

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

Avaliação do comportamento de cultivares de cana de açúcar em diferentes ambientes produtivos monitoradas por sensor multiespectral embarcado em aeronave remotamente pilotada

Matheus Sterzo Nilsson

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Engenharia de Sistemas Agrícolas

**Piracicaba
2024**

Matheus Sterzo Nilsson
Bacharel em Agronomia

Avaliação do comportamento de cultivares de cana de açúcar em diferentes ambientes produtivos monitoradas por sensor multiespectral embarcado em aeronave remotamente pilotada

versão revisada de acordo com a Resolução CoPGr 6018 de 2011

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

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Engenharia de Sistemas Agrícolas

Piracicaba
2024

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

Nilsson, Matheus Sterzo

Avaliação do comportamento de cultivares de cana de açúcar em diferentes ambientes produtivos monitoradas por sensor multiespectral embarcado em aeronave remotamente pilotada / Matheus Sterzo Nilsson. - - versão revisada de acordo com a Resolução CoPGr 6018 de 2011. - - Piracicaba, 2024.

61 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Drone 2. Espectroscopia 3. Sensoriamento remoto 4. Fechamento do dossel I. Título

Dedicatória

Aos meus amados pais Gustavo Rother Nilsson;
Aos meus irmãos Bianca Sterzo Nilsson e Vinícius Sterzo Nilsson
DEDICO!

AGRADECIMENTOS

Agradeço a Deus, pois sem ele nada conseguiria ter, nem essa vida. Agradeço por toda a minha saúde e de meus familiares.

Aos meus pais Gustavo Rother Nilsson e Elaine Ismênia Sterzo Nilsson, por toda a educação e ensinamentos dados dentro de casa como também todo esforço realizado para eu ter uma boa formação. Lembro de meu pai trabalhar horas e horas e até mesmo virar noites para consertar máquinas nas fábricas de papel. Você é o maior exemplo de pai que alguém poderia ter.

Aos meus irmãos Vinícius Sterzo Nilsson e Bianca Sterzo Nilsson por todo o apoio sempre dado para eu realizar meus sonhos e todas as conversas nos momentos mais difíceis.

Aos meus colegas de laboratório do Topo Geo: Ana Karla, Carlos, Ester, Matheus, Hugo e Pedro sem vocês essa pesquisa nunca teria saído.

Ao meu orientador Peterson Ricardo Fiorio por toda a confiança depositada em mim. Assim como todos os ensinamentos que me ajudaram muito a me tornar um profissional melhor.

A empresa São Martinho pela disponibilidade das áreas de estudo e por todo o auxílio fornecido. Em especial ao meu colega de trabalho René Assis Sordi por ajudar a conseguir as áreas, por ajudar a realizar os levantamentos e todo o apoio em sua conclusão. Uma vez que o delimitamento do experimento bem como os dados de biometria e análises tecnológicas foram elaboradas para a tese de doutorado dele. Cujo este trabalho é um complemento.

A Escola Superior de Agricultura “Luiz de Queiroz”- ESALQ por todas as estruturas fornecidas para meus estudos, ao Programa de Pós Graduação em Engenharia de Sistemas Agrícolas, por promover meu crescimento intelectual e profissional.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (Capes).

EPÍGRAFE

“Sua tarefa é descobrir o seu trabalho e, então, com todo o coração, dedicar-se a ele.”

Buda

SUMÁRIO

RESUMO	7
ABSTRACT.....	8
1.INTRODUÇÃO	9
2. REVISÃO DE LITERATURA	11
2.1 Cana-de-açúcar.....	11
2.2 A cadeia produtiva da cana-de-açúcar hoje	13
2.3 Ambientes de produção da cana-de-açúcar.....	13
2.3.1 Água.....	14
2.3.2 Temperatura	14
2.3.3 Textura do solo.....	15
2.3.4 Fertilidade do solo.....	15
2.4 Aeronaves remotamente pilotadas	17
2.5 RPAs na agricultura	19
2.5.1 Levantamento topográfico.	19
2.5.2 Monitoramento de lavouras	20
3.MATERIAL E MÉTODOS	23
3.1 Área de estudo.....	23
3.2 Descrição da Plataforma de Aquisição dos dados	26
3.3 Processamento Fotogramétrico <i>Structure from Motion</i>	26
3.4 Segmentação de imagens	27
3.5 Extração espectral dos dados.....	27
3.6 Aquisição de dados biométricos	29
3.7 Estatísticas utilizadas	30
4. RESULTADOS E DISCUSSÃO	31
4.1 Índices espectrais em cada ambiente	31
4.2 Parâmetros Biométricos em cada ambiente	41
4.3 Fechamento do Dossel em cada ambiente	45
4.4 Produtividade das cultivares em cada ambiente	49
4.5 ATR das cultivares em cada ambiente	51
5. CONCLUSÃO	53
REFERÊNCIAS.....	55

RESUMO

Avaliação do comportamento de cultivares de cana de açúcar em diferentes ambientes produtivos monitoradas por sensor multiespectral embarcado em aeronave remotamente pilotada

Os ambientes produtivos são um dos principais fatores que afetam a produtividade da cultura da cana-de-açúcar. Deste modo, testes experimentais envolvendo diferentes cultivares em locais produtivos distintos são essenciais. As tecnologias que envolvem o uso de aeronaves remotamente pilotadas em conjunto com câmeras multiespectrais têm auxiliado no monitoramento das lavouras agrícolas de diversas culturas. Deste modo, o objetivo deste trabalho foi avaliar como os dados de sensoriamento remoto, obtidos com um sensor multiespectral, podem auxiliar no monitoramento ao longo do tempo de um experimento com cultivares de cana-de-açúcar em ambientes produtivos distintos. Para isso, foram plantadas 16 cultivares em dois ambientes produtivos diferentes (alto e baixo). Para a coleta de dados, uma câmera multiespectral foi embarcada em uma aeronave remotamente pilotada e realizaram-se três coletas de dados espectrais ao longo do ensaio experimental. Deste modo, foram obtidos os principais índices espectrais e o índice de fechamento da cultura. Foram realizadas também duas coletas de dados biométricos para auxiliar nas análises. Ao término do experimento, foram obtidos os dados de produtividade. Os dados entre as duas áreas foram comparados utilizando o teste t de Student ao nível de $p < 0,05$. O índice SFDVI (Spectral Feature Depth Vegetation Index) permitiu uma boa diferenciação entre os valores comparados entre as duas áreas nas duas primeiras coletas de dados. Assim como os índices que utilizam a banda Green em suas fórmulas, como o GRVI (Green Red Vegetation Index) e o ExG (Excess Greenness). Alguns índices que utilizam fatores de correção, como o SAVI (Soil Adjusted Vegetation Index) e OSAVI (Optimized Soil Adjusted Vegetation Index), mostraram média maior em uma área do que na outra, indicando que estes índices podem ser usados em determinadas épocas do crescimento da cana-de-açúcar. O índice de fechamento permitiu identificar quais cultivares tiveram maior cobertura do dossel em cada área. A utilização de drones para o monitoramento de cultivares de cana-de-açúcar mostrou-se uma técnica eficaz que pode ser utilizada em experimentos agrícolas, pois permitiu detectar diferenças entre os dois locais de cultivo, além de identificar características interessantes das cultivares.

Palavras-chave: Drone, Espectroscopia, Sensoriamento remoto, Fechamento do dossel

ABSTRACT

Evaluation of sugarcane cultivars in different productive environments monitored by multispectral sensor on remotely piloted aircraft

Productive environments are one of the main factors affecting the productivity of sugarcane cultivation. Thus, experimental tests involving different cultivars in distinct productive locations are essential. Technologies involving the use of remotely piloted aircraft coupled with multispectral cameras have assisted in monitoring agricultural fields across various crops. Therefore, the objective of this study was to evaluate how remote sensing data obtained through a multispectral sensor can aid in the monitoring over time of an experiment with sugarcane cultivars in distinct productive environments. To this end, 16 cultivars were planted in two different productive environments (high and low). For data collection, a multispectral camera was mounted on a remotely piloted aircraft, and three spectral data collections were conducted throughout the experimental trial. Consequently, the main spectral indices and the canopy closure index were obtained. Two biometric data collections were also performed to assist in the analyses. At the end of the experiment, productivity data were acquired. The data from the two areas were compared using the Student's t-test at a level of $p < 0.05$. The SFDVI (*Spectral Feature Depth Vegetation Index*) enabled a good differentiation between the compared values from the two areas in the first two data collections. Similarly, indices that utilize the *Green* band in their formulas, such as the GRVI (*Green Red Vegetation Index*) and ExG (*Excess Greenness*), were effective. Some indices that use correction factors, such as SAVI (*Soil Adjusted Vegetation Index*), and OSAVI (*Optimized Soil Adjusted Vegetation Index*), showed higher averages in one area than in the other, indicating that these indices can be used at certain stages of sugarcane growth. The closure index helped to identify which cultivars had greater canopy coverage in each area. The use of drones for monitoring sugarcane cultivars proved to be an effective technique that can be utilized in agricultural experiments, as it allowed for the detection of differences between the two cultivation sites, in addition to identifying interesting characteristics of the cultivars.

Keywords: Drone, Spectroscopy, Remote sensing, Canopy closure

1. INTRODUÇÃO

O Brasil é o maior produtor de cana-de-açúcar do mundo, seguido pela Índia e China. Segundo dados da CONAB (2023), a produção total do Brasil na safra de 2022/2023 foi de mais de 610 milhões de toneladas de cana-de-açúcar, com destaque para o estado de São Paulo, que colheu 312.880 mil toneladas. A cultura da cana-de-açúcar tem alta relevância para a humanidade, pois, através do seu processamento, origina-se o açúcar, que é essencial à alimentação humana, bem como se produz o etanol, um importante combustível veicular, que contribui para uma matriz energética mais sustentável (BOSSO, 2002).

Um dos fatores que alavancaram o Brasil como líder de produção mundial de cana-de-açúcar foi o constante estudo em melhoramento genético e o lançamento de novas cultivares. Este é um dos fatores que mais interfere na produtividade da cana-de-açúcar, o qual aumenta a competitividade e a consolidação da agroindústria brasileira (SZMRECSÀNYI, 1994). Um modo de avaliar quais cultivares são mais adaptadas às condições de campo é através de campos experimentais com delineamentos experimentais, pois, segundo Carvalho et al. (2022), as estatísticas experimentais são a chave para a inovação do setor agrícola.

Outro fator que interfere na produtividade agrícola são os diferentes tipos de ambientes produtivos em que cada cultivar de cana-de-açúcar é introduzida. Os ambientes de produção são a junção das condições meteorológicas de cada local com a combinação das propriedades físicas, hídricas, químicas e mineralógicas dos solos (PRADO, 2011). Portanto, o entendimento da alocação de uma determinada cultivar no seu correto ambiente de produção permite um melhor desenvolvimento da cultura ao longo do ciclo.

Uma ferramenta que está sendo utilizada na agricultura são as RPAs — do inglês "remotely piloted aircraft" (aeronaves remotamente pilotadas) —, as quais podem embarcar sensores como câmeras RGB, multiespectrais ou hiperespectrais (AMARAL, 2021). Esses sensores funcionam através da abordagem científica do sensoriamento remoto que, segundo Formaggio e Sanches (2017), é a capacidade de obter informações sobre um objeto sem necessariamente tocar neste objeto, utilizando o princípio da reflectância da radiação eletromagnética.

Diversos autores já utilizaram os RPAs com sensores remotos para avaliar a cultura da cana-de-açúcar em experimentos, Júnior *et al* (2022) buscou determinar se os dados das imagens poderiam discriminar diferentes cultivares de cana-de-açúcar de grau comercial e se o horário do dia afetava a expressividade das bandas espectrais e índices de vegetação usados na modelagem biofísica. Utilizando um RPA para auxiliar nas coletas imagens em alta resolução

ao longo do dia, eles analisaram como a variação diurna influencia a reflectância e a capacidade de discriminar as cultivares. Os resultados foram que o horário mais confiável para realizar voos era ao meio-dia, quando a reflectância era mais distinta entre as cultivares, possibilitando uma discriminação eficaz sem ser influenciada pelo momento do dia.

Um outro autor que fez uso de RPA para auxiliar na coleta de dados em experimentos de cana-de-açúcar foi Martello (2017), ao utilizar as imagens o autor gerou modelos digitais da superfície (MDS) e aplicar técnicas de sensoriamento remoto para estimar a altura do dossel da planta e, conseqüentemente, sua produtividade. Mostrando a aplicabilidade desta tecnologia. Contudo, estudos envolvendo a utilização do sensoriamento remoto em RPAs para avaliar as cultivares em campos experimentais e em diferentes ambientes produtivos são necessários para assim entender como essa tecnologia pode auxiliar na observação do comportamento da cana-de-açúcar em ambientes produtivos variados

Diante do exposto o objetivo deste estudo é avaliar como as técnicas de sensoriamento remoto obtidas através de um sensor multiespectral embarcado em um drone podem auxiliar no monitoramento ao longo do tempo de um experimento o qual há diferentes cultivares de cana-de-açúcar em ambientes produtivos distintos.

2. REVISÃO DE LITERATURA

2.1 A cultura da cana-de-açúcar

A cana-de-açúcar é uma planta que pertence à família Poaceae; portanto, é uma monocotiledônea do gênero *Saccharum*, alógama, que tem como característica a transformação de água e nutrientes em açúcares (principalmente sacarose, glicose e frutose), concentrados nos colmos (MATOS; SANTOS; EICHLER, 2020; MELO, 2018). É uma planta semiperene originária de regiões quentes e temperadas da Ásia, principalmente da Índia (MATOS; SANTOS; EICHLER, 2020). Atualmente, há cultivares híbridas interespecíficas, como as espécies *Saccharum officinarum*, *S. spontaneum*, *S. sinense*, *S. barberi*, *S. robustum* e *S. edule* (JADOSKI et al., 2010).

A cana-de-açúcar possui um ciclo fotossintético C4; seu desenvolvimento ocorre em touceiras, nas quais a parte aérea é composta por colmos, inflorescências, sementes e folhas com forma de lança. Estas brotam dos colmos e perfilham abundantemente na fase inicial do desenvolvimento, enquanto a parte subterrânea é composta por raízes e rizomas (MOZAMBANI et al., 2006; SANTOS; COLODETTE; QUEIROZ, 2013). Com relação à quantidade de água, na parte superior, a planta possui maior umidade, enquanto na parte inferior, há menos umidade, com folhas secas. Para melhor entendimento, na hora da colheita, do total de umidade, cerca de 57% fica na massa total da planta, sendo o restante dividido entre palha, bagaço e açúcar (MATOS; SANTOS; EICHLER, 2020).

Os estádios de desenvolvimento da cana-de-açúcar são quatro (Figura 1): a emergência, que é o primeiro estágio e dura de 30 a 60 dias após o plantio da cultura, mas essa quantidade de dias pode ter prolongamento ou encurtamento devido à influência de condições ambientais, fatores genéticos e de tecnologia de plantio; o segundo é o perfilhamento (crescimento dos colmos), com período de 60 a 90 dias, dependendo da incidência de luz solar, temperatura e umidade do solo; o terceiro estágio é o desenvolvimento da cultura, em que ocorre um prolongamento dos colmos com o começo de acúmulo de sacarose, que é o estágio mais demorado e leva cerca de 180 a 210 dias; o quarto é a maturação, em que há intenso acúmulo de sacarose, ocorrendo entre 60 a 90 dias após o estágio de desenvolvimento da cultura (CASAGRANDE; VASCONCELOS, 2008; MARIN, 2009).

Resumidamente, o ciclo da cana-de-açúcar ocorre em dois estágios. Após a cultura ser plantada, ela se desenvolve até ocorrer o primeiro corte, nesse estágio é denominada cana-planta. Depois da primeira colheita, termina o ciclo da cana-planta e começa o ciclo da cana-

soca. O período de cana-soca é de cerca de 12 meses, independente da variedade da cultura (VASCONCELOS; CASAGRANDE, 2008). A quantidade de safras da cana-soca será limitada pelo decaimento da produtividade, que ocorre devido aos fatores meteorológicos, de nutrientes do solo e da variedade utilizada.

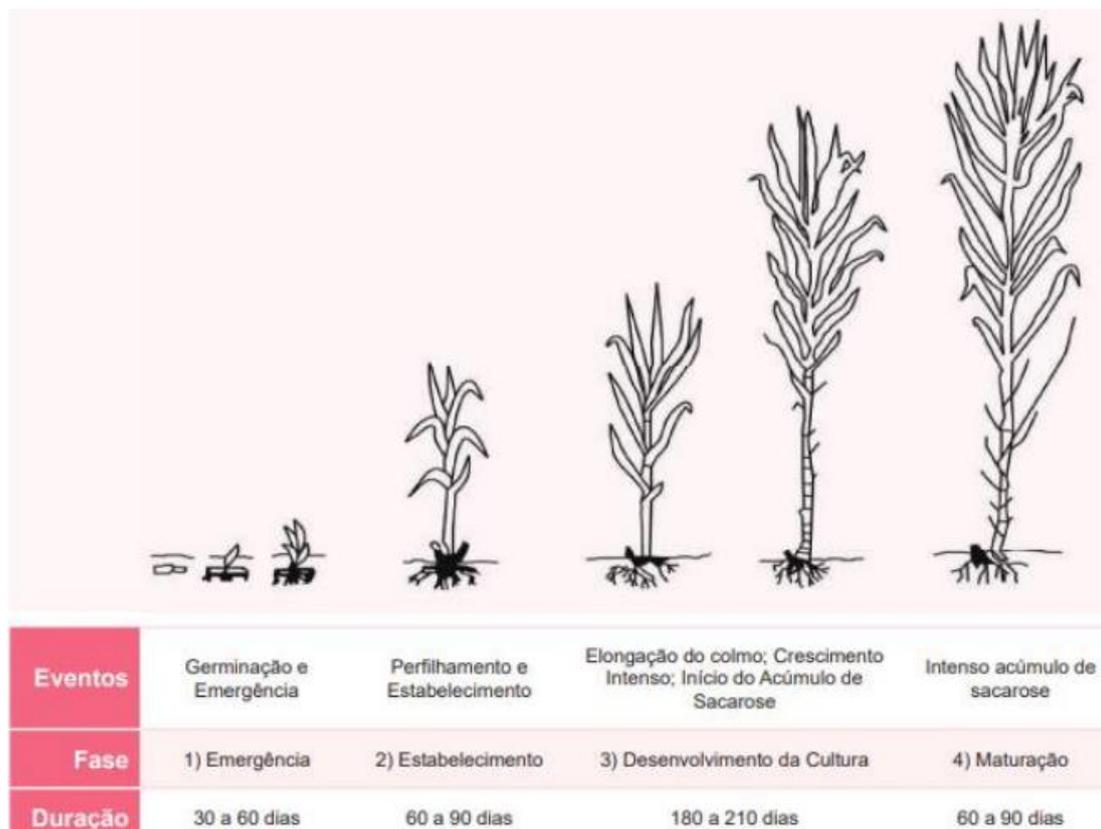


Figura 1. Esquema das fases fenológicas da cana-de-açúcar. Fonte: (MARIN, 2009)

Cultivada em regiões tropicais e subtropicais, a cana-de-açúcar é uma importante cultura agroindustrial, pois a partir da planta são produzidos açúcar, bioetanol e bioenergia. O etanol oriundo da cana-de-açúcar é uma das melhores alternativas para a diminuição da emissão de gases que causam o efeito estufa, conferindo a esta cultura um elevado valor ambiental (MELLO et al., 2014). Devido a esse fato, há um aumento de projetos que buscam investir na produção de etanol como fonte alternativa aos combustíveis não renováveis, uma vez que sua utilização auxilia na diminuição das mudanças climáticas (VON STECHOW et al., 2015).

