



UNIVERSIDADE FEDERAL DO TOCANTINS  
CÂMPUS DE GURUPI  
PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO VEGETAL

**JOSÉ AVELINO CARDOSO**

**Modelos de previsão por meio de imagens de vants do comportamento fisiológico e biométrico do milho em convivência com diferentes densidades de plantio de braquiária**

**TESE DE DOUTORADO**

GURUPI/TO  
2025



**UNIVERSIDADE FEDERAL DO TOCANTINS  
CÂMPUS DE GURUPI  
PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO VEGETAL**

**MODELOS DE PREVISÃO POR MEIO DE IMAGENS DE VANTS DO  
COMPORTAMENTO FISIOLÓGICO E BIOMÉTRICO DO MILHO EM CONVIVÊNCIA  
COM DIFERENTES DENSIDADES DE PLANTIO DE BRAQUIÁRIA**

**JOSÉ AVELINO CARDOSO**

**ORIENTADOR: DR. EDUARDO ANDREA LEMUS ERASMO  
CO-ORIENTADOR: DR. ROGÉRIO NOGUEIRA DE SOUSA**

**TESE DE DOUTORADO**

**PUBLICAÇÃO: \_\_\_\_/2025**

**GURUPI/TO  
2025**



UNIVERSIDADE FEDERAL DO TOCANTINS  
CÂMPUS DE GURUPI  
PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO VEGETAL

**MODELOS DE PREVISÃO POR MEIO DE IMAGENS DE VANTS DO  
COMPORTAMENTO FISIOLÓGICO E BIOMÉTRICO DO MILHO EM CONVIVÊNCIA  
COM DIFERENTES DENSIDADES DE PLANTIO DE BRAQUIÁRIA**

**JOSÉ AVELINO CARDOSO**

**TESE DE DOUTORADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM  
PRODUÇÃO VEGETAL, COMO PARTE DOS REQUISITOS NECESSÁRIOS À  
OBTENÇÃO DO GRAU DE DOUTOR EM PRODUÇÃO VEGETAL APROVADA  
POR:**

---

**Eduardo Andrea Lemus Erasmo, Dr. (Orientador) / Universidade Federal do  
Tocantins/ [erasmolemus@mail.uft.edu.br](mailto:erasmolemus@mail.uft.edu.br)**

---

**Dr. Rogério Nogueira de Sousa (Membro interno) / Universidade Federal do  
Tocantins/ [roger@mail.uft.edu.br](mailto:roger@mail.uft.edu.br)**

**Gurupi/TO, 25 de junho de 2025**

## FICHA CATALOGRÁFICA

## **DEDICO**

Dedico esta tese ao meu pai (in memoriam), por ser meu exemplo eterno; à minha mãe, pelo amor e apoio incondicional; à minha esposa, pelo companheirismo, paciência e força que tornaram esta conquista possível; e ao meu filho, que é minha maior motivação e razão para nunca desistir.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, pelo dom da vida, por me dar forças para enfrentar os desafios, sabedoria para tomar decisões e serenidade para não desistir diante das dificuldades. Sem a presença dele iluminando meu caminho, esta conquista não seria possível.

Ao meu pai Mario Cardoso (In memória), que continua vivo em minhas lembranças e em cada valor que me ensinou, principalmente aos estudos. Seus ensinamentos de honestidade e amor ao trabalho me guiaram até aqui.

À minha mãe Maria Domingues, pelo amor incondicional, pela compreensão e pelo apoio em todos os momentos. Obrigado por suas orações, por acreditar em mim e por me incentivar a nunca desistir, mesmo quando o caminho parecia difícil: vencemos mãe!

À minha esposa Tamara Thalia, minha companheira de vida e maior sustentação nesta jornada. Obrigado pela ajuda no experimento, paciência, amor e compreensão nos momentos em que precisei me ausentar. Você assumiu responsabilidades, cuidou do nosso lar e do nosso filho para que eu pudesse me dedicar a este desafio. Seu incentivo diário, suas palavras de motivação e sua presença ao meu lado foram fundamentais para que eu chegasse até aqui. Esta conquista é tão sua quanto minha.

Ao meu filho José Mario, que é a razão da minha maior felicidade. Cada sorriso seu, cada gesto inocente renovava minhas forças e me lembrava do motivo pelo qual eu não podia desistir.

Aos meus sogros, pela consideração, apoio e incentivo em todos os momentos desta caminhada. Agradeço a compreensão nas minhas ausências, pelas palavras de ânimo e por me acolherem como parte da família. O apoio de vocês foi essencial para que eu pudesse seguir firme nesta jornada e alcançar mais esta conquista.

Ao meu orientador Dr. Eduardo Erasmo, pela orientação firme e conselhos valiosos. Serei eternamente grato pela sua humanidade, pelo conhecimento compartilhado e principalmente pela confiança que depositou em mim. Levarei essa experiência para o resto da minha vida: o meu muito obrigado!

Ao meu coorientador, Dr. Rogério Nogueira, pela valiosa orientação e por me introduzir ao mundo da programação. Suas dicas e ensinamentos foram fundamentais para o desenvolvimento das análises computacionais desta pesquisa e ampliaram minha visão sobre o potencial das ferramentas digitais aplicadas à agronomia.

Aos integrantes da banca examinadora, Dr. Jacinto Pereira, Dr. Otacílio Silveira e Dr. Ítalo Cordeiro, pela disponibilidade, atenção e pelas contribuições valiosas que enriqueceram este trabalho. Agradeço pelas sugestões criteriosas, pelo olhar técnico e pelas reflexões que ampliaram a qualidade científica desta pesquisa.

A todos os meus familiares: irmã, vó, tios e primos, pelo apoio, carinho e palavras de incentivo em todos os momentos desta trajetória. Vocês foram parte essencial para que este sonho se tornasse realidade.

Aos colegas de trabalho, Marcos Euzébio, Joabe, Ana Rafaela e Fredson, pelo apoio, logística e conhecimento na execução do experimento.

Aos alunos, Jean e Leonardo, que estiveram ao meu lado no experimento de campo, sob sol forte e condições difíceis. Sem essa ajuda, não teria conseguido.

Ao campus Dianópolis, na gestão do Professor Pietro, por disponibilizar o local físico e pelo auxílio financeiro para realização do doutorado.

Ao grupo de pesquisa Ecofisiologia vegetal (Nádia, Rita, Flavia, Clemilda, Ritona e Carmiran) pela união e valiosos conhecimentos compartilhados.

A Universidade Federal do Tocantins por me proporcionar um ambiente de aprendizado, mas também de crescimento acadêmico, científico e pessoal na realização dos estudos de doutorado.

## BIOGRAFIA DO AUTOR

Nascido no dia 21 de setembro de 1986 em Espinosa-MG, no extremo norte mineiro, na divisa com a Bahia. Filho de pai agricultor e mãe dona de casa com pouco estudo, mas que me ensinou o valor aos estudos desde cedo.

Na zona rural do semiárido baiano me cresci e aprendi desde cedo com meu pai, o valor do trabalho, da terra e da perseverança. Em meio às dificuldades do campo e do incentivo incessante dos meus pais foi brotando o sonho de buscar conhecimento e transformar em oportunidades para viver da agricultura.

O primeiro passo dessa trajetória foi dado ao ingressar na Escola Agrotécnica Federal de Guanambi, onde concluí o curso de Técnico em Agropecuária. Ali descobri que a educação poderia abrir caminhos e mudar destinos. Movido por essa certeza, segui para a Universidade Estadual da Bahia (UNEB), em Barreiras, onde me formei em Engenharia Agrônoma, consolidando minha paixão pelo agro e pelo desenvolvimento sustentável.

Com o desejo de evoluir ainda mais, cheguei à Universidade de Brasília (UnB), onde realizei o Mestrado em Produção Sustentável, aprofundando estudos sobre práticas que conciliam produtividade e preservação ambiental. Essa experiência fortaleceu minha convicção de que ciência e campo devem caminhar juntos.

A carreira docente surgiu como missão. Iniciei como professor contratado no Instituto Federal do Tocantins (IFTO) e, posteriormente, alcancei minha primeira grande vitória em concursos, sendo aprovado em primeiro lugar como técnico e posteriormente como professor efetivo no Instituto Federal do Amazonas (IFAM-Lábrea), onde permaneci por um tempo depois retornei para IFTO. Cada aula ministrada reafirmava meu propósito de formar profissionais preparados para transformar a realidade do campo.

Hoje, coroando essa caminhada, concluo o Doutorado na Universidade Federal do Tocantins (UFT), em Gurupi, carregando comigo não apenas títulos, mas a certeza de que toda conquista é fruto de persistência, fé e trabalho.

**"Do sertão ao doutorado, provei que nenhum sonho é grande demais para quem acredita e persiste."**

## RESUMO

O conhecimento da competição entre plantas e seus efeitos em meio de cultivos agrícolas é uma ferramenta essencial para o aperfeiçoamento do manejo e aumento na produtividade. Os veículos aéreos não tripulados (VANTs) podem ser usados para obter tais informações permitindo análises espectrais e temporais. Sendo assim, o objetivo deste trabalho foi avaliar o comportamento fisiológico e espectral da cultura do milho (*Zea mays*) em competição com diferentes densidades de plantio do capim braquiária para obtenção de modelos de previsão que interprete imagens aéreas. O experimento em questão foi implantado no campo experimental do IFTO- Dianópolis em blocos casualizados com 6 repetições com duplo fatorial. Foram realizadas avaliações fisiológicas da cultura do milho com diferentes densidades de plantas de capim braquiária (0;5;10;20 pl/m) e obtidas imagens aéreas a altura de 44 metros. Aos 20 (V6), 33 (V10), 48 (VT) e 62 (R2) dias após a emergência foram feitas análises fisiológicas e o levantamento de imagens aéreas concomitantemente entre as 10-12 horas do dia. A análise fisiológica da cultura do milho foi feita com um analisador de gás no infravermelho obtendo: a taxa fotossintética líquida (A), a condutância estomática ao vapor de água (gs), a taxa transpiratória (E) é a razão entre a concentração interna e a concentração externa de CO<sub>2</sub> (C<sub>i</sub>/C<sub>e</sub>). As imagens aéreas foram feitas com o uso do VANT modelo EbeeX portando uma câmera multiespectral RedEdge-M para a obtenção de imagens. A avaliação das imagens foi feita através de uma análise espectral de cada parcela. O processo de estimação que foi utilizado neste estudo é baseado em métodos de regressão paramétricos (regressão linear múltipla) e não paramétricos (Random forest e Redes neurais), e seus resultados comparados, utilizando o software VS Code. A raiz do erro quadrático médio (RMSE), e o RMSE normalizado (RMSE%) foram utilizadas para validar a precisão dos modelos, considerando o resíduo da diferença entre as variáveis fisiológicas estimadas. Os melhores modelos foram aplicados ao conjunto de teste obtendo o fator de determinação R<sup>2</sup> %. Portanto foi possível estimar as variáveis biométricas e fisiológicas, através de imagens de VANTs por processo de estimação utilizando métodos paramétricos e não paramétricos, permitindo a substituição de medições pontuais em campo.

**Palavras-chaves:** Competição entre plantas; imagens aéreas; índice de vegetação e algoritmo.

## ABSTRACT

Knowledge of plant competition and its effects on agricultural crops is an essential tool for improving management and consequently increasing gains in final productivity. Unmanned aerial vehicles (UAVs) can be used to obtain such information, allowing spectral and temporal analyses. Therefore, the objective of this study was to evaluate the physiological and spectral behavior of corn (*Zea mays*) in consortium with different planting densities of *Brachiaria* grass to obtain an algorithm that interprets aerial images. The experiment in question was implemented in the experimental field of IFTO- Dianópolis in randomized blocks with 6 replicates in a double factorial design. Physiological evaluations of corn crops were performed with different densities of *Brachiaria* grass plants (0, 5, 10, 20 pl/m) and aerial images were obtained at a height of 44 meters. At 20 (V6), 33 (V10), 48 (VT) and 62 (R2) days after emergence, physiological analyses and aerial images were taken concomitantly between 10 and 12 noon. The physiological analysis of the corn crop was performed with an infrared gas analyzer, obtaining: net photosynthetic rate (A), stomatal conductance to water vapor (gs), transpiration rate (E) and the ratio between the internal and external concentration of CO<sub>2</sub> (C<sub>i</sub>/C<sub>e</sub>). Aerial images were taken using an EbeeX model UAV carrying a RedEdge-M multispectral camera to obtain images. The images were evaluated through a spectral analysis of each plot. The estimation process used in this study is based on parametric (multiple linear regression) and nonparametric (random forest and neural networks) regression methods, and their results compared using VS code software. The root mean square error (RMSE) and the normalized RMSE (RMSE%) were used to validate the accuracy of the models, considering the residual of the difference between the estimated physiological variables. The best models were applied to the test set, obtaining the determination factor R<sup>2</sup> %. Therefore, it was possible to estimate the biometric and physiological variables, through UAVs images through a study process using parametric and non-parametric methods, allowing the replacement of specific latitudes in the field.

**Keywords:** Competition between plants; aerial images; vegetation index and algorithm.

## SUMÁRIO DAS TABELAS

Tabela 1. Resultado da análise química dos solos da área experimental (EMBRAPA, 2009).....	23
Tabela 2. Valores de quadrado médios baseado em variáveis biométricas, fisiológicas e espectrais do milho submetido a diferentes densidades de competição com braquiária.....	27
Tabela 3. Teste de comparação de médias dos atributos fisiológicos do milho submetido a competição com diferentes densidades de plantio da braquiária e em diferentes épocas de desenvolvimento.....	29
Tabela 4. Teste de comparação de médias dos dados espectrais do milho submetido a competição com diferentes densidades de plantio da braquiária e em diferentes épocas de desenvolvimento.....	33
Tabela 5. Teste de comparação de média dos dados biométricos do milho em competição com as diferentes densidades de plantio da braquiária.....	35
Tabela 6. Resultado da análise química dos solos da área experimental (EMBRAPA, 2009).....	44
Tabela 7. Média, desvio padrão e coeficiente de variação do conjunto de variáveis biométricas, fisiológicos e espectrais do milho em competição com diferentes populações de braquiária e em diferentes épocas de desenvolvimento.....	49
Tabela 8. Desempenho dos modelos de regressão linear múltipla para prever características biométricas e fisiológicas de plantas com base em bandas espectrais do milho em competição com diferentes densidades de braquiária.....	53
Tabela 9. Desempenho modelos dos métodos de Florestas Aleatórias para prever características biométricas e fisiológicas com base em bandas espectrais do milho em competição com diferentes densidades de braquiária.....	57
Tabela 10. Desempenho dos modelos criados por rede neurais para prever características biométricas e fisiológicas com base em bandas espectrais do milho em competição diferentes densidades de braquiária.....	61
Tabela 11. Resumo demonstrando o desempenho dos modelos de predição das variáveis biométricas e fisiológicas do milho em competição com a braquiária mostrando o coeficiente de regressão ( $R^2$ ) e a raiz do erro quadrado médio normalizado (RMSE %) .....	64

## SUMÁRIO DAS FIGURAS

Figura 1. Gráfico do regime pluviométrico e datas das leituras.....	23
Figura 2. Croqui da área experimental.....	24
Figura 3. Equipamento IRGA –Infrared Gas Analyzer, modelo Li-6400.....	25
Figura 4. VANT de asa fixa Ebeex com câmera multiespectral e plano de voo da área experimental.....	26
Figura 5. Gráfico do regime pluviométrico e datas das leituras.....	44
Figura 6. Croqui da área experimental.....	45

## SUMÁRIO

RESUMO GERAL.....	VII
ABSTRACT .....	VIII
SUMÁRIO DE TABELAS .....	IX
SUMÁRIO DE FIGURAS.....	X
SUMÁRIO.....	XII
1. INTRODUÇÃO GERAL.....	1
1.1. OBJETIVO GERAL.....	3
1.1.1. OBJETIVOS ESPECÍFICOS .....	3
1.2. HIPÓTESES .....	4
2. REVISÃO DE LITERATURA.....	5
2.1 Consórcio do milho/pastagem.....	5
2.2 Fisiologia da cultura do milho em consórcio.....	6
2.3 Estresse fisiológico das plantas de milho.....	8
2.4 Comportamento espectral da vegetação em estresse.....	9
2.5 Veículos aéreos não tribulados no monitoramento de plantas .....	10
2.6 Avaliação da fisiologia das plantas por algoritmos.....	11
3. CONSIDERAÇÕES FINAIS.....	13
4. REFERÊNCIAS BIBLIOGRÁFICAS .....	14
CAPÍTULO 1. COMPORTAMENTO FISIOLÓGICO, BIOMÉTRICO E ESPECTRAL DO MILHO EM CONVIVÊNCIA COM AS DIFERENTES DENSIDADES DE PLANTIO DE CAPIM BRAQUIÁRIA.....	20
1.1. INTRODUÇÃO .....	22
1.2. MATERIAL E MÉTODOS.....	23
1.3. RESULTADOS E DISCUSSÃO .....	27
1.4. CONCLUSÕES .....	37
1.5. REFERÊNCIAS .....	38
CAPÍTULO 2 - MODELOS DE PREVISÃO POR IMAGENS DE VANTS DO COMPORTAMENTO FISIOLÓGICO E BIOMÉTRICO DO MILHO EM CONVIVÊNCIA COM AS DIFERENTES DENSIDADES DE PLANTIO DO CAPIM BRAQUIÁRIA.....	41
2.1. INTRODUÇÃO .....	43
2.2. MATERIAL E MÉTODOS.....	44
2.3. RESULTADOS E DISCUSSÃO .....	49

<b>2.4. CONCLUSÕES .....</b>	<b>66</b>
<b>2.5. REFERÊNCIAS .....</b>	<b>68</b>
<b>2.6 APÊNDICE .....</b>	<b>78</b>

## 1. INTRODUÇÃO

O milho (*Zea mays* L.) é considerado o cereal mais cultivado no mundo, sendo o grão o produto principal, ele fornece nutrientes para a alimentação humana e animal, além de matéria-prima para a indústria. A produção mundial de milho ficou em torno de 1,21 bilhão de toneladas para a safra 2021/22. Os Estados Unidos lideram a produção com 383,9 milhões de toneladas, seguindo pela china com 272,6 milhões de toneladas e o Brasil com 116 milhões de toneladas (USDA, 2022).

O consórcio de forrageira perene com o milho vem sendo utilizado como alternativa para aumentar a produção de grãos e cobertura morta para plantio direto, proporcionando maior retorno das culturas (CECCON et al., 2014), sendo que o produtor pode ainda utilizar os consórcios ou a rotação de culturas graníferas com forrageiras, para a implantação e/ou recuperação de pastagens (REZENDE et al., 2022). No entanto, a população de plantas forrageiras pode interferir na produtividade do milho, segundo Freitas et al. (2021), a competição exercida pelas plantas das pastagens pode limitar o fornecimento de alguns recursos para o milho, tais como: déficits hídricos, nutricionais e a baixa qualidade ou quantidade de luz, ocasionando deficiências que afetam algumas características fisiológicas relacionadas à fotossíntese.

