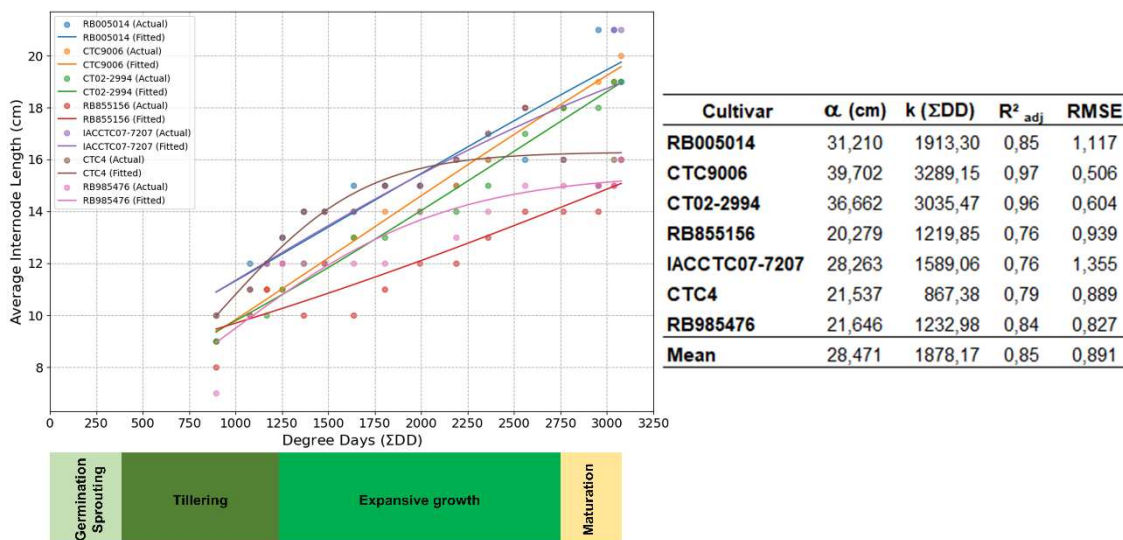


Figura 10: Ajuste do modelo de Michaelis-Menten para comprimento médio dos entrenós (cm) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2.3 Definição do Número de Entrenós

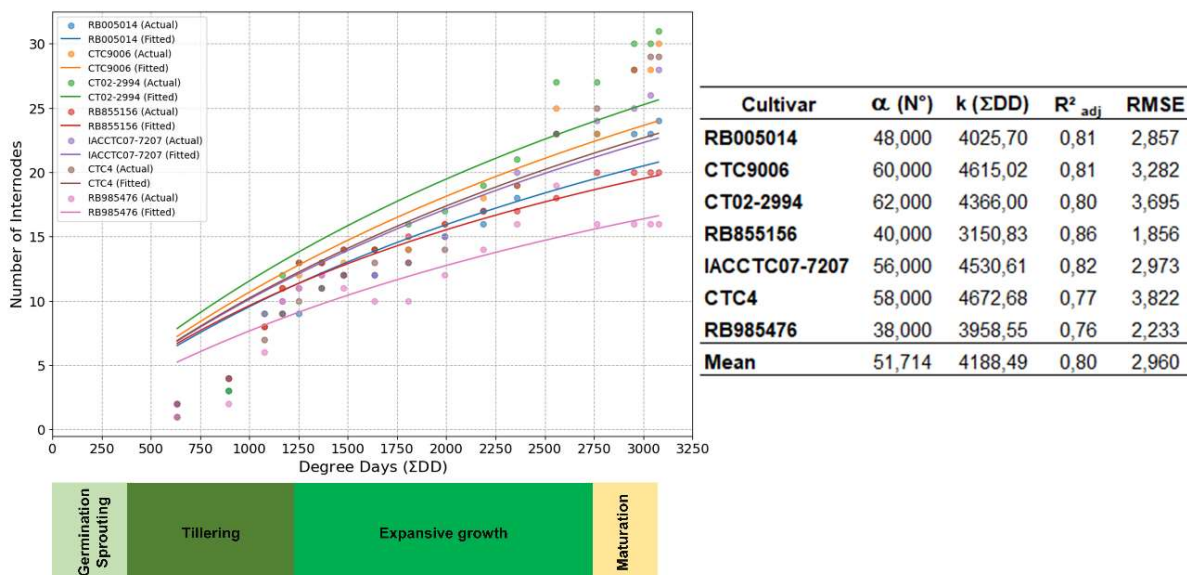


Figura 11: Ajuste do modelo de Michaelis-Menten para número de entrenós em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2.4 Emissão e Estabilização de Perfilhos