Já a utilização da cana-de-açúcar para geração de bioenergia decorre do uso do subproduto denominado bagaço. Este subproduto é aproveitado em caldeiras para gerar calor e bioeletricidade e pode ainda gerar excedente de energia elétrica que é comercializado (LEITE et al., 2009). Assim como o bagaço, a palha também pode ser usada para gerar calor e bioeletricidade (WALTER et al., 2014). Outra aplicação da palha, além de ser utilizada para

gerar calor e bioeletricidade, é o seu potencial como matéria-prima para a produção de etanol celulósico ou etanol de segunda geração (LANDELL et al., 2013).

2.2 A cadeia produtiva da cana-de-açúcar hoje

O Brasil é o maior produtor de cana-de-açúcar do mundo. Na safra de 2023/2024, a estimativa é de que serão produzidas cerca de 610 milhões de toneladas. A área cultivada total na safra de 2022/2023 foi de 8.290 mil hectares, divididos entre todos os estados produtores brasileiros. O estado de São Paulo é o maior produtor, pois respondeu por 50,03% (4.148 mil hectares) do total plantado no país. Em seguida vem o estado de Goiás com 11,54% (957 mil hectares), Minas Gerais com 10,80% (896 mil hectares), Mato Grosso do Sul com 7,66% (636 mil hectares), Paraná com 5,73% (475 mil hectares) e Alagoas com 3,63% (301 mil hectares). Nos demais estados, as áreas de produção são de menor tamanho, totalizando 10,81% (880 mil hectares) (CONAB, 2023).

Com relação às exportações dos produtos derivados da cana-de-açúcar, segundo dados divulgados pelo Ministério da Indústria, Comércio Exterior e Serviços (MDIC), a exportação de açúcar foi de 9,2 milhões de toneladas na safra de 2023/2024, de abril a julho, o que representou um aumento de 13,5% em comparação com o mesmo período do ciclo anterior. Além disso, houve um aumento de 40% no valor comercializado na safra 2023/2024 em comparação com o ciclo anterior, com o rendimento financeiro da exportação de açúcar alcançando US\$ 4,5 bilhões, enquanto na safra 2022/2023 foi de US\$ 3,2 bilhões. Os países que mais importam açúcar são Arábia Saudita, Índia e Argélia (CONAB, 2023).

Quanto à produção de etanol, os dados brasileiros também são positivos. Segundo o MDIC, a exportação de etanol foi de 674,9 milhões de litros na safra de 2023/2024, de abril até julho, o que representou um aumento de 15,9% em relação às exportações para o mesmo período da safra passada. Em termos monetários, as importações e exportações de etanol renderam US\$ 13 milhões e US\$ 442 milhões, respectivamente, resultando em um superávit de US\$ 429 milhões durante a safra de 2023/2024. Os países com maiores volumes de destino do etanol brasileiro foram a Coreia do Sul, com cerca de 43,5% do volume exportado para o período, seguida pelos Estados Unidos, com 26%, e Holanda, com 15,5%. Juntos, esses três países importaram 85,3% do etanol brasileiro (CONAB, 2023).

2.3 Ambientes de produção da cana-de-açúcar

O cultivo da cana-de-açúcar é antigo, tendo suas primeiras mudas plantadas no Brasil por volta de 1515, vindas da Ilha da Madeira (Portugal). Os portugueses puderam observar que as terras brasileiras possuíam alguns atributos essenciais para a produção de cana-de-açúcar, tais como: solos férteis, águas profusas, temperaturas quentes e relevos planos (RODRIGUES; ROSS, 2020). Contudo, apesar de vários locais possuírem áreas propícias para a produção de cana-de-açúcar, nem todos devem ser manejados da mesma forma, pelo fato de que há vários fatores que interferem no crescimento e, conseqüentemente, na produtividade da cana-de-açúcar (STORINO et al., 2010). Portanto, para haver maior ganho na produtividade, é interessante associar as variedades de cana-de-açúcar mais adaptadas a cada ambiente de produção.

Segundo Cavalcante e Prado (2010), um ambiente de produção pode ser definido como a junção das características físicas, hídricas, morfológicas, químicas e mineralógicas dos solos, sob manejo correto da superfície arável em que as raízes irão se desenvolver. Além dos aspectos do solo, envolve o controle de plantas daninhas, assim como o controle de pragas e doenças, todos esses associados com o clima regional (índice de precipitação, temperatura, radiação solar, evaporação).

Diante do exposto, seguem alguns fatores que podem limitar o crescimento e a produção da cana-de-açúcar nos ambientes produtivos:

2.3.1 Água

A água é um recurso de grande impacto no crescimento e desenvolvimento da cana-de-açúcar, cuja falta ou excesso pode prejudicar a cultura, mesmo em solos com históricos de boa produtividade. A cana-de-açúcar apresenta, ao longo de seus estádios vegetativos, diferentes necessidades hídricas, que, segundo Doorenbos e Kassam (1979), variam de 1500 a 2500 mm.

O déficit hídrico provoca diversas alterações nos processos bioquímicos e fisiológicos das plantas, como alterações iônicas, distúrbios nutricionais e estresse oxidativo, que resultam em desarranjo da membrana, atraso na fotossíntese e toxicidade metabólica (KUMAR; MALIK; SENGAR, 2021). Portanto, o déficit hídrico pode causar até a morte da planta ao provocar desequilíbrio iônico e estresse hiper-osmótico, perturbando as atividades metabólicas gerais (KARUPPANAPANDIAN et al., 2011; LIU et al., 2011; ZHU, 2001).

2.3.2 Temperatura

A temperatura influencia diretamente o crescimento dos colmos, sendo um dos fatores de maior importância (CAPONE et al., 2011). Segundo Magalhães (1987), a temperatura basal situa-se na faixa de 20°C, a temperatura ótima varia entre 22°C e 30°C, e acima de 38°C não ocorre crescimento.

Marin (2014) afirma que a temperatura desempenha um papel importante no início do estágio de maturação da cana-de-açúcar, uma vez que, quando há uma queda gradativa de temperatura em conjunto com a diminuição das precipitações, a cultura começa o acúmulo de sacarose nos colmos, dando início a essa fase do ciclo da cana-de-açúcar. Segundo o mesmo autor, a temperatura exerce uma função importante no florescimento da cana, em que a indução das flores ocorre, de maneira geral, quando há pequenas diferenças entre as temperaturas máxima e mínima, desde que a temperatura mínima seja maior ou igual a 18°C. Resumidamente, a temperatura provoca alterações nas reações bioquímicas e nas atuações das enzimas responsáveis pelo crescimento celular da planta (CASAGRANDE; VASCONCELOS, 2008).

2.3.3 Textura do solo

A quantidade dos grânulos de argila, areia e silte na terra fina seca ao ar compõe a textura do solo. A relação da porcentagem destes teores influencia a estrutura física, coesão e estabilidade do solo (MANHÃES et al., 2015). Esses fatores atuam na resistência da camada superficial ao rompimento pelos brotos primários de cana-de-açúcar.

A estrutura dos grânulos do solo afeta a quantidade de retenção de água no solo, o que pode interferir na velocidade de brotação e na água disponível para a cultura durante as fases subsequentes do ciclo. A relação de porcentagem de argila em um volume de solo também afeta a quantidade de nutrientes disponíveis para as plantas; ocorre que a quantidade de argila interfere em algumas características químicas do solo, como capacidade de troca de cátions, a dinâmica da matéria orgânica e a disponibilidade hídrica (PRADO, 2005).

2.3.4 Fertilidade do solo

REETZ (2017) retrata que os nutrientes são essenciais para o desenvolvimento dos vegetais. Dos 17 elementos essenciais, três são fornecidos pelo ar e pela água: carbono (C), hidrogênio (H) e oxigênio (O); os outros 14 são elementos minerais, os quais são fornecidos pelo solo ou por meio de resíduos de plantas e animais, e/ou de outras fontes orgânicas, bem como adicionados através de fertilizantes minerais. O mesmo autor afirma que, para um elemento ser classificado como essencial, a planta não pode completar seu ciclo de vida sem esse elemento.

A produtividade da cultura da cana-de-açúcar (TCH – toneladas de cana-de-açúcar por hectare) está diretamente relacionada com as condições químicas do solo no horizonte subsuperficial, segundo REETZ (2017), ocorrendo uma maior correlação conforme se avança nos cortes da cana-de-açúcar. Na mesma pesquisa, os autores observaram que a produtividade das canas soqueiras decaiu conforme os atributos químicos dos grupos de solo na seguinte ordem: eutrófico > mesotrófico > distrófico > ácrico.

Diante do exposto, ao se conhecer os principais fatores que afetam a produtividade da cana-de-açúcar, na Tabela 1, estão os critérios que separam os diferentes ambientes de produção na cana-de-açúcar, incluindo os aspectos hídricos, químicos e morfológicos dos solos. O Programa Cana do Instituto Agrônomo de Campinas, juntamente com as usinas que são conveniadas a este programa, forneceu os dados das colheitas de cana-de-açúcar usados na Tabela 1; as observações foram feitas em centenas de ensaios pedológicos estaduais e regionais.

Tabela 1. Ambientes de produção de cana-de-açúcar na região Centro-Sul do Brasil.

AMBIENTES	PRODUTIVIDADE MÉDIA TCH _h	SOLOS
A1	> 100	ADA; e, ef, m, mf; CTC média/alta: Argissolos, Latossolos, Nitossolos, Chernossolos, Cambissolos, Gleissolos
A2	96 - 100	ADM; e, ef; CTC média/alta: Argissolos, Latossolos, Nitossolos, Cambissolos, Gleissolos
B1	92 - 96	ADA; mf, m; CTC média/alta: Argissolos, Latossolos, Cambissolos ADM; ma*; CTC média/alta: Argissolos ADM; e; m; CTC baixa: Argissolos ADB; ef, e; CTC média/alta: Latossolos, Argissolos, Cambissolos
B2	88 - 92	ADM; m; mf; d; CTC média/baixa: Argissolos, Latossolos, Cambissolos ADB; e; m; CTC baixa: Argissolos ADA; a; CTC alta: Gleissolos
C1	84 - 88	ADM; d; CTC média/baixa: Argissolos ADM; ma*; CTC média/alta: Latossolos ADM; e; CTC média/alta: Cambissolos ADM; a; CTC alta: Nitossolos ADB; e, m; CTC média/baixa: Argissolos ADB; df, d; CTC média/alta: Latossolos
C2	80 - 84	ADM; a*, d; CTC média/alta: Argissolos ADM; d, a; CTC média/alta: Cambissolos ADB; d; CTC baixa: Latossolos ADB; d; CTC média/baixa: Argissolos ADMB; ef, e; mf, m; CTC média/alta: Latossolos
D1	76 - 80	ADM; a, ma; CTC média/baixa: Argissolos ADM; d, a; CTC média/alta: Cambissolos ADB; wf, w; CTC média/alta: Latossolos ADB; ma; CTC média: Latossolos ADB; d; CTC média/baixa: Argissolos ADMB; e; m; CTC média: Latossolos
D2	72 - 76	ADM; a, ma; CTC média/baixa: Argissolos ADB; ma; CTC baixa: Latossolos ADM; e; m; CTC alta; A chernozêmico: Neossolos Litólico ADB; d; CTC baixa: Argissolos ADMB; e; m; CTC baixa: Latossolos ADMB; d; CTC média: Cambissolos
E1	68 - 72	ADB; a; ma; CTC média/baixa: Argissolos ADB; e; m; CTC baixa: Argissolos ADB; e; m; CTC média/alta: Plintossolos Háplico ADMB; d; ma; wf, w; CTC média/alta: Latossolos ADMB; ma; CTC média/alta: Argissolos
E2	< 68	ADEB; e; m; d; ma; a; aa; CTC baixa/média/alta: Argissolos, Latossolos, Neossolos Quartzarênicos, Neossolos Litólicos A moderado, Plintossolos Petríco

ÁGUA DISPONÍVEL: ADA: água disponível alta; ADM: água disponível média; ADB: água disponível baixa; ADMB: água disponível muito baixa; ADEB: água disponível extremamente baixa.

QUÍMICA ABAIXO DA CAMADA ARÁVEL: ef: eutroférico, e: eutrófico, mf: mesotroférico, df: distroférico, d: distrófico, wf: acriférico, w: ácrico; ma: mesoálico, a: álico, aa: alumínico.

CTC DO SOLO NA CAMADA ARÁVEL: alta > 8 cmol.kg⁻¹; média: 4 a 8 cmol.kg⁻¹; baixa: < 4 cmol.kg⁻¹.

FONTE: (PRADO, 2007 apud CAVALCANTI, 2010).

2.4 Aeronaves remotamente pilotadas

O início das aeronaves remotamente pilotadas teve suas origens com os equipamentos usados para a guerra. Começou mais precisamente com veículos que eram programados para voar a uma distância pré-determinada e explodir ou liberar uma carga explosiva. Essas primeiras invenções eram bem diferentes dos drones conhecidos atualmente, pois eram

montados com madeira, panos e contadores de revolução de giroscópios ou hélice para transportar as cargas (WHITMORE, 2016).

Segundo Whitmore (2016), um dos primeiros projetos de aeronave não tripulada foi o “Kettering Bug”, projetado por Charles Franklin Kettering. Esse protótipo, uma bomba voadora não tripulada de longo alcance, era lançado através de um sistema de trilhos e carrinho. Contava com um motor pequeno de quatro cilindros, refrigerado a ar, com 40 cavalos de potência. Este protótipo foi ajustado para ser guiado até o alvo através de controles pré-ajustados, utilizando cálculos inseridos antes do voo, que eram feitos com base nas previsões de vento durante o percurso e no número de rotações do motor para atingir o alvo. Quando as rotações estimadas chegavam ao final, um controle fechava o circuito elétrico que parava as rotações e acionava os detonadores. A aeronave então caía no alvo, explodindo no impacto junto com os explosivos.

A origem da palavra “drone”, que é usada para designar a aeronave não tripulada, está relacionada com o barulho que é semelhante ao emitido pelas abelhas ou zangões (em inglês, “drone bees”) quando estão voando. Segundo Puri et al. (2017), o termo “drone” era uma palavra técnica usada por militares, e somente 80 anos depois passou a ser amplamente conhecido como uma palavra civil.

Há mais termos utilizados para denominar os veículos aéreos não tripulados, além do termo popular “drone”. Denominações como veículo aéreo não tripulado (VANT), aeronave remotamente pilotada (ARP), unmanned aircraft (UA), unmanned aerial vehicle (UAV) e remotely piloted aircraft (RPA) são alguns exemplos (AMARAL, 2021).

Os RPAs podem ser classificados mais simplificadaamente devido ao tipo de voo que realizam, sendo de dois tipos principais: os modelos de asa fixa e os modelos multirrotores. Os modelos de asa fixa se assemelham a aviões, possuem como principal vantagem uma autonomia de voo maior, mas apresentam maior dificuldade para decolar e pousar. Já os modelos multirrotores, que têm de dois a oito rotores, oferecem mais facilidade para decolar e pousar, além de maior manobrabilidade; contudo, apresentam menor autonomia de voo se comparados aos de asa fixa. Atualmente, há a possibilidade de encontrar RPAs híbridos que minimizam as desvantagens de ambos os modelos (AMARAL, 2021).

Resumidamente, o RPA é um equipamento feito para voar sob o comando de um ser humano remotamente, podendo ser guiado à distância dependendo de sua estrutura e realizar determinadas tarefas, como transportar objetos e cargas ou coletar informações através de sensores. Atualmente, sua utilização ocorre em diversos setores, sejam eles militares, recreativos ou comerciais.

2.5 RPAs na agricultura

A estimativa é de que a população mundial em 2050 seja de nove bilhões de habitantes (FAO, 2019). Com o aumento da população mundial, deverá também aumentar a produção de alimentos para atender essa demanda. Contudo, produzir alimentos no setor agrícola pode ser desafiador, devido ao fato de a produção ser dependente das condições climáticas, dos atributos do solo, além da quantidade de água disponível e do controle de pragas e doenças (AHIRWAR et al., 2019).

A transformação digital que está ocorrendo na chamada Agricultura 4.0 certamente ajudará no processo de aumentar esse fornecimento de alimentos. Esta transformação digital, que começou no início do século XXI, caracteriza-se pela rápida alteração da indústria tradicional através da adoção de tecnologia da informação (CLAY; KITCHEN, 2018).

Dentro das tecnologias que estão surgindo com a Agricultura 4.0, uma ferramenta de grande auxílio na aquisição de dados são os RPAs (Remotely Piloted Aircraft - Aeronaves Remotamente Pilotadas), que possuem a capacidade de transportar os mais variados tipos de sensores a bordo. Conforme Borém et al. (2021) retratam, as imagens adquiridas pelos sensores possuem uma baixa cobertura, contudo têm uma ótima resolução e acurácia. Outra vantagem é a facilidade de se obter os dados em tempo real, de maneira mais rápida (MALVEAUX; HALL; PRICE, 2014). Além disso, ao voar a altitudes menores, os RPAs conseguem captar imagens mesmo na presença de nuvens, desde que sejam calibrados corretamente, o que difere dos problemas enfrentados pela utilização de satélites orbitais (AYDOĞAN, 2018).

Os drones estão sendo cada vez mais procurados pelas empresas, e o motivo para esta procura está nas diversas funcionalidades que eles possuem e também nas imagens disponibilizadas para o produtor rural, auxiliando nas tomadas de decisão na lavoura e na facilidade de atuação diante de alguns problemas. Diante do exposto, seguem algumas aplicações que a utilização das imagens e dos RPAs desempenha e que foram utilizadas neste trabalho.

2.5.1 Levantamento topográfico

Na agricultura, os levantamentos topográficos são essenciais para um adequado manejo e conservação do solo, pois através do levantamento obtêm-se informações de altitude, tamanho da área, declividade e índices associados. Com esses dados, há a oportunidade de realizar uma sistematização correta da área, realizar o plantio em nível e a elaboração de

terraços. Esses levantamentos topográficos podem ser realizados com procedimentos que envolvam a utilização de estação total e teodolito. Atualmente, são utilizados o Sistema de Navegação Global por Satélites (GNSS), com correções diferenciais de sinal (DGNS) que proporciona exatidões de centímetros.

Uma maneira de realizar o levantamento topográfico é com a utilização de RPAs empregando os conceitos de fotogrametria. Para efetuar este tipo de levantamento, são necessários pontos de controle no local com as coordenadas conhecidas, que posteriormente serão vinculadas às imagens. Então, o processamento das imagens georreferenciadas é realizado em software com a técnica SFM (da sigla inglesa Structure From Motion), que detecta na imagem pontos em comum nos objetos, por exemplo, feições geométricas ou outros detalhes, e através destas semelhanças reconstrói a cena em três dimensões (TURNER; LUCIEER; WATSON, 2012; VERHOEVEN, 2012).

O modelo de topografia em três dimensões dá origem a dois tipos de produtos: 1) modelo digital de superfície (MDS), que é a imagem com a informação sobre a altura dos objetos que estão acima do solo, por exemplo, a cobertura vegetal; e 2) modelo digital do terreno (MDT), que consta a informação da altura do nível do solo, portanto desconsidera o que está acima dele. Um terceiro produto resulta ao realizar a subtração do MDS com o MDT, que é a informação sobre os objetos que estão na superfície, como altura de plantas ou do volume do dossel (AMARAL, 2021). Vários autores já utilizaram a técnica SFM como ferramenta para modelar a altura e observar a dinâmica de crescimento das culturas (BENDIG; BOLTEN; BARETH, 2013; MARTELLO, 2017).

2.5.2 Monitoramento de lavouras

Um dos principais direcionamentos que os drones possuem na agricultura é o monitoramento das culturas desde antes do plantio até o término do seu desenvolvimento. Contudo, a utilização dos RPAs para o monitoramento das lavouras só é possível quando esses equipamentos atuam conjuntamente com as técnicas de sensoriamento remoto.