A convivência simultânea entre plantas pode proporcionar uma relação de competição entre as espécies pelos recursos essenciais de crescimento, como água, luz e nutrientes (SANTOS et al., 2017). Essa relação ocorre quando a disponibilidade de recursos no meio é inferior ao requerido pelas espécies presentes na área. Desta maneira, espera-se que os efeitos negativos da competição sejam intensificados à medida que o recurso se torna escasso, e o sucesso de uma espécie em dominar o ecossistema agrícola dependerá da eficiência no uso dos recursos nessa situação.

Avaliações das características fisiológicas relacionadas à fotossíntese, eficiência do uso da água, entre outros parâmetros, podem ser indicadores do nível de interferência. Um monitoramento adequado dos casos de competição entre plantas permite uma identificação precoce das condições sanitárias das lavouras e elaboração de estratégias para reduzir o problema sobre lavouras produtivas.

Atualmente o aparelho analisador de gás por infravermelho (IRGA) tem sido a principal ferramenta utilizada por alguns autores para o monitoramento e detecção de respostas fisiológicas ao estresse das plantas de milho em campo (LEMOS et al.,

2012; GOMES et al., 2011). Porém, apesar de se obter taxa fotossintética, transpiração, condutância estomática, concentração intercelular de CO<sub>2</sub> e eficiência do uso da água que irá refletir diretamente no desenvolvimento normal da planta o método possui uma aplicabilidade menor em larga escala impedindo a análise de grandes lavouras em curto espaço de tempo.

Trabalhos recentes mostraram que bandas multiespectrais cuidadosamente selecionadas em conjunto com ferramentas sofisticadas de aprendizado de máquina, também conhecido como algoritmos, podem resultar em abordagens sensíveis para a detecção precoce de uma variedade de características da planta, incluindo assinaturas de estresse (GUO et al., 2021).

Segundo JENSEN (1983) a condição fisiológica das plantas pode ser descrita pelo seu comportamento espectral onde a vegetação no espectro do visível é controlado pelos pigmentos de clorofila, carotenoides e xantofila presentes na camada mesófila das folhas. Quando a vegetação se encontra em condições de estresse hídrico ou de ressecamento, a produção de clorofila é reduzida e a vegetação passa a absorver menor quantidade de radiação. A vegetação verde e sadia reflete na região do infravermelho próximo cerca de 45 a 50% da energia que chega. O restante da energia (outros 45 a 50%) é praticamente transmitido para as camadas inferiores ou adjacentes do dossel.

Diante disso, se faz necessário a proposta de um modelo de previsão baseado em análises fisiológicas feitas com o IRGA e em combinações de bandas espectrais, que aplicado sobre imagens capturadas por VANTs, portando sensores multiespectrais, possibilite um diagnóstico que descreva de forma rápida e confiável as condições sanitárias da lavoura, onde seja possível diagnosticar de forma indireta o estresse fisiológico da convivência do milho com o capim braquiária ao longo do seu ciclo de cultivo.

## 1.1 Objetivo Geral

Avaliar o comportamento fisiológico, biométrico e espectral da cultura do milho (*Zea mays*) em consórcio com diferentes densidades de plantio do capim braquiária para obtenção de um modelo de previsão a partir de imagens aéreas.

### 1.1.1 Objetivos Específicos

- Analisar características fisiológicas e biométricas do milho em convivência com densidades de capim braquiária;
- Caracterizar o comportamento espectral da cultura do milho em convivência com a braquiária ao longo de distintos estádios fenológicos.
- Estabelecer correlações entre as variáveis fisiológicas e biométricas do milho e os índices espectrais derivados de imagens aéreas obtidas por VANTs, considerando diferentes densidades de braquiária.
- Desenvolver e validar modelos de previsão capazes de estimar o desempenho fisiológico e biométrico do milho em convivência com o capim braquiária, por meio de dados espectrais obtidos por sensoriamento remoto.

## 1.2 Hipóteses

- As diferentes populações de capim braquiária em convivência com a cultura do milho promove modificações de ordem fisiológica, biométricas e espectrais por competirem pelos recursos necessários para seu desenvolvimento.
- Sensores ópticos ativos possibilitam em tempo real o diagnóstico da condição espectral e espacial da lavoura do milho em convivência com a braquiária permitindo uma ilação sobre condições de estresse de competição da cultura sofrido.
- As bandas multiespectrais capturas pelo sensor da câmera MicaSense expressa valores de refletância condicionados por variações da atividade da vegetação, de ordem fisiológica ou biométrica.
- Combinações matemáticas de diferentes bandas espectrais permitem a composição de modelos de previsões das condições fisiológicas e biométricas

do milho em convivência com a braquiária, possibilitando a substituição de aparelhos que façam medidas pontuais nas lavouras.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 Consórcio do milho/pastagem

O consórcio de forrageira perene com o milho vem sendo utilizado como alternativa para aumentar a produção de grãos e a cobertura morta para plantio direto, proporcionando maior retorno das culturas (CECCON et al., 2014), sendo que o produtor pode ainda utilizar os consórcios ou a rotação de culturas graníferas com forrageiras, para a implantação e/ou recuperação de pastagens (REZENDE et al., 2022). No entanto, a população de plantas forrageiras pode interferir na produtividade do milho e o estabelecimento adequado dessa população depende da germinação das sementes, e não apenas da taxa de viabilidade.

Segundo Ceccon et al. (2018) estudando consórcio milho-braquiária com densidades populacionais da forrageira no Centro Sul do Brasil, observou efeito semelhante onde o milho apresentou redução linear na produtividade de grãos com aumento da população de plantas de *B. brizantha* e redução quadrática em função da população de *B. ruziziensis*. O aumento na população de plantas de braquiária eleva a sua produtividade de massa, mas reduz a produtividade de massa do milho. Sendo indispensável o manejo correto dessas culturas para obter bons resultados durante o ciclo, uma vez que o aumento na densidade de plantas forrageiras reduz a produção de massa e grãos de milho.

De acordo com Silva et al. (2015), a produtividade de grãos é afetada negativamente em densidade de braquiária superior a 15 plantas m<sup>2</sup> e que existe uma interferência da *U. brizantha* sobre o milho, em plantio simultâneo, reduzindo os teores de fósforo, cálcio e magnésio, independentemente da densidade de plantas. A produtividade de grãos e o teor de nitrogênio são reduzidos em densidades de braquiária superiores a 15 plantas m<sup>2</sup>. Segundo o mesmo autor forrageiras implantadas em integração ocorrem interferências interespecíficas, provocando menor crescimento e desenvolvimento das espécies, devido a picos e demandas de nutrientes, água e luz, inviabilizando assim o sistema. A competição no milho tem sido vista tradicionalmente como um processo impulsionado pela limitação de recursos.

O cultivo intenso feito de forma consorciada estabelece condições de competição, especialmente quando plantadas ao mesmo tempo. Para controlar a competição entre culturas que ocupam a mesma área podem ser utilizadas técnicas culturais, que incluem densidade de plantas e características do gênero, que podem retardar a competição inicial da forrageira com a cultura principal (MAKINO et al, 2019).

A competição entre plantas pode ser explicada por mecanismos fisiológicos em todo o nível da planta. Em sistemas consorciados, a competição exercida pelas plantas das pastagens pode limitar o fornecimento de alguns recursos para a cultura do milho, tais como: déficits hídricos, nutricionais e a baixa qualidade ou quantidade de luz, ocasionando deficiências que afetam algumas características fisiológicas relacionadas à fotossíntese (FREITAS et al., 2021).

Avaliações das características fisiológicas relacionadas à fotossíntese, eficiência do uso da água, entre outros parâmetros, podem ser indicadores do nível de interferência e tem sido estudada por vários autores mostrando que a adoção de práticas culturais, como o arranjo espacial de plantas, pode ser considerada uma das formas de amenizar a competição interespecífica em cultivos consorciados (TAKASU et al., 2013; CECCON et al., 2014).

## **2.2 Fisiologia da cultura do milho em consórcio**

O desenvolvimento das plantas de milho é afetado diretamente por fatores ambientais tais como temperatura, radiação solar e disponibilidade hídrica, ocasionando estresses fisiológicos sobre estas, que são determinantes na produtividade final da lavoura. Contudo, dentro de uma determinada população de plantas em densidades e condições ambientais ideais, o manejo correto impede perdas de rendimento de uma lavoura de milho pela competição com outra gramínea (LORENZETTI et al., 2023).

A fisiologia da planta do milho em convivência com pastagem ou plantas daninhas sofre efeitos negativos sobre a transpiração, condutância estomática e taxa fotossintética, principalmente sob restrição hídrica em diferentes intensidades (FREITAS et al., 2020).

Silva (2014) avaliando o efeito da densidade populacional da braquiária sobre as características fisiológicas e produtivas do milho e da forrageira em consórcio

observou que o aumento da densidade da braquiária resultou em redução linear da condutância estomática, taxa fotossintética, taxa transpiratória, mas não alterou a eficiência do uso da água do milho. As características fisiológicas da braquiária foram influenciadas negativamente pelo sombreamento do milho. Os resultados refletiram diretamente nas produções das espécies, sendo que em altas densidades de plantas de braquiária (acima de 8 plantas m<sup>2</sup>) a produção do milho foi reduzida em valores superiores a 25 %, enquanto a braquiária tem sua biomassa diminuída em aproximadamente 85% em comparação ao seu monocultivo.

Em outro trabalho, segundo Rodrigues et al. (2014), estudando características fisiológicas de milho e *Urochloa brizantha* em cultivo consorciado com relação ao tempo de emergência da braquiária, as plantas de milho apresentaram menores transpiração, taxa fotossintética, condutância estomática e eficiência do uso da água nos tratamentos com emergência precoce da braquiária. As plantas que surgiram antes do milho obtiveram uma vantagem competitiva sobre a cultura agrícola, pois estavam prontas para absorver maiores quantidades de água e nutrientes. Sob deficiência hídrica moderada, foi constatado que o milho apresentou diminuição da fotossíntese devido à redução da condutância estomática, levando ao fechamento estomático e à redução da transpiração.

O resultado fisiológico das plantas de milho também foi observado por Freitas et al. (2021), onde avaliando as características fisiológicas do milho consorciado com diferentes arranjos de plantas de capim braquiária observou que o aumento da densidade do capim braquiária provocou alterações prejudiciais na eficiência do uso da água com consequências diretas na produtividade da cultura. Segundo o mesmo a resposta fisiológica e a produtividade do milho dependem do arranjo de plantas e do manejo adotado.

A interceptação de radiação solar, absorção de água e nutrientes, além da competição intraespecífica é ocasionado especialmente pela densidade populacional e tem influência direta na produtividade do milho (VIAN et al., 2016).

As limitações impostas pela competição entre plantas podem influenciar vários processos metabólicos das plantas, como o fechamento estomático, redução da condutância estomática, redução da fotossíntese e transpiração, levando ao declínio da taxa de crescimento (RODRIGUES et al., 2014; MAKINO, 2018).

A competição entre o consórcio milho/pastagem pode ser amenizado com o uso do controle químico. Segundo Rodrigues et al. (2014) analisando características

fisiológicas do milho e da *Urochloa brizantha* constatou que subdoses de herbicidas promoveram um aumento na fotossíntese, na condutância estomática, na transpiração, e nas taxas de eficiência do uso de água em plantas de milho e reduziram as mesmas variáveis em plantas de braquiária. A maior disponibilidade de nutrientes aumentou também a taxa fotossintética da cultura.

### **2.3 Estresse fisiológico das plantas de milho**

Em diferentes regiões do mundo, estresses abióticos, incluindo frio, seca, deficiência de nutrientes, toxicidade, salinidade e inundações, minimizam a taxa de produção agrícola. Em condições ambientais de campo, as plantas experimentam vários estresses ambientais ao mesmo tempo (RAZA et al., 2020). Bianchi et al. (2016) afirmam que entre os fatores abióticos que podem causar estresse em vegetais estão respectivamente: água, radiação, temperatura, gases e minerais.

O estresse biótico envolve competições interespecíficas e intraespecíficas com outros organismos vivos, bem como doenças causadas por patógenos fúngicos e bacterianos, ervas daninhas, pragas de insetos e/ou danos às plantas por nematoides, protistas, vírus (MADANI et al., 2019).

As interações bióticas quanto as abióticas podem afetar a sobrevivência ou o sucesso das espécies de plantas . As mudanças ambientais de curto prazo podem ser refletidas na mudança das taxas de fluxo de fotossíntese, respiração e transpiração ( Damm et al., 2018 ). O estresse que ocorre durante períodos de longo prazo durante diferentes estágios de desenvolvimento pode afetar o crescimento de forma variada.

A competição das plantas cultivadas com ervas daninhas afeta a quantidade e a qualidade da produção, assim como a eficiência de aproveitamento dos recursos disponíveis no ambiente, principalmente no que diz respeito às características fisiológicas associadas à fotossíntese e ao acúmulo de massa.

Segundo Lemos et. al., (2012) estudando a competição por plantas no milho observou que o estresse ocasionado na competição por plantas influenciou os aspectos fisiológicos avaliados nas plantas de milho reduzindo a fotossíntese, a transpiração, provocando maior capacidade de interferência no comportamento morfológico do milho, reduzindo a razão de massa foliar e aumentando a razão de massa radicular e maior capacidade de interferência no acúmulo de matéria seca total do milho, em comparação com áreas sem competição.

## 2.4 Comportamento espectral da vegetação em estresse

Estudos têm demonstrado o potencial das ferramentas espectrais para a detecção de respostas das plantas a vários fatores de estresses biótico e abiótico. A utilização de tecnologias de detecções remotas na agricultura é de grande interesse, permitindo medições não destrutivas e que podem ser utilizadas para investigação e aplicações de campo (GIROLAMO-NETO et al., 2019; RONAY et al., 2021).

Os estresses das plantas podem ser monitorados usando imagens ou espectrometria de folhas de plantas nas bandas de ondas visível (vermelho-verde-azul ou RGB), infravermelho próximo (NIR), infravermelho (IR) e ultravioleta (UV). A geração de imagens em vários comprimentos de onda específicos (imagem multiespectral) ou em uma ampla gama de comprimentos de onda (imagem hiperespectral) pode fornecer informações excepcionais sobre o estresse da planta e as doenças subsequentes (ZUBLER E YOON, 2022).

O padrão espectral da vegetação está relacionado com os pigmentos fotossintéticos, onde alterações no teor de clorofila resultantes do estresse alterarão a maneira como a planta interage com a energia luminosa. Uma diminuição no teor de clorofila pode ocorrer quando a planta é submetida a estresse, que pode ser caracterizado de várias maneiras, incluindo um aumento da refletância próximo a 700 nm (ZHU et al., 2020) e diminuição da refletância na faixa de 530 a 630 nm (LICHTENTHALER et. al., 1996). Outros pigmentos além da clorofila, como carotenos (GITELSON, et al., 2002) e xantofilas (VILFAN et al., 2018), também podem alterar as propriedades de refletância de uma planta. Sendo assim, quando a vegetação se encontra em condições de estresse hídrico ou de ressecamento, a produção de clorofila é reduzida e a vegetação passa a absorver menor quantidade de radiação.

O déficit hídrico é um dos estresses agrícolas provocados em plantas mais estudados por sensoriamento remoto. Dam et al., (2022) observou em um período de duas semanas, medindo o estado hidráulico e fisiológico das plantas de milho in situ e complementados com extensas observações aéreas com fluorescência de clorofila induzida pelo sol, índices de vegetação sensíveis à fotossíntese, pigmento e teor de água e temperatura da superfície terrestre. Observaram uma resposta dupla do infravermelho distante com fluorescência de clorofila induzida pelo sol aumentando em curto prazo após a manifestação da limitação hídrica do solo e uma diminuição posteriormente.

Na região do infravermelho próximo (0.74 a 1.1  $\mu\text{m}$ ) a vegetação reflete grande quantidade de energia. A energia refletida é bem correlacionada com a quantidade de biomassa produzida pelas plantas. Esta correlação é observada porque o principal fator que controla a reflectância no infravermelho próximo são os espaços intercelulares presentes na camada mesófila. A vegetação verde e sadia reflete na região do infravermelho próximo cerca de 45 a 50% da energia que chega. O restante da energia (outros 45 a 50%) é praticamente transmitido para as camadas inferiores ou adjacentes do dossel (JENSEN, 1983).

As imagens obtidas por câmera digital RGB (vermelho, verde e azul) são as mais utilizadas para identificação de plantas devido ao seu baixo custo, baixo peso e alta resolução. Operando no mesmo espectro eletromagnético sobre o qual o olho humano opera, podem ser utilizados na obtenção de características morfológicas incluindo altura, área foliar, forma, detecção e contagem de órgãos, estimativa de densidade de planta e discriminação de planta de ervas daninhas, entre outros. A forte integração entre o hardware embarcado e o sistema UAS (Unmanned Aerial System) é viabilizada pela coleta simultânea de imagens RGB e dados de georreferenciamento (GPS) a bordo, o que reduz significativamente problemas posteriores relacionados ao registro e alinhamento espacial das imagens (ISLAM et al., 2020).

Estudos recentes demonstraram que a utilização de bandas multiespectrais criteriosamente selecionadas, aliada a técnicas avançadas de aprendizado de máquina (Machine Learning – ML), permite o desenvolvimento de abordagens altamente sensíveis para a detecção precoce de diversas características fenotípicas das plantas, incluindo assinaturas espectrais associadas a condições de estresse biótico e abiótico. (GUO et al, 2021).

## **2.5 Veículos aéreos não tripulados (VANTS) no monitoramento de plantas**

Os VANTs ou Aeronaves Remotamente Pilotadas (RPA) são aeronaves capazes de serem operadas por controle remoto ou autonomamente e diversas aplicações têm sido empregadas no seu uso por todo o mundo (FLOREANO E WOOD, 2015).

O sistema dos VANTS apresenta a possibilidade de coletar dados facilmente implementáveis em tempo real, permitindo que os operadores coletem dados mesmo

com condições climáticas desfavoráveis, sob os quais os sistemas de detecção por satélite falham ou produzem conjuntos de dados muito alterados. Embora os sistemas de VANTs não ofereçam a mesma cobertura territorial que os satélites, eles oferecem uma resolução espacial e temporal que outros sistemas não oferecem (ESPOSITO et al., 2021).

Segundo Peña et al., (2013) entre as vantagens obtidas no uso de VANTs pode se citar a aplicação no sensoriamento remoto reduzindo custos para a obtenção de imagens aéreas, maior flexibilidade para a aquisição de imagens em alta resolução, possibilidade de execução, facilidade e velocidade de incorporação de novas tecnologias.

A identificação de estresses em plantas por meio de VANTs é possível usando dados de sensores remotos e processamento de imagem pós voo para criar mapas de sanidade de plantas, podendo facilmente diferenciar áreas de cultivo saudáveis, especializadas na lavoura, de outras áreas necessitando de algum manejo sanitário (MERROTO JR, et al., 2012).

## **2.6 Avaliação da fisiologia das plantas por algoritmos**

Os métodos baseados em física abriram caminhos atraentes para entender melhor as relações de causa e efeito sobre a fisiologia das plantas e usar simultaneamente o conjunto completo de variáveis espectrais. Sendo uma abordagem promissora fornecida pelo modelo de observação do dossel do solo, fotoquímica e fluxos de energia e suas versões verticalmente heterogêneas que combina abordagens de transferência radiativa com fotossíntese e modelagem de balanço de energia (JENSEN, 2009).