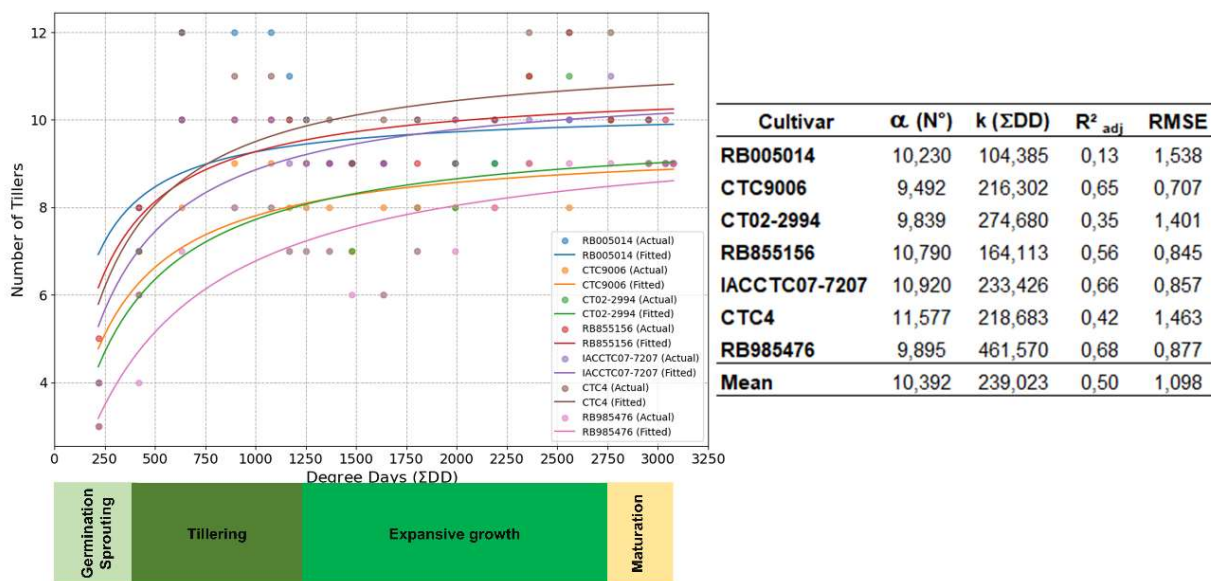


Figura 12: Ajuste do modelo de Michaelis-Menten para número de perfilhos em função do acúmulo térmico (Σ DD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2.5 Análise do Diâmetro Médio do Colmo




Figura 13: Ajuste do modelo de Michaelis-Menten para diâmetro médio do colmo (mm) em função do acúmulo térmico (Σ DD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2.6 Dinâmica do Índice de Área Foliar (LAI)

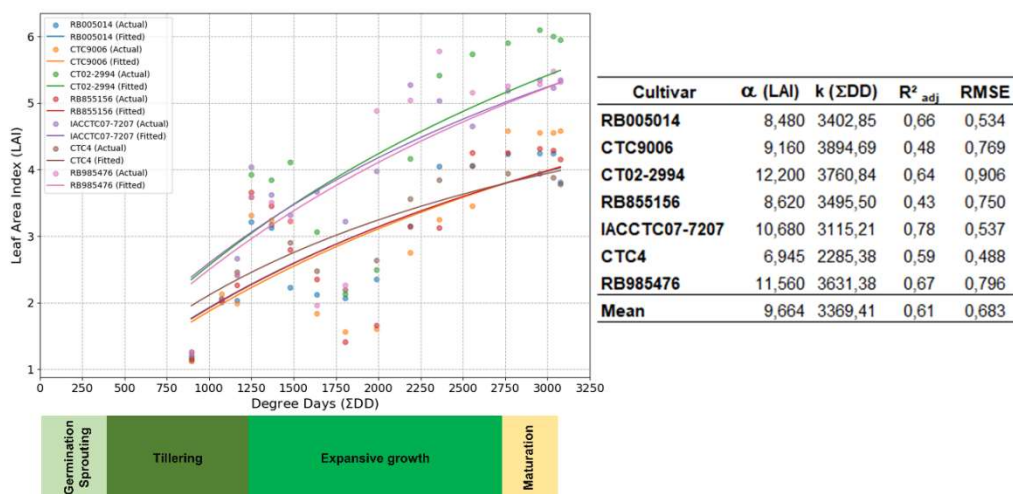


Figura 14: Ajuste do modelo de Michaelis-Menten para índice da área foliar (LAI) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