Os sensores remotos são, segundo Moraes (2015), aparelhos que detectam certas faixas do espectro eletromagnético, medem a quantidade de energia de um objeto, transformam essa energia em sinal elétrico e o registram; posteriormente, esses dados são convertidos em informações que descrevem e oferecem mais detalhes sobre os objetos que estão na superfície terrestre, como vegetação, solo, água, entre outros. Diversas pesquisas já utilizaram os sensores remotos com foco na agricultura, tais como: estimativa de rendimento e avaliação da fenologia

das culturas (MULLA, 2013); efeito do déficit hídrico (GAGO et al., 2015; JORGE; VALLBÉ; SOLER, 2019; KATSOULAS et al., 2016; ZHAO et al., 2017); deficiências nutricionais (QUEMADA; GABRIEL; ZARCO-TEJADA, 2014); estressores bióticos nos vegetais, como patógenos (CALDERÓN et al., 2013; MAHLEIN et al., 2013; ZARCO-TEJADA et al., 2018); nematóides (NUTTER et al., 2002) e ervas daninhas (PEÑA et al., 2015; RASMUSSEN et al., 2013).

Uma das principais abordagens dentro da área de sensoriamento remoto, que auxiliam nos monitoramentos, é a utilização dos índices espectrais, que são formulações matemáticas elaboradas com origem nas bandas espectrais, principalmente na banda do vermelho e infravermelho próximo. Tem como objetivo possibilitar avaliações e estimativas de cobertura vegetal de uma área, como área foliar, biomassa, quantidade de área de solo e atividade fotossintética (FORMAGGIO; SANCHES, 2017).

Dentre os principais índices pode-se citar o NDVI (*normalized difference vegetation index*) proposto por ROUSE et al. (1973), este índice é usado há bastante tempo e isso ocorre devido à sua ótima responsividade a alterações no vigor da vegetação (FORMAGGIO; SANCHES, 2017). Várias publicações relacionam este índice com o estado fisiológico de diferentes culturas; SILVEIRA et al. (2020) utilizaram este índice para avaliar o estresse hídrico em cana-de-açúcar; ZERBATO et al. (2016) ao correlacionar este índice com a cobertura vegetal e com a produtividade tiveram bons resultados. Contudo, este índice possui a limitação de saturação; a saturação acontece quando o valor numérico do índice não aumenta conforme aumenta a biomassa vegetal, isso ocorre após a biomassa atingir em torno de 0,3 g/cm² (MUTANGA; MASENYAMA; SIBANDA, 2023).

Outros índices foram desenvolvidos e são muito utilizados, como o EVI (*enhanced vegetation index*) proposto por HUETE (1988), tem como característica realçar o sinal da vegetação, pelo fato de possuir maior sensibilidade em locais com alta fitomassa. Já o índice *Excess Greenness* (ExG) proposto por WOEBBECKE et al. (1995), tem como objetivo analisar a vegetação utilizando bandas do espectro do visível, segundo o mesmo autor é um índice superior na distinção de material verde no solo em comparação com outros índices.

Os índices que podem ser escolhidos para o monitoramento do estado da vegetação irão depender do tipo de sensor embarcado no RPA. Estes podem ser os sensores do tipo RGB, multiespectrais e hiperespectrais.

As siglas RGB representam as bandas espectrais com as quais o sensor trabalha: do inglês *R-Red* (Vermelho), *G-Green* (Verde) e *B-Blue* (Azul). No processamento das imagens desses tipos de sensores, consegue-se a composição de cores semelhantes à cor verdadeira que

a visão humana é capaz de enxergar (AMARAL, 2021), assim como a obtenção de alguns índices como o mencionado acima ExG. São os mais utilizados, por serem relativamente mais acessíveis financeiramente.

Os sensores multiespectrais são equipados com uma ou mais bandas além do espectro do visível (RGB). As bandas mais utilizadas são a do NIR do inglês (infravermelho próximo), que possui boa relação com o dossel da vegetação; a banda do *RedEdge* (borda do vermelho), que é susceptível a variações no vigor da vegetação; e mais recentemente a banda com infravermelho termal, que é capaz de captar a temperatura permitindo cálculos de evapotranspiração (AMARAL, 2021). Contudo, um cuidado que deve ser tomado ao fazer uso destes sensores é a realização da calibração radiométrica (IQBAL; LUCIEER; BARRY, 2018).

Os sensores hiperespectrais são capazes de registrar centenas a milhares de faixas radiométricas estreitas, principalmente nas faixas do visível e do infravermelho. Contudo, apesar de serem sensores que oferecem um alto número de observações sobre os alvos, sua utilização é limitada devido ao alto preço em relação aos RGB e multiespectrais, além de serem mais pesados, dificultando seu transporte no RPA (ESPOSITO et al., 2021). Assim como nos sensores multiespectrais, os sensores hiperespectrais também necessitam de calibração.

3. MATERIAL E MÉTODOS

O delinamento do experimento bem como os dados de biometria e análises tecnológicas foram elaboradas para a tese de Doutorado de Renê Assis Sordi. Cujo este trabalho é um complemento.

3.1 Área de estudo

O estudo foi conduzido em dois campos experimentais, conforme representado na Figura 2, pertencentes à Usina Iracema. O primeiro campo está localizado no município de Itirapina-SP, na fazenda Santana de Cima (Latitude: 22°14'30'' S e Longitude: 47°41'47,31'' W; Altitude: 844 m). Esta cidade possui clima Cfa, segundo a classificação climática de Köppen, com temperatura média anual de 27,1 °C e precipitação média anual de 1356 mm. O solo é um Latossolo Vermelho Amarelo Álico, LVAa 4.1, de textura arenosa/média, e a área está em topografia plana, classificada como ambiente tipo E (PRADO, 2007, apud CAVALCANTI, 2010), conforme a Tabela 1.

No município de Iracemápolis-SP, na fazenda Boa Vista (Latitude: 22°35'15,81'' S e Longitude: 47°33'15,59'' W; Altitude: 681 m), foi realizado o outro experimento. O local tem o clima classificado como Aw, segundo a classificação climática de Köppen, com invernos secos, apresentando uma temperatura média anual de 28,7 °C e precipitação de 1352 mm. O solo é um Latossolo Vermelho Eutrófico LVef, de textura argilosa e topografia plana; o ambiente de produção é do Tipo A (PRADO, 2007, apud CAVALCANTI, 2010), conforme indicado na Tabela 1.

As características físicas e químicas dos solos da área de Boa Vista (ambiente tipo A) e Santana de Cima (ambiente tipo E) estão na Tabela 2.

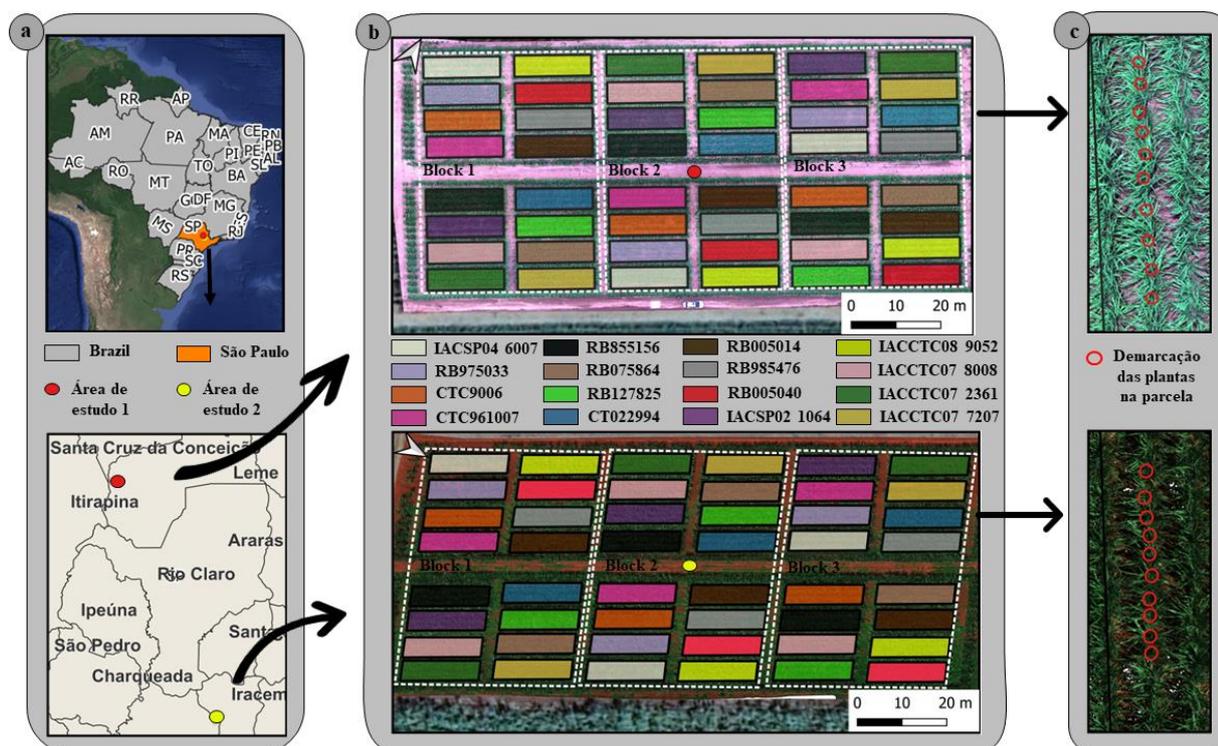


Figura 2. (a) Localização dos experimentos no Brasil. (b) Orthomosaicos das áreas de estudo com as cultivares. (c) Uma parcela de cada campo experimental com as plantas que foram amostradas dentro da parcela.

Tabela 2. Características físico-químicas dos solos dos ensaios das Fazendas Boa Vista e Santana de Cima.

	Boa Vista	Santana de Cima
Argila %	61,0	14,6
Areia fina %	16,2	12,9
Areia grossa %	8,9	72,1
Silte %	14,0	0,4
pH (KCL)	4,6	4,9
Matéria orgânica %	19,8	12,5
P resina (mg dm ⁻³)	25,4	30,3
K (mmol _c dm ⁻³)	9,1	0,3
Ca (mmol _c dm ⁻³)	22,7	10,6
Mg (mmol _c dm ⁻³)	8,0	3,5
Soma bases	39,8	14,4
Alumínio	1,7	3,4
Capacidade de Troca Catiônica	76,7	42,4
Soma de Bases V%	51,7	29,0
Saturação de Alumínio %	3,9	38,2
Solo	Latossolo Vermelho Eutroférico	Latossolo Vermelho Amarelo álico
Unidade	L Vef 1.1	LVAa 4.1
Ambiente de Produção ⁽¹⁾	A	E

⁽¹⁾(PRADO, 2007 apud CAVALCANTI, 2010).

Os tratamentos foram 16 cultivares diferentes. Em delineamento de blocos casualizados (DBC) com 3 repetições Figura 2(b). As parcelas foram 4 sulcos de 18,2 m, contendo 28 plantas, espaçadas a 0,65 m entre elas, de espaçamento igual a 1,5 m entre os sulcos, utilizando mudas pré brotadas. Optou-se pelo delineamento de blocos ao acaso em função da necessidade de controlar variações ambientais intraexperimentais que poderiam influenciar o comportamento das diferentes cultivares de cana-de-açúcar como ervas daninha, doenças ou desbalanço nutricional. Essa abordagem permitiu uma avaliação mais precisa dos efeitos dos tratamentos aplicados, ao minimizar as influências de variáveis não controladas e garantir que as comparações entre os tratamentos fossem feitas em condições o mais uniformes possível dentro de cada bloco.

Na Tabela 3, estão os clones e cultivares utilizadas no experimento bem como seus respectivos ambientes produtivos. A escolha destas cultivares foi devido a utilização frequente dessas em campos produtivos e o interesse de saber como algumas cultivares novas crescem e se desenvolvem nos diferentes ambientes.

Os dados de precipitação foram obtidos através de dados do Centro Europeu de Previsão do Tempo de Médio Prazo (ECMWF). O modelo ECMWF utiliza informações de estações meteorológicas de superfície, radares meteorológicos, satélites e outras fontes, para estimar valores de precipitação e temperatura em todo o mundo, com uma resolução espacial de 0,25 graus (DEE et al., 2011). A média histórica obtida foi realizada levando em consideração a média dos últimos 5 anos.

A colheita do ensaio de Santana de Cima (ambiente E) ocorreu no dia 5 de maio de 2022 já no local do ensaio de Boa Vista (ambiente A) a colheita ocorreu dia 22 de maio de 2022.

Tabela 3. Cultivares e ambientes de produção

Cultivar	Ambiente de produção	Fonte
CT022994	A, B e C	CTC,2023
CT961007	D e E	CTC,2023
CTC9006	C e D	CTC,2023
IACCTC07 2361	B, C e D	IAC, 2021
IACCTC07 7207	A, B e C	IAC, 2021
IACCTC07 8008	A, B e C	IAC, 2021
IACCTC08 9052	A, B e C	IAC, 2021
IACSP02 1064	A, B e C	IAC, 2021
IACSP04 6007	B, C e D	IAC, 2021
RB005014	A, B e C	RIDESAS, 2023
RB005040	A e B	RIDESAS, 2023
RB075864	A, B e C	RIDESAS, 2023
RB127825	A, B e C	RIDESAS, 2023
RB855156	B, C e D	RIDESAS, 2023
RB975033	C e D	RIDESAS, 2023
RB985476	A, B e C	RIDESAS, 2023

3.2 Descrição da plataforma de aquisição dos dados

O multi-rotor UAV de seis hélices, DJI Matrice 600 Pro, foi equipado com o sensor multiespectral MicaSense Altum-Pt para a coleta de dados espectrais. As bandas capturadas pelo sensor foram Blue, Green, Red, RedEdge e Nir (os comprimentos de onda estão apresentados na Tabela 4). O voo foi controlado por um software de planejamento de missão, com sobreposição lateral de 80% e frontal de 70%; a altura do voo foi de 30 metros. Os voos foram realizados nas duas áreas de estudo nos dias 06/09/2021, 17/11/2021 e 10/02/2022. Todos os voos ocorreram entre 10:00 am e 14:00 pm. Antes de realizar o voo, foi tirada uma fotografia de uma placa de calibração radiométrica para a posterior correção das imagens (MicaSense).

Tabela 4. Comprimento de onda e largura total à meia altura (FWHM) para as bandas presentes no sensor Micasense Altum-Pt.

Número da Banda	Região da Banda	Centro da onda (nm)	Largura da banda FWHM (nm)
1	Blue	475	20
2	Green	560	20
3	Red	668	10
4	Red-Edge	717	10
5	Nir	840	40

3.3 Processamento fotogramétrico *structure from motion*

As imagens multiespectrais coletadas pelo sensor MicaSense Altum-Pt foram processadas pelo software SfM (Agisoft Metashape Professional 1.5.5) para montar as imagens. A técnica SfM estima estruturas tridimensionais a partir de um conjunto de imagens bidimensionais projetadas (JIANG; JIANG; JIANG, 2020). Neste processo, as informações iguais das imagens sobrepostas são identificadas pelos algoritmos de correspondência de características para assim ocorrer a junção das imagens. Logo após, forma-se uma nuvem de pontos densificada e, por fim, essa nuvem de pontos pode ser usada para formar um modelo digital de elevação (DEM) e o ortomosaico (ASHAPURE et al., 2020).

3.4 Segmentação de imagens

Para remover a interferência do fundo do solo e de sombras foi criado um conjunto de treinamento de duas classes, uma classe com amostragem das plantas e a outra do solo. A amostragem foi realizada nos pixels do ortomosaico. Deste modo, para cada voo em cada área foram criados 3644 pontos amostrais, considerando cada ponto como um pixel, os valores dos pontos foram classificados como vegetação e não-vegetação observando os valores de NDVI (ROUSE et al., 1973). Posteriormente separamos 20% dos pontos para validação e 80% foi utilizado como treinamento, o classificador Random Forest foi escolhido devido ao seu alto grau de utilização e recomendação (KAWAMURA et al., 2021; RODRÍGUEZ et al., 2021).

O Random Forest é um conjunto de numerosas árvores independentes de classificação e regressão individuais (BREIMAN, 2001). Os hiperparâmetros do classificador foram otimizados levando em consideração os dados de entrada (GridSearchCV) e uma validação cruzada de 10 vezes foi realizada para evitar overfitting (JÚNIOR et al., 2022). A utilização de validação cruzada permite que o modelo seja testado em várias subdivisões dos dados para garantir que ele performe consistentemente bem, não apenas em um subconjunto específico que é o problema do overfitting. O procedimento todo foi realizado no software (Quantum Gis 3.22.14) com o plugin (Dzetsaka) que utiliza o pacote Skit-learn (BARUPAL; FIEHN, 2019). O resultado foi a seleção da camada de máscara contendo a vegetação de cada parcela. A segmentação retornou uma precisão acima de 96% em todos os voos nos testes de validação.

3.5 Extração espectral dos dados

As informações espectrais foram obtidas nas mesmas plantas que foram retirados os dados referentes à biometria (Figura 2c), para isso, a seleção das plantas foi feita manualmente colocando-se um Buffer redondo de diâmetro igual a 0,45 m em 10 plantas em cada parcela. Soube-se quais eram as plantas porque foi padronizado utilizar a segunda linha de cada parcela, depois de contar 5 plantas do começo da parcela. A próxima etapa foi utilizar a ferramenta de Máscara e Estatísticas Zonais do QGIS. Deste modo, obteve-se os valores das bandas descritas na Tabela 3, também foram calculados índices de vegetação, Tabela 5, para fazer o acompanhamento da cultura da cana-de-açúcar, os índices vegetais são formulações matemáticas elaboradas com origem nas bandas espectrais que são muito utilizados em aplicações na agricultura (FORMAGGIO; SANCHES, 2017; JÚNIOR et al., 2022).

Através desta segmentação de imagens foi obtido o índice de fechamento para cada cultura. Este índice foi calculado ao transformar a camada raster obtida através do algoritmo Random Forest em vetor, em seguida foi calculada a área da vegetação e fez-se a subtração pelo tamanho da parcela. Por último calculou-se a porcentagem de área verde da parcela. Essa metodologia foi utilizada para todos os voos nos dois lugares.

Tabela 5. Índices utilizados neste estudo.

Índice	Nome	Equação	Referência
NDVI	<i>Normalized Difference Vegetation Index</i>	$\frac{NIR - RED}{NIR + RED}$	(ROUSE et al., 1973)
NDRE	<i>Normalized Difference Red Edge Index</i>	$\frac{NIR - REEDGE}{NIR + REEDGE}$	(TUCKER, 1979)
GNDVI	<i>Green Normalized Difference Vegetatio Index</i>	$\frac{NIR - GREEN}{NIR + GREEN}$	(GITELSON et al., 1996)
GRVI	<i>Green-Red Vegetation Index</i>	$\frac{GREEN - RED}{GREEN + RED}$	(TUCKER, 1979)
OSAVI	<i>Optimized Soil Adjusted Vegetation Index</i>	$\frac{NIR - RED}{NIR + GREEN + 0,16}$	(RONDEAUX; STEVEN; BARET, 1996)
SAVI	<i>Soil Adjusted Vegetation Index</i>	$1,5 * \frac{NIR - RED}{NIR + RED + 0,5}$	(HUETE, 1988)
EVI	<i>Enhanced Vegetation Index</i>	$2,5 * \left(\frac{NIR - RED}{(NIR + 6 * RED - 7,5 * BLUE) + 1} \right)$	(HUETE, 1997)
EXG	<i>Excess Greenness</i>	$2 * G - R - B$	(WOEBBECKE et al., 1995)
SFDVI	<i>Spectral Feature Depth Vegetation Index</i>	$\frac{NIR + GREEN}{2} - \frac{RED + REEDGE}{2}$	(BAPTISTA, 2015)

3.6 Aquisição de dados biométricos

A primeira coleta dos dados biométricos foi iniciada na semana do dia 17 de novembro de 2021, quando a cana estava com 76 dias após o plantio; essa coleta foi realizada em conjunto com a aquisição dos dados do sensor da MicaSense para ambas as áreas. Já a segunda aquisição dos dados biométricos ocorreu na semana do dia 10 de fevereiro de 2022, quando a cana estava com 149 dias após o plantio; também foi realizada em conjunto com a aquisição dos dados do sensor MicaSense.