A avaliação da fisiologia das plantas por meio de algoritmos tem sido uma área crescente de pesquisa nos últimos anos, impulsionada pelo rápido avanço da tecnologia de sensores e computação. Esses algoritmos geralmente utilizam dados espectrais coletados por sensores para modelar e prever o desempenho fisiológico das plantas, permitindo assim a otimização do crescimento e produção (BARZIN et al., 2020).

Os algoritmos usados na avaliação da fisiologia das plantas incluem técnicas de aprendizado de máquina, como redes neurais e algoritmos genéticos. Essas

técnicas permitem que os algoritmos aprendam com os dados e possam fazer previsões precisas sobre o estado fisiológico das plantas e como elas podem responder a diferentes condições ambientais (ASAARI et al., 2022; LIU et al., 2021; MARTINS et al., 2021)

Em estudo realizado por HAN et al. (2019) foi usada uma combinação de sensores de alta resolução e algoritmos de aprendizado de máquina para prever a produção de plantas de milho e descobriram que as previsões baseadas em algoritmos de floresta aleatória mais precisas em comparação com os de regressão linear múltiplas, máquina de vetor de suporte e vizinho mais próximo, isto baseado nas medições realizadas em campo.

Outro estudo de Barzin et al. (2020) empregou algoritmos de aprendizado de máquina para prever a produtividade do milho com base em dados coletados por sensores. Os autores encontraram uma correlação significativa entre os dados coletados e a produtividade. Segundo eles à medida que o desenvolvimento do milho avançava, os modelos previam o rendimento final de grãos com mais precisão.

Em estudo publicado por Ampatzidis e Partel (2019) foi proposto um algoritmo baseado em inteligência artificial para avaliar a saúde de plantas de citros. Pequenos VANTs, imagens multiespectrais e redes neurais convolucionais de aprendizado profundo para avaliar características fenotípicas em culturas cítricas. O algoritmo foi treinado com imagens de folhas de citros saudáveis e infectadas por uma doença fúngica, e conseguiu detectar a presença da doença com precisão superior a 95%.

Brewer et al., 2022, utilizando um algoritmo de regressão floresta aleatória previu de forma otimizada indicadores na fenotipagem do milho em estresse hídrico ao longo do período de crescimento. Olhando para os resultados do estudo, pode-se concluir que a temperatura foliar e a condutância estomática são indicadores adequados para quantificação.

### **3. CONSIDERAÇÕES FINAIS**

O uso da tecnologia dos VANTs para a obtenção de imagens oferece uma função operacional superior em relação a coleta de informações pontuais de extensos campos de cultivos agrícolas, demandando muito tempo e custos.

A utilização de sensores ópticos ativos para o diagnóstico da condição nutricional, populacional, volume da biomassa, entre outras informações já vem sendo

utilizada comercialmente para o levantamento e recomendação de manejo na agricultura. A implementação dessa tecnologia na avaliação das condições fisiológicas da lavoura, garante uma maior rapidez na tomada de decisão comparado com avaliações pontuais realizadas em campo por meio de equipamentos como o analisador de gás infravermelho.

O uso da tecnologia de interpretação de imagens por um algoritmo específico que correlacione o espectro das plantas, observados em imagens de VANTs em diferentes altitudes, e a fisiologia de plantas de milho em convivência com o capim braquiária facilita o monitoramento e identificação por profissionais em área agrícola de estresses em plantas, podendo aplicar um manejo em tempo hábil ampliando os ganhos produtivos e, conseqüentemente financeiros.

#### 4. REFERÊNCIAS BIBLIOGRÁFICAS

ASAARI, M. S. M.; MERTENS, S.; VERBRAEKEN, L.; DHONDT, S.; INZÉ, D.; BIKRAM, K.; SCHEUNDERS, P. Non-destructive analysis of plant physiological traits using hyperspectral imaging: A case study on drought stress. **Computers and Electronics in Agriculture**, v. 195, p. 106806, 2022.

AMPATZIDIS, Y.; PARTEL, V. Fenotipagem de alto rendimento baseada em UAV em citros utilizando imagens multiespectrais e inteligência artificial. **Sensoriamento remoto**, v. 11, n. 4, p. 410, 2019.

ATZBERGER, C. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013.

BARZIN, R.; PATHAK, R.; LOTFI, H.; VARCO, J.; BORA, GC. Use of UAS Multispectral Imagery at Different Physiological Stages for Yield Prediction and Input Resource Optimization in Corn. **Remote sensing**, v. 12, n. 15, p. 2392, 2020.

BREWER, K.; CLULOW, A.; SIBANDA, M.; GOKOOL, S.; ODINDI, J.; MUTANGA, O.; NAIKEN, V.; CHIMONYO, V. G.P.; MABHAUDHI, T. Estimativa da temperatura foliar do milho e condutância estomática como indicadores de estresse hídrico com base em imagens ópticas e térmicas adquiridas usando uma plataforma de Veículo Aéreo Não Tripulado (UAV). **Drones**, v. 6, n. 7, p. 169, 2022.

BIANCHI, L.; GERMINO, G.H.; SILVA, M. de A. Adaptação das plantas ao déficit hídrico. **Acta Iguazu**, v. 5, n. 4, p. 15-32, 2016.

CECCON, G.; SILVA, J. F. DA; NETO, A. L. N.; MAKINO, P. A.; SANTOS, A. DOS. Produtividade de milho safrinha em espaçamento reduzido com populações de milho e de *Brachiaria ruziziensis*. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v. 13, n. 3, p. 326-335, 2014.

CECCON, G.; DA SILVA, J. F.; MAKINO, P. A.; NETO, A. L. N. Consórcio milho-braquiária com densidades populacionais da forrageira no centro-sul do Brasil. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v. 17, n. 1, p. 157-167, 2018.

DAMM, A.; COGLIATI, S.; COLOMBO, R.; FRITSCHÉ, L.; GENANGELI, A.; GENESIO, L.; HANUS, J.; PERESSOTTI, A.; RADEMSKE, P.; RASCHER, U.; SCHUETTEMAYER, D.; SIEGMANN, B.; STURM, J.; MIGLIETTA, F. Response times of remote sensing measured sun-induced chlorophyll fluorescence, surface temperature and vegetation indices to evolving soil water limitation in a crop canopy. **Remote Sensing of Environment**, v. 273, 2022.

DOS SANTOS, O. L.; PADOLFI, A. S.; RAMALDES, G. P. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v.14, n.1, p.145-165, 2018.

SANTOS, H. G. DOS; JACOMINE, P. K. T.; ANJOS, L. H. C. DOS; OLIVEIRA, V. A. DE; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. DE; ARAUJO FILHO, J. C. DE; OLIVEIRA, J. B. DE; CUNHA, T. J. F. **Sistema brasileiro de classificação do solo**. 5. ed. Brasília: Embrapa, 2018.

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. 1-11, 2021.

EMBRAPA. **Manual de análises químicas de solos, plantas e fertilizantes**. Ed. DA SILVA, F. C. Brasília: EMBRAPA informação tecnológica, 2009.

FLOREANO, D.; WOOD, R.J. Science, technology and the future of small autonomous drones. **Nature**, v. 521, p. 460-466, 2015.

FREITAS, C. D.; PAMPLONA, J. D. P.; LINS, H. A.; SOUZA, M. D. F.; DOMBROSKI, J. L.; SILVA, D. V. Gaseous exchanges of corn and weeds under competition and

water regimes. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 24, p. 465-473, 2020.

FREITAS, M.A.; SILVA, D.V.; PEREIRA, G.A.; SOUZA, W.M.; NUNES JR, J.; SILVA, A.A. Características fisiológicas do milho consorciado com diferentes arranjos de plantas de capim-maruca. **Advances in Weed Science**, v. 39, 2021.

GIROLAMO-NETO, C. D.; SANCHES, I. D. A.; NEVES, A. K.; PRUDENTE, V. H. R.; KÖRTING, T. S.; PICOLI, M. C. A.; ARAGÃO, L. E. O. E. C. D. Assessment of texture features for bermudagrass (*Cynodon dactylon*) detection in sugarcane plantations. **Drones**, v.3, n.2, p.36, 2019.

GITELSON, A. A.; ZUR, Y.; CHIVKUNOVA, O. B.; MERZLYAK, M.N. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochem Photobiol.** v. 75, p. 272–281, 2002.

GOMES, K. R.; AMORIM, A. V.; FERREIRA, F. J.; A FILHO, F. L.; LACERDA, C. F.; GOMES-FILHO, E. Respostas de crescimento e fisiologia do milho submetido a estresse salino com diferentes espaçamentos de cultivo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, p. 365-370, 2011.

GALON, L.; CONCENÇO, G.; TIRONI, S. P.; ROCHA, P. R. R.; SILVA, A. F.; ASPIAZÚ, I.; FERREIRA, E. A.; SILVA, A. A.; BORGES, E. T. Influence of brachiaria brizantha in physiological characteristics related to photosynthesis and efficient use of water in sugarcane. **Planta Daninha**, Viçosa, v. 29, p. 1037-1043, 2011.

GUO, W.; CARROLL, M. E.; SINGH, A.; SWETNAM, T. L.; MERCHANT, N., SARKAR, S.; ASHEESH, K. S.; GANAPATHYSUBRAMANIAN, B. UAS-based plant phenotyping for research and breeding applications. **Plant Phenomics**, v. 2021, 2021.

HAN, L.; YANG, G.; DAI, H.; XU, B.; YANG, H.; FENG, H.; LI, Z.; YANG, X. Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. **Plant methods**, v. 15, n. 1, p. 1-19, 2019.

ISLAM, N.; RASHID, M. M.; WIBOWO, S.; WASIMI, S.; MORSHED, A.; XU, C.; MOORE, S. Machine learning based approach for Weed Detection in Chilli field using RGB images. *Advances in natural computation, fuzzy systems and knowledge discovery*. **Springer International Publishing**, p. 1097-1105, 2020.

JENSEN, J. R. Biophysical remote sensing. **Annals of the Association of American Geographers**, v. 73, n. 1, p. 111-132, 1983.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma perspectiva sobre recursos terrestres**. São José dos Campos: Parêntese, 2009.

LEMONS, J. P.; GALVÃO, J. C. C.; SILVA, A. A.; FONTANETTI, A.; CORRÊA, M. L. P.; CECON, P. R. Morfofisiologia de plantas de milho em competição com picão-preto e trapoeraba submetidas a roçada. **Planta Daninha**, v. 30, p. 487-496, 2012.

LIU, S.; JIN, X.; NIE, C.; WANG, S.; YU, X.; CHENG, M.; SHAO, M.; WANG, Z.; TUOHUTI, N.; BAI, Y. LIU, Y. Estimating leaf area index using unmanned aerial vehicle data: shallow vs. deep machine learning algorithms. **Plant Physiology**, v. 187, n. 3, p. 1551-1576, 2021.

LICHTENTHALER, H. K.; GITELSON, A.; LANG, M. Non-destructive determination of chlorophyll content of leaves of a green and an aurea mutant of tobacco by reflectance measurements. **J. Plant Physiol.** v. 148, p. 483–493, 1996.

LORENZETTI, J. G.; RODRIGUES, M. A.; DE PAIVA SOARES, A.; VIEIRA, C. R. Densidade de plantas e os efeitos nas características agrônômicas, temperatura e umidade do solo em consórcio milho-braquiária. **Nativa**, v. 11, n. 1, p. 101-107, 2023.

MADANI, B.; MIRSHEKARI, A.; IMAHORI, Y. Physiological responses to stress. In: *Postharvest physiology and biochemistry of fruits and vegetables*. **Woodhead Publishing**, p. 405-423, 2019.

MARTINS, G. D.; SILVA, O. F. D.; CARMO, G. J. D. S.; CASTOLDI, R.; SANTOS, L.; CHARLO, H. C. D. O. Estimation of biometric, physiological, and nutritional variables

in lettuce seedlings using multispectral images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, p. 689-695, 2021.

MAKINO, P. A. Desempenho agrônômico e fisiológico de milho em arranjos de plantas, com e sem braquiária, no verão e outono-inverno. Orientador: Gessi Ceccon, 2018. Tese (Doutorado em Agronomia) - Universidade Federal de Grande Dourados, Dourados, 2018. Disponível em: <https://repositorio.ufgd.edu.br/jspui/bitstream/prefix/476/1/PriscilaAkemiMakino.pdf> acesso: 27 nov. 2022, às 09:44

MAKINO, P. A.; CECCON, G.; FACHINELLI, R. Produtividade e teor de nutrientes em populações de milho safrinha solteiro e consorciado com braquiária. **Revista Brasileira de Milho e Sorgo**, v. 18, n. 2, p. 206-220, 2019.

MEROTTO JR, A.; BREDEMEIER, C.; VIDAL, R. A.; GOULART, I. C. G. D. R.; BORTOLI, E. D.; ANDERSON, N. L. Reflectance indices as a diagnostic tool for weed control performed by multipurpose equipment in precision agriculture. **Planta Daninhas**, v. 30, p. 437-447, 2012.

OLIVEIRA, RA; NASI, R.; NIEMELÄINEN, O.; NYHOLM, L.; ALHONOJA, K.; KAIVOSOJA, J.; JAUHAINEN, L.; VILJANEN, N.; NEZAMI, S.; MARKELIN, L. Estimadores de aprendizado de máquina para a quantidade e qualidade de pastos usados para produção de silagem usando espectrometria de imagem baseada em drones e fotogrametria. *Sensoriamento Remoto do Meio Ambiente*, v.246, p.1-20, 2020.

PEÑA-BARRAGÁN, J. M.; KELLY, M.; DE CASTRO, A.I.; LÓPEZ-GRANADOS, L. Object-based approach for crop row characterization in UAV images for site-specific weed management. **Proc. GEOBIA**, v. 1, p. 426-430, 2012.

PEÑA, J. M; TORRES-SÁNCHEZ, F.; CASTRO, A. I.; KELLY, M; LÓPEZ-GRANADOS, F. Weed Mapping in Early- Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. **PloS one**, v. 8, n. 10, p. e77151, 2013.

QGIS. Geographic Information System QGIS - Open Source Geospatial Foundation Project Versão 3.16, 2019. Disponível em: <<http://qgis.osgeo.org>>. Acesso em: 22 de abril de 2023

RAZA, A.; CHARAGH, S.; SADAQAT, N.; JIN, W. Arabidopsis thaliana: Model plant for the study of abiotic stress responses. **The Plant Family Brassicaceae: Biology and Physiological Responses to Environmental Stresses**, p.129-180, 2020.

REZENDE, A. V.; DO PRADO, R. A. T.; FAUSTINO, T. F.; FLORENTINO, L. A.; DIAS, N. C.; DOS SANTOS, P. C. D. O. Potencial agrônômico e valor nutritivo de forrageiras implantadas na integração com a cultura do milho. **Research, Society and Development**, v. 11, n. 4, 2022.

RODRIGUES, O. L.; GALVÃO, J. C. C.; FERREIRA, E. A.; SILVA, D. V.; SANTOS, M. V., FERREIRA, L. R.; & FELIPE, R. S. Physiologic characteristics of corn and Urochloa brizantha (Hochst. ex A. Rich.) RD Webster in intercropping cultivation. **Chilean journal of agricultural research**, v. 74, n. 3, p. 257-262, 2014.

RONAY, I.; EPHRATH, J. E.; EIZENBERG, H.; BLUMBERG, D. G.; MAMAN, S. Hyperspectral reflectance and indices for characterizing the dynamics of crop–weed competition for water. **Remote Sensing**, v. 13, n. 3, 513, 2021.

SANTOS, Claiton. **Monitoramento aéreo e diagnóstico de plantas daninhas de difícil controle no sudoeste goiano**, 2019. Disponível em: <https://repositorio.ifgoiano.edu.br/handle/prefix/610>.

SILVA, D. V. **Efeitos da densidade populacional da braquiária sobre as características fisiológicas e produtivas do milho e da forrageira em consórcio**. Orientador: Tocio Sedyama, 2014. Tese (Doutorado em Fitotecnia) – Universidade Federal de Viçosa, Viçosa, 2014. Disponível em: <https://www.locus.ufv.br/bitstream/123456789/1240/1/texto%20completo.pdf> acesso: 26 nov. 2022, às 9:43

SILVA, D. V.; PEREIRA, G. A. M.; FREITAS, M. A. M. D.; SILVA, A. A. D.; SEDIYAMA, T.; SILVA, G. S.; FERREIRA, L. R.; CECON, P. R. Produtividade e teor de nutrientes do milho em consórcio com braquiária. **Ciência Rural**, v45, n.8, p.1394–1400, 2015.

SOUSA, D. M. G. de; LOBATO, E. **Cerrado: correção do solo e adubação**. 2. ed. Brasília: Embrapa, 2004.

TAKASU, A. T.; RODRIGUES, R. A. F.; GOES, R. J.; ARF, O.; HAGA, K. I. Desempenho agrônômico do milho sob diferentes arranjos populacionais e espaçamento entrelinhas. **Agrarian**, Dourados, v. 7, n. 23, p. 34-41, 2013.

USDA - UNITED STATES DEPARTMENT OF AGRICULTURE. Grain: World Markets and Trade. Disponível em: <<https://apps.fas.usda.gov/psdonline/app/index.html#/app/advQuery>>. Acesso em: 20 out. 2022.

VIAN, A. L., SANTI, A. L., AMADO, T. J. C., CHERUBIN, M. R., SIMON, D. H., DAMIAN, J. M., & BREDEMEIER, C. Variabilidade espacial da produtividade de milho irrigado e sua correlação com variáveis explicativas de planta. **Ciência Rural**, v. 46, p. 464-471, 2016.

VILFAN, N.; VAN DER TOL, C.; YANG, P.; WYBER, R.; MALENOVSKÝ, Z.; ROBINSON, S.A.; VERHOEF, W. Extending Fluspect to simulate xanthophyll driven leaf reflectance dynamics. **Remote Sensing Environment**. v. 211, p. 345–356, 2018.

ZUBLER, A. V.; YOON, J. Proximal methods for plant stress detection using optical sensors and machine learning. **Biosensors**, v. 10, n. 12, p. 193, 2020.

ZHU, J.; ELE, W.; YAO, J.; YU, Q.; XU, C.; HUANG, H.; MHAIE, B.; JANDUG, C. Spectral reflectance characteristics and chlorophyll content estimation model of quercus aquifolioides leaves at different altitudes in Sejila Mountain. **Applied Science**, v.10, n. 10, p.3636, 2020.