1.2.7 Dinâmica de Acúmulo de Produtividade (TCH)




Figura 15: Ajuste do modelo de Michaelis-Menten para produtividade estimada (TCH) em função do acúmulo térmico (ΣDD), e tabela com parâmetros e avaliação do modelo (R^2_{adj} e RMSE) por cultivar.

Apêndice 2.

Tabela A2: Área colhida de cana-de-açúcar no ano de 2022 dos municípios que foram utilizados para a geração dos modelos de *Machine Learning*.

ID	Latitude	Longitude	Município	UF	Área colhida (ha)
1	-9,504739761	-36,07249832	Atalaia	AL	12500
2	-9,814849854	-36,28290176	Campo Alegre	AL	12500
3	-9,480039597	-35,86439896	Rio Largo	AL	12000
4	-9,772809982	-36,10079956	São Miguel dos Campos	AL	20000
5	-1,370919943	-59,98960114	Presidente Figueiredo	AM	580
6	-13,09659958	-44,20360184	Canápolis	BA	350
7	-17,65749931	-39,68880081	Caravelas	BA	16000
8	-12,19400024	-44,25880051	Cristópolis	BA	285
9	-17,74300003	-40,01279831	Ibirapuã	BA	5600
10	-17,11540031	-40,3783989	Itanhém	BA	300
11	-9,556879997	-40,27470016	Juazeiro	BA	15483
12	-17,55960083	-40,30979919	Lajedão	BA	7150
13	-17,89970016	-39,7154007	Nova Viçosa	BA	1000
14	-7,403739929	-39,34460068	Barbalha	CE	192
15	-4,232769966	-40,91540146	Guaraciaba do Norte	CE	1350
16	-3,95111199	-41,00619888	Ibiapina	CE	150
17	-4,040850163	-40,9695015	São Benedito	CE	2000
18	-3,736150026	-41,05500031	Tianguá	CE	800
19	-20,96579933	-40,94469833	Itapemirim	ES	6500
20	-18,18239975	-40,03710175	Pedro Canário	ES	5156
21	-18,36989975	-40,19820023	Pinheiros	ES	5147
22	-17,99370003	-49,65879822	Goiatuba	GO	49500
23	-17,9095993	-51,73220062	Jataí	GO	24000
24	-17,63100052	-52,76599884	Mineiros	GO	52000
25	-17,04710007	-50,63800049	Paraúna	GO	15000
26	-17,73920059	-51,03850174	Rio Verde	GO	23000
27	-17,80179977	-50,57910156	Santa Helena de Goiás	GO	16000
28	-4,50274992	-43,38349915	Aldeias Altas	MA	7200
29	-4,866409779	-43,29919815	Caxias	MA	3630
30	-4,607250214	-43,88600159	Codó	MA	1160
31	-4,248050213	-43,11190033	Coelho Neto	MA	4900
32	-20,0053997	-48,08420181	Água Comprida	MG	22500
33	-21,38870049	-45,96630096	Alfenas	MG	4500
34	-20,25970078	-45,54719925	Arcos	MG	3400
35	-19,68449974	-45,28609848	Bom Despacho	MG	2550
36	-18,75790024	-49,27190018	Canápolis	MG	16000
37	-19,75020027	-50,82979965	Carneirinho	MG	18800