Para saber se ter a garantia de que seriam as mesmas plantas avaliadas em ambas as coletas foi definido que seria sempre a segunda fileira do início de cada parcela, ao passar por cinco plantas, foi amarrado uma fita, as amostragens foram realizadas em 10 plantas por parcela, a última planta também foi amarrada com uma fita para sinalizar o término das plantas amostradas em cada parcela.

A metodologia de Nassif et al (2013), foi utilizada como critério para as avaliações biométricas. Com uma régua graduada de madeira mediu-se a largura e o comprimento da Folha +3 (ARTSCHWAGER, 1940). Também foi realizada a medida do ângulo de inserção foliar.

Os outros dados biométricos avaliados foram o número de folhas verdes ativas por colmo, o número de colmos por planta em cada touceira e a altura do colmo primário. O diâmetro dos colmos foi avaliado apenas na segunda coleta.

Mediu-se também as larguras das folhas, o comprimento das folhas e contou-se a quantidade de folhas ativas no colmo principal.

3.7 Estatística utilizada

Para a análise dos dados coletados, foi empregado o teste t de Student (STUDENT, 1908), com o objetivo de comparar os diferentes ambientes produtivos em termos de índices vegetativos, resultados do levantamento biométrico, e produção de tonelada de cana-de-açúcar por hectare e de açúcares redutores totais. A significância estatística foi estabelecida em $p < 0,05$. As hipóteses testadas foram: a hipótese nula (H_0) não haveria diferença significativa nos parâmetros avaliados entre os diferentes ambientes produtivos. A hipótese alternativa (H_1) é de que existem diferenças significativas nos parâmetros avaliados entre os diferentes ambientes produtivos.

O teste t de Student foi escolhido por sua capacidade de determinar se as médias de duas amostras independentes diferem significativamente, uma abordagem padrão quando se comparam médias em estudos agronômicos. O teste foi conduzido utilizando o software Sigma Plot 11 (Systat Software Inc., San Jose, CA, EUA).

O teste t de Student é amplamente utilizado em pesquisas agrícolas para comparar as médias de dois grupos distintos, assumindo que as amostras vêm de distribuições normais com variâncias iguais. Este teste foi escolhido baseado na sua robustez e na recomendação ampla na literatura para estudos comparativos em condições controladas e de campo (DE CASTRO, 2009; DE ASSIS, 2023). Além disso, a utilização do teste t de Student foi precedida por uma análise exploratória dos dados para verificar a normalidade e a homogeneidade das variâncias, assegurando que as premissas do teste fossem atendidas.

4. RESULTADOS E DISCUSSÃO

4.1 Condições meteorológicas

Na Figura 3 está o gráfico de precipitação e de temperatura para as áreas dos experimentos. Durante o período do experimento, de março de 2021 a maio de 2022, observou-se uma variação significativa nas condições meteorológicas, influenciando potencialmente o desenvolvimento da cana-de-açúcar nos dois locais. Em termos de precipitação, Boa Vista registrou um volume total de precipitação de 1229 mm durante todo o ciclo da cultura. A quantidade de chuva foi maior em Boa Vista nos meses de março a maio de 2021, período crucial para o estabelecimento inicial das plantas. Já em Santana, a precipitação total do local durante todo o ciclo da cana-de-açúcar foi de 1320mm, marcada por um pico em fevereiro de 2022, sugerindo uma distribuição temporal distinta que pode afetar as fases subsequentes do ciclo vegetativo da cana-de-açúcar.

Com relação a média histórica, durante todo o experimento as precipitações observadas ficaram frequentemente abaixo da média histórica, com algumas exceções como em outubro de 2021. Em Santana, padrões similares de precipitação foram notados, apesar de algumas elevações acima da média histórica em janeiro e fevereiro de 2022. Para as duas áreas houve redução do regime de chuvas com relação à média histórica desde o plantio até a primeira coleta dos dados. A área de Santana de Cima teve um acumulado no mês de agosto de 7 mm e a média histórica da área foi de 27 mm por mês. Já a área de Boa Vista teve para o mês de agosto o acumulado de precipitação de 20 mm com a média histórica de 28,6 mm.

Quanto às temperaturas médias, elas se mostraram consistentemente superiores em Boa Vista em comparação com Santana. A flutuação térmica observada demonstrou um aumento gradativo até outubro/novembro de 2021, seguido de uma queda e um subsequente aumento.

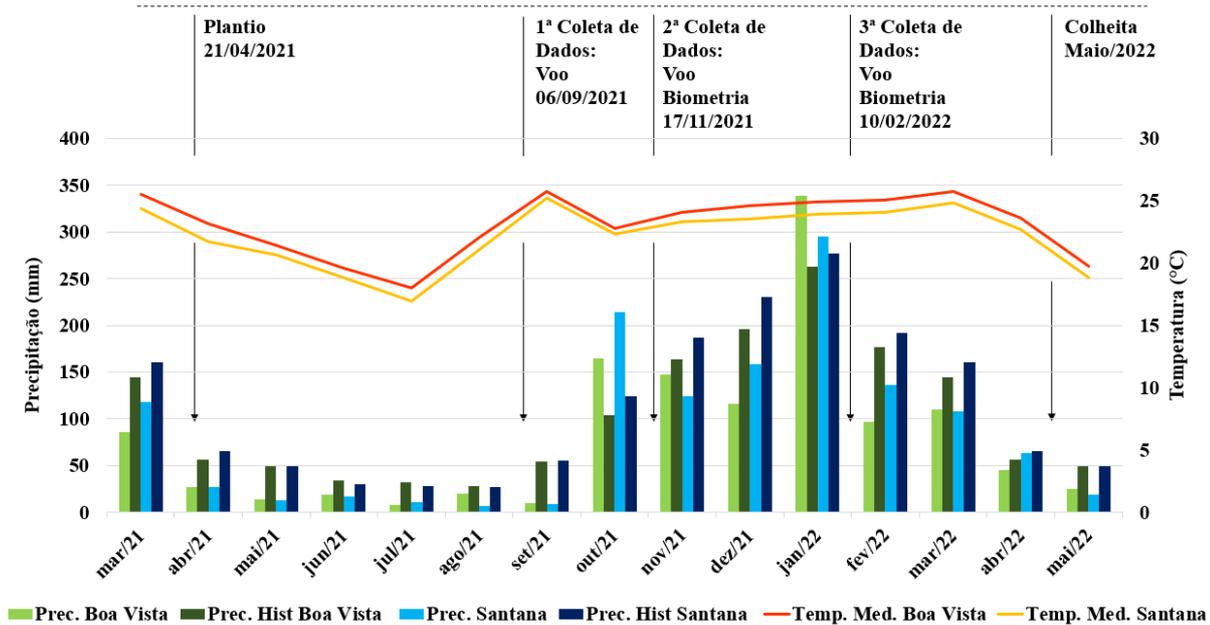


Figura 3. Gráfico de temperatura (°C) e dados de precipitação (mm) nos dois locais em que foram conduzidos os ensaios, a precipitação foi comparada com a média histórica.

4.2 Índices espectrais em cada ambiente

Os resultados dos índices da primeira coleta de dados espectrais estão na Tabela 6, o voo foi realizado em seis de setembro de 2021. No mês de agosto, as áreas de Santana de Cima e Boa Vista registraram uma média diária de precipitação de 0,23 mm e 0,66 mm respectivamente. Esses valores são inferiores aos intervalos de evapotranspiração diária para a cana-de-açúcar reportados por Santos (2005), que variam de 0,52 mm em condições mínimas a 8,60 mm em condições máximas. Essas taxas de evapotranspiração dependem de fatores como a variedade da cana-de-açúcar, o local de cultivo e o sistema de produção. Assim, a precipitação foi insuficiente para atender à demanda de água da cultura da cana-de-açúcar, sem considerar ainda as características de retenção e drenagem do solo.

Para cada índice, conduziu-se uma análise comparativa individual entre as duas áreas de estudo, Boa Vista e Santana de Cima. Utilizou-se o teste t de Student para determinar se as diferenças observadas nos valores dos índices entre as cultivares nas duas localidades distintas eram estatisticamente significativas. Os resultados foram representados com letras maiúsculas para denotar as diferenças estatísticas entre os grupos. A significância foi estabelecida em um nível de $p < 0,05$.

Os resultados do índice SFDVI (*Spectral Feature Depth Vegetation Index*) apresentaram médias mais altas com significância estatística em Santana de Cima para 14

cultivares. Proposto por Baptista (2015), esse índice é fundamentado na combinação das profundidades de feição das bandas verde e do infravermelho próximo, onde as médias dos pontos correspondem à máxima reflectância. No mesmo estudo, os autores constataram que esse índice foi capaz de identificar nuances mais sutis em dosséis densos de vegetação de forma mais efetiva do que os índices NDVI e EVI.

Tabela 6. Índices espectrais da primeira coleta dos dados do sensor MicaSense.

Cultivares	NDVI		SFDVI		NDRE		GNDVI	
	Boa Vista	Santana de Cima						
RB005040	0,600 B	0,680 A	0,078 B	0,135 A	0,258 B	0,319 A	0,519 B	0,569 A
CT022994	0,718 A	0,699 A	0,098 B	0,141 A	0,350 A	0,331 A	0,600 A	0,573 A
RB985476	0,616 B	0,685 A	0,074 B	0,132 A	0,260 B	0,338 A	0,529 B	0,587 A
IACCTC07 7207	0,653 A	0,693 A	0,082 B	0,143 A	0,327 A	0,342 A	0,581 A	0,582 A
IACCTC07 8008	0,679 A	0,638 A	0,094 A	0,126 A	0,316 A	0,293 A	0,576 A	0,536 A
IACCTC08 9052	0,591 B	0,697 A	0,075 B	0,141 A	0,282 B	0,337 A	0,554 A	0,589 A
IACSP02 1064	0,642 A	0,709 A	0,079 B	0,141 A	0,311 A	0,335 A	0,563 A	0,584 A
RB127825	0,721 A	0,704 A	0,100 A	0,141 A	0,391 A	0,338 B	0,624 A	0,582 A
RB005014	0,649 A	0,689 A	0,082 B	0,135 A	0,303 A	0,339 A	0,569 A	0,586 A
RB075864	0,672 A	0,716 A	0,089 B	0,144 A	0,343 A	0,334 A	0,576 A	0,585 A
RB855156	0,701 A	0,652 B	0,094 B	0,124 A	0,388 A	0,275 B	0,608 A	0,535 B
IACCTC07 2361	0,684 A	0,697 A	0,087 B	0,141 A	0,320 A	0,322 A	0,566 A	0,572 A
IACSP04 6007	0,651 A	0,687 A	0,084 B	0,136 A	0,328 A	0,327 A	0,585 A	0,574 A
CTC9006	0,665 A	0,687 A	0,080 B	0,138 A	0,317 A	0,325 A	0,576 A	0,567 A
RB975033	0,575 B	0,672 A	0,067 B	0,132 A	0,258 A	0,310 A	0,524 A	0,557 A
CT961007	0,716 A	0,686 A	0,095 B	0,140 A	0,352 A	0,320 A	0,607 A	0,556 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$)

Tabela 6. Índices espectrais da primeira coleta dos dados do sensor MicaSense. Continuação.

Cultivares	GRVI		OSAVI		SAVI		EVI	
	Boa Vista	Santana de Cima						
RB005040	0,118 A	0,181 A	0,430 B	0,530 A	0,499 B	0,615 A	0,711 A	0,700 A
CT022994	0,208 A	0,209 A	0,503 B	0,543 A	0,584 B	0,630 A	0,607 A	0,619 A
RB985476	0,129 A	0,165 A	0,433 B	0,529 A	0,502 B	0,614 A	0,732 A	0,683 A
IACCTC07 7207	0,117 A	0,187 A	0,452 B	0,541 A	0,525 B	0,628 A	0,619 A	0,721 A
IACCTC07 8008	0,168 A	0,160 A	0,485 A	0,500 A	0,563 A	0,580 A	0,671 A	0,765 A
IACCTC08 9052	0,056 B	0,184 A	0,423 B	0,544 A	0,490 B	0,631 A	0,744 A	0,718 A
IACSP02 1064	0,125 B	0,215 A	0,444 A	0,551 A	0,515 B	0,639 A	0,619 A	0,702 A
RB127825	0,178 A	0,209 A	0,504 B	0,547 A	0,584 B	0,634 A	0,580 A	0,669 A
RB005014	0,126 A	0,174 A	0,455 B	0,533 A	0,528 B	0,618 A	0,673 A	0,704 A
RB075864	0,160 A	0,226 A	0,467 B	0,558 A	0,541 B	0,647 A	0,597 A	0,655 A
RB855156	0,162 A	0,181 A	0,482 A	0,510 A	0,559 A	0,592 A	0,592 B	0,768 A
IACCTC07 2361	0,197 A	0,210 A	0,473 B	0,545 A	0,549 B	0,632 A	0,558 A	0,700 A
IACSP04 6007	0,108 B	0,186 A	0,456 B	0,534 A	0,529 B	0,619 A	0,663 A	0,678 A
CTC9006	0,144 B	0,197 A	0,455 B	0,536 A	0,528 B	0,622 A	0,629 A	0,724 A
RB975033	0,073 B	0,184 A	0,403 B	0,523 A	0,468 B	0,607 A	0,752 A	0,694 B
CT961007	0,197 A	0,210 A	0,499 A	0,535 A	0,579 A	0,621 A	0,584 A	0,656 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 6. Índices espectrais da primeira coleta dos dados do sensor MicaSense. Continuação.

Cultivares	ExG	
	Boa Vista	Santana de Cima
RB005040	0,073 A	0,101 A
CT022994	0,071 B	0,104 A
RB985476	0,073 A	0,087 A
IACCTC07 7207	0,054 B	0,101 A
IACCTC07 8008	0,073 B	0,106 A
IACCTC08 9052	0,052 B	0,097 A
IACSP02 1064	0,058 B	0,106 A
RB127825	0,059 B	0,103 A
RB005014	0,062 A	0,091 A
RB075864	0,063 B	0,108 A
RB855156	0,057 B	0,115 A
IACCTC07 2361	0,070 B	0,110 A
IACSP04 6007	0,055 B	0,099 A
CTC9006	0,061 B	0,108 A
RB975033	0,060 B	0,105 A
CT961007	0,065 B	0,113 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Ao analisar a Tabela 6, nota-se que os índices que registraram o maior número de cultivares com diferenças estatísticas significativas foram SFDVI, OSAVI, ExG e GRVI. Uma característica comum a esses índices é a inclusão, em suas fórmulas apresentadas na Tabela 5, das bandas verde e vermelha do espectro visível. Estas bandas são conhecidas por realçar a atividade fotossintética dos pigmentos de clorofila (HOFFER, 1978), indicando que, apesar da restrição hídrica, havia atividade nos cloroplastos.

Os resultados dos índices da segunda coleta de dados espectrais constam na Tabela 7. O segundo voo ocorreu em 17 de novembro de 2021. O acumulado de precipitação na área de Boa Vista, em outubro, foi de 165 mm, enquanto a média histórica para o mesmo mês é de 104 mm, indicando, assim, um excedente hídrico que contribuiu para o crescimento da cultura. Na área de Santana de Cima, a precipitação foi ainda maior, com um total de 214 mm em outubro, superando a média histórica de 124 mm. Essa quantidade de chuva promoveu o crescimento da cultura e resultou em um aumento dos índices em comparação com a coleta de dados espectrais do primeiro voo, como apresentado na Tabela 6.

Tabela 7. Índices espectrais da segunda coleta dos dados do sensor MicaSense.

Cultivares	NDVI		SFDVI		NDRE		GNDVI	
	Boa Vista	Santana de Cima						
RB005040	0,784 A	0,852 A	0,141 B	0,211 A	0,496 A	0,474 A	0,718 A	0,737 A
CT022994	0,867 A	0,842 A	0,161 A	0,217 A	0,622 A	0,492 A	0,811 A	0,739 B
RB985476	0,822 A	0,845 A	0,163 B	0,202 A	0,495 A	0,505 A	0,708 A	0,734 A
IACCTC07 7207	0,833 A	0,829 A	0,143 A	0,191 A	0,570 A	0,458 A	0,772 A	0,721 A
IACCTC07 8008	0,832 A	0,825 A	0,173 A	0,209 A	0,544 A	0,442 A	0,745 A	0,696 A
IACCTC08 9052	0,822 A	0,863 A	0,156 A	0,214 A	0,532 A	0,472 A	0,732 A	0,727 A
IACSP02 1064	0,819 A	0,850 A	0,157 A	0,200 A	0,555 A	0,480 A	0,741 A	0,725 A
RB127825	0,853 A	0,871 A	0,149 B	0,245 A	0,632 A	0,524 B	0,807 A	0,751 B
RB005014	0,814 A	0,868 A	0,144 B	0,220 A	0,547 A	0,538 A	0,764 A	0,773 A
RB075864	0,819 A	0,850 A	0,154 A	0,205 A	0,565 A	0,470 B	0,748 A	0,738 A
RB855156	0,845 A	0,842 A	0,156 B	0,206 A	0,610 A	0,460 B	0,790 A	0,727 B
IACCTC07 2361	0,834 A	0,830 A	0,156 A	0,190 A	0,538 A	0,433 B	0,753 A	0,699 A
IACSP04 6007	0,810 A	0,845 A	0,145 A	0,215 A	0,552 A	0,497 A	0,585 A	0,574 A
CTC9006	0,837 A	0,829 A	0,152 B	0,201 A	0,588 A	0,470 B	0,777 A	0,726 A
RB975033	0,781 A	0,823 A	0,131 B	0,213 A	0,512 A	0,472 A	0,728 A	0,717 A
CT961007	0,827 A	0,814 A	0,159 A	0,192 A	0,538 A	0,448 A	0,747 A	0,701 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 7. Índices espectrais da segunda coleta dos dados do sensor MicaSense. Continuação.

Cultivares	GRVI		OSAVI		SAVI		EVI	
	Boa Vista	Santana de Cima						
RB005040	0,158 A	0,321 A	0,577 A	0,681 A	0,670 A	0,790 A	0,804 B	0,986 A
CT022994	0,187 B	0,278 A	0,631 B	0,677 A	0,732 B	0,786 A	0,768 B	1,005 A
RB985476	0,272 A	0,293 A	0,618 B	0,664 A	0,717 B	0,770 A	0,809 A	0,909 A
IACCTC07 7207	0,170 B	0,274 A	0,598 A	0,651 A	0,694 A	0,755 A	0,722 B	0,924 A
IACCTC07 8008	0,230 B	0,311 A	0,627 A	0,664 A	0,728 A	0,770 A	0,822 B	0,984 A
IACCTC08 9052	0,153 A	0,314 A	0,593 A	0,676 A	0,688 A	0,784 A	0,806 B	0,970 A
IACSP02 1064	0,189 A	0,316 A	0,603 A	0,670 A	0,699 B	0,777 A	0,738 B	0,939 A
RB127825	0,146 B	0,348 A	0,610 B	0,707 A	0,708 B	0,820 A	0,711 B	1,005 A
RB005014	0,168 B	0,331 A	0,590 B	0,688 A	0,685 B	0,798 A	0,760 B	0,922 A
RB075864	0,183 B	0,301 A	0,601 B	0,676 A	0,697 B	0,784 A	0,737 B	0,982 A
RB855156	0,167 B	0,296 A	0,614 B	0,673 A	0,713 B	0,780 A	0,742 B	1,015 A
IACCTC07 2361	0,219 B	0,316 A	0,617 A	0,655 A	0,715 A	0,760 A	0,772 A	0,919 A
IACSP04 6007	0,132 B	0,302 A	0,584 A	0,676 A	0,677 A	0,784 A	0,741 B	0,948 A
CTC9006	0,170 B	0,261 A	0,609 B	0,660 A	0,706 B	0,765 A	0,764 B	1,004 A
RB975033	0,127 B	0,259 A	0,563 B	0,662 A	0,653 B	0,768 A	0,794 B	1,002 A
CT961007	0,208 A	0,276 A	0,613 A	0,645 A	0,711 A	0,749 A	0,801 B	0,953 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 7. Índices espectrais da segunda coleta dos dados do sensor MicaSense. Continuação.