## COMPORTAMENTO FISIOLÓGICO, BIOMÉTRICO E ESPECTRAL DO MILHO EM CONVIVÊNCIA COM AS DIFERENTES DENSIDADES DE PLANTIO DE CAPIM BRAQUIÁRIA

### RESUMO

O estudo da biometria, fisiologia e características espectrais tem se mostrado relevante para a compreensão do estresse de competição ocasionado sobre a cultura do milho. O objetivo do presente trabalho foi avaliar as características biométricas, fisiológicas e espectral do milho em convivência com densidades variáveis de capim braquiária e em diferentes fases da cultura. O experimento foi implantado no campo em blocos casualizados com 6 repetições. O milho GNZ 7720 VIP3 foi cultivado em consórcio com o capim braquiária (*Urochloa brizantha cv Piatã*) na proporção de 0, 5, 10 e 20 plantas por metro. Aos 20 (V6), 33 (V10), 48 (VT) e 62 (R2). A análise fisiológica foi realizada obtendo a taxa fotossintética líquida, condutância estomática, Carbono interno, transpiração, temperatura foliar e a relação carbono interno/carbono do ambiente. Com as imagens aéreas foram produzidas 5 bandas (azul (B), verde (G), vermelho ®, infravermelho próximo (NIR) e borda do infravermelho (RE). Aos 62 DAS foram mensuradas as características biométricas da cultura do milho, sendo medidas 3 plantas por parcela. No software SISVAR os resultados foram submetidos à análise de variância (teste F), e a comparação entre as médias e interações foi efetuada pelo teste de Tukey a 5% de probabilidade. Observou-se que para as variáveis biométricas houve diferença significativa apenas na altura de plantas (AP) e no número de folhas (NF) realizado com diferentes densidades de competição da braquiária. Enquanto as variáveis fisiológicas não apresentaram diferença significativa entre os tratamentos e as variáveis espectral houve diferença provocada pelos tratamentos na banda B, e nos índices NDVI e GNDVI. Entretanto, todos os atributos fisiológicos e espectrais avaliados apresentaram diferença significativa ao nível de 5% a nível da época da leitura, pode se observar também que não houve interação entre os tratamentos e as épocas de leitura. As diferentes populações de braquiária em competição com o milho não apresentaram diferenças exceto para os valores da banda R, NDVI, GNDVI e altura de planta. Mudanças fisiológicas e espectrais são notáveis ao longo das leituras, refletindo diferentes valores de acordo com a fase de desenvolvimento.

**Palavra-chave:** Biometria; Fisiologia; Espectro e Estresse em plantas.

## ABSTRACT

The study of biometrics, physiology and spectral characteristics has proven to be relevant for understanding the competitive stress caused to corn crops. The objective of this study was to evaluate the biometric, physiological and spectral characteristics of corn in coexistence with variable densities of Brachiaria grass and in different phases of the crop. The experiment was implemented in the field in randomized blocks with 6 replicates. Corn GNZ 7720 VIP3 was grown in consortium with Brachiaria grass (*Brachiaria brizantha* cv. Piatã) at the proportion of 0, 5, 10 and 20 plants per meter. At 20 (V6), 33 (V10), 48 (VT) and 62 (R2). Physiological analysis was performed obtaining the net photosynthetic rate, stomatal conductance, internal carbon, transpiration, leaf temperature and the internal carbon/environmental carbon ratio. With the aerial images, 5 bands were produced (blue (B), green (G), red (R), near infrared (NIR) and infrared edge (RE)). At 62 DAS, the biometric characteristics of the corn crop were measured, with 3 plants per plot being measured. In the SISVAR software, the results were subjected to analysis of variance (F test), and the comparison between the means and interactions was performed by the Tukey test at 5% probability. It was observed that for the biometric variables there was a significant difference only in the plant height (AP) and in the number of leaves (NF) performed with different competition densities of the brachiaria. While the physiological variables did not present a significant difference between the treatments and the spectral variables there was a difference caused by the treatments in the B band, and in the NDVI and GNDVI indices. However, all the physiological and spectral attributes evaluated presented a significant difference at the 5% level at the level of the reading time. It can also be observed that there was no interaction between the treatments and the reading times. The different populations of Brachiaria in competition with corn did not show differences except for the values of the R band, NDVI, GNDVI and plant height. Physiological and spectral changes are notable throughout the readings, reflecting different values according to the development phase.

**Keywords:** Biometrics; Physiology; Spectrum and Stress in plants.

## 1. INTRODUÇÃO

Na agricultura a competição entre as plantas podem resultar em maiores danos econômicos, levando a perdas de produtividade ocasionados por estresses fisiológicos as plantas cultivadas.

Estudos que avaliam estresse na cultura do milho, tem se mostrado relevante para a compreensão das dinâmicas agrônômicas e ecológicas em sistemas de cultivo consorciados ou solteiros infestados por plantas invasoras. Alguns autores tem estudado também a dinâmica da biometria (CECCON et al., 2018; LOBO et al, 2021), fisiologia (RODRIGUES et al., 2014; MAKINO et al., 2019) e características espectrais da cultura do milho (SONG et al., 2024).

Segundo Lemos et. al., (2012) estudando a competição por plantas no milho observou que o estresse ocasionado influenciou os aspectos fisiológicos avaliados nas plantas de milho reduzindo a fotossíntese, a transpiração, provocando maior capacidade de interferência no comportamento morfológico do milho, reduzindo a razão de massa foliar e aumentando a razão de massa radicular e maior capacidade de interferência no acúmulo de matéria seca total do milho, em comparação com áreas sem competição.

Os dados multiespectrais fornecem variadas informações sobre modificações na fisiologia do milho que pode ser utilizada para uma leitura do estado das plantas: altos valores iniciais de reflectância podem ser atribuídos à presença de solo exposto ou vegetação jovem, que reflete mais nas bandas visíveis e borda do vermelho (RE). O declínio subsequente ocorre devido ao aumento da biomassa e do dossel vegetal, que intensificam a absorção de luz, especialmente no vermelho (R) e no azul (B), devido à maior presença de clorofila, mas podem também levar a um declínio precoce no NIR devido à senescência (SUN et al., 2010).

Baseado no pressuposto o efeito espectral de plantas saudias e plantas anormais pode ajudar monitorar em tempo real o efeito do estresse fisiológico na cultura do milho por convivência com o capim braquiária, possibilitando o uso da tecnologia de um manejo de controle eficaz, reduzindo perdas de rendimento da lavoura.

## 1.2. MATERIAL E MÉTODOS

O experimento foi conduzido em área de cultivo agrícola do Instituto Federal do Tocantins, Campus Dianópolis, Tocantins-Brasil, localizado a 11°38'10" de latitude sul, 46°45'55" de longitude oeste e 574 metros de altitude, no período de novembro de 2022 a fevereiro de 2023,


O solo da área foi caracterizado como Latossolo amarelo distrófico típico, franco argilo-arenoso, com as seguintes características químicas (tabela 1):

Tabela 1. Resultado da análise química dos solos da área experimental (EMBRAPA, 2009).

pH (CaCl <sub>2</sub> )	P mg dm <sup>-3</sup>	K mg dm <sup>-3</sup>	Ca	Mg cmol <sub>c</sub> dm <sup>-3</sup>	Al cmol <sub>c</sub> dm <sup>-3</sup>	H+Al
6,1	19	104	5,6	0,9	0	1,20
SB cmol <sub>c</sub> dm <sup>-3</sup>	T	V	MO	Argila %	Silte	Areia
6,77	7,97	85	1,2	22,5	7,5	70

Segundo a Köppen e Geiger o clima é classificado como Aw- clima tropical quente e semiúmido, com sucessão de chuvas durante o verão e o inverno seco. A temperatura média é 22 °C, e uma pluviosidade média anual de 1500mm. Na figura 1 é apresentado os valores registrados para a período da execução do experimento.

Figura 1. Gráfico do regime pluviométrico e datas das leituras.



A variedade de milho cultivada foi o GNZ 7720 VIP3 no espaçamento de 80 cm entre linhas em consórcio com o capim braquiária (*Urochloa brizantha cv Piatã*) na proporção de 0, 5, 10 e 20 plantas por metro. Aos 20 (V6), 33 (V10), 48 (VT) e 62 (R2) dias após a emergência foram feitas análises fisiológicas, biométricas e o levantamento de imagens aéreas, concomitantemente entre as 10-12 horas do dia.

O experimento foi implantado no campo em blocos casualizados com 6 repetições. A área foi dividida 24 parcelas de 12 m<sup>2</sup> cada (3x4m) distribuídos em seis blocos homogêneos (B1, B2, B3, B4, B5 e B6) com espaçamento de 1m entre os mesmos e 1 m entre as parcelas (Figura 2).

Figura 2. Croqui da área experimental.

B1	B2	B3	B4	B5	B6
4	3	2	3	4	1
1	2	4	1	2	3
3	4	1	2	3	4
2	1	3	4	1	2

Densidades de capim braquiária:

- 1- 0 plantas/metro linear
- 2- 5 plantas/metro linear
- 3- 10 plantas/metro linear
- 4- 20 plantas/metro linear

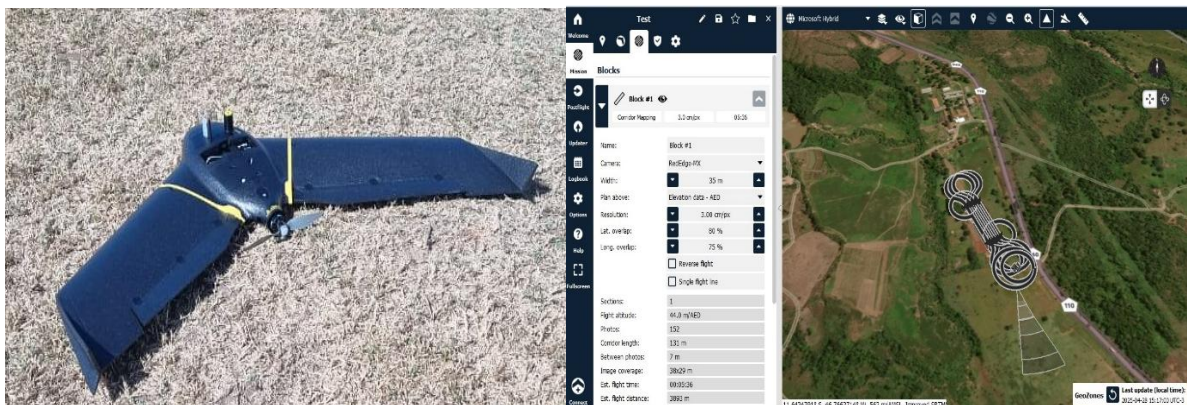
A análise fisiológica foi realizada através das trocas gasosas utilizando o equipamento IRGA – Infrared Gas Analyzer, modelo Li-6400 (Li-Cor, Biosciences Inc., Nebraska, EUA) (Figura 3). Onde foi obtida a taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca) conforme metodologia proposta por Lima et al. (2016). Os teores de CO<sub>2</sub> foram utilizados em 400  $\mu\text{mol m}^{-2} \text{ s}^{-1}$  e a intensidade luminosa em 1500  $\mu\text{mol de fótons m}^{-2} \text{ s}^{-1}$ . As avaliações foram realizadas em folhas jovens, recém-expandidas, não danificadas e bem iluminadas realizadas em triplicata, em plantas diferentes dentro da parcela.

Figura 3. Equipamento IRGA –Infrared Gas Analyzer, modelo Li-6400.



As imagens aéreas foram produzidas utilizando um VANTs de asa fixa EbeeX com câmera multiespectral (Rededge-M) de 5 bandas (azul (B), verde (G), vermelho (R), infravermelho próximo (NIR) e borda do infravermelho (RE)) em altura de voo de 44 metros, correspondendo a 3 cm<sup>2</sup>/pixel de resolução espacial. O intervalo entre disparos foi de dois segundos com uma sobreposição de 75% longitudinal e 80% latitudinal para montagem de um mosaico da área (Figura 4).

Figura 4. VANT de asa fixa EbeeX com câmera multiespectral e plano de voo da área experimental.



Os voos foram realizados sempre ao mesmo horário das leituras com o IRGA (10-12 horas), uma vez também que neste horário a angulação da luz solar incidente é a mais adequada para captura da reflectância.

O trabalho da obtenção dos dados espectrais foi dividido nas seguintes etapas: Captura de imagens em lavouras utilizando VANT; pré-processamento das mesmas

utilizando o software WebODM para calibração da reflectância do alvo (parcelas) por meio dos dados do painel de Calibração; alinhamento das imagens, construção de uma nuvem tridimensional de pontos e construção de um modelo digital de elevação (DEM) para obtenção do ortomosaico.

Após a construção do ortomosaico, estes foram exportados em formato tiff para ambiente SIG, utilizando o software QGIS 3.2, onde foi utilizada a calculadora matricial para determinação dos Índices de Vegetação em cada imagem. Após essa etapa, foram criadas imagens vetoriais para que seja possível um recorte em cada parcela. A partir desse recorte, foi calculada a média de cada índice em cada parcela usando a ferramenta de estatística zonal do software QGIS.

Para a avaliação espectral do milho foram consideradas as bandas: vermelha (R); verde (G); azul (B); infravermelho próximo (NIR) e a borda do vermelho (RE) e os índices vegetativos: índice de vegetação da diferença normalizada (NDVI), índice de vegetação da diferença normalizada verde (GNDVI) e razão simples (SR), segue as equações:

$$NDVI = \frac{NIR - R}{NIR + R}$$

$$GNDVI = \frac{NIR - G}{NIR + G}$$

$$SR = \frac{NIR}{R}$$

Aos 62 DAS foram mensuradas as características biométricas da cultura do milho, sendo medidas 3 plantas por parcela: Altura de planta (AP – cm); Diâmetro de colmo (DC - mm); Número de folhas (NF); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF) e massa seca total (MST) a folhas foram secas em estufa de circulação de ar forçado por 72 horas a 65 °C. Foi medida também a produtividade do milho nas diferentes parcelas experimentais.

Após a obtenção dos dados, os dados obtidos foram submetidos às análises estatísticas utilizando o software SISVAR. Os resultados foram submetidos à análise de variância (teste F), e a comparação entre as médias e interações foi efetuada pelo teste de Tukey a 5% de probabilidade.

### 1.3. RESULTADOS E DISCUSSÃO

Um resumo da análise de variância é apresentado na Tabela 2 com valores dos quadrados médios e coeficientes de variação das variáveis biométricas, fisiológicas e espectrais.

Tabela 2. Valores de quadrado médios baseado em variáveis biométricas, fisiológicas e espectrais do milho submetido a diferentes densidades de competição com braquiária.

FV	Trat	Leit	Leit x trat	Bloco	Res1	Res2	CV 1(%)	CV2(%)
<b>Biométrica</b>								
GI	3			5	15			
AP	182,19*			160,53*	52,87		2,74	
NF	0,498*			0,4964*	0,1482		2,99	
Diam	0,022			0,018	0,2245		8,67	
MFT	11260,32			4705,83	5605,14		17,75	
MST	342,46			129,59	176,85		15,24	
MSF	19,59			9,78	11,64		12,32	
MSC	113,56			34,81	61,99		15,19	
Prod	44220,1			63195,66	72071,83		28,35	
<b>Fisiologia</b>								
GL	3	3	9	5	15	60		
A	22,32	263,55**	23,84	304,99**	33,49	41,56	15,35	17,1
gs	0,00004	0,111**	0,00067	0,0064	0,0023	0,0037	16,1	20,15
Ci	136,58	71317,42**	495,32	11138,29**	581,15	1101,21	16,4	22,58
E	0,206	59,90**	0,28	4,92**	0,69	0,806	11,82	12,78
Tleaf	0,685	78,6**	0,1	58,39**	1,03	1,08	3,06	3,13
Ci/Ca	0,0013	0,383**	0,0029	0,048**	0,0033	0,0085	14,63	23,42
<b>Espectral</b>								
GL	3	3	9	5	75			
R	0,0002**	0,038696**	0,000016	0,000073	0,000025	0,000044	8,40	11,08
G	0,000015	0,006983**	0,000009	0,000079	0,000047	0,000041	6,88	6,4
B	0,000008	0,002547**	0,000002	0,000013	0,000005	0,000008	4,98	6,5
NIR	0,000841	0,179358**	0,000101	0,001362**	0,00031	0,000266	5,31	4,92
RE	0,000035	0,015816**	0,00024	0,000165	0,000078	0,00009	6,47	6,93
NDVI	0,006242*	1,410407**	0,000478	0,002211*	0,000645	0,000936	3,72	4,48
GNDVI	0,001378*	0,322766**	0,000102	0,000601*	0,000291	0,000236	3,25	2,93
SR	14,71	392,1189**	5,5656	5,5824	6,2	5,39	32,07	29,9

Altura de planta (AP – cm); Número de folhas (NF); Diâmetro de colmo (DC - mm); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF); massa seca total (MST); Taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf, °C) e a relação carbono interno/carbono do ambiente (Ci/Ca); Bandas espectrais: vermelha (R); verde (G); azul (B); infravermelho próximo (NIR) e a borda do vermelho (RE) e os índices vegetativos: índice de vegetação da diferença normalizada (NDVI), índice de vegetação da diferença normalizada verde (GNDVI) e razão simples (SR). \*\*,\*: significativo pelo teste F a 1% e 5% de probabilidade respectivamente. Valores sem indicação não significativo pelo teste F a 5% de probabilidade. CV (%): coeficiente de variação.

As variáveis biométricas apresentaram diferença significativa apenas na altura de plantas (AP) e no número de folhas (NF) realizado com diferentes densidades de competição da braquiária. Enquanto as variáveis fisiológicas não apresentaram diferença significativa entre os tratamentos e as variáveis espectral houve diferença provocada pelos tratamentos na banda B, e nos índices NDVI e GNDVI. Entretanto, todos os atributos fisiológicos e espectrais avaliados apresentaram diferença significativa a nível de 5% a nível da época da leitura, pode-se observar também que não houve interação entre os tratamentos e as épocas de leitura.

A análise das variáveis fisiológicas indica que não existem diferenças significativas, o que demonstra a presença de mecanismos homeostáticos na cultura do milho que permitem diminuir os efeitos da competição.

De acordo com Rodrigues et al. (2014), plantas submetidas a condições adversas podem enfrentar situações desfavoráveis alterando suas propriedades fisiológicas, incluindo o fechamento dos estômatos e a diminuição da taxa de fotossíntese, em resposta à escassez de água e à competição entre espécies. Além disso, a eficácia da fotossíntese está profundamente ligada a fatores externos, como a luz disponível e a temperatura do ambiente, que podem ocultar os efeitos diretos da competição em sistemas mistos (Freitas et al., 2020).

A redução da altura das plantas de milho na presença da braquiária pode estar vinculada à limitação no acesso a recursos essenciais, como radiação solar e nutrientes, corroborando com pesquisas que indicam que a competição por esses fatores pode comprometer significativamente o crescimento das culturas agrícolas (Ceccon et al., 2018).

Resultados semelhantes foram observados por Silva et al. (2015), que apontaram que a presença de espécies forrageiras em altas densidades pode comprometer o desenvolvimento inicial do milho, minimizando a disponibilidade de nutrientes essenciais como nitrogênio e fósforo.

No contexto das variáveis espectrais, a influência da competição foi evidente na banda B e nos índices NDVI e GNDVI. O comportamento espectral das plantas está diretamente relacionado à maneira como as folhas absorvem e refletem a luz, sendo a concentração de clorofila um fator determinante nesse processo (JENSEN, 2009). Quando as plantas enfrentam estresse ocasionado pela competição, é previsível uma queda na refletância do vermelho (R) e um aumento na refletância do

infravermelho próximo (NIR), em virtude da diminuição da biomassa e da eficácia fotossintética da cultura.