38	-20,03569984	-49,00049973	Frutal	MG	49700
39	-18,99259949	-49,5442009	Ituiutaba	MG	41000
40	-20,13279915	-45,52909851	Japaraíba	MG	4350
41	-20,01099968	-45,49399948	Lagoa da Prata	MG	8900
42	-18,84449959	-48,88679886	Monte Alegre de Minas	MG	4500
43	-17,17300034	-46,88420105	Paracatu	MG	25500
44	-20,71859932	-46,62200165	Passos	MG	8250
45	-19,40019989	-47,19599915	Perdizes	MG	25500
46	-20,08130074	-48,64630127	Planura	MG	8000
47	-19,1310997	-44,92359924	Pompéu	MG	17680
48	-18,98950005	-50,27519989	Santa Vitória	MG	35000
49	-19,79680061	-49,8594017	São Francisco de Sales	MG	13520
50	-20,92239952	-47,00640106	São Sebastião do Paraíso	MG	2300
51	-17,78409958	-40,26440048	Serra dos Aimorés	MG	2250
52	-18,53499985	-48,75529861	Tupaciguara	MG	12750
53	-21,69610023	-54,55780029	Rio Brillhante	MS	66000
54	-15,06779957	-57,55960083	Barra do Bugres	MT	48480
55	-14,73009968	-56,96160126	Denise	MT	33938
56	-7,148970127	-35,10269928	Cruz do Espírito Santo	PB	6300
57	-6,720739841	-35,15589905	Mamanguape	PB	9000
58	-7,055389881	-35,19710159	Sapé	PB	10000
59	-7,60258007	-35,19300079	Aliança	PE	10000
60	-8,612469673	-35,39310074	Gameleira	PE	10000
61	-8,437179565	-35,08890152	Ipojuca	PE	28000
62	-7,44990015	-35,13430023	Itambé	PE	15000
63	-4,71393013	-42,52489853	José de Freitas	PI	4707
64	-4,24052	-42,77360153	Miguel Alves	PI	2012
65	-22,99699974	-50,08280182	Cambará	PR	12505
66	-23,38279915	-52,95849991	Cidade Gaúcha	PR	8707
67	-23,32519913	-52,8260994	Guaporema	PR	8308
68	-22,74270058	-51,40990067	Porecatu	PR	11183
69	-23,47769928	-52,80450058	Rondon	PR	20492
70	-21,74769974	-41,40409851	Campos dos Goytacazes	RJ	37650
71	-6,395090103	-35,14849854	Canguaretama	RN	16000
72	-29,73480034	-51,04899979	Novo Hamburgo	RS	450
73	-27,94000053	-53,38230133	Palmeira das Missões	RS	150
74	-29,65920067	-50,85609818	Parobé	RS	150
75	-27,33569908	-53,07799911	Planalto	RS	180
76	-29,62899971	-50,54999924	Rolante	RS	270
77	-29,53560066	-51,25759888	São José do Hortêncio	RS	153
78	-29,67009926	-50,76200104	Taquara	RS	150
79	-29,57859993	-52,19499969	Venâncio Aires	RS	150

80	-29,71319962	-52,5387001	Vera Cruz	RS	200
81	-27,2390995	-52,00740051	Concórdia	SC	100
82	-28,2798996	-49,37189865	Orleans	SC	140
83	-27,74180031	-48,79660034	Santo Amaro da Imperatriz	SC	100
84	-10,80449963	-37,18619919	Laranjeiras	SE	8454
85	-20,51420021	-48,65200043	Barretos	SP	79145
86	-20,86779976	-47,57479858	Batatais	SP	45200
87	-21,93499947	-48,46360016	Boa Esperança do Sul	SP	35000
88	-21,88120079	-47,65459824	Descalvado	SP	33200
89	-21,79290009	-48,84780121	Ibitinga	SP	31000
90	-21,54809952	-48,81549835	Itápolis	SP	45340
91	-20,3295002	-47,80960083	Ituverava	SP	46000
92	-21,21829987	-48,28789902	Jaboticabal	SP	57550
93	-22,29610062	-48,55599976	Jaú	SP	44000
94	-21,55270004	-47,7818985	Luís Antônio	SP	35000
95	-20,18470001	-48,10549927	Miguelópolis	SP	38100
96	-22,30139923	-48,86109924	Pederneiras	SP	31018
97	-21,00620079	-48,24940109	Pitangueiras	SP	30500
98	-22,28280067	-50,92829895	Rancharia	SP	65000
99	-21,21080017	-47,82130051	Ribeirão Preto	SP	37104
100	-21,46150017	-47,56829834	São Simão	SP	30103