Cultivares	ExG	
	Boa Vista	Santana de Cima
RB005040	0,054 B	0,102 A
CT022994	0,038 B	0,097 A
RB985476	0,080 A	0,091 A
IACCTC07 7207	0,040 B	0,092 A
IACCTC07 8008	0,064 B	0,119 A
IACCTC08 9052	0,051 A	0,105 A
IACSP02 1064	0,058 B	0,102 A
RB127825	0,031 B	0,108 A
RB005014	0,048 B	0,091 A
RB075864	0,050 B	0,097 A
RB855156	0,038 B	0,104 A
IACCTC07 2361	0,056 B	0,109 A
IACSP04 6007	0,038 B	0,095 A
CTC9006	0,042 B	0,095 A
RB975033	0,045 B	0,102 A
CT961007	0,057 B	0,101 A

As médias seguidas de mesma letra nas linhas não diferem entre si pelo teste t de Student ($p < 0,05$).

Conforme observado na Tabela 7, o índice NDVI não mostrou diferença significativa entre as cultivares ao comparar as duas áreas; isso pode ter sido devido à saturação do índice. A saturação ocorre quando há um aumento na biomassa vegetal, mas o valor do índice não acompanha proporcionalmente (MUTANGA, MASENYAMA E SIBANDA, 2023). A Tabela 6 também revela que o índice EVI apresentou médias significativamente maiores para 14 cultivares na área de Santana de Cima. Este índice foi desenvolvido para realçar os sinais da vegetação detectados pelos sensores, aumentando a sensibilidade em áreas com maior fitomassa e minimizando as influências do solo e atmosféricas (HUETE, 1988).

Uma outra vantagem do EVI é que ele leva em conta a não linearidade entre a reflectância e a cobertura vegetal, incorporando em sua fórmula a banda azul além das bandas vermelha e infravermelha próxima, ao contrário do NDVI (QIU et al., 2018). Em contextos com níveis significativos de solo exposto e interferência atmosférica, o EVI demonstra maior robustez (ABDO, 2018). Isso ocorre porque a banda azul ajuda a corrigir a dispersão atmosférica que pode afetar a qualidade dos sinais captados, principalmente em regiões com alta biomassa onde a saturação do sinal é uma preocupação. Ajustando a distorção causada pela atmosfera e refletância do solo, o EVI fornece uma medição mais precisa da vitalidade e densidade vegetativa.

Na Tabela 7, o índice SAVI registrou 9 cultivares com significância, enquanto o índice OSAVI apresentou 8 cultivares com significância maior para a área de Santana de Cima, um ambiente do tipo E. Os índices OSAVI e SAVI foram projetados para atenuar os efeitos do solo na análise da vegetação, e sua eficácia já foi avaliada em diversos estudos (PRUDNIKOVA et al., 2019; STEVEN, 1998). Esse resultado sugere que os índices espectrais que empregam fatores de correção representam uma alternativa viável para o monitoramento da cultura da cana-de-açúcar em estudos que envolvem diferentes tipos de solo.

Analisando ainda a Tabela 7, verifica-se que os índices ExG e GRDVI apresentaram, respectivamente, 14 e 11 cultivares com índices significativamente maiores para a área de Santana de Cima, caracterizada como ambiente tipo E. A elevação desses índices pode ser atribuída ao estágio de crescimento da cana-de-açúcar, que, com 149 dias na data da segunda coleta espectral, encontrava-se na fase de crescimento rápido. Esta fase, que ocorre em média de outubro até março, é quando a cana acumula cerca de 75% da massa seca nas folhas (100-250 dias) (MACHADO et al., 1982). O GRDVI é sensível ao teor de clorofila das plantas (RADOČAJ et al., 2023), enquanto o ExG também reflete a concentração de clorofila, com valores elevados indicando vegetação saudável e vigorosa, e valores mais baixos sugerindo vegetação estressada ou danificada (PATRIGNANI e OCHSNER, 2015). Portanto, a

quantidade de chuva registrada na área de Santana de Cima em outubro pode ter sido um fator contribuinte para o aumento desses índices.

O índice NDRE, apresentado na Tabela 7, registrou médias significativamente maiores para cinco cultivares na área de Boa Vista (ambiente tipo A). Esse resultado deve-se ao uso da banda de absorção do “red-edge” por esse índice, que não é sensível apenas às clorofilas presentes nas folhas, mas também avalia a saúde da vegetação e as necessidades nutricionais das plantas, principalmente em relação ao nitrogênio (Voitik et al., 2023; Cho e Skidmore, 2006). Ao analisar diferentes teores de nitrogênio em cana-de-açúcar com um sensor hiperespectral, Martins (2016) identificou que a região do “red-edge” é fortemente influenciada pelos teores de nitrogênio.

O solo da área de Boa Vista (ambiente tipo A) possui melhores condições químicas e físicas do que o solo de Santana de Cima (ambiente tipo E), o que justifica os maiores índices de NDRE nesta área. As cultivares RB127825 e RB075864, que são recomendadas para ambientes do tipo A (RIDESA, 2023), apresentaram os maiores índices de NDRE em Boa Vista, indicando que estavam em um ambiente propício para seu crescimento. As cultivares RB855156 e IACCTC072361, recomendadas para solo tipo BCD, e a CTC9006, para solo tipo CD (IAC, 2021; CTC, 2023), também exibiram maiores índices de NDRE em Boa Vista do que em Santana de Cima (ambiente tipo E), demonstrando eficiência na assimilação de nutrientes no solo dessa área.

Os resultados referentes à terceira coleta espectral estão na Tabela 8; o voo ocorreu em 10 de fevereiro de 2022, quando a cana estava com 295 dias após o plantio, fase considerada de crescimento lento (MACHADO et al., 1982). O acumulado de precipitação para o mês de janeiro na área de Boa Vista foi de 339 mm, com a média histórica sendo de 243 mm. Na área de Santana de Cima, a precipitação foi de 295 mm, com a média histórica de 232 mm, resultando, portanto, em um excedente hídrico.

Para a área de Boa Vista, os índices espectrais de NDVI, SFDVI, NDRE, GNDVI, GRVI, OSAVI e SAVI, registrados durante o terceiro voo e apresentados na Tabela 8, tiveram um aumento nos valores ao comparar com os mesmos índices no segundo voo (Tabela 7). A quantidade suficiente de água, aliada ao fato de a área de Boa Vista estar situada em um Latossolo, que é caracterizado por ser profundo, poroso e bem drenado (SANTOS, 2018), e possuir a maior quantidade de nutrientes (Tabela 2), propiciou diferenças estatísticas maiores nos índices para esta área.

Cultivares	NDVI		SFDVI		NDRE		GNDVI	
	Boa Vista	Santana de Cima						
RB005040	0,870 A	0,865 A	0,171 A	0,146 B	0,539 A	0,529 A	0,737 A	0,756 A
CT022994	0,949 A	0,846 B	0,204 A	0,142 B	0,667 A	0,477 B	0,838 A	0,721 A
RB985476	0,935 A	0,862 B	0,191 A	0,150 B	0,628 A	0,504 B	0,808 A	0,736 B
IACCTC07 7207	0,941 A	0,868 B	0,200 A	0,150 B	0,641 A	0,524 A	0,817 A	0,739 A
IACCTC07 8008	0,918 A	0,830 B	0,215 A	0,138 B	0,588 A	0,448 B	0,777 A	0,691 B
IACCTC08 9052	0,929 A	0,854 B	0,212 A	0,145 B	0,651 A	0,473 B	0,817 A	0,715 B
IACSP02 1064	0,906 A	0,901 A	0,196 A	0,156 B	0,600 A	0,567 A	0,780 A	0,771 A
RB127825	0,938 A	0,870 B	0,192 A	0,156 A	0,655 A	0,511 A	0,838 A	0,738 B
RB005014	0,944 A	0,871 B	0,193 A	0,150 B	0,627 A	0,517 B	0,812 A	0,746 B
RB075864	0,888 A	0,844 B	0,198 A	0,148 B	0,587 A	0,441 B	0,748 A	0,690 A
RB855156	0,943 A	0,866 B	0,187 A	0,150 B	0,672 A	0,486 B	0,834 A	0,721 B
IACCTC07 2361	0,929 A	0,866 B	0,207 A	0,151 B	0,608 A	0,499 B	0,797 A	0,726 B
IACSP04 6007	0,942 A	0,874 B	0,204 A	0,151 A	0,656 A	0,522 B	0,837 A	0,745 B
CTC9006	0,940 A	0,864 B	0,201 A	0,146 B	0,638 A	0,503 B	0,817 A	0,728 B
RB975033	0,929 A	0,866 B	0,194 A	0,156 A	0,620 A	0,536 B	0,803 A	0,748 B
CT961007	0,931 A	0,863 B	0,195 A	0,152 B	0,609 A	0,522 A	0,805 A	0,732 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 8. Índices espectrais da terceira coleta dos dados do sensor MicaSense. Continuação

Cultivares	GRVI		OSAVI		SAVI		EVI	
	Boa Vista	Santana de Cima						
RB005040	0,418 A	0,366 A	0,654 A	0,631 A	0,759 A	0,731 A	0,553 A	0,622 A
CT022994	0,539 A	0,333 B	0,713 A	0,615 B	0,827 A	0,713 B	0,678 A	0,662 A
RB985476	0,519 A	0,351 A	0,697 A	0,628 B	0,808 A	0,728 B	0,638 A	0,641 A
IACCTC07 7207	0,539 A	0,355 B	0,706 A	0,626 A	0,819 A	0,726 B	0,623 A	0,601 A
IACCTC07 8008	0,492 A	0,327 B	0,710 A	0,602 B	0,823 A	0,699 B	0,679 A	0,630 A
IACCTC08 9052	0,465 A	0,362 B	0,709 A	0,621 B	0,822 A	0,721 A	0,652 A	0,632 A
IACSP02 1064	0,435 A	0,426 A	0,685 A	0,648 A	0,795 A	0,752 B	0,608 A	0,613 A
RB127825	0,469 A	0,366 B	0,698 A	0,637 B	0,810 A	0,739 B	0,675 A	0,678 A
RB005014	0,566 A	0,356 B	0,696 A	0,623 A	0,808 A	0,723 B	0,647 A	0,666 A
RB075864	0,420 A	0,367 A	0,675 A	0,621 A	0,783 A	0,720 A	0,577 B	0,680 A
RB855156	0,511 A	0,386 B	0,693 A	0,632 B	0,804 A	0,733 B	0,611 A	0,653 A
IACCTC07 2361	0,510 A	0,377 B	0,709 A	0,631 B	0,822 A	0,732 B	0,658 A	0,618 A
IACSP04 6007	0,498 A	0,371 B	0,711 A	0,630 B	0,825 A	0,730 B	0,683 A	0,605 A
CTC9006	0,538 A	0,364 B	0,707 A	0,623 B	0,820 A	0,722 B	0,682 A	0,653 A
RB975033	0,499 A	0,336 B	0,696 A	0,633 B	0,807 A	0,734 B	0,654 A	0,643 A
CT961007	0,504 A	0,361 B	0,700 A	0,627 B	0,812 A	0,727 B	0,642 A	0,615 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 8. Índices espectrais da terceira coleta dos dados do sensor MicaSense. Continuação.

Cultivares	ExG	
	Boa Vista	Santana de Cima
RB005040	0,074 A	0,062 A
CT022994	0,055 A	0,071 A
RB985476	0,063 A	0,068 A
IACCTC07 7207	0,061 A	0,066 A
IACCTC07 8008	0,009 A	0,006 A
IACCTC08 9052	0,059 B	0,076 A
IACSP02 1064	0,068 A	0,062 A
RB127825	0,045 B	0,072 A
RB005014	0,065 A	0,067 A
RB075864	0,078 A	0,090 A
RB855156	0,049 A	0,078 A
IACCTC07 2361	0,072 A	0,073 A
IACSP04 6007	0,054 A	0,066 A
CTC9006	0,064 A	0,072 A
RB975033	0,065 A	0,064 A
CT961007	0,065 A	0,069 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

4.3 Parâmetros biométricos em cada ambiente

Para cada parâmetro biométrico, conduziu-se uma análise comparativa individual entre as duas áreas de estudo, Boa Vista e Santana de Cima. Utilizou-se o teste t de Student para determinar se as diferenças observadas nos valores dos índices entre as cultivares nas duas localidades distintas eram estatisticamente significativas. Os resultados foram representados com letras maiúsculas para denotar as diferenças estatísticas entre os grupos. A significância foi estabelecida em um nível de $p < 0,05$.

Os resultados da primeira coleta de dados biométricos estão na Tabela 9. O número de colmos apresentou a maior média significativa para cinco cultivares na área de Santana de Cima (ambiente tipo E). Essa maior média no número de colmos para a área de Santana de Cima está associada ao fato de essa área ter recebido maior quantidade de precipitação antes da coleta desses dados biométricos, conforme mostrado na Figura 4.

Na Tabela 9, a cultivar RB075864 apresentou maior número de colmos na área de Santana de Cima, mas maior altura na área de Boa Vista (ambiente tipo A). Isso pode ter ocorrido porque essa cana é melhor adaptada a ambientes do tipo ABC (RIDESA, 2023). O solo de Boa Vista, de melhor fertilidade e com maior teor de argila, segundo Rosseto et al. (2014), fornece um ambiente mais favorável do que os solos álicos. O maior alongamento do colmo está relacionado com a maior quantidade de água e nutrientes disponíveis, uma vez que um ambiente com bom regime hídrico e nutricional mais favorável pode resultar em colmos mais robustos, alongados, que acumularão mais fotoassimilados (ROBERTSON et al., 1999; RAO et al., 2005; GONÇALVES, 2008).

Tabela 9. Médias para a primeira coleta de dados biométricos.

Cultivares	Número de colmos		Altura da planta (cm)		Comprimento da folha (cm)		Largura da folha (cm)	
	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima
RB005040	8,70 B	10,60 A	42,23 A	39,97 A	112,67 A	101,50 A	3,68 A	2,89 B
CT022994	9,77 A	11,97 A	57,43 A	56,83 A	127,00 A	114,00 A	3,42 A	3,25 A
RB985476	9,77 A	12,70 A	43,43 A	39,77 A	122,40 A	103,93 A	3,71 A	3,34 A
IACCTC07 7207	11,80 A	17,00 A	45,87 B	56,47 A	115,07 A	105,87 A	2,57 A	2,21 B
IACCTC07 8008	14,23 A	15,50 A	41,37 A	43,93 A	111,30 A	104,40 A	2,85 A	2,53 A
IACCTC08 9052	10,77 A	11,47 A	51,30 A	61,70 A	121,57 A	106,17 A	3,70 A	3,35 A
IACSP02 1064	9,50 A	12,67 A	68,70 A	61,53 A	130,83 A	116,63 A	3,09 A	3,11 A
RB127825	10,00 A	11,20 A	62,43 A	49,43 A	130,40 A	115,93 B	3,80 A	3,34 A
RB005014	11,30 A	15,77 A	40,43 A	44,03 A	110,33 A	111,63 A	2,67 A	2,76 A
RB075864	8,87 B	11,10 A	71,57 A	52,93 B	134,97 A	106,70 B	3,70 A	3,22 A
RB855156	9,10 A	8,20 A	67,43 A	63,23 A	129,43 A	112,23 A	2,95 A	2,90 A
IACCTC07 2361	11,10 A	13,97 A	57,70 A	52,57 A	131,90 A	113,63 B	3,20 A	2,87 A
IACSP04 6007	9,50 A	11,60 A	61,93 A	65,83 A	128,20 A	113,50 A	3,18 A	2,80 A
CTC9006	10,20 B	14,53 A	60,15 A	65,30 A	118,33 A	107,73 A	3,03 A	3,44 A
RB975033	8,10 B	12,67 A	42,03 A	51,03 A	127,33 A	116,40 B	2,94 A	2,63 B
CT961007	9,00 B	12,33 A	56,03 A	56,77 A	124,83 A	117,37 A	3,65 A	3,42 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 9. Médias para a primeira coleta de dados biométricos. Continuação.

Cultivares	Folhas por colmo		Ângulo da folha	
	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima
RB005040	7,57 A	7,30 A	15,73 B	28,03 A
CT022994	7,80 A	7,90 A	18,30 B	26,87 A
RB985476	7,87 B	8,57 A	17,60 B	29,80 A
IACCTC07 7207	7,17 A	6,53 B	18,00 A	25,70 A
IACCTC07 8008	7,37 A	7,17 A	21,23 B	29,67 A
IACCTC08 9052	8,03 A	7,96 A	20,53 A	31,97 B
IACSP02 1064	8,77 A	8,33 A	14,20 B	21,93 A
RB127825	8,03 A	7,60 A	14,40 A	33,13 A
RB005014	8,23 A	7,06 A	20,57 A	22,70 A
RB075864	9,20 A	8,10 A	13,60 B	25,80 A
RB855156	9,10 A	8,20 A	14,60 A	18,80 A
IACCTC07 2361	7,87 A	7,30 A	20,73 A	28,13 A
IACSP04 6007	7,97 A	7,83 A	15,00 A	25,37 A
CTC9006	8,80 A	7,90 A	16,83 B	21,70 A
RB975033	7,83 A	7,57 A	14,53 B	23,23 A
CT961007	8,30 A	7,57 A	15,47 A	23,73 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Os resultados das médias para a segunda coleta de dados biométricos estão na Tabela 10. Os parâmetros de largura da folha e comprimento da folha registraram, respectivamente, 8 e 2 cultivares com maiores médias significativas para Boa Vista (ambiente tipo A). Já o parâmetro número de folhas apresentou 10 cultivares com maior número de folhas para Boa Vista.

A quantidade de perfilhos diminuiu na área de Santana de Cima em comparação com a primeira coleta de dados biométricos, conforme indicado na Tabela 10. Isso ocorre porque, à medida que o dossel da cultivar se fecha, a luminosidade diminui; conseqüentemente, há acúmulo de auxina na base da planta, o que promove o alongamento do colmo e impede o desenvolvimento de novas gemas laterais, propiciando assim uma dominância apical (Casagrande, 1991).

Como pode-se observar na Tabela 11, as cultivares da área de Boa Vista (ambiente tipo A) apresentaram maiores diâmetros de colmo, com seis cultivares sendo estatisticamente maiores. Na data de colheita desses segundos dados biométricos, a cana-de-açúcar estava com 295 dias após o plantio. Segundo Machado et al. (1982), a cana está nessa fase em crescimento lento, período em que começa um lento acúmulo de sacarose nos colmos, que precede a fase de maturação com intensa acumulação de sacarose.

Os resultados de altura, apresentados na Tabela 9, mostram que oito cultivares na área de Boa Vista tiveram médias estatisticamente maiores. Isso ocorre porque solos com maiores teores de argila e nutrientes propiciam um melhor crescimento da cana-de-açúcar (LANDELL et al., 2003).

Tabela 10. Médias para a segunda coleta de dados biométricos.