Segundo Guo et al. (2021) o uso de índices espectrais, como o NDVI, pode ser uma ferramenta eficiente para detectar precocemente condições de estresse em plantas, fornecendo subsídios para estratégias de manejo mais eficazes.

A análise mostrou que as variações nos atributos fisiológicos e espectrais foram relevantes durante as medições, mas não houve interação entre os diferentes tratamentos e os períodos analisados. Isso sugere que a resposta fisiológica e espectral do milho pode ser mais condicionada pela fase de desenvolvimento da planta do que pelas diversas densidades de competição da braquiária. Conforme apontado por Sun et al. (2010), as alterações dos índices espectrais durante o ciclo da cultura estão relacionadas a senescência das folhas e ao aumento da biomassa, servindo como um indicador da eficiência fotossintética ao longo do tempo.

Estudos que avaliam estresse na cultura do milho, tem se mostrado relevante para a compreensão das dinâmicas agrônomicas e ecológicas em sistemas de cultivo consorciados ou solteiros infestados por plantas invasoras. Alguns autores têm estudado também a dinâmica da biometria (CECCON et al., 2018; LOBO et al, 2021), fisiologia (RODRIGUES et al., 2014; MAKINO et al., 2019) e características espectrais da cultura do milho (SONG et al., 2024).

Analisando a competição do milho com a braquiária semeados na mesma época e na linha de plantio permite concluir que a presença da braquiária não influencia o desenvolvimento e produtividade do milho. A competição da braquiária com o milho em diferentes densidades de plantio e semeadura concomitante revela que a emergência posterior da braquiária não afeta o desenvolvimento do milho, ocasionado pelo arranque do milho ser mais rápido, porém é afetado a formação da pastagem que irá apresentar menor desempenho e produtividade, (GARCIA et al., 2013).

Os resultados apresentados na tabela 3 mostram uma análise estatística das respostas fisiológicas do milho em consórcio com diferentes densidades de plantio de braquiária e leituras realizadas ao longo do seu desenvolvimento. Os resultados sugerem que os tratamentos aplicados com diferentes densidades de plantas de braquiária por metro não resultaram em diferenças significativas nas respostas fisiológicas do milho, entretanto as diferentes épocas das leituras influenciaram significativamente essas variáveis.

Tabela 3. Teste de comparação de médias dos atributos fisiológicos do milho submetido a competição com diferentes densidades de plantio da braquiária e em diferentes épocas de desenvolvimento.

Trat. (pl/m)	A	gs	Ci	E	Tleaf	Ci/Ca
0	38,26 a	0,301 a	146,00 a	7,10 a	33,40 a	0,388 a
5	38,72 a	0,299 a	144,24 a	7,12 a	33,25 a	0,387 a
10	36,61 a	0,299 a	147,80 a	6,94 a	33,02 a	0,396 a
20	37,19 a	0,302 a	149,79 a	6,96 a	33,10 a	0,403 a
CV(%)	15,35	16,10	16,40	11,82	3,06	14,63
Erro P	1,18	0,01	4,92	0,17	0,21	0,012
leituras	A	gs	Ci	E	Tleaf	Ci/Ca
1	36,51 ab	0,202 a	66,11 a	4,77 a	35,43 c	0,207 a
2	41,37 b	0,359 b	174,62 b	8,07 c	33,19 b	0,461 b
3	39,17 b	0,316 b	163,58 b	7,12 b	30,99 a	0,428 b
4	33,72 a	0,324 b	183,52 b	8,16 c	33,16 b	0,479 b
CV(%)	17,10	20,15	22,58	12,78	3,13	23,42
Erro P	1,32	0,01	6,77	0,18	0,21	0,019

Taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf;  $^{\circ}\text{C}$ ) e a relação carbono interno/carbono do ambiente (Ci/Ca). Teste Tukey a 5 % de probabilidade

O comportamento do milho, quando em consórcio com a braquiária, é muito influenciado pela velocidade de estabelecimento da forrageira e do aumento da competição por água, luz e nutrientes, o que pode prejudicar o desenvolvimento e consequentemente a produtividade de grãos da cultura (SILVA et al., 2015). No entanto no presente trabalho, a emergência da *U. brizantha* foi observada após a do milho, e esse fato pode ter contribuído para a menor capacidade competitiva das diferentes quantidades de plantas de braquiária por metro.

Ceccon et al. (2018), indicam que a competição entre espécies que coexistem pode ser reduzida quando ocorre uma variação no crescimento inicial, o que possibilita que a planta principal desenvolva seu sistema de radicular e folhas antes da intensificação da competição por recursos ambientais.

Makino et al., (2015) observou efeito parecido quanto as diferentes densidades de plantas de braquiária, onde em cultivo solteiro e consorciado as trocas gasosas e a taxa fotossintética nas folhas de milho não diferiram.

Nunes (2019) analisando o efeito das trocas gasosas e do desempenho dos componentes do rendimento de milho consorciado com a fava em diferentes épocas de semeadura, também observou que a competição entre as plantas não mostrou diferença significativa entre as variáveis analisadas: taxa fotossintética, Condutância estomática e Transpiração.

Ao analisar o crescimento e trocas gasosas na cultura de milho em plantio direto e convencional, Lopes et al., (2019) também encontrou diferenças entre as épocas de leitura, onde demonstra que podem ocorrer variações ao longo dos estádios fenológicos bem como ao longo do dia ou sob estresse hídrico.

A taxa fotossintética (A) apresentou uma variação nas leituras, com a leitura 2 e 3 apresentando a maior taxa de fotossíntese ( $41,37$  e  $39,17 \mu\text{mol CO}_2 \text{ m}^{-2}\text{s}^{-1}$ ), significativamente maior do que leitura 4 ( $33,72 \mu\text{mol CO}_2 \text{ m}^{-2}\text{s}^{-1}$ ), porém estatisticamente semelhante a leitura 1 ( $36,51 \mu\text{mol CO}_2 \text{ m}^{-2}\text{s}^{-1}$ ). Isso indica que, ao longo das leituras, fatores ambientais ou temporais influenciaram a fotossíntese, como variações na luz, disponibilidade de água ou temperatura, bem como o estágio fenológico da cultura: onde inicialmente a capacidade fotossintética é mínima por conta da área foliar e mais ao final sofre influência da senescência das folhas e do sombreamento das folhas inferiores (BERGAMASCHI e MATZENAUER, 2014).

Para as diferentes épocas de leituras observou um comportamento similar nos valores de  $g_s$ ,  $C_i$  e  $C_i/C_a$ . Onde os menores valores foram observados para a primeira leitura, sendo que as demais não apresentaram diferença estatística entre elas.

Segundo observado Khamis et al (2020) a energia para atividade de fotossíntese para processo vegetativo é válida desde o início da plantação até o dia 30, após isso a condutância estomática ainda se mantém aberta, porém a concentração de  $\text{CO}_2$  intercelular, taxa de transpiração, déficit de pressão de vapor com base na temperatura da folha e radiação fotossinteticamente ativa, vão diminuir até a data da colheita.

A ausência de variações relevantes nas variáveis fisiológicas indica que o milho tem estratégias para lidar com a competição, possivelmente associadas a adaptações na condutância estomática e no uso eficiente da água. De acordo com Silva et al. (2015), plantas que crescem em ambientes com competição moderada podem manifestar plasticidade fisiológica, ajustando a abertura dos estômatos e maximizando a absorção de carbono para reduzir os impactos da escassez de água. Esse

comportamento pode explicar a continuidade das taxas de fotossíntese, mesmo em diferentes densidades de braquiária.

As leituras de transpiração ( $T_{mmol}$ ) mostraram diferenças significativas, onde apenas as leituras 2 e 4 foram semelhantes. Para os valores encontrados a leitura 4 e 2 teve as maiores taxas de transpiração (8,16 e 8,07  $mmol\ m^{-2}\ s^{-1}$  respectivamente) e a leitura 1 teve a menor (4,77  $mmol\ m^{-2}\ s^{-1}$ ). Isso pode estar associado a mudanças ambientais, como umidade relativa do ar ou temperatura, que afetam diretamente a transpiração das plantas.

Segundo Dos Santos (2018) a transpiração é um dos métodos que a planta utiliza para manter a temperatura foliar igual ou ligeiramente inferior à temperatura do ar. A transpiração é um mecanismo essencial para a regulação térmica, sendo influenciada diretamente pelo déficit de pressão de vapor e pela disponibilidade hídrica no solo. Assim, os períodos de maior transpiração coincidem com condições de alta demanda evaporativa, o que pode justificar as diferenças encontradas entre as leituras.

Houve uma pequena variação para a temperatura foliar ( $T_{leaf}$ ), mas ainda assim significativa. A leitura 1 apresentou uma temperatura foliar mais elevada (35,43°C), seguida pela leitura 2 e 4 (33,19°C e 33,16°C) e por último a leitura 3 (30,99°C). O que pode estar associado a uma menor transpiração e maior fechamento estomático, levando a um aumento da temperatura da folha. Este aumento pode ser um indicativo de estresse térmico durante esse período de medição, ocasionado pelo regime pluviométrico durante o experimento em campo, sendo baixo na primeira leitura.

Khamis et al. (2020) relatam que temperaturas foliares elevadas são indicativos de menor atividade transpiratória, podendo afetar a eficiência fotossintética a longo prazo. Esse fenômeno pode ser particularmente relevante em condições de déficit hídrico, onde a menor disponibilidade de água leva ao fechamento estomático e ao consequente aumento da temperatura da folha.

Os valores de CV variaram de 3,06% a 23,42%, indicando uma variabilidade de média a baixa para os tratamentos e uma variabilidade média entre as épocas de leituras, com as variáveis  $T_{leaf}$  e  $T_{mmol}$  apresentando a menor variabilidade, enquanto  $g_s$ ,  $C_i$  e  $C_i/C_a$  apresentando as maiores variabilidades. Esses valores são importantes para avaliar a consistência dos dados e a influência de fatores externos.

Os erros padrão são relativamente baixos, indicando que as medições são precisas e as médias são representativas dos dados obtidos. Isso reflete a confiabilidade dos resultados para comparações entre os tratamentos e leituras.

A interação entre o milho e a braquiária caracteriza-se como um sistema competitivo dinâmico, no qual a eficiência do uso dos recursos hídricos e luminosos determina o sucesso de cada espécie. Freitas et al. (2021) demonstraram que a braquiária pode reduzir a eficiência fotossintética do milho sob densidades acima de 15 plantas m<sup>2</sup>, resultado compatível com o presente estudo. Por outro lado, Vian et al. (2016) apontaram que ajustes de densidade e arranjo espacial podem mitigar esses efeitos, indicando que estratégias de manejo são decisivas para equilibrar a competição e maximizar o desempenho das duas culturas no consórcio.

A tabela 4 traz a análise dos dados espectrais da variedade de milho GNZ 7720 VIP3 em relação a diferentes densidades de plantas/m de braquiária em consórcio e diferentes épocas de leituras.

Tabela 4. Teste de comparação de médias dos dados espectrais do milho submetido a competição com diferentes densidades de plantio da braquiária e em diferentes épocas de desenvolvimento.

Trat	B	G	R	NIR	RE	NDVI	GNDVI	SR
0	0,045 a	0,101 a	0,064 b	0,325 a	0,139 a	0,661 a	0,514 a	6,60 a
5	0,044 a	0,100 a	0,059 a	0,333 a	0,135 a	0,689 b	0,527 ab	8,02 a
10	0,044 a	0,100 a	0,060 ab	0,330 a	0,137 a	0,684 b	0,525 ab	8,13 a
20	0,043 a	0,100 a	0,057 a	0,339 a	0,136 a	0,699 b	0,531 b	8,30 a
CV(%)	4,98	6,88	8,40	5,31	6,47	3,72	3,25	32,07
Erro P	0,0004	0,001	0,001	0,003	0,0018	0,005	0,0035	0,51
leituras	B	G	R	NIR	RE	NDVI	GNDVI	SR
1	0,057 d	0,111 c	0,119 c	0,230 a	0,159 d	0,320 a	0,351 a	1,95 a
2	0,041 b	0,111 c	0,045 b	0,412 d	0,150 c	0,803 bc	0,575 b	8,55 b
3	0,045 c	0,104 b	0,047 b	0,395 c	0,138 b	0,788 b	0,583 bc	9,28 b
4	0,032 a	0,075 a	0,029 a	0,289 b	0,101 a	0,822 c	0,589 c	11,27 c
CV(%)	6,50	6,40	11,08	4,92	6,93	4,48	2,93	32,07
Erro P	0,0005	0,001	0,001	0,003	0,0019	0,0062	0,0031	0,474

Bandas espectrais: vermelha (R); verde (G); azul (B); infravermelho próximo (NIR) e a borda do vermelho (RE) e os índices vegetativos: índice de vegetação da diferença normalizada (NDVI), índice de vegetação da diferença normalizada verde (GNDVI) e razão simples (SR). Médias seguidas da mesma letra não diferem entre si pelo teste tukey a 5% de probabilidade.

Apenas a banda vermelha (R) mostrou diferenças significativas para as diferentes populações de plantas por metro. Quanto aos índices vegetativos foi

observada diferenças significativas entre os valores de NDVI e GNDVI indicando que a densidade da braquiária promoveu influência sobre os valores.

A refletância da banda R apresentou um valor no tratamento 0 de 0,064 superior a leitura 2 (0,059) e 4 (0,057) e semelhante a leitura 3 (0,060), indicando uma ligeira diferença na refletância dessa banda entre os tratamentos. A maior refletância no tratamento 0 pode estar relacionada a densidade das plantas de milho com braquiária na linha de plantio, onde o menor recobrimento do solo houve uma maior refletância da banda.

A banda vermelha é uma região onde ocorre alta absorção de luz pela clorofila. Quando há variações significativas na densidade de plantas: densidades maiores podem aumentar a competição por luz, levando a um desenvolvimento foliar distinto, refletindo menos no vermelho (maior absorção pela clorofila). Em densidades menores, há menor competição, resultando em maior reflexão devido a folhas menos sobrepostas (LIU e LERSEL, 2021).

Porém vale observar nos tratamentos que entre as bandas espectrais os valores de refletância seguiram a seguinte ordem do maior para o menor: NIR > RE > G > R > B.

A ordem de refletância espectral descrita segue um padrão típico de culturas como o milho e a braquiária, especialmente quando observadas em sistemas consorciados. Esse comportamento pode ser explicado com base nas características físicas e bioquímicas das plantas, bem como na interação com a luz em diferentes comprimentos de onda (FENG et al., 2013).

Quanto aos índices vegetativos foi observado um aumento dos valores ao longo dos tratamentos e nas leituras ao longo do desenvolvimento do milho, exceto para o SR nos tratamentos que não apresentou diferenças significativas.

O NDVI apresentou variações significativas, com os valores aumentando de 0,661 no tratamento 0 para 0,699 no tratamento 20. O NDVI é um dos principais índices usados para estimar a biomassa vegetal e a saúde da vegetação, e esses resultados sugerem que os tratamentos com maior densidade de braquiária promoveram um leve aumento na biomassa ou no vigor da vegetação. A maior densidade de braquiária nos tratamentos pode ter reduzido a exposição do solo, aumentando o valor de NDVI.

Vian et al., (2021) destaca que maiores densidades de plantas resultaram em aumento nos índices espectrais, como o NDVI, devido à melhoria da cobertura do solo.

O comportamento dos dados observados quanto as diferentes épocas de leituras das bandas B, G, R, RE foram de valores altos iniciais com declínio nas demais leituras. Para os valores de NIR começou baixo (0,230) aumentou na segunda leitura (0,412), com declínio para leitura 3 (0,395) e leitura 4 (0,289). O NDVI apresentou valor baixo inicial (0,320) com significativo aumento para a leitura 4 (0,822).

Os altos valores iniciais podem ser atribuídos à presença de solo exposto ou vegetação jovem, que reflete mais nas bandas visíveis e borda do vermelho (RE). O declínio subsequente ocorre devido ao aumento da biomassa e do dossel vegetal, que intensificam a absorção de luz, especialmente no vermelho (R) e no azul (B), devido à maior presença de clorofila, mas podem também levar a um declínio precoce no NIR devido à senescência (SUN et al., 2010).

A tabela 5 apresenta a análise estatística dos dados biométricos do milho onde foi avaliada as variáveis altura da planta (Altura), número de folhas (folhas), diâmetro do colmo (Diam.), massa fresca total (MFT), massa seca total (MST), massa seca da folha (MSF), massa seca do colmo (MSC), massa seca de espiga (MSE) e produção (PROD) conduzida por meio do teste de Tukey a 5% de probabilidade, mostra variações nas respostas das plantas submetidas a diferentes tratamentos.

Tabela 5. Teste de comparação de média dos dados biométricos do milho em competição com as diferentes densidades de plantio da braquiária.

Trat.	Ap	NF	DC	MFT	MST	MSF	MSC	PROD.
0	268,39ab	13,11b	1,74a	437,47a	91,80a	29,85a	53,89a	1011,92a
5	270,72b	12,94ab	1,76a	437,25a	88,75a	27,72a	52,70a	973,77a
10	258,06a	12,44a	1,64a	358,08a	76,18a	25,43a	45,50a	981,36a
20	266,28ab	12,94ab	1,77a	454,75a	92,31a	27,76a	55,26a	820,52a
CV	2,74	2,99	8,87	17,75	15,24	12,32	15,19	28,35
ErroP	2,97	0,16	0,061	30,56	5,43	1,39	3,21	109,60

Altura de planta (AP – cm); Número de folhas (NF); Diâmetro de colmo (DC - mm); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF) e massa seca total (MST). Médias seguidas da mesma letra não diferem entre si pelo teste tukey a 5% de probabilidade.

A análise biométrica do milho mostrou que, embora algumas variáveis tenham apresentado diferenças numéricas entre os tratamentos, a maioria não apresentou diferenças estatisticamente significativas, apenas a altura e número de folhas apresentaram diferenças estatísticas. Enquanto a maior altura foi registrada para o tratamento com densidade de 5 pl/m com 270,72 cm, a menor altura foi o tratamento 10 (258,06cm). Para o número de folhas o maior número foi para o tratamento 0 (13,11 und) e o menor para o tratamento 10 (12,44 und).

Isso pode indicar que os tratamentos avaliados não tiveram um efeito profundo nas características de crescimento e produção das plantas, ou que a variabilidade entre as amostras dentro de cada tratamento foi elevada, o que pode ter mascarado os efeitos reais dos tratamentos.

Lobo et al., (2021) encontrou resultado parecido onde a consorciação com a braquiária não interfere negativamente nos parâmetros biométricos do milho, como em relação à altura de plantas, diâmetro do colmo, altura de espiga e número de folhas de plantas de milho.

O comportamento das variáveis biométricas do milho em convivência com diferentes densidades de braquiária mostrou-se semelhante ao relatado por Makino et al. (2018), que também observaram pequena redução gradual da altura de plantas e do número de folhas à medida que aumentava a população da forrageira. Essa tendência é explicada pela competição interespecífica por luz e nutrientes, conforme discutido por Ceccon et al. (2018) e Silva et al. (2015). No presente trabalho, o decréscimo de crescimento em densidades mais elevadas reforça o impacto do sombreamento e da interceptação de radiação pela braquiária, sobretudo durante o estágio vegetativo do milho.