Cultivares	N° Colmos		Diâmetro do colmo (cm)		Altura do colmo (cm)		Comprimento da folha (cm)	
	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima
RB005040	8,57 A	7,57 A	3,17 A	2,58 A	207,30 A	156,00 A	165,43 A	151,50 A
CT022994	8,93 A	8,53 A	2,90 A	2,50 B	231,37 A	196,80 B	151,90 A	164,57 A
RB985476	9,83 A	8,90 A	2,88 A	2,18 A	215,93 A	171,57 B	158,97 A	151,70 B
IACCTC07 7207	11,60 A	12,50 A	2,77 A	2,40 A	200,27 A	188,70 A	180,10 A	168,70 A
IACCTC07 8008	12,23 A	10,93 A	2,95 A	2,52 B	210,70 A	166,00 B	145,93 A	138,73 A
IACCTC08 9052	10,20 A	8,87 A	2,95 A	2,60 A	242,87 A	225,40 A	158,33 A	155,43 A
IACSP02 1064	11,70 A	11,07 A	2,92 A	2,50 A	245,67 A	220,40 A	170,30 A	162,63 A
RB127825	9,97 A	7,83 B	2,83 A	2,52 B	217,57 A	187,63 A	151,00 A	162,00 A
RB005014	11,40 A	9,00 A	2,77 A	2,45 A	238,63 A	185,00 B	172,27 A	159,43 B
RB075864	8,23 A	8,93 A	2,90 A	2,52 A	252,80 A	188,03 B	166,10 A	150,07 A
RB855156	9,50 A	10,97 A	2,77 A	2,21 B	250,47 A	201,57 B	156,07 A	161,20 A
IACCTC07 2361	8,83 A	10,47 A	3,63 A	3,10 A	229,03 A	182,30 B	170,37 A	163,97 A
IACSP04 6007	10,07 A	9,23 A	2,97 A	2,50 B	215,27 A	220,90 A	152,57 A	159,87 A
CTC9006	9,77 A	11,03 A	3,15 A	2,93 A	223,70 A	202,53 A	148,47 A	150,43 A
RB975033	8,17 A	8,07 A	2,91 A	2,52 B	223,10 A	194,37 B	167,10 A	172,43 A
CT961007	9,57 A	9,13 A	3,18 A	2,90 A	238,13 A	198,57 A	157,27 A	159,20 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Tabela 10. Médias para a segunda coleta de dados biométricos. Continuação.

Cultivares	Largura da folha (cm)		Folhas por colmo		Ângulo	
	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima	Boa Vista	Santana de Cima
RB005040	4,87 A	4,20 A	6,87 A	5,83 A	22,63 A	21,33 A
CT022994	5,57 A	4,98 A	8,07 A	6,50 B	30,03 A	30,27 A
RB985476	4,93 A	4,37 B	7,20 A	6,57 A	25,93 B	31,87 A
IACCTC07 7207	4,03 A	3,23 B	7,37 A	5,93 A	19,97 B	29,17 A
IACCTC07 8008	3,97 A	3,85 A	7,27 A	5,93 B	29,33 A	35,97 A
IACCTC08 9052	5,63 A	5,28 A	8,27 A	6,83 A	33,90 A	37,07 A
IACSP02 1064	4,33 A	3,93 A	7,33 A	5,90 B	30,47 A	35,33 A
RB127825	5,37 A	5,00 A	6,97 A	5,90 B	35,90 A	33,30 A
RB005014	4,17 A	3,75 A	7,53 A	5,70 B	22,47 A	29,53 A
RB075864	5,18 A	4,28 B	8,10 A	6,43 B	35,77 A	32,67 A
RB855156	4,83 A	4,05 A	8,33 A	6,37 B	32,50 A	32,30 A
IACCTC07 2361	5,48 A	4,67 B	8,30 A	6,13 B	26,37 A	33,30 A
IACSP04 6007	4,83 A	4,23 B	8,43 A	6,73 A	26,97 A	28,47 A
CTC9006	3,03 A	3,47 A	6,80 A	5,87 A	33,83 A	31,07 A
RB975033	4,90 A	4,57 A	7,40 A	5,67 B	30,93 B	35,27 A
CT961007	6,00 A	5,05 B	8,13 A	6,00 B	32,70 A	37,50 A

As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

4.4 Fechamento do dossel em cada ambiente

Os resultados para o fechamento do dossel da primeira coleta de dados espectrais estão na Figura 4, que ocorreu em 6 de setembro de 2021. De maneira geral, as médias de fechamento do dossel foram melhores na área de Boa Vista (ambiente tipo A), devido às melhores condições de precipitação nesta área durante os meses de julho e agosto, conforme mostrado na Figura 3.

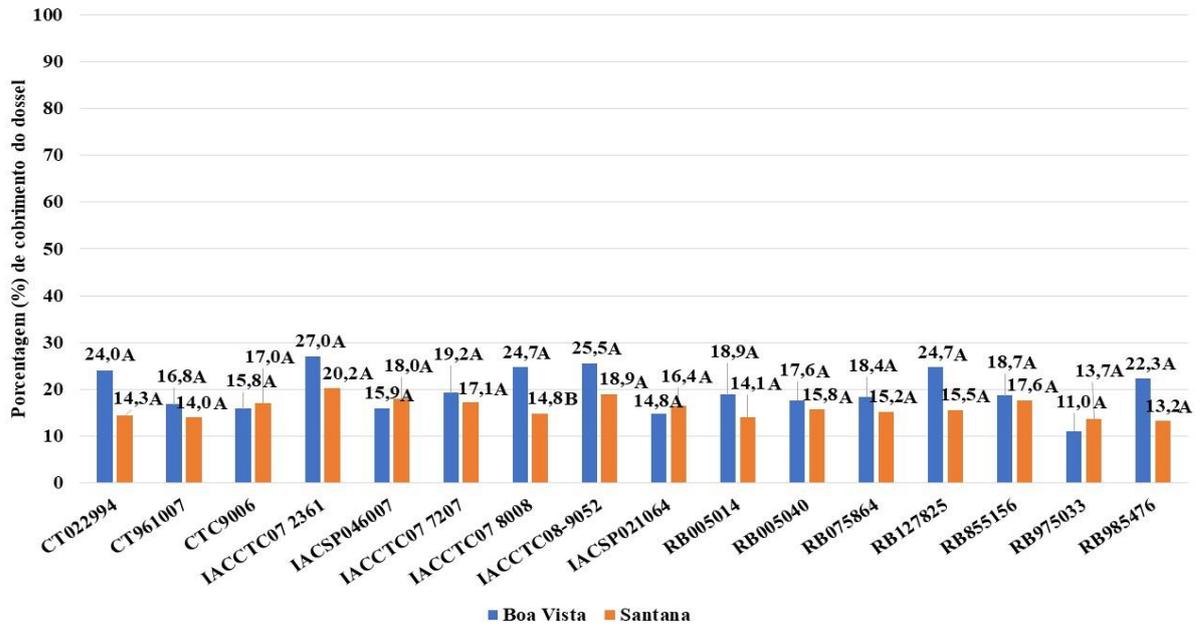


Figura 4. Resultados do cobrimento do dossel pelas cultivares na primeira coleta de dados espectrais. As barras representam a quantidade em porcentagem de área coberta por folhas verdes. As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Na Figura 4, a cultivar IACCTC 8008 foi a única que teve média significativamente maior para a área de Boa Vista. Esta é indicada para ambientes ABC (IAC, 2021), mostrando que ela foi mais adaptada ao cobrimento do dossel nas condições de solo com maiores quantidades de nutrientes.

Os resultados da quantidade de cobrimento do dossel para o segundo voo estão na Figura 5. Os dados foram obtidos quando a cana-de-açúcar estava com 149 dias. Das 16 cultivares, 5 apresentaram média com significância maior para a área de Boa Vista. Destas 5 cultivares, a RB985476, IACCTC07 8008 e IACCTC07 7207 são indicadas para locais tipo ABC (IAC, 2021; CTC, 2023; RIDESA, 2023), mostrando que estas estavam bem adaptadas no local que tinha mais nutrientes.

Na Figura 5, as cultivares IACCTC07 2361, indicada para locais BCD, e a cultivar CTC96 1007, indicada para os ambientes DE também (IAC, 2021; CTC, 2023), tiveram melhor índice de fechamento com média significativa em Boa Vista, mostrando que essas cultivares desenvolveram melhor o dossel na área de melhor fertilidade do solo.

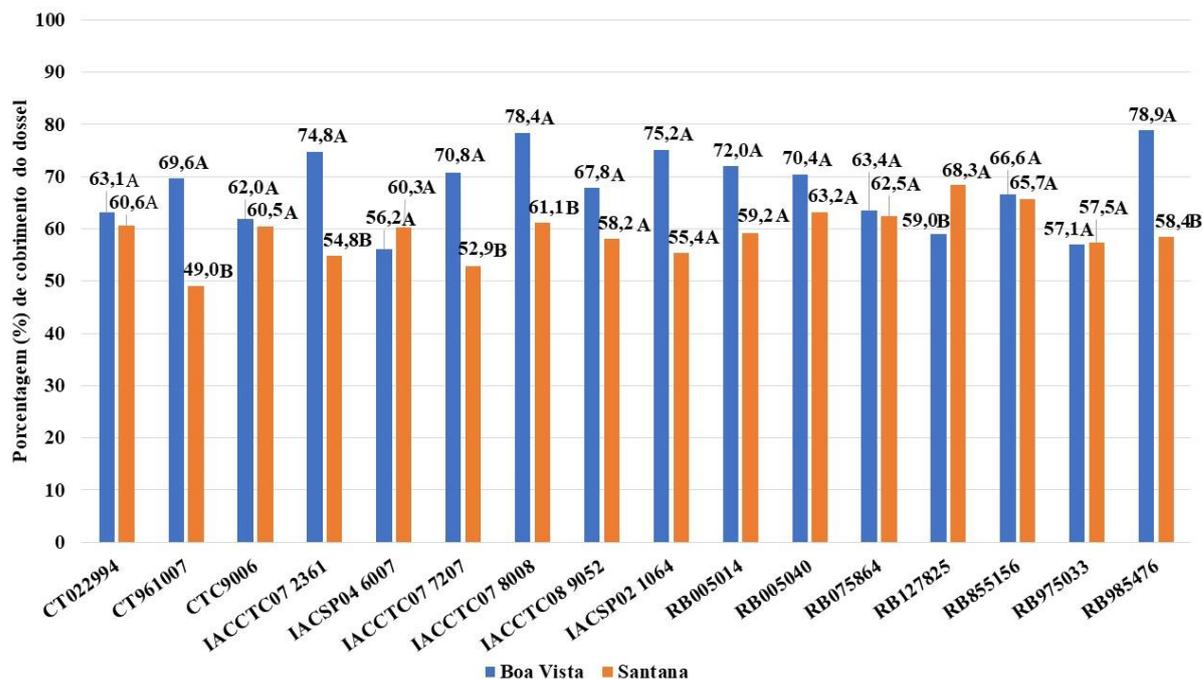


Figura 5. Resultados do fechamento do dossel pelas cultivares na segunda coleta de dados espectrais. As barras representam a quantidade em porcentagem de área coberta por folhas verdes. As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

A cultivar RB127825, indicada para regiões com ambientes tipos ABC (RIDESA, 2023), teve melhor fechamento de dossel na área de Santana de Cima (ambiente tipo E) no segundo voo, ao observar a Figura 5. Isso mostra que quando esta cultivar está no estágio de desenvolvimento vegetativo acelerado, de 100 a 250 dias, onde há intenso acúmulo de matéria verde nas folhas (MACHADO et al., 1982), necessita de solo com constante demanda hídrica, uma vez que esta área teve maior incidência de precipitação em outubro (Figura 2).

Ao reparar na Figura 5, notamos que a cultivar IACCTC07 7207, indicada para os ambientes ABC (IAC, 2021), teve o menor resultado de fechamento do dossel na área de Santana de Cima (ambiente tipo E) no segundo voo, com 49% do dossel fechado, em comparação com todas as demais. Ao observar a primeira coleta de dados biométricos (Tabela 9), observamos que a mesma cultivar teve menor número médio de folhas para a mesma área e menor largura de folha. Isso comprova que o desenvolvimento da copa da cana-de-açúcar depende do aparecimento das folhas, da extensão foliar e do tamanho de cada folha (MACHADO, 1981).

Os resultados de fechamento do dossel para a terceira coleta de dados espectrais estão na Figura 6. Como pode-se observar, as cultivares, de uma maneira geral, tiveram um aumento na cobertura do dossel ao se comparar com a segunda coleta de dados espectrais (Figura 5), tanto para a área de Santana de Cima (ambiente tipo E) quanto para a área de Boa Vista

(ambiente tipo A). Apenas as cultivares CTC961007 e IACCC07 8008 tiveram média maior com significância para a área de Boa Vista, com 77,7% e 86,5%, respectivamente. Estas cultivares também tiveram média maior de cobertura do dossel na área de Boa Vista na segunda coleta de dados espectrais. Nota-se que estas cultivares fecham bem o dossel em ambiente tipo A.

Na Figura 6, as cultivares IACCTC2361, IACCTC077207, IACCTC08 9052 e IACSP02 1064 estavam com uma alta taxa de recobrimento do dossel em relação às demais, superior a 80%, para a área de Boa Vista (ambiente tipo A).

Ao se observar a Figura 6, nota-se que a cultivar RB005040 teve índice de fechamento do dossel de 69% resultado inferior ao se comparar a taxa de recobrimento da segunda coleta de dados espectrais (Figura 5) que foi de 70%, a cultivar RB985476 também apresentou uma redução que neste caso foi de 3% com relação a segunda coleta de dados espectrais. Essa redução ocorre devido a tombamentos recorrentes do canal que são ocasionados por diversos fatores como: características varietais, ocorrências ambientais, deficiências nos colmos ou raízes, como também simplesmente pela elevada massa do colmo (CARLIN; SILVA; ROSSETTO, 2008).

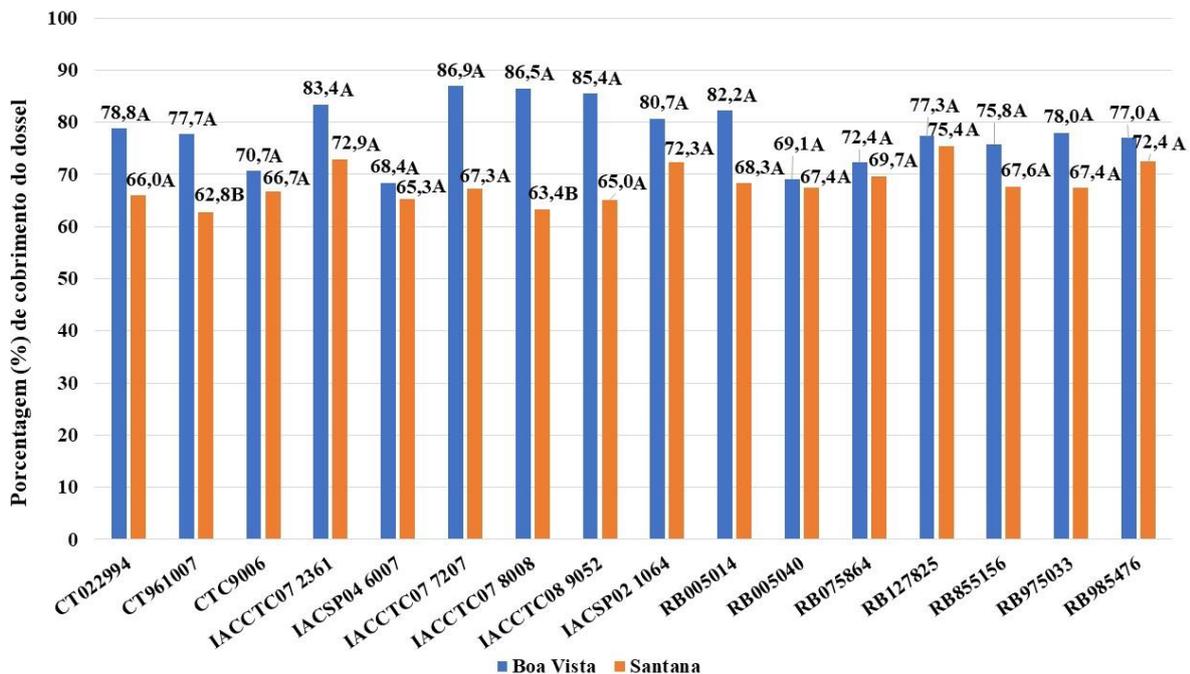


Figura 6. Resultados do cobrimento do dossel pelas cultivares na segunda coleta de dados espectrais. As barras representam a quantidade em porcentagem de área coberta por folhas verdes. As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

4.5 Produtividade das cultivares em cada ambiente

Os resultados de produtividade em toneladas de cana por hectare podem ser visualizados na Figura 7. As colheitas dos ensaios ocorreram em maio de 2022 (Figura 3). Como se pode visualizar, a área de Boa Vista (ambiente tipo A) teve a maior quantidade de TCH, com significância para todas as cultivares. Isso ocorre devido ao fato de o ambiente A possuir um solo de melhor estrutura física e química. O solo é um fator de produção importante, pois proporciona às plantas suporte físico, hídrico e de nutrientes (MAULE; MAZZA; MARTHA JR., 2001). Com isso, ter o conhecimento das características inerentes de cada solo é essencial para se saber qual é o potencial de produção agrícola que se planeja atingir (LEPSCH, 1987).

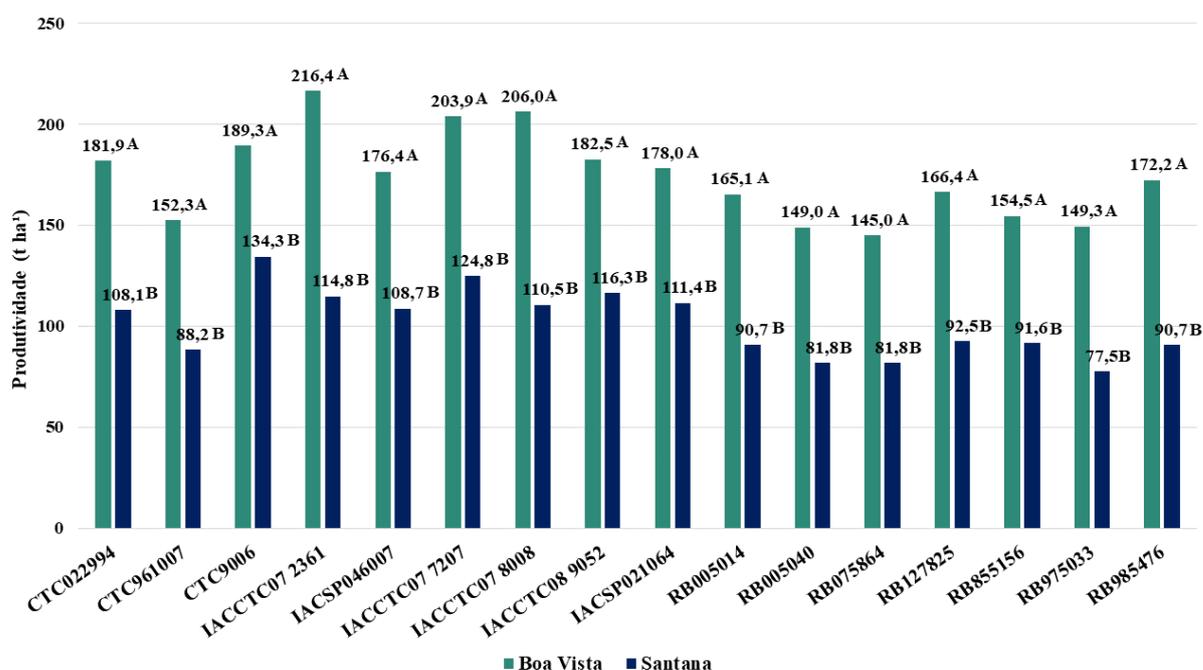


Figura 7. Resultados de toneladas de cana-de-açúcar por hectare. Para as áreas experimentais de Boa Vista e Santana de Cima. As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Na Figura 8 estão os dados de produtividade da cana-de-açúcar por hectare com os respectivos ambientes produtivos indicados para as cultivares utilizadas neste estudo (Tabela 2). As cultivares que mais produziram, em ordem crescente, na área de Boa Vista (Ambiente tipo A), foram: a IACCTC07 2361, indicada para ambiente BCD (CTC, 2023), que produziu 216 (t ha¹); a IACCTC07 8008, indicada para ambiente ABC (IAC, 2021), que produziu 216 (t ha¹); a IACCTC07 7207, indicada para ambiente ABC (IAC, 2021), que produziu 203 (t ha¹); e a CTC9006, indicada para ambiente CD (CTC, 2023), que produziu 189 (t ha¹).