#### 1.4. CONCLUSÕES

As diferentes populações de braquiária em competição com o milho não apresentaram diferenças para as características fisiológicas, espectrais e biométricas, exceto para os valores da banda R, NDVI, GNDVI, altura de planta e número de folhas.

Mudanças fisiológicas e espectrais são notáveis ao longo das leituras, refletindo diferentes valores de acordo com a fase de desenvolvimento.

Portanto a competição avaliada do milho/braquiária não compromete a fisiologia e produção do milho, embora modifique a dinâmica espectral do dossel.

## 1.5. REFERÊNCIAS BIBLIOGRÁFICAS

BERGAMASCHI, H.; MATZENAUER, R. O milho e o clima. **Porto Alegre: Emater/RS-Ascar**, v. 84, p. 85, 2014.

CECCON, G.; DA SILVA, J. F.; MAKINO, P. A.; NETO, A. L. N. Consórcio milho-braquiária com densidades populacionais da forrageira no centro-sul do Brasil. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v. 17, n. 1, p. 157-167, 2018.

DOS SANTOS, A. L. F., MECCHI, I. A., RIBEIRO, L. M., & CECCON, G. Eficiência fotossintética e produtiva de milho safrinha em função de épocas de semeadura e populações de plantas. **Revista de Agricultura Neotropical**, v. 5, n. 4, p. 52-60, 2018.

FENG, R.; ZHANG, Y.; YU, W.; HU, W.; WU, J.; JI, R.; WANG, H.; ZHAO, X. Analysis of the relationship between the spectral characteristics of maize canopy and leaf area index under drought stress. **Acta Ecologica Sinica**, 33(6), 301-307, 2013.

FREITAS, C. D.; PAMPLONA, J. D. P.; LINS, H. A.; SOUZA, M. D. F.; DOMBROSKI, J. L.; SILVA, D. V. Gaseous exchanges of corn and weeds under competition and water regimes. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 24, p. 465-473, 2020.

GARCIA, C. M. D. P., ANDREOTTI, M., TEIXEIRA FILHO, M. C. M., BUZETTI, S., CELESTRINO, T. D. S., & LOPES, K. S. M. Desempenho agrônômico da cultura do milho e espécies forrageiras em sistema de Integração Lavoura-Pecuária no Cerrado. **Ciência Rural**, 43, 589-595, 2013.

KHAMIS, A. K.; ASLI, U. A.; SARJUNI, M. N. H.; JALAL, M. A.; KARIM, H. A. A.; SULAIMAN, S. Relationship between Photosynthetic Rate and Stomatal Conductance, Intercellular CO<sub>2</sub> Concentration, Transpiration Rate, Vapour Pressure Deficit and Photosynthetically Active Radiation in Sweet Corn (*Zea mays*). *Journal of Sustainable Natural Resources*, v. 1, n. 2, p. 1-8, 2020.

LIU, J.; VAN IERSEL, M. W. Photosynthetic physiology of blue, green, and red light: Light intensity effects and underlying mechanisms. **Frontiers in plant science**, v. 12, p. 619987, 2021.

LOBO, C. A. N.; MARQUES, F.; REZENDE, C. F. A. Diferentes Densidades da braquiária na produtividade do milho consorciado. *Revista Brasileira de Agropecuária Sustentável*, v. 11, n. 1, p. 423-429, 2021.

LOPES, J. P., MACHADO, E. C., DEUBER, R., & MACHADO, R. S. Análise de crescimento e trocas gasosas na cultura de milho em plantio direto e convencional. **Bragantia**, v. 68, p. 839-848, 2009.

MAKINO, P. A., CECCON, G., RIBEIRO, L. M., & CECCON, F. Agronomic performance and photosynthetically active radiation intercepted by maize intercropped with Brachiaria. **Revista de Agricultura Neotropical**, v. 6, n. 4, p. 42-48, 2019.

NUNES, J. A. "Trocas gasosas e componentes do rendimento de milho consorciado com fava no brejo paraibano." (2019).

RODRIGUES, O. L., GALVÃO, J. C. C., FERREIRA, E. A., SILVA, D. V., SANTOS, M. V., FERREIRA, L. R., PEREIRA, R. C.; FELIPE, R. S. Physiologic characteristics of corn and *Urochloa brizantha* (Hochst. ex A. Rich.) RD Webster in intercropping cultivation. **Chilean journal of agricultural research**, v. 74, n. 3, p. 257-262, 2014.

SILVA, D. V.; PEREIRA, G. A. M.; FREITAS, M. A. M. D.; SILVA, A. A. D.; SEDIYAMA, T.; SILVA, G. S.; CECON, P. R. Produtividade e teor de nutrientes do milho em consórcio com braquiária. *Ciência Rural*, 45, 1394-1400, 2015.

SONG, W.; XIANG, K.; LU, Y.; LI, M.; LIU, H.; CHEN, L.; CHEN, X.; ABBAS, H. Unlocking the Secrets of Corn: Physiological Responses and Rapid Forecasting in Varied Drought Stress Environments. **Remote Sensing**, v. 16, n. 22, 2024.

SUN, H., LI, M. Z., ZHANG, Y. E., ZHAO, Y., & WANG, H. H.. Spectral characteristics of corn under different nitrogen treatments. **Spectroscopy and Spectral Analysis**, v. 30, n. 3, p. 715-719, 2010.

VIAN, A. L., BREDEMEIER, C., DRUM, M. A., PIRES, J. L. F., & FOCHESSATTO, E. Sensores de vegetação como ferramenta para identificação de população de plantas e estimativa de produtividade de grãos de milho. **Pesquisa Agropecuária Tropical**, v. 51, p. e66926, 2021.

## MODELOS DE PREVISÃO POR IMAGENS DE VANTS DO COMPORTAMENTO FISIOLÓGICO E BIOMÉTRICO DO MILHO EM CONVIVÊNCIA COM AS DIFERENTES DENSIDADES DE PLANTIO DO CAPIM BRAQUIÁRIA

### RESUMO

A avaliação da fisiologia das plantas por meio de algoritmos tem sido uma área crescente de pesquisa nos últimos anos, impulsionada pelo rápido avanço da tecnologia de sensores e computação. Sendo assim, o objetivo deste trabalho foi criar um modelo de previsão que interprete dados biométrico, fisiológico e espectral da cultura do milho (*Zea mays*) em consórcio com diferentes densidades de plantio do capim braquiária a parti das imagens aéreas. O experimento foi implantado no campo em blocos casualizados com 6 repetições. O milho GNZ 7720 VIP3 foi cultivado em consórcio com o capim braquiária (*Urochloa brizantha* cv Piatã) na proporção de 0, 5, 10 e 20 plantas por metro. Aos 21(V6), 36(V10), 58(VT) e 66(R2). A análise fisiológica foi realizada obtendo a taxa fotossintética líquida, condutância estomática, Carbono interno, transpiração, temperatura foliar e a relação carbono interno/carbono do ambiente. Com as imagens aéreas foram produzidas 5 bandas (azul (B), verde (G), vermelho ®, infravermelho próximo (NIR) e borda do infravermelho (RE). Aos 66 DAS foram mensuradas as características biométricas da cultura do milho, sendo medidas 3 plantas por parcela. O processo de estimação foi baseado em métodos de regressão paramétricos (regressão linear múltipla) e não paramétricos (rede neural e Random forest) e os resultados comparados, utilizando o software R studio code. A raiz do erro quadrático médio (RMSE), e o RMSE normalizado (RMSE%) foram utilizadas para validar a precisão dos modelos, considerando o resíduo da diferença entre as variáveis fisiológicas estimadas. Os melhores modelos foram aplicados ao conjunto de teste. Para este experimento, a maior variabilidade espectral extraídos da imagem, foi para o espectro R e o NDVI indicando ser as melhores para discriminar diferenças. Neste estudo foi possível quantificar as variáveis biométricas, fisiológicas por processo de estimação utilizando métodos de regressão paramétricos e não paramétricos. O algoritmo paramétrico de regressão linear múltipla (MLR), apresentou melhor resultados em comparação com os não paramétricos: Random forest (RF) e rede Neural (RN) apresentando melhores valores de coeficientes de determinação.

**Palavras-chaves:** sensoriamento remoto; drone; imagem; índice de vegetação e algoritmo.

## ABSTRACT

Plant physiology assessment through algorithms has been a growing area of research in recent years, driven by the rapid advancement of sensor and computing technology. Therefore, the objective of this work was to create a prediction model that interprets biometric, physiological and spectral data of corn (*Zea mays*) intercropped with different planting densities of *Brachiaria* grass from images obtained by UAVs. The experiment was implemented in the field in randomized blocks with 6 replicates. Corn GNZ 7720 VIP3 was grown intercropped with *Brachiaria* grass (*Brachiaria brizantha* cv Piatã) at the proportions of 0, 5, 10 and 20 plants per meter. At 20 (V6), 33 (V10), 48 (VT) and 62 (R2). Physiological analysis was performed by obtaining the net photosynthetic rate, stomatal conductance, internal carbon, transpiration, leaf temperature and the internal carbon/environmental carbon ratio. With the aerial images, 5 bands were produced (blue (B), green (G), red (R), near infrared (NIR) and infrared edge (RE)). At 62 DAS, the biometric characteristics of the corn crop were measured, with 3 plants per plot being measured. The estimation process was based on parametric (multiple linear regression) and nonparametric (neural network and Random Forest) regression methods and the results compared, using the R studio code software. The root mean square error (RMSE) and the normalized RMSE (RMSE%) were used to validate the accuracy of the models, considering the residual of the difference between the estimated physiological variables. The best models were applied to the test set. For this experiment, the greatest spectral variability extracted from the image was for the R spectrum and NDVI, indicating that they were the best to discriminate differences. In this study, it was possible to quantify the biometric and physiological variables by estimation process using parametric and nonparametric regression methods. The parametric multiple linear regression (MLR) algorithm presented better results compared to the non-parametric ones: Random forest (RF) and neural network (RN), presenting better values of determination coefficients.

**Keywords:** remote sensing; drone; image; vegetation index and algorithm.

## 2.1. INTRODUÇÃO

As avaliações das características fisiológicas relacionadas à fotossíntese, eficiência do uso da água, entre outros parâmetros, podem ser indicadores do nível de interferência e têm sido estudados por vários autores mostrando que a adoção de práticas culturais, como o arranjo espacial de plantas, pode ser considerada uma das formas de amenizar a competição interespecífica em cultivos consorciados (TAKASU et al., 2013; CECCON et al., 2014).

Estudos têm demonstrado o potencial das ferramentas espectrais para a detecção de respostas das plantas a vários fatores de estresses bióticos e abióticos. A utilização de tecnologias de detecções remotas na agricultura é de grande interesse, permitindo medições não destrutivas e que podem ser utilizadas para investigação e aplicações de campo (GIROLAMO-NETO et al., 2019; RONAY et al., 2021).

Trabalhos recentes mostraram que bandas multiespectrais cuidadosamente selecionadas em conjunto com ferramentas sofisticadas de aprendizado de máquina (ML) podem resultar em abordagens sensíveis para a detecção precoce de uma variedade de características da planta, incluindo assinaturas de estresse (GUO et al., 2021).

Os modelos preditivos utilizados na avaliação da fisiologia das plantas incluem técnicas de aprendizado de máquina, como redes neurais e algoritmos genéticos (ARAB et al., 2018). Essas técnicas permitem que os algoritmos aprendam com os dados e possam fazer previsões precisas sobre o estado fisiológico das plantas e como elas podem responder a diferentes condições ambientais (ASAARI et al., 2022; LIU et al., 2021; MARTINS et al., 2021).

A avaliação da fisiologia das plantas por meio de algoritmos tem sido uma área crescente de pesquisa nos últimos anos, impulsionada pelo rápido avanço da tecnologia de sensores e computação. Esses algoritmos geralmente utilizam dados espectrais coletados por sensores para modelar e prever o desempenho fisiológico das plantas, permitindo assim a otimização do crescimento e produção (BARZIN et al., 2020).

## 2.2. MATERIAL E MÉTODOS

O experimento foi conduzido em área de cultivo agrícola do Instituto Federal do Tocantins, Campus Dianópolis, Tocantins-Brasil, localizado a 11°38'10" de latitude sul, 46°45'55" de longitude oeste e 574 metros de altitude, no período de novembro de 2022 a fevereiro de 2023.

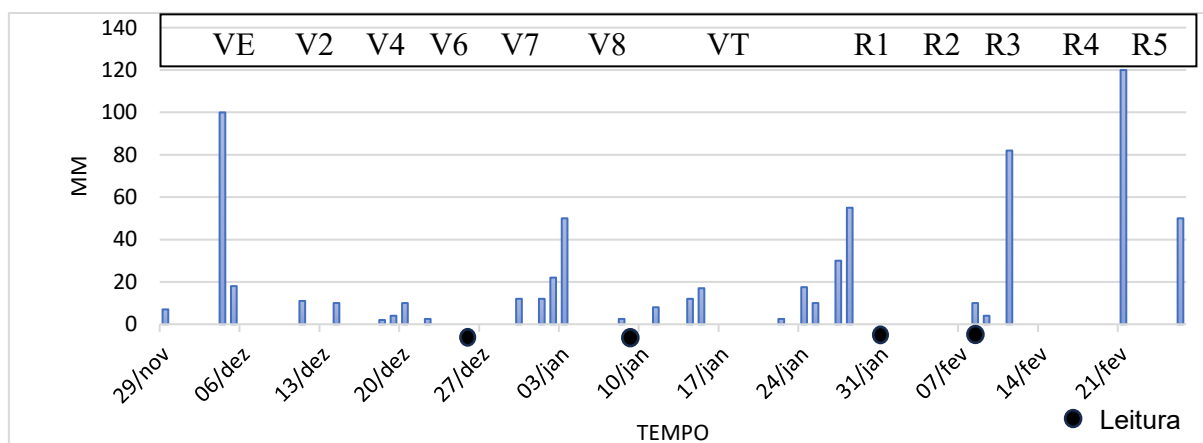
O solo da área é caracterizado como Latossolo amarelo distrófico típico, franco argilo-arenoso, com as seguintes características químicas (tabela 6):

Tabela 6. Resultado da análise química dos solos da área experimental (EMBRAPA, 2009).

pH (CaCl <sub>2</sub> )	P mg dm <sup>-3</sup>	K mg dm <sup>-3</sup>	Ca mg dm <sup>-3</sup>	Mg cmol <sub>c</sub> dm <sup>-3</sup>	Al cmol <sub>c</sub> dm <sup>-3</sup>	H+Al cmol <sub>c</sub> dm <sup>-3</sup>
6,1	19	104	5,6	0,9	0	1,20
SB cmol <sub>c</sub> dm <sup>-3</sup>	T mg dm <sup>-3</sup>	V mg dm <sup>-3</sup>	MO mg dm <sup>-3</sup>	Argila %	Silte %	Areia %
6,77	7,97	85	1,2	22,5	7,5	70

Segundo a Köppen e Geiger o clima é classificado como Aw- clima tropical quente e semiúmido, com sucessão de chuvas durante o verão e o inverno seco. A temperatura média é 22 °C, e uma pluviosidade média anual de 1500mm. Na figura 1 é apresentado os valores registrados para a período da execução do experimento.

Figura 5. Gráfico do regime pluviométrico e datas das leituras.



Foi conduzido o cultivo de milho no espaçamento de 80 cm entre linhas em consórcio com o capim braquiária na proporção de 0, 5, 10 e 20 plantas por metro. Aos 21(V6), 36(V10), 58(VT) e 66(R2) dias após a emergência foram realizadas análises fisiológicas, biométricas e o levantamento de imagens aéreas, concomitantemente entre as 10-12 horas do dia.

A variedade de milho cultivada foi o GNZ 7720 VIP3, planta semi-ereta de alta tolerância aos enfezamentos e com 130 dias de maturidade relativa, que possui a recomendação de média a alta tecnologia, com finalidade de uso para grãos ou silagem, podendo ser plantada na época de safra ou safrinha.

O capim braquiária (*Urochloa brizantha* cv Piatã) utilizado é uma planta de porte médio, com folhas longas e ásperas, que pode ser usada para pastejo e fenação com tempo médio de estabelecimento de 2 a 3 meses após o plantio. É uma planta de crescimento ereto e crepitosa tem folhas longas, de até 45 cm de comprimento e 1,8 cm de largura, robusta, com alta produção de forragem, alto teor de proteína bruta, resistente a cigarrinhas das pastagens.

O experimento foi implantado no campo em blocos casualizados com seis repetições. A área foi dividida em 24 parcelas de 12 m<sup>2</sup> cada (3x4m) distribuídas em seis blocos homogêneos (B1, B2, B3, B4, B5 e B6) com espaçamento de 1m entre os mesmos e 1 m entre as parcelas (Figura 2).

Figura 6. Croqui da área experimental.

<b>B1</b>	<b>B2</b>	<b>B3</b>	<b>B4</b>	<b>B5</b>	<b>B6</b>
4	3	2	3	4	1
1	2	4	1	2	3
3	4	1	2	3	4
2	1	3	4	1	2

Densidades de capim braquiária:

- 1- 0 plantas/metro linear
- 2- 5 plantas/metro linear
- 3- 10 plantas/metro linear
- 4- 20 plantas/metro linear

A análise fisiológica foi realizada por meio de medições das trocas gasosas utilizando o equipamento IRGA – Infrared Gas Analyzer, modelo Li-6400 (Li-Cor, Biosciences Inc., Nebraska, EUA). Onde foi obtida a taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2}\text{s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca) conforme metodologia proposta por Lima et al. (2016). Os teores de CO<sub>2</sub> foram utilizados em 400  $\mu\text{mol m}^{-2} \text{ s}^{-1}$  e a intensidade luminosa em 1500  $\mu\text{mol de f\u00f3tons m}^{-2} \text{ s}^{-1}$ . As avaliações foram realizadas em folhas jovens, recém-expandidas, não danificadas e bem iluminadas realizadas em triplicata, em plantas diferentes dentro da parcela.

As imagens aéreas foram produzidas utilizando um VANT de asa fixa EbeeX com câmera multiespectral (RedEdge-M) de cinco bandas (azul (B), verde (G), vermelho ®, infravermelho próximo (NIR) e borda do infravermelho (RE) em alturas de voo de 44 metros, correspondendo a 3  $\text{cm}^2/\text{pixel}$  de resolução espacial. O intervalo entre disparos foi de dois segundos com uma sobreposição de 75% longitudinal e 80% latitudinal, visando à geração de um ortomosaico da área.

Os voos foram realizados sempre no mesmo horário das leituras com o IRGA (10-12 horas), uma vez também que neste horário a angulação da luz solar incidente é a mais adequada para captura da reflectância.

O trabalho da obtenção dos dados espectrais foi dividido nas seguintes etapas: Captura de imagens em lavouras utilizando VANT; pré-processamento das mesmas utilizando o software WebODM para calibração da reflectância do alvo (parcelas) por meio dos dados do painel de calibração; alinhamento das imagens, construção de uma nuvem tridimensional de pontos e construção de um modelo digital de elevação (DEM) para obtenção do ortomosaico.