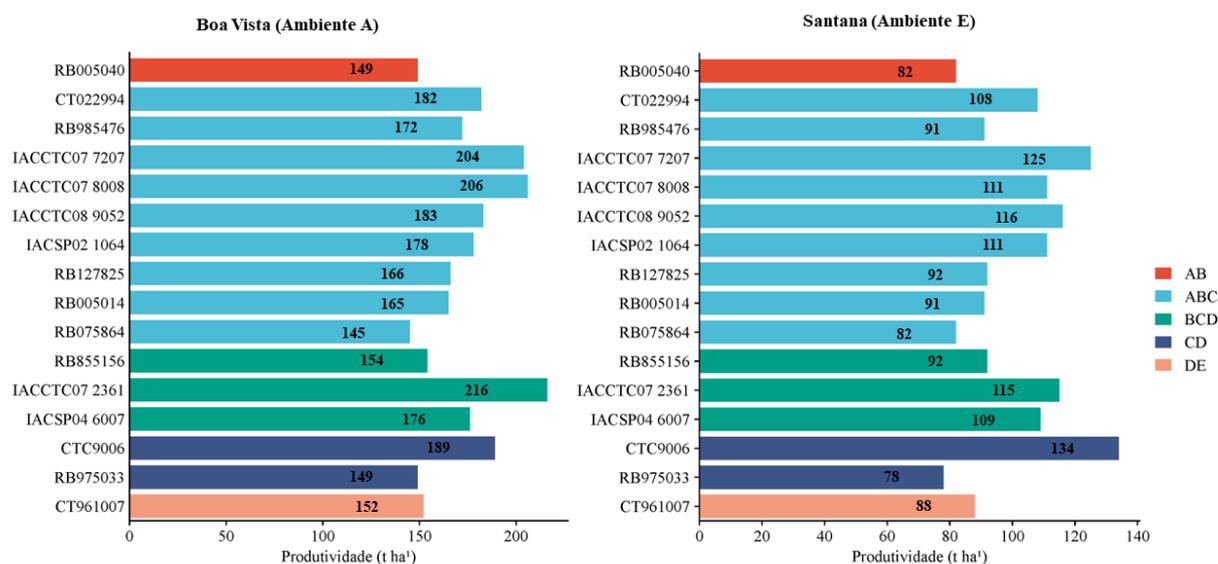


Figura 4. Resultados de toneladas de cana-de-açúcar por hectare com as cultivares indicadas para cada ambiente. Para as áreas experimentais de Boa Vista e Santana de Cima.

Ao observar os resultados de fechamento do dossel na terceira coleta de dados espectrais (Figura 6) e compará-los com os dados de produtividade da área de Boa Vista na Figura 8, nota-se que as cultivares que produziram maiores toneladas de cana por hectare tiveram altos índices de fechamento para a mesma área, superior a 80% do dossel, com 295 dias. Isso demonstra que este parâmetro pode ser útil para monitorar a produtividade das culturas (SHEPHERD; LINDSEY; LINDSEY, 2018).

Isso ocorre devido ao fato de que um bom fechamento de dossel permite que a fotossíntese da copa seja máxima para interceptar a maioria da luz incidente e, deste modo, absorver a radiação fotossintética necessária nos processos fotobioquímicos e, posteriormente, haver o acúmulo de biomassa produzida (WELLS, 1991).

Ao observar a Figura 8, notamos que a cultivar CTC9006, indicada para os ambientes CD (CTC, 2023), foi uma das que melhor produziu no ambiente de Boa Vista (ambiente tipo A) e foi a que mais produziu no ambiente de Santana de Cima (ambiente tipo E).

4.6 ATR das cultivares em cada ambiente

Os resultados de ATR (Açúcares Totais Recuperáveis) para os dois ambientes estão na Figura 9. De uma maneira geral, a área de Santana de Cima obteve melhores resultados de ATR do que a área de Boa Vista. Ocorre que o ATR pode variar dependendo de alguns fatores como o estágio de maturação, as cultivares utilizadas, condições climáticas e de solos (PARAZZI et al., 2018).

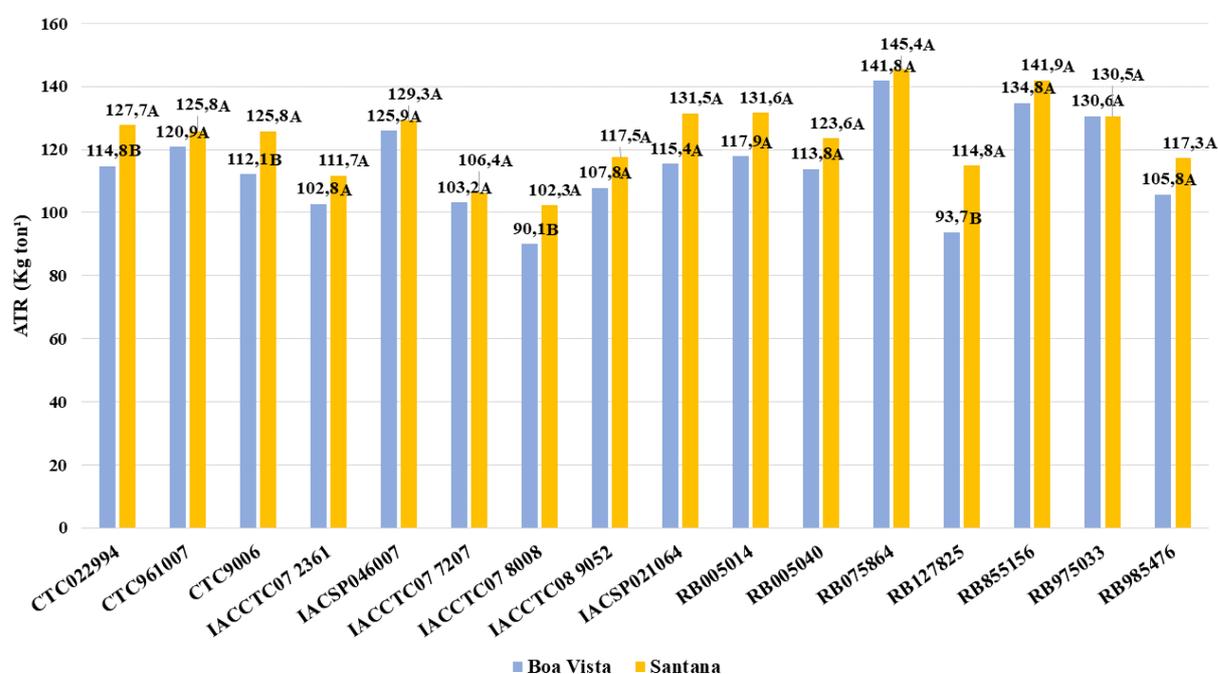


Figura 9. Resultados de Açúcares Totais Recuperáveis (ATR) em kg de açúcar por toneladas de cana por hectare. Para as áreas experimentais de Boa Vista e Santana de Cima. As médias seguidas de mesma letra não diferem entre si pelo teste T de Student ($p < 0,05$).

Considerando os dados da Conab (2022), a média de ATR para o estado de São Paulo na safra de 2021/2022 foi de 134,2 kg por tonelada de cana-de-açúcar. Deste modo, apenas as cultivares RB075864 e RB855156 estavam acima da média nacional. Segundo o mesmo boletim, a queda no ATR foi em função das chuvas durante a colheita, que, embora resultem em um aumento da produtividade, podem não resultar em um aumento das qualidades tecnológicas.

5. CONCLUSÃO

Os levantamentos realizados pela câmera espectral através do drone em conjunto com as técnicas de sensoriamento remoto são capazes de monitorar o crescimento de cultivares de cana-de-açúcar em áreas experimentais. Por meio da utilização dos índices espectrais e do índice de fechamento do dossel é possível identificar diferenças nos comportamentos fisiológicos de crescimento das cultivares em ambientes produtivos diferentes.

Nas diferentes datas de aquisição de dados espectrais alguns índices são mais eficazes do que outros em detectar diferenças nas características das cultivares. Isso demonstra que na escolha do índice espectral a ser utilizado no monitoramento deve-se levar em consideração o estágio de crescimento da cultura de cana-de-açúcar.

Os diferentes ambientes alteram a produtividade da cana-de-açúcar. O ambiente que produziu mais foi o ambiente A. As seis cultivares que mais produziram no ambiente tipo A foram, em ordem crescente, a IACCTC07 2361, IACCTC07 8008, IACCTC 7207, CTC9006, IACCTC08 9052 e CTC22994 estas cultivares também foram as seis que mais produziram no ambiente tipo E apenas com alterações entre na ordem crescente de produtividade.

Os dados de ATR apresentaram pouca diferença entre os ambientes, sendo o ambiente que teve resultados maiores o ambiente tipo E.

Como recomendação para trabalhos futuros, é aconselhável aprofundar a análise dos dados por meio da aplicação de métodos estatísticos avançados. Essa abordagem permitirá uma avaliação mais precisa das adaptações das cultivares em diversos ambientes, facilitando a identificação daquelas que melhor performam em condições específicas. Além disso, recomenda-se a integração de dados provenientes de sensores orbitais. Apesar de apresentarem uma resolução espectral inferior, esses sensores oferecem vantagens como a rápida coleta de dados abrangentes, o que pode enriquecer as análises e proporcionar resultados mais robustos e consistentes.

REFERÊNCIAS

- ABDO, H. G. Impacts of war in Syria on vegetation dynamics and erosion risks in Safita area, Tartous, Syria. **Regional Environmental Change**, v. 18, n. 6, p. 1707–1719, 17 ago. 2018.
- AHIRWAR, S.; SWARNKAR, R.; BHUKYA, S.; NAMWADE, G. Application of Drone in Agriculture. **International Journal of Current Microbiology and Applied Sciences**, v. 8, n. 01, p. 2500–2505, 20 jan. 2019.
- AMARAL, L. R. Aplicações de drones na agricultura. *In*: DE QUEIROZ, D. M.; VALENTE, D. S. M.; PINTO, F. D. A. D. C.; BORÉM, A. **Agricultura digital**. Oficina de Textos, 2021. p. 80–88.
- ARTSCHWAGER, E. Morphology of the vegetative organs of sugarcane. **Journal of Agricultural Research**, Washington, 60(8): 503-49, 1940.
- ASHAPURE, A.; JUNG, J.; CHANG, A.; OH, S.; YEOM, J.; MAEDA, M.; MAEDA, A.; DUBE, N.; LANDIVAR, J.; HAGUE, S.; SMITH, W. Developing a machine learning based cotton yield estimation framework using multi-temporal UAS data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 169, p. 180–194, nov. 2020.
- AYDOĞAN, Y. DRONE TECHNOLOGY IN AGRICULTURAL MECHANIZATION. **Mechanization in Agriculture & Coserving of resources**, v. 64, n. 2, p. 36–39, 2018.
- BAPTISTA, G. M. DE M. “Aplicação do Índice de Vegetação por Profundidade de Feição Espectral (SFDVI - Spectral Feature Depth Vegetation Index) em dados RapidEye,” **Anais. XVII Simpósio Bras. Sensoriamento Remoto - SBSR**, João Pessoa-PB, Bras. 25 a 29 abril 2015, INPE, pp. 2277–2284, 2015.
- BARUPAL, D. K.; FIEHN, O. Generating the Blood Exposome Database Using a Comprehensive Text Mining and Database Fusion Approach. **Environmental Health Perspectives**, v. 127, n. 9, set. 2019.
- BENDIG, J.; BOLTEN, A.; BARETH, G. UAV-BASED Imageing for Multi-Temporal, very high Resolution Crop Surface Models to monitor Crop Growth Variability. **Photogrammtrie - Fernerkundung - Geoinformation**, v. p. 551–562, 2013.
- BREIMAN, Leo. Random forests. **Machine learning**, v. 45, p. 5-32, 2001.
- BORÉM, A.; ET AL. Nova Revolução Verde. *In*: QUEIROZ, D. M.; VALENTE, D. S. M.; PINTO, F. DE A. DE C.; BORÉM, A. **Agricultura digital**. 2. ed. São Paulo: Oficina de Textos, 2021. p. 11–19.
- BOSSO, R. M. V. **Investigação de biomarcadores de suscetibilidade e de exposição ambiental em indivíduos ocupacionalmente expostos à queima de canaviais**. 2002. Tese (Doutorado) 2002 - Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista (UNESP), São José do Rio Preto, 2002.
- CALDERÓN, R.; NAVAS-CORTÉS, J. A.; LUCENA, C.; ZARCO-TEJADA, P. J. High-resolution airborne hyperspectral and thermal imagery for early detection of Verticillium wilt of olive using fluorescence, temperature and narrow-band spectral indices. **Remote Sensing of Environment**, v. 139, p. 231–245, dez. 2013.
- CAPONE, A.; LUI, J. J.; SILVA, T. R. da; DIAS, M. A. R.; MELO, A. V. de. Avaliação do comportamento de quinze cultivares de cana-de-açúcar na Região Sul do Tocantins. **Journal of Biotechnology and Biodiversity**, v. 2, n. 3, p. 72–80, 8 ago. 2011.
- CARLIN, S. D.; SILVA, M. de A.; ROSSETTO, R. Parâmetros biométricos e produtividade da cana-de-açúcar após tombamento dos colmos. **Bragantia**, v. 67, n. 4, p. 845–853, dez. 2008.
- CARVALHO, A. M. X. de; MENDES, F. Q.; BORGES, P. H. de C.; KRAMER, M. A brief review of the classic methods of experimental statistics. **Acta Scientiarum. Agronomy**, v. 45, 22 nov. 2022.
- CASAGRANDE, A. A.; VASCONCELOS, A. C. M. Fisiologia da parte aérea. *In*: DINARDO-MIRANDA, L. L.; VASCONCELOS, A C M; ANDRADE LANDELL, M G DE. **Cana-de-açúcar**. Campinas: Instituto Agrônomo, 2008. p. 57–78.

- CASAGRANDE, A. A. **Tópicos de morfologia e fisiologia da cana-de-açúcar**. Jaboticabal: FUNEP, 1991. 157 p.
- CAVALCANTE, E. P.; PRADO, H. do. Ambientes de produção de cana-de-açúcar de latossolos da região de Araxá-MG. **Nucleus**, v. 7, n. 2, out. 2010.
- CHO, M. A.; SKIDMORE, A. K. A new technique for extracting the red edge position from hyperspectral data: The linear extrapolation method. **Remote Sensing of Environment**, v. 101, n. 2, p. 181–193, mar. 2006.
- CLAY, D.; KITCHEN, N. Precision Agriculture Basics. **New York: American Society of Agronomy**, p. 287, 2018.
- CLEBER, J. J.; EDER VICTOR BRAGANTI TOPPA; ALESSANDRA JULIANETTI; TARCISIO HULSHOF; ELIZABETH ORIKA ONO; JOÃO DOMINGUES RODRIGUES. Fisiologia do desenvolvimento do estágio vegetativo da cana-de-açúcar (*Saccharum officinarum* L.). **Pesquisa Aplicada & Agrotecnologia**, v. 3, n. 2, 2010.
- CONAB - COMPANHIA NACIONAL DE ABASTCIMENTO. **Acompanhamento da safra brasileira de cana-de-açúcar**, Brasília, DF, v. 9, n. 3 dezembro 2022. Disponível em: <http://www.conab.gov.br>. Acesso em: 23. Dez. 2023.
- CONAB - COMPANHIA NACIONAL DE ABASTCIMENTO. **Acompanhamento da safra brasileira de cana-de-açúcar**, Brasília, DF, v. 11, n. 3, novembro 2023. Disponível em: <http://www.conab.gov.br>. Acesso em: 15. Dez. 2023.
- CTC. Características das variedades CTC. <https://ctc.com.br/en/genetic-improvement/> Acesso em: 15 out. 2023.
- DEE, D. P. et al. The ERA-Interim reanalysis: configuration and performance of the data assimilation system. **Quarterly Journal of the Royal Meteorological Society**, v. 137, n. 656, p. 553–597, abr. 2011.
- DE ASSIS, Janilson Pinheiro et al. Estatística descritiva e indutiva de dados biométricos referentes a características da semente de maracujá gigante amarelo (*Passiflora edulis* Sims). **Observatório de la economía latinoamericana**, v. 21, n. 6, p. 5587-5614, 2023.
- DE CASTRO, Maiza Vieira Leão et al. Industrial yield and chemical composition of high quality protein maize as compared to commercial hybrids. **Pesquisa Agropecuária Tropical**, v. 39, n. 3, p. 233, 2009.
- DOORENBOS, J.; KASSAM, A. H. Yield response to water. **Irrigation and Drainage Paper**, n. 33, p. 193, 1979.
- ESPOSITO, M.; CRIMALDI, M.; CIRILLO, V.; SARGHINI, F.; MAGGIO, A. Drone and sensor technology for sustainable weed management: a review. **Chemical and Biological Technologies in Agriculture**, v. 8, n. 1, p. 18, 25 mar. 2021.
- FAO – FOOD AND AGRICULTURAL ORGANIZATION. **The Future of Food and Agriculture: Trends and Challenges**. Rome, 2019. 166 p. Disponível em: <https://www.fao.org/3/i6583e/i6583e.pdf>. Acesso em: 24. dez. 2023.
- FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em agricultura**. São Paulo: Oficina Textos, 2017.
- GAGO, J.; DOUTHE, C.; COOPMAN, R. E.; GALLEGRO, P. P.; RIBAS-CARBO, M.; FLEXAS, J.; ESCALONA, J.; MEDRANO, H. UAVs challenge to assess water stress for sustainable agriculture. **Agricultural Water Management**, v. 153, p. 9–19, maio 2015.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289–298, dez. 1996.
- GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, abr. 2002.

GONÇALVES, E. R. **Fotossíntese, osmorregulação e crescimento inicial de quatro variedades de cana-de-açúcar submetidas à deficiência hídrica**. 2008. 79 p. Dissertação (Mestrado em Agronomia) – Universidade Federal de Alagoas, Alagoas, 2008.

HOFFER, R. M. Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. *In*: SWAIN, P. H.; DAVIS, S. M. **Remote Sensing: The Quantitative Approach**. New York: McGraw- Hill Book Company, 1978. p. 227–289.

HUETE, A. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, mar. 1997.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, ago. 1988.

IAC Variedades de cana-de-açúcar para o Centro-Sul do Brasil. **Boletim Técnico IAC**, 227. 50p. 2021.

IQBAL, F.; LUCIEER, A.; BARRY, K. Simplified radiometric calibration for UAS-mounted multispectral sensor. **European Journal of Remote Sensing**, v. 51, n. 1, p. 301–313, 1 jan. 2018.

JADOSKI, C. J.; TOPPA, E. V. B.; JULIANETTI, A.; HULSHOF, T.; ONO, E. O.; RODRIGUES, J. D. Physiology development in the vegetative stage of sugarcane. **Applied Research & Agrotechnology**, v. 3, n. 2, p. 169–186, 2010.

JIANG, S.; JIANG, C.; JIANG, W. Efficient structure from motion for large-scale UAV images: A review and a comparison of SfM tools. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 167, p. 230–251, set. 2020.

JORGE, J.; VALLBÉ, M.; SOLER, J. A. Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images. **European Journal of Remote Sensing**, v. 52, n. 1, p. 169–177, 5 jan. 2019.

JÚNIOR, M. R. B.; TEDESCO, D.; CARREIRA, V. dos S.; PINTO, A. A.; MOREIRA, B. R. de A.; SHIRATSUCHI, L. S.; ZERBATO, C.; SILVA, R. P. da. The Time of Day Is Key to Discriminate Cultivars of Sugarcane upon Imagery Data from Unmanned Aerial Vehicle. **Drones**, v. 6, n. 5, p. 112, 29 abr. 2022.