Após a construção do ortomosaico, estes foram exportados em formato tiff para ambiente SIG, utilizando o software QGIS 3.2, onde foi utilizada a calculadora matricial para determinação dos Índices de Vegetação em cada imagem. Após essa etapa, foram criadas imagens vetoriais para que seja possível um recorte em cada parcela. A partir desse recorte, foi calculada a média de cada índice em cada parcela usando a ferramenta de estatística zonal do software QGIS.

Para a avaliação espectral da cultura do milho foram consideradas as bandas: vermelha (R); verde (G); azul (B); infravermelho próximo (NIR) e a borda do vermelho (RE) e os índices vegetativos: índice de vegetação da diferença normalizada (NDVI),

índice de vegetação da diferença normalizada verde (GNDVI) e razão simples (SR), com as fórmulas que seguem:

$$NDVI = \frac{NIR - R}{NIR + R}$$

$$GDVI = \frac{NIR - G}{NIR + G}$$

$$SR = \frac{NIR}{R}$$

Aos 62 DAS (R2) foram mensuradas as características biométricas da cultura do milho, sendo medidas 3 plantas por parcela: Altura de planta (AP – cm); Diâmetro de colmo (DC - mm); Número de folhas (NF); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF) e massa seca total (MST) a folhas foram secas em estufa de circulação de ar forçado por 72 horas a 65 °C. Foi medida também a produtividade do milho nas diferentes parcelas experimentais.

Após a obtenção dos dados, foi realizada análise de dispersão e as variáveis foram submetidas à análise estatística descritiva para obtenção de média, desvio padrão e coeficiente de variação.

Após validados, os dados foram construídos modelos de previsão com o software Visual Studio Code com linguagem de programação Python utilizando o espectro e índices de vegetação que melhor se relacione com as características fisiológica e biométricas.

O processo de estimação que foi utilizado neste estudo é baseado em métodos de regressão paramétricos e não paramétricos. O algoritmo paramétrico utilizado como estimadores foi a regressão linear múltipla (MLR) e não paramétricos a Rede Neural (RN) e o Random forest (RF) e os resultados comparados.

O banco de dados gerado integrou as variáveis coletadas no experimento da seguinte forma:

- Variáveis identificadoras: bloco, parcela, época de avaliação;
- Variáveis espectrais (preditoras): bandas espectrais (Vermelho, Verde, Azul, Infravermelho Próximo, Borda do Vermelho) e índices de vegetação (NDVI, GNDVI e SR);

- Variáveis biométricas (resposta): altura da planta, número de folhas, diâmetro do colmo, massa fresca total, massa seca total, massa seca das folhas, massa seca do caule e produtividade;
- Variáveis fisiológicas (resposta): taxa fotossintética líquida, condutância estomática, concentração interna de CO<sub>2</sub>, transpiração, temperatura foliar e razão Ci/Ca.

O conjunto final contou com 576 observações (6 blocos × 4 épocas × 4 repetições), contemplando 8 variáveis espectrais e 8 respostas biométricas e 6 respostas fisiológicas.

Antes da modelagem, foi realizado o pré-processamento dos dados, incluindo verificação de dados faltantes, detecção e tratamento de outliers, normalização das variáveis espectrais quando necessário, e análise exploratória para identificar correlações e padrões. O dataset foi dividido em 80% para treinamento e 20% para teste.

Foram empregadas três abordagens para modelagem preditiva das variáveis biométricas e fisiológicas a partir das variáveis espectrais:

1. Regressão Linear Múltipla (MLR): com seleção de variáveis via eliminação reversa (backward elimination) usando nível de significância  $\alpha = 0,05$ .
2. Random Forest (RF): modelo com 100 árvores, onde o número de variáveis candidatas para divisão correspondia à raiz quadrada do número total de preditores. Validação cruzada k-fold (k=5) foi aplicada, e a importância das variáveis foi calculada com base na redução da impureza.
3. Redes Neurais Artificiais (RNA): multi-layer perceptron com 8 neurônios na camada de entrada, 2 neurônios na camada oculta e número variável de neurônios na saída. O ajuste de hiperparâmetros foi realizado via Grid Search com validação cruzada K-Fold (k=5).

Para avaliação dos modelos, foram utilizadas as métricas: Raiz do Erro Quadrático Médio (RMSE), RMSE normalizado (RMSE%), Coeficiente de Determinação (R<sup>2</sup>). O processo de validação incluiu divisão temporal dos dados respeitando a estrutura experimental para testar a generalização em conjunto independente.

### 2.3. RESULTADOS E DISCUSSÃO

A análise descritiva das variáveis biométricas, fisiológicas e espectrais do milho (Tabela 7) permite compreender a variabilidade e o comportamento das plantas em competição com diferentes densidades de braquiária. O coeficiente de variação (CV) variou de 3,63 a 59,61%, indicando boa precisão experimental e confiabilidade nos dados.

Tabela 7. Média, desvio padrão e coeficiente de variação do conjunto de variáveis biométricas, fisiológicas e espectrais do milho em competição com diferentes populações de braquiária e em diferentes épocas de desenvolvimento.

Variáveis	Média	Desvio Padrão	Coeficiente de variação (%)
<b>Biométricas</b>			
Ap	265,86	9,65	3,63
NF	12,86	0,52	4,04
Diam.	1,73	0,15	8,50
MFT	421,89	78,40	18,58
MST	87,26	13,72	15,72
MSF	27,69	3,50	12,65
MSC	51,84	7,93	15,29
Prod	946,89	257,89	27,24
<b>Fisiológicas</b>			
A	37,69	7,67	20,36
gs	0,300	0,081	27,02
Ci	146,96	60,64	41,26
E	7,028	1,67	23,82
Tleaf	33,19	2,54	7,64
Ci/Ca	0,39	0,144	36,68
<b>Espectrais</b>			
B	0,044	0,009	21,27
G	0,100	0,016	16,10
R	0,060	0,036	59,61
NIR	0,332	0,077	23,34
RE	0,137	0,024	17,61
NDVI	0,683	0,213	31,23
GNDVI	0,525	0,102	19,5
SR	7,765	4,249	54,7

Altura de planta (AP – cm); Número de folhas (NF); Diâmetro de colmo (DC - mm); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF); massa seca total (MST); Taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca); Bandas espectrais: vermelha (R); verde (G); azul (B); infravermelho próximo (NIR) e a borda do vermelho (RE) e os índices vegetativos: índice de vegetação da diferença normalizada (NDVI), índice de vegetação da diferença normalizada verde (GNDVI) e razão simples (SR).

As variáveis altura de planta (AP), número de folhas (NF) e diâmetro do colmo (DC) apresentaram baixo CV (<10%), indicando crescimento uniforme e homogeneidade populacional. Essa uniformidade morfológica reflete o bom estabelecimento inicial das plantas de milho, a adequada distribuição de plantas e a ausência de competição severa nos estádios iniciais do consórcio.

Estudos anteriores, como os de Silva et al. (2015) e Ceccon et al. (2018), observaram comportamento semelhante em consórcios milho-braquiária, destacando que a competição inicial tende a ser mais intensa nas fases V3–V6, quando o sistema radicular da forrageira se estabelece e começa a competir por luz, água e nutrientes. Ainda assim, o milho apresenta elevada plasticidade morfológica, ajustando o crescimento foliar e o alongamento do colmo para manter a interceptação de luz e a produtividade.

A massa fresca total (MFT), massa seca total (MST) e produtividade (PROD) apresentaram CVs moderados (15 – 27%) indicam maior variabilidade associada à alocação de biomassa no final do ciclo. Essa variabilidade é típica de sistemas consorciados, onde pequenas diferenças na competição por recursos geram respostas diferenciadas de alocação de carbono. Lorenzetti et al. (2023) observaram que, em consórcios milho-braquiária, a braquiária pode modificar a partição de fotoassimilados, reduzindo ligeiramente o crescimento vegetativo do milho, mas sem comprometer significativamente o rendimento de grãos.

Alves et al 2013, observou o mesmo comportamento avaliando a morfologia e produtividade de híbridos de milho safrinha solteiro e consorciado com braquiária, indicando que o aumento da densidade de plantas pode levar ao aumento de variabilidade nas características morfológicas e fenológicas das plantas para manter seu potencial produtivo, principalmente no conteúdo da biomassa aérea das plantas.

Segundo Borrás e Vitantonio-Mazzini (2018), a alocação de biomassa em plantas sob competição é uma estratégia de homeostase adaptativa, permitindo que o milho mantenha o equilíbrio entre captação de luz (via área foliar) e eficiência fotossintética (via condutância estomática). Essa resposta explica a baixa variação em altura e diâmetro mesmo com variações ambientais ou de densidade da forrageira.

A presença da braquiária pode também ter efeitos indiretos positivos sobre o sistema, especialmente pela melhoria da estrutura física e biológica do solo, o que favorece o enraizamento do milho e a retenção de água (CHIODEROLI et al., 2012;

LORENZETTI et al., 2023). Esses efeitos estruturais, embora nem sempre quantificados diretamente, explicam parte da resiliência fisiológica observada.

As variáveis fisiológicas apresentaram valor baixo de CV para temperatura foliar ( $T_{leaf}$ ); moderados para taxa fotossintética ( $A$ ), condutividade estomática ( $g_s$ ), transpiração ( $T_{mmol}$ ); e altos para carbono interno e carbono interno/carbono ambiente ( $C_i/C_a$ ), refletindo a forte influência das condições microclimáticas e da disponibilidade hídrica.

A condição fisiológica do milho é retratada pelo desempenho fotossintético e o funcionamento estomático moderados demonstrando assim variações ocasionadas por diferenças no status hídrico, comprovado pela variável regime pluviométrico ao longo das avaliações. Apesar das variações ambientais, não foi possível observar uma situação de estresse hídrico visual ao longo do ciclo de cultivo, evidenciado também pela baixa variação da temperatura foliar permanecendo praticamente estável. Porém o gasto de energia ocorrido para manter estável a temperatura foliar acarretou prejuízos variados para a eficiência do uso do carbono, onde este mostrou variação considerável.

O crescimento da cultura do milho é limitado pela disponibilidade hídrica, reduzindo as trocas gasosas pela limitação da água, com a condutância estomática se mostrando a mais sensível ao estresse (BRITO et al, 2013).

A taxa fotossintética ( $A$ ) apresentou CV de 20,36%, valor considerado normal em medições de campo, segundo Bergamaschi e Matzenauer (2014). A variação observada é coerente com as flutuações de irradiância e umidade ao longo das avaliações. Estudos de Zhao et al. (2023) e Wang et al. (2023) indicam que o milho, sendo uma espécie  $C_4$ , possui grande estabilidade fotossintética mesmo sob moderadas restrições hídricas, graças à elevada eficiência do ciclo de Hatch-Slack e à capacidade de manter o gradiente de  $CO_2$  entre o mesófilo e a bainha vascular.

A condutância estomática ( $g_s$ ) apresentou CV de 27%, o que denota sensibilidade à variação de umidade e temperatura do ar. Carvalho et al. (2022) demonstrou que a  $g_s$  é um dos parâmetros mais responsivos ao estresse hídrico e térmico, ajustando-se rapidamente para equilibrar a difusão de  $CO_2$  e a perda de água. No presente estudo, a ausência de reduções drásticas em  $A$  e  $E$  confirma que o sistema de cultivo manteve estabilidade fisiológica, sem estresse severo.

O carbono interno ( $C_i$ ) e a relação  $C_i/C_a$  apresentaram CVs elevados (41,26% e 36,68%, respectivamente), indicando variação significativa na assimilação de  $CO_2$  e

eficiência fotossintética entre plantas. Esse comportamento está relacionado à heterogeneidade do dossel e às microvariações de sombreamento causadas pela braquiária. Segundo Boyd et al. (2015) variações em  $C_i/C_a$  refletem ajustes metabólicos na atividade da Rubisco e no transporte de elétrons, sendo indicadores sensíveis da eficiência do uso do carbono (CUE).

A temperatura foliar ( $T_{leaf}$ ) manteve CV baixo (7,64%), evidenciando estabilidade térmica e eficiente regulação pela transpiração. O fato de  $T_{leaf}$  se manter próxima de 33 °C ao longo das avaliações indica que o milho conseguiu conservar sua homeostase térmica, mesmo sob competição, confirmando observações de Khamis et al. (2020) sobre a capacidade da cultura em manter a temperatura foliar relativamente constante em condições tropicais.

Com relação as variáveis espectrais o comportamento do coeficiente de variação foi de moderado a alto, onde os valores foram moderados para azul (B), verde (G), infravermelho próximo (NIR) e borda do vermelho (RE) e valores altos para o vermelho (R), o índice de vegetação por diferença normalizada (NDVI) e a razão simples (SR), revelando que o sensoriamento remoto captou diferenças significativas de vigor e sanidade entre plantas. Essa heterogeneidade é típica de sistemas consorciados, nos quais a mistura espectral do dossel (milho + braquiária) altera a refletância registrada em diferentes comprimentos de onda.

As propriedades ópticas do dossel do milho revelam diferenças na saúde e vigor das plantas avaliadas, apresentando uma alta variabilidade para a banda R, que impacta diretamente os índices de vegetação, demonstrando variações no teor de clorofila e indicando um possível estresse fisiológico.

As altas variações observadas na banda R indicam diferenças no teor de clorofila a, uma vez que essa região do espectro é altamente absorvida por esse pigmento (JENSEN, 2009; MARTINS et al., 2021). Isso reforça o potencial do uso de imagens multiespectrais obtidas por VANTs para detectar variações sutis no estado fisiológico das plantas, antes mesmo de sintomas visuais de estresse se manifestarem.

Os resultados obtidos neste estudo sugerem que o NDVI pode ter sofrido influência positiva da braquiária, uma vez que essa forrageira contribui com alta refletância no infravermelho próximo (NIR). Isso confirma observações de Macedo et al. (2023) de que o consórcio milho-braquiária altera a assinatura espectral do sistema e pode levar à superestimação do vigor aparente do milho.

A alta variabilidade na banda R e nos índices NDVI e SR indica que esses parâmetros são promissores para detecção de estresse fotossintético e variações na clorofila, conforme sugerido por Martins et al. (2021).

A alta variabilidade de algumas variáveis biométricas e fisiológicas garantem que as plantas de milho não estão homogêneas, indicando anormalidade na sua sanidade. Para os dados extraídos da imagem, um maior CV indica que o espectro conseguiu ser influenciado por tal anormalidade e pode ser a melhor região para discriminar diferenças entre o estado das plantas analisadas (JENSEN, 2009).

Para este experimento, a maior variabilidade espectral extraídos da imagem, foi para o espectro R, NDVI e SR indicando ser as melhores para discriminar diferenças, dado que a energia refletida na faixa espectral é influenciada por variáveis relacionadas à fotossíntese, como NF15 e clorofila a (MARTINS et al., 2021).

Os modelos de regressão linear múltipla (RLM) apresentados na Tabela 8 descrevem de forma quantitativa as relações entre as variáveis espectrais e as respostas biométricas e fisiológicas do milho cultivado em consórcio com *Brachiaria*. Cada modelo pode ser interpretado pela contribuição de cada variável espectral e o valor do coeficiente de determinação ( $R^2$ ), que reflete a proporção da variação explicada por cada modelo.

Tabela 8. Desempenho dos modelos criados por regressão linear múltipla para prever características biométricas e fisiológicas de plantas com base em bandas espectrais (R, G, B, NIR, RE) do milho em competição com diferentes densidades de braquiária.

Variável	Modelo	R <sup>2</sup> (%)
Ap	$-318.2259 + (-2184.9693 * R) + (12518.4577 * B) + (-864.8448 * NIR) + (822.6971 * GNDVI)$	68
NF	$-4.8387 + (325.8968 * B) + (-50.8060 * RE) + (20.2848 * GNDVI)$	61
DC	$2.3258 + (-17.0234 * B)$	12
MFT	$2345.2572 + (-11731.0031 * R) + (-1929.8835 * NDVI)$	17
MST	$246.4993 + (-27584.2437 * R) + (24913.6570 * G) + (7585.4151 * B) + (-4266.7224 * NIR) + (-4783.0417 * NDVI) + (6162.3962 * GNDVI) + (4.0834 * SR)$	59
MSF	$112.5634 + (-1872.7953 * R) + (2548.9094 * B) + (-253.6671 * NDVI) + (157.8935 * GNDVI)$	53

MSC	$190.9166 + (-17118.9478 * R) + (15084.8833 * G) + (4578.9120 * B) + (-2524.4485 * NIR) + (-2938.6975 * NDVI) + (3712.8130 * GNDVI) + (2.3156 * SR)$	60
PROD.	$-3414.0150 + (-55035.7780 * G) + (44115.2593 * RE) + (4939.8949 * NDVI)$	31
A	$-36,78 + (425,12 * R) + (71,84 * NDVI)$	11
Gs	$-0,594 + (7,46 * R) + (-8,24 * B) + (1,187 * NDVI)$	56
Ci	$214,43 + (-3777,39 * B) + (297,22 * NIR)$	63
E	$-12.98 + (269.95 * R) + (-89.32 * G) + (-145.98 * B) + (69.95 * NDVI) + (-51.60 * GNDVI) + (-0.191 * SR)$	71
Tleaf	$36.26 + (-160.08 * R) + (-68.44 * NIR) + (213.26 * RE)$	47
Ci/Ca	$1.41 + (-12.84 * B) + (2.66 * NIR) + (-4.78 * RE) + (-0.989 * NDVI)$	63

Altura de planta (AP – cm); Diâmetro de colmo (DC - cm); Número de folhas (NF); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF); massa seca total (MST); taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca).

Os modelos apresentados têm uma ampla variação nos valores de  $R^2$ , que vão de 10% (A) a 71% (E). Esses resultados indicam que, enquanto algumas variáveis podem ser previstas com maior precisão, outras possuem maior variabilidade residual, possivelmente devido à influência de fatores ambientais e à complexidade das interações fisiológicas da cultura, ou seja, que a capacidade preditiva dos modelos varia bastante de acordo com a variável dependente (biométrica ou fisiológica) em questão.

Os modelos lineares múltiplos apresentaram maiores coeficientes de determinação ( $R^2$ ) onde incorporaram mais bandas e/ou índices nas equações de regressão, como verificado para as variáveis E (71%), altura (68%) e Ci/Ca (63%) (Tabela 8). Esse comportamento reforça a natureza multifatorial das interações espectrais, já que variáveis fisiológicas são influenciadas simultaneamente pela arquitetura foliar, pelo conteúdo de pigmentos e pelo status hídrico (COTROZZI ET AL., 2020).

Segundo Oliveira et al., (2020), os modelos que estimam variáveis agrícolas, quando compostos por uma única variável preditiva, tendem a apresentar baixo coeficiente de determinação. No entanto, isso não resulta necessariamente em uma estimativa imprecisa da variável porque, se os dados de validação forem distribuídos

normalmente, os erros na variabilidade dos dados em torno da média serão nulos e diminuirão o RMSE.