KARUPPANAPANDIAN, T.; MOON, J.-C.; KIM, C.; MANOHARAN, K.; KIM, W. Reactive Oxygen Species in Plants: Their Generation, Signal Transduction, and Scavenging Mechanisms. **Australian Journal of Crop Science**, v. 5, n. 6, p. 709–725, 2011.

KATSOULAS, N.; ELVANIDI, A.; FERENTINOS, K. P.; KITTAS, C.; BARTZANAS, T. Calibration methodology of a hyperspectral imaging system for greenhouse plant water status assessment. **Acta Horticulturae**, n. 1142, p. 119–126, out. 2016.

KAWAMURA, K.; ASAI, H.; YASUDA, T.; SOISOUVANH, P.; PHONGCHANMIXAY, S. Discriminating crops/weeds in an upland rice field from UAV images with the SLIC-RF algorithm. **Plant Production Science**, v. 24, n. 2, p. 198–215, 3 abr. 2021.

KUMAR, D.; MALIK, N.; SENGAR, R. S. Physio-biochemical insights into sugarcane genotypes under water stress. **Biological Rhythm Research**, v. 52, n. 1, p. 92–115, 2 jan. 2021.

LANDELL, M. G. A.; PRADO, H.; VASCONCELOS, A. C.; PERECIN, D.; ROSSETTO, R.; BIDÓIA, M. A. P.; XAVIER, M. A. Oxisol subsurface chemical attributes related sugarcane productivity. **Scientia Agricola**, v. 60, p. 741–745, 2003.

LANDELL, M. G. de A.; SCARPARI, M. S.; XAVIER, M. A.; ANJOS, I. A. dos; BAPTISTA, A. S.; AGUIAR, C. L. de; SILVA, D. N. da; BIDÓIA, M. A. P.; BRANCALÍÃO, S. R.; BRESSIANI, J. A.; CAMPOS, M. F. de; MIGUEL, P. E. M.; SILVA, T. N. da; SILVA, V. H. P. da; ANJOS, L. O. S.; OGATA, B. H. Residual biomass potential of commercial and pre-commercial sugarcane cultivars. **Scientia Agricola**, v. 70, n. 5, p. 299–304, out. 2013.

- LEITE, R. C. de C. **Bioetanol combustível: uma oportunidade para o Brasil**. Brasília, DF:Centro de Gestão e Estudos Estratégicos, 2009.
- LEPSCH, I. F. Influência dos fatores edáficos na produção. *In*: CASTRO, P. R. C.; FERREIRA, S. O.; YAMADA, T. **Ecofisiologia da produção**. Piracicaba: Associação Brasileira para Pesquisa da Potassa e do Fosfato, 1987. p. 83–98.
- LIU, C.; LIU, Y.; GUO, K.; FAN, D.; LI, G.; ZHENG, Y.; YU, L.; YANG, R. Effect of drought on pigments, osmotic adjustment and antioxidant enzymes in six woody plant species in karst habitats of southwestern China. **Environmental and Experimental Botany**, v. 71, n. 2, p. 174–183, jun. 2011.
- MACHADO, E. C. **Um modelo matemático-fisiológico para simular o acúmulo de matéria seca na cultura da cana-de-açúcar (Sacchum sp)**. 1981. Universidade Estadual de Campinas, Campinas, 1981.
- MACHADO, E. C.; PEREIRA, A. R.; FAHL, J. I.; ARRUDA, J. V.; CIONE, J. Índices biométricos de duas variedades de cana-de-açúcar. **Pesquisa Agropecuária brasileira**, v. 17, n. 9, p. 1323–1329, 1982.
- MAGALHÃES, A. C. N. Ecofisiologia da cana-de-açúcar: aspecto do metabolismo do carbono na planta. *IN*: CASTRO, P. R. C.; FERREIRA, S. O.; YAMADA, T. **Ecofisiologia da produção**. Piracicaba: Associação Brasileira para Pesquisa da Potassa e do Fosfato (POTAFOS), 1987. p. 113–118.
- MAHLEIN, A.-K.; RUMPF, T.; WELKE, P.; DEHNE, H.-W.; PLÜMER, L.; STEINER, U.; OERKE, E.-C. Development of spectral indices for detecting and identifying plant diseases. **Remote Sensing of Environment**, v. 128, p. 21–30, jan. 2013.
- MALVEAUX, C.; HALL, S. G.; PRICE, R. Using drones in agriculture: unmanned aerial systems for agricultural remote sensing applications. **American Society of Agricultural and Biological Engineers**, p. 1, 13 jun. 2014.
- MANHÃES, C. M. C.; GARCIA, R. F.; FRANCELINO, F. M. A.; FRANCELINO, H. de O.; COELHO, F. C. Factors that affect sprouting and tillering of sugar cane. **Revista Vértices**, v. 17, n. 1, p. 163–181, 2015.
- MARIN, F. Cana-de-açúcar. *In*: MONTEIRO, J. **Agrometeorologia dos Cultivos O fator meteorológico na produção agrícola**. Brasília-DF: Instituto Nacional de Meteorologia – INMET, 2009. p. 109–130.
- MARIN, F. R. **Eficiência de produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos**. 2014. Tese (Livre Docência) - Universidade de São Paulo, Piracicaba, 2014.
- MARTELLO, M. **Estimativa da altura e produtividade da cana-de-açúcar utilizando imagens obtidas por aeronave remotamente pilotada**. 2017. Dissertação (Mestrado) - Universidade de São Paulo, Piracicaba, 2017.
- MARTINS, J. A. **Dados hiperespectrais para a predição do teor foliar de nitrogênio em cana-de-açúcar**. 2016. Tese (Doutorado) Universidade de São Paulo, Piracicaba, 2016.
- MATOS, M.; SANTOS, F.; EICHLER, P. Sugarcane world scenario. *In*: **Sugarcane Biorefinery, Technology and Perspectives**. Elsevier, 2020. p. 1–19.
- MAULE, R. F.; MAZZA, J. A.; MARTHA JR., G. B. Produtividade agrícola de cultivares de cana-de-açúcar em diferentes solos e épocas de colheita. **Scientia Agricola**, v. 58, n. 2, p. 295–301, jun. 2001.
- MELLO, F. F. C.; CERRI, C. E. P.; DAVIES, C. A.; HOLBROOK, N. M.; PAUSTIAN, K.; MAIA, S. M. F.; GALDOS, M. V.; BERNOUX, M.; CERRI, C. C. Payback time for soil carbon and sugar-cane ethanol. **Nature Climate Change**, v. 4, n. 7, p. 605–609, 8 jul. 2014.
- MELO, P. L. A. de. **Avaliação do sistema radicular da cana-de-açúcar sob diferentes quantidades de palha mantidas na superfície do solo**. 2018. Dissertação (Mestrado) -Universidade de São Paulo, Piracicaba, 2018.
- MORAES, E. C. **Fundamentos do sensoriamento remoto. Apostila**. 2015. Instituto Nacional de Pesquisas Espaciais (INPE/MCTI). 2015.

MOZAMBANI, A. E.; ET AL. História e morfologia da cana-de-açúcar. **Atualização em produção de cana-de-açúcar**, v. 1, p. 11–18, 2006.

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, abr. 2013.

MUTANGA, O.; MASENYAMA, A.; SIBANDA, M. Spectral saturation in the remote sensing of high-density vegetation traits: A systematic review of progress, challenges, and prospects. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 198, p. 297–309, abr. 2023.

NASSIF, D.S.P.; MARIN, F.R.; COSTA, L.G. **Padrões mínimos para coleta de dados experimentais para estudos sobre crescimento e desenvolvimento da cultura da cana-de-açúcar**. Embrapa Informática Agropecuária, Documentos 127, Campinas, setembro de 2013. 28 p.

NUTTER, F. W.; TYLKA, G. L.; GUAN, J.; MOREIRA, A. J. D.; MARETT, C. C.; ROSBURG, T. R.; BASART, J. P.; CHONG, C. S. Use of Remote Sensing to Detect Soybean Cyst Nematode-Induced Plant Stress 1. 2002. Acesso em: 11 dez. 2023.

PARAZZI, C.; ORTIGOSA, L. M.; MEDEIROS, S. D. S. de; VERRUMA-BERNARDI, M. R. Estudo da qualidade físico-química, tecnológica e sensorial de caldos de cana-de-açúcar para consumo. **Revista Cincia, Tecnologia & Ambiente**, v. 8, n. 1, p. 3–10, 2018.

PATRIGNANI, A.; OCHSNER, T. E. Canopeo: A Powerful New Tool for Measuring Fractional Green Canopy Cover. **Agronomy Journal**, v. 107, n. 6, p. 2312–2320, nov. 2015.

PEÑA, J.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; DE CASTRO, A.; LÓPEZ-GRANADOS, F. Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution. **Sensors**, v. 15, n. 3, p. 5609–5626, 6 mar. 2015.

PÔÇAS, I.; RODRIGUES, A.; GONÇALVES, S.; COSTA, P.; GONÇALVES, I.; PEREIRA, L.; CUNHA, M. Predicting Grapevine Water Status Based on Hyperspectral Reflectance Vegetation Indices. **Remote Sensing**, v. 7, n. 12, p. 16460–16479, 5 dez. 2015.

PRADO, H. **Solos do Brasil: gênese, morfologia, classificação, levantamento, manejo**. Piracicaba, 2005 281 p.

PRADO, H. do. **Pedologia fácil: aplicações**. 3. ed. Piracicaba: Hélio do Prado, 2011. 180 p.

PRUDNIKOVA, E.; SAVIN, I.; VINDEKER, G.; GRUBINA, P.; SHISHKONAKOVA, E.; SHARYCHEV, D. Influence of Soil Background on Spectral Reflectance of Winter Wheat Crop Canopy. **Remote Sensing**, v. 11, n. 16, p. 1932, 19 ago. 2019.

PURI, V.; NAYYAR, A.; RAJA, L. Agriculture drones: A modern breakthrough in precision agriculture. **Journal of Statistics and Management Systems**, v. 20, n. 4, p. 507–518, 4 jul. 2017.

QIU, J.; YANG, J.; WANG, Y.; SU, H. A comparison of NDVI and EVI in the DisTrad model for thermal sub-pixel mapping in densely vegetated areas: a case study in Southern China. **International Journal of Remote Sensing**, v. 39, n. 8, p. 2105–2118, 18 abr. 2018.

QUEMADA, M.; GABRIEL, J.; ZARCO-TEJADA, P. Airborne Hyperspectral Images and Ground-Level Optical Sensors as Assessment Tools for Maize Nitrogen Fertilization. **Remote Sensing**, v. 6, n. 4, p. 2940–2962, 31 mar. 2014.

RADOČAJ, D.; ŠILJEG, A.; PLAŠČAK, I.; MARIĆ, I.; JURIŠIĆ, M. A Micro-Scale Approach for Cropland Suitability Assessment of Permanent Crops Using Machine Learning and a Low-Cost UAV. **Agronomy**, v. 13, n. 2, p. 362, 26 jan. 2023.

RAO, C. M.; KUMAR, M. V.; REDDY, L. K. Management of sugarcane clones under limited moisture situations (drought) at formative stage. **Indian Sugar**, p. 949-953, 2005.

RASMUSSEN, J.; NIELSEN, J.; GARCIA-RUIZ, F.; CHRISTENSEN, S.; STREIBIG, J. C. Potential uses of small unmanned aircraft systems (UAS) in weed research. **Weed Research**, v. 53, n. 4, p. 242–248, ago. 2013. Acesso em: 11 dez. 2023.

REETZ, H. F. **Fertilizantes e o seu uso eficiente**. São Paulo: Anda, 2017. v. 178

RIDESA **Melhoramento Genético da Cana-de-açúcar**. <https://www.ridesa.com.br/variedades>. Acesso em: 15 nov. 2023.

RODRIGUES, G. S. de S. C.; ROSS, J. L. S. **A trajetória da cana-de-açúcar no Brasil: perspectivas geográfica, histórica e ambiental**. Uberlândia: EDUFU, 2020. 269 p.

RODRÍGUEZ, J.; LIZARAZO, I.; PRIETO, F.; ANGULO-MORALES, V. Assessment of potato late blight from UAV-based multispectral imagery. **Computers and Electronics in Agriculture**, v. 184, p. 106061, maio. 2021.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, fev. 1996.

ROBERTSON, M. J. et al. Estimating the risk associated with drying-off strategies for irrigated sugarcane before harvest. **Australian Journal of Agricultural Research**, v. 50, p. 65-77, 1999.

ROUSE, J. W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D. W. Monitoring vegetation systems in the Great Planins with ERTS. In: EARTH TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3. 1973. Washington. **Anais**. Washington: NASA, 1973. V.1, p.309-317.

ROSSETTO, R.; DIAS, F. L. F.; VITTI, ré C.; CANTARELLA, H. FERTILITY MAINTENANCE AND SOIL RECOVERY IN SUGARCANE CROPS. In: **Sugarcane bioethanol — R&D for Productivity and Sustainability**. Editora Edgard Blücher, 2014. p. 381–404.

SANTOS, F.; COLODETTE, J.; QUEIROZ, J. H. **Estratégias tecnológicas para biorrefinarias da cana-de-açúcar**. 2018. 251–267 p.

SANTOS, M. A. L. dos. **Irrigação suplementar da cana-de-açúcar (Saccharum spp): um modelo de análise de decisão para o estado de Alagoas**. 2005. Tese (Doutorado) - Universidade de São Paulo, Piracicaba, 2005.

SHEPHERD, M. J.; LINDSEY, L. E.; LINDSEY, A. J. Soybean Canopy Cover Measured with Canopeo Compared with Light Interception. **Agricultural & Environmental Letters**, v. 3, n. 1, jan. 2018.

SILVEIRA, J. M. de C.; CANDIDO, B. M.; SILVA, A. L. B. de O.; PAVÃO, G. C.; XAVIER, M. A.; PIRES, R. C. de M. USO DE IMAGENS MULTIESPECTRAIS E TERMOGRÁFICAS PARA MONITORAMENTO DAS CONDIÇÕES HÍDRICAS DA CANA-DE-AÇÚCAR. **IRRIGA**, v. 25, n. 4, p. 689–696, 16 dez. 2020.

STEVEN, M. D. The Sensitivity of the OSAVI Vegetation Index to Observational Parameters. **Remote Sensing of Environment**, v. 63, n. 1, p. 49–60, jan. 1998.

STORINO, M.; PECHE FILHO, A.; KURACHI, S. A. H.; DINARDO-MIRANDA, L. L.; VASCONCELOS, A. C. M.; LANDELL, M. G. A. Aspectos operacionais do preparo do solo. In: DINARDO-MIRANDA, L. L.; VASCONCELOS, A. C. M.; LANDELL, M. G. A. **Aspectos operacionais do preparo do solo**. Campinas: Instituto Agrônomo de Campinas, 2010. p. 547–572.

STUDENT. THE PROBABLE ERROR OF A MEAN. **Biometrika**, v. 6, n. 1, p. 1–25, 1 mar. 1908.

SZMRECSÁNYI, T. Tecnologia e degradação ambiental: o caso da agroindústria canavieira no Estado de São Paulo. **Instituto de Economia Agrícola**, v. 24, n. 10, out. 1994.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, maio 1979.

TURNER, D.; LUCIEER, A.; WATSON, C. An Automated Technique for Generating Georectified Mosaics from Ultra-High Resolution Unmanned Aerial Vehicle (UAV) Imagery, Based on Structure from Motion (SfM) Point Clouds. **Remote Sensing**, v. 4, p. 1392–1410, 2012.

VASCONCELOS, A. C. M.; CASAGRANDE, A. A. Fisiologia do Sistema Radicular. In: MIRANDA, L. L. D.; VASCONCELOS, A. C. M. **Cana-de-açúcar**. Campinas: Instituto Agrônomo, 2008. p. 882.

VERHOEVEN, G. Three-dimensional Reconstructions from Aerial Photographs with Photo Scan. **Archaeological Prospection**, v. 19, p. 103–121, 2012.

VOITIK, A.; KRAVCHENKO, V.; PUSHKA, O.; KUTKOVETSKA, T.; SHCHUR, T.; KOCIRA, S. Comparison of NDVI, NDRE, MSAVI and NDSI Indices for Early Diagnosis of Crop Problems. **Agricultural Engineering**, v. 27, n. 1, p. 47–57, 1 jan. 2023.

VON STECHOW, C.; MCCOLLUM, D.; RIAHI, K.; MINX, J. C.; KRIEGLER, E.; VAN VUUREN, D. P.; JEWELL, J.; ROBLEDO-ABAD, C.; HERTWICH, E.; TAVONI, M.; MIRASGEDIS, S.; LAH, O.; ROY, J.; MULUGETTA, Y.; DUBASH, N. K.; BOLLEN, J.; ÜRGE-VORSATZ, D.; EDENHOFER, O. Integrating Global Climate Change Mitigation Goals with Other Sustainability Objectives: A Synthesis. **Annual Review of Environment and Resources**, v. 40, p. 363–394, 5 nov. 2015.

WALTER, A.; GALDOS, M. V.; SCARPARE, F. V.; LEAL, M. R. L. V.; SEABRA, J. E. A.; DA CUNHA, M. P.; PICOLI, M. C. A.; DE OLIVEIRA, C. O. F. Brazilian sugarcane ethanol: developments so far and challenges for the future. **WIREs Energy and Environment**, v. 3, n. 1, p. 70–92, 22 jan. 2014.

WELLS, R. Soybean Growth Response to Plant Density: Relationships among Canopy Photosynthesis, Leaf Area, and Light Interception. **Crop Science**, v. 31, n. 3, p. 755–761, maio 1991.

WIJAYANTO, A. W.; WAHYU TRISCOWATI, D.; MARSUHANDI, A. H. Maize field area detection in East Java, Indonesia: An integrated multispectral remote sensing and machine learning approach. In: **2020 12th International Conference on Information Technology and Electrical Engineering (ICITEE)**, 2020, IEEE, 2020. p. 168–173.

WHITMORE, Bishane A. **Evolution of unmanned aerial warfare: a historical look at remote airpower—a case study in innovation**. 2016. Tese (Doutorado). Fort Leavenworth, KS: US Army Command and General Staff College.

WOEBBECKE, D. M.; MEYER, G. E.; VON BARGEN, K.; MORTENSEN, D. A. Shape Features for Identifying Young Weeds Using Image Analysis. **Transactions of the ASAE**, v. 38, n. 1, p. 271–281, 1995.

ZARCO-TEJADA, P. J.; CAMINO, C.; BECK, P. S. A.; CALDERON, R.; HORNERO, A.; HERNÁNDEZ-CLEMENTE, R.; KATTENBORN, T.; MONTES-BORREGO, M.; SUSCA, L.; MORELLI, M.; GONZALEZ-DUGO, V.; NORTH, P. R. J.; LANDA, B. B.; BOSCIA, D.; SAPONARI, M.; NAVAS-CORTES, J. A. Previsual symptoms of *Xylella fastidiosa* infection revealed in spectral plant-trait alterations. **Nature Plants**, v. 4, n. 7, p. 432–439, 25 jun. 2018.

ZERBATO, C.; ROSALEN, D. L.; FURLANI, C. E. A.; DEGHAID, J.; VOLTARELLI, M. A. Agronomic characteristics associated with the normalized difference vegetation index (NDVI) in the peanut crop. **Australian Journal of Crop Science**, v. 10, n. 5, p. 758–764, 2016.

ZHAO, T.; STARK, B.; CHEN, Y.; RAY, A. L.; DOLL, D. Challenges in Water Stress Quantification Using Small Unmanned Aerial System (sUAS): Lessons from a Growing Season of Almond. **Journal of Intelligent & Robotic Systems**, v. 88, n. 2–4, p. 721–735, 7 dez. 2017.

ZHU, J.-K. Cell signaling under salt, water and cold stresses. **Current Opinion in Plant Biology**, v. 4, n. 5, p. 401–406, out. 2001.