Os modelos lineares múltiplos mostraram um bom desempenho ( $R^2 > 50\%$ ) para as variáveis: Ap, NF, MST, MSF e MSC, indicando que a banda B e o GNDI Impactaram mais no processo de predição de crescimento e biomassa. A banda B teve influência positiva, ligada a maior refletância em tecidos mais jovens, associada ao crescimento ativo. Entretanto o NDVI teve influência negativa podendo estar relacionada com a saturação da densidade populacional da vegetação, dossel misto braquiária/milho.

Os modelos indicam que a altura das plantas de milho pode ser estimada com uma precisão de 68% utilizando uma combinação das bandas vermelha (R), azul (B), infravermelho próximo (NIR) e o índice GNDVI. A influência da banda azul está em consonância com pesquisas que demonstram que essa faixa do espectro é extremamente sensível à quantidade de clorofila nas folhas, possivelmente relacionada ao vigor vegetativo da planta (GITELSON et al., 2003). O índice GNDVI, de sua parte, tem sido amplamente empregado para a estimativa da biomassa foliar em culturas agrícolas, ressaltando sua importância na previsão da altura e de outras variáveis biométricas.

A quantidade de folhas (NF) apresentou um  $R^2$  de 61%, sendo afetada de forma positiva pela banda azul e pelo GNDVI, enquanto a borda do vermelho (RE) teve um efeito negativo. Isso indica que plantas com uma densidade foliar mais alta podem ter uma refletância menor na RE, o que se deve ao aumento da absorção de luz para os processos de fotossíntese, como demonstrado em pesquisas anteriores relacionadas à cana-de-açúcar e ao milho em diferentes práticas de manejo (ZHANG et al., 2014).

O diâmetro do colmo apresentou uma capacidade preditiva baixa ( $R^2 = 12\%$ ), sendo influenciado apenas pela banda azul. Esse índice reduzido indica que a variação do diâmetro do colmo pode ser influenciada por fatores fisiológicos e estruturais que não são facilmente identificáveis por meio de sensoriamento remoto. Estudos sugerem que propriedades como a rigidez do colmo e a distribuição de biomassa podem estar mais ligadas à estrutura interna da planta do que às características espectrais das folhas (SILVA et al., 2023).

As variáveis biométricas constituem parte da biomassa da vegetação, o que pode explicar a presença do GNDVI correlacionados com a biomassa das copas de diversas culturas (JENSEN, 2009).

Os melhores modelos foram obtidos para: E, gs, Ci e Ci/Ca, apresentando um bom desempenho preditivo ( $R^2 \geq 50\%$ ), mostrando que as bandas espectrais captam informações ligadas ao funcionamento estomático e trocas gasosas. A banda B novamente teve forte peso, porém sendo negativo para Ci e Ci/Ca, sugerindo que valores elevados estão associados a menor eficiência fotossintética ou estresse fisiológico. O modelo E apresentou o melhor ajuste ( $R^2=71\%$ ), reforçando a importância do uso de sensores para monitorar perda hídrica de forma indireta.

A taxa fotossintética líquida (A) apresentou uma das menores capacidades preditivas ( $R^2 = 11\%$ ), sendo influenciada apenas pelas bandas vermelha e NDVI. Esse resultado corrobora com estudos que indicam que a fotossíntese é regulada não apenas pela estrutura do dossel, mas também por fatores internos, como a eficiência da enzima rubisco e a capacidade de transporte de elétrons (MEDRANO et al., 2002).

A condutância estomática (gs) demonstrou um  $R^2$  de 56%, sendo correlacionada positivamente com a banda vermelha e negativamente com a banda azul e o NDVI. Esse comportamento sugere que plantas com maior condutância estomática possuem maior absorção na região azul do espectro, o que pode estar relacionado à maior atividade fotossintética e maior abertura estomática em resposta às condições ambientais.

A transpiração (E), que demonstrou o maior coeficiente de determinação  $R^2$  de 71%, foi analisada por meio de diversas variáveis espectrais, como as bandas R, G e B e os índices NDVI e GNDVI. Essa forte correlação espectral pode ser explicada pela conexão entre a taxa de transpiração e fatores como a estrutura do dossel, o nível de clorofila e a regulação estomática, todos os quais podem ser avaliados por meio do sensoriamento remoto (FLEXAS et al., 2002).

A temperatura das folhas ( $T_{leaf}$ ) teve um  $R^2$  de 47%, sendo afetada negativamente pelas bandas vermelha e NIR, enquanto a borda do vermelho (RE) exerceu influência positiva. Essa correlação confirma investigações anteriores que indicam que folhas mais quentes tendem a absorver menos na faixa do infravermelho próximo, devido ao fechamento dos estômatos e à redução da transpiração (ZHU et al., 2020).

O carbono interno (Ci) demonstrou um coeficiente de determinação ( $R^2$ ) de 63%, mostrando uma correlação negativa com a banda azul e uma correlação positiva com o infravermelho (NIR). Isso indica que as folhas que possuem uma maior concentração de  $CO_2$  internamente tendem a refletir mais no NIR, possivelmente

devido a uma densidade estomática reduzida e uma eficiência do uso da água maior (WUE) (LAWSON et al., 2014).

A razão entre a concentração interna de  $CO_2$  e a atmosfera ( $C_i/C_a$ ) demonstrou um elevado coeficiente de determinação ( $R^2 = 63\%$ ), sugerindo que esse indicador pode ser adequadamente estimado com base em dados espectrais. Esse resultado tem implicações importantes para o monitoramento da eficiência do uso da água e para a identificação precoce de estresses hídricos, possibilitando ajustes no manejo agrícola para maximizar a produtividade e minimizar perdas causadas por déficits hídricos.

Portanto, os modelos lineares permitem uma interpretação visual dos coeficientes, sendo útil para compreender a direção dos efeitos espectrais, se mostrando promissores para estimativa das variáveis como: Ap, NF, gs,  $C_i$  e E com valores de  $R^2$  entre (60-71%). O uso do GNDVI e NDVI se reafirma como componentes importantes para a predição de características ligadas ao seu crescimento e trocas gasosas. Dentre as bandas, a banda B e R apresentaram a maiores influências, com a B influenciando positivamente e a R negativamente para as variáveis biométricas e o contrário foi observado para as variáveis fisiológicas.

A Tabela 9 apresenta os modelos preditivos gerados pelo algoritmo Random Forest (RF) para estimar variáveis biométricas e fisiológicas do milho em consórcio com braquiária, com base em dados espectrais.

Tabela 9. Desempenho dos modelos criado pelo método de Florestas Aleatórias (Random Forest) para prever características biométricas e fisiológicas com base em bandas espectrais do milho em competição com diferentes densidades de braquiária.

Variável	RMSE	RMSE (%)	R <sup>2</sup> (%)	Contribuições							
				R	G	B	NIR	RE	NDVI	GNDVI	SR
Ap	16,77	6,8	54,67	0,046	0,037	0,149	0,166	0,049	0,222	0,175	0,155
NF	0,818	6,6	51,02	0,036	0,043	0,142	0,251	0,052	0,087	0,262	0,126
DC	0,144	8,4	-17,24	0,048	0,078	0,243	0,287	0,106	0,050	0,132	0,056
MFT	67,53	15,4	36,23	0,087	0,123	0,136	0,285	0,121	0,076	0,099	0,074
MST	14,24	18,0	16,92	0,047	0,044	0,109	0,211	0,077	0,141	0,201	0,171
MSF	3,06	12,5	48,79	0,049	0,029	0,097	0,347	0,067	0,146	0,143	0,122
MSC	8,24	17,7	31,10	0,025	0,047	0,102	0,237	0,071	0,155	0,212	0,150
PROD,	368,84	46,7	1,76	0,072	0,073	0,166	0,351	0,063	0,070	0,136	0,069
A	7,457	20,2	11,75	0,072	0,075	0,075	0,310	0,133	0,068	0,160	0,064

Gs	0,053	18,4	48,08	0,106	0,041	0,140	0,087	0,041	0,211	0,210	0,163
Ci	30,31	21,1	72,51	0,078	0,030	0,489	0,094	0,043	0,074	0,119	0,073
E	1,104	15,9	51,61	0,130	0,025	0,085	0,029	0,229	0,076	0,076	0,170
Tleaf	1,689	5,0	47,36	0,055	0,059	0,211	0,242	0,066	0,043	0,282	0,041
Ci/Ca	0,078	20,2	64,27	0,094	0,027	0,458	0,105	0,057	0,080	0,115	0,064

Altura de planta (AP – cm); Diâmetro de colmo (DC - mm); Número de folhas (NF); massa fresco das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF) e massa seca total (MST). taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca).

Os resultados da Tabela 9 mostram grande variação nos coeficientes de determinação ( $R^2$ ), que oscilaram de -17,24% para o diâmetro do colmo até 72,51% para o carbono interno (Ci). Essa variação reflete as diferentes sensibilidades das variáveis à modelagem baseada em aprendizado de máquina, destacando-se a importância da escolha das bandas espectrais, ou seja, indica que a capacidade preditiva dos modelos com comportamento parecido com o modelo de regressão múltipla.

A aprendizagem de máquina utilizando o RF é eficaz para lidar com relações não lineares entre variáveis e é amplamente aplicada na modelagem de eventos agrícolas, como previsão de produtividade, avaliação do estresse hídrico e monitoramento da vegetação via sensoriamento remoto (HAN et al., 2019).

Uma das grandes vantagens do RF é a habilidade de unir diversas variáveis (como bandas espectrais) e identificar padrões complexos, algo que frequentemente apresenta desafios em modelos de regressão linear convencionais. Contudo, a eficácia do modelo pode ser restringida pela quantidade e pela qualidade dos dados utilizados no treinamento, assim como pela escolha correta dos hiperparâmetros, incluindo o número de árvores e a profundidade dos nós (BARZIN et al., 2020).

Para as variáveis biométricas observou que a Ap, NF e MSF apresentaram coeficientes de determinação superiores maiores que 48% utilizando o modelo RF com dados espectrais. Portanto, reforçando a importância do NDVI e GNDVI na associação com o acúmulo de biomassa e crescimento vegetal. O modelo, no entanto, não conseguiu prever adequadamente a Prod ( $R^2= 1,76\%$ ), possivelmente devido à influência de fatores externos não detectados por reflectância como variabilidade edáfica, manejo agrônômico, estresse hídrico ou fitossanitário.

Esses resultados indicam a necessidade de incorporar variáveis complementares ao modelo, provenientes de fontes adicionais (ex.: dados meteorológicos, propriedades do solo ou características genéticas), para aprimorar a acurácia na predição da produtividade.

Macedo et al. (2023), estudando a estimativa da produtividade e biomassa aérea do milho via índices de vegetação identificou correlações acima de 70% para o NDVI e GNDI com a produtividade e a biomassa da parte aérea, permitindo adequadamente que a obtenção periódica de imagens e processamento possa estimar o desenvolvimento e a produtividade das culturas.

Para uma análise de predição utilizando o método Random Forest a altura do milho apresentou um  $R^2$  de 54,67%, indicando uma predição moderada e  $RMSE\% = 6,8$  e número de folhas teve um desempenho semelhante ( $R^2 = 51,02\%$ ,  $RMSE\% = 6,6\%$ ), que indica uma previsão razoável.

Por outro lado, o modelo não conseguiu prever o diâmetro do colmo, resultando em um  $R^2$  negativo (-17,24%) e um erro relativamente alto ( $RMSE\% = 8,4\%$ ). Esse resultado indica que a variabilidade dessa variável não foi explicada pelas bandas espectrais, por meio deste modelo, e que possivelmente fatores como estrutura interna da planta e variabilidade genética podem ser mais determinantes para essa característica.

As variáveis biométricas MFT, MST, MSF e MSC variam em precisão. Por exemplo, a MSF tem um  $RMSE\%$  mais baixo (12,5%) e  $R^2$  48,79%, sugerindo uma moderada previsão.

A predição da massa fresca total (MFT) apresentou um  $R^2$  de 36,23% e  $RMSE$  (18,0) sugerindo uma precisão limitada. Já a massa seca das folhas (MSF) obteve um desempenho melhor que a MFT, com  $R^2$  de 48,79% e um erro relativo menor ( $RMSE\% = 12,5\%$ ), indicando que os índices espectrais utilizados foram mais eficientes para estimar essa variável.

Contudo, a produtividade (PROD) teve um desempenho insatisfatório, apresentando um  $R^2$  de apenas 1,76% e um erro muito alto ( $RMSE\% = 46,7\%$ ). Isso mostra que o modelo RF, com esse conjunto de dados, não conseguiu detectar padrões mediante a complexidade dos fatores que influenciam a produtividade do milho. Isso pode estar relacionado à influência de variáveis não espectrais, como condições edafoclimáticas e manejo agrícola, que não foram incluídas na modelagem (SILVA et al., 2023).

Han et al. (2019), em seu estudo usou imagens multiespectrais e digitais coletadas por um sistema UAV para estimar a biomassa do milho usando quatro algoritmos de aprendizado de máquina (MLR, SVM, ANN e RF) e observou que o modelo RF deu os resultados mais equilibrados, com baixo erro e uma alta proporção da variância explicada para o conjunto de treinamento e o conjunto de teste.

Para as variáveis fisiológicas foi possível observar que o Ci e a relação Ci/Ca apresentaram os melhores desempenhos ( $R^2 > 64\%$ ), com alta contribuição da banda B, reflexo da maior sensibilidade dessa banda à clorofila e estrutura celular em condições de estresse (Li et al., 2024).

Para as variáveis gs, E e Tleaf a predição foi satisfatória, com valores de  $R^2$  próximo 50%. Entretanto, a variável A apresentou baixo desempenho ( $R^2 = 11,75\%$ ), sugerindo que a fotossíntese líquida envolve fatores complexos que não são completamente captados pela reflectância espectral, com as limitações bioquímicas já referidas no trabalho, bem como pela variação ao longo do dia (LOPES et al., 2009).

O desempenho do RF para o carbono interno (Ci), que teve o maior  $R^2$  da análise (72,51%) e um erro moderado (RMSE% = 21,1%). Isso sugere que as bandas espectrais foram eficazes para estimar a concentração interna de  $CO_2$ , um fator crítico na avaliação da fotossíntese e do estresse hídrico.

A razão Ci/Ca (Ci/ Ca) também apresentou um bom desempenho ( $R^2 = 64,27\%$ , RMSE% = 20,2%), indicando que a relação entre a absorção e a fixação de  $CO_2$  pode ser estimada com relativa precisão a partir de imagens espectrais.

A temperatura foliar (Tleaf) teve um  $R^2$  de 47,36% e um erro baixo (RMSE% = 5,0%), indicando que a modelagem conseguiu prever essa variável com um grau razoável de confiabilidade. A condutância estomática (gs) teve um desempenho semelhante ( $R^2 = 48,08\%$ , RMSE% = 18,4%), mostrando que as aberturas estomáticas podem ser correlacionadas com as respostas espectrais da planta.

A taxa fotossintética líquida (A), no entanto, teve um  $R^2$  baixo (11,75%) e um erro relativamente alto (RMSE% = 20,2%), o que indica que essa variável pode depender de fatores que não foram capturados pelos índices espectrais empregados na modelagem. Pesquisas sugerem que índices específicos, como o Photochemical Reflectance Index (PRI), podem melhorar a predição da fotossíntese ao correlacionar-se diretamente com a eficiência do uso da luz (ZARCO-TEJADA et al., 2018).

Segundo Barzin et al. (2020) existem vantagens nos modelos de aprendizado de conjunto não paramétricos sobre o modelo baseado em regressão, pois pode ser

associada à existência de relações não lineares que o RF pode integrar durante o desenvolvimento do modelo. Além disso, a flexibilidade na configuração de hiperparâmetros dos métodos de boosting pode resultar em maior desempenho na previsão de características.

Analisando as contribuições das bandas e os índices vegetativos derivados (tabela 9) podemos observar que o NIR, seguindo do GNDVI e a Banda B foram as que mais contribuíram para construção dos modelos.

A análise da importância das variáveis espectrais na construção dos modelos revela que a banda do infravermelho próximo (NIR) foi a mais relevante para a maioria das previsões, seguida pelo GNDVI e pela banda azul (B). A importância do NIR está relacionada à sua associação com a biomassa vegetal e a atividade fotossintética, enquanto o GNDVI tem sido amplamente utilizado para estimar o teor de clorofila em culturas agrícolas (GITELSON et al., 2003).

A tabela 10 mostra o desempenho do modelo criado por rede neurais na previsão de variáveis biométricas e fisiológicas da cultura do milho analisada utilizando RMSE, RMSE % e R<sup>2</sup> %.

Tabela 10. Desempenho dos modelos criados por rede neurais para prever características biométricas e fisiológicas com base em bandas espectrais do milho em competição com diferentes densidades de braquiária.

Variável	RMSE	RMSE (%)	R <sup>2</sup> (%)
Biométricas			
AP	85,00	0,343	-1064,70
NF	1,92	0,156	-169,19
DC	0,25	0,144	-245,09
MFT	250,50	0,569	-777,29
MST	18,38	0,233	-38,43
MSF	4,66	0,190	-18,67
MSC	9,70	0,209	4,45
PROD.	655,85	0,831	-210,61
Fisiológicas			
A	8,33	0,225	-10,04
gs	0,059	0,202	31,17
Ci	29,65	0,207	73,70

E	1,33	0,192	29,40
Tleaf	4,18	0,125	-223,28
Ci/Ca	0,055	0,141	82,50

Altura de planta (AP – cm); Diâmetro de colmo (DC - mm); Número de folhas (NF); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF) e massa seca total (MST). taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca).

Os resultados mostram que os modelo de redes neurais não foram capazes de prever com precisão as variáveis biométricas do milho. O  $R^2$  negativo para todas as variáveis biométricas, como altura da planta (-1064,70%), número de folhas (-169,19%) e diâmetro do colmo (-245,09%), indica que a rede neural não conseguiu estabelecer uma relação significativa entre as bandas espectrais e essas variáveis. Esse resultado sugere que o modelo não registrou corretamente os padrões subjacentes ou que há limitação na qualidade e quantidade dos dados de entrada.

A PROD, variável de maior interesse agrônomo, também apresentou um desempenho muito fraco ( $R^2 = -210,61\%$  e  $\text{RMSE}\% = 83,1\%$ ), indicando que os parâmetros espectrais utilizados no treinamento não foram suficientes para gerar previsões confiáveis. Esse resultado é consistente com estudos que mostram que a produtividade depende de múltiplos fatores além dos espectrais, como condições edafoclimáticas, manejo e interações fisiológicas da planta (HAN et al., 2019).

Uma possível explicação para esses baixos desempenhos é que as variáveis biométricas são influenciadas por fatores que não se refletem diretamente nos índices espectrais. Alternativamente, o modelo pode não ter sido ajustado corretamente, e arquiteturas mais complexas poderiam melhorar a precisão (BARZIN et al., 2020).

O modelo mostrou bons resultados para algumas variáveis fisiológicas, diferente das variáveis biométricas, especialmente aquelas relacionadas ao metabolismo do carbono. O carbono interno (Ci) teve um  $R^2$  de 73,70% e um  $\text{RMSE}\%$  de 20,7%, indicando que a rede neural conseguiu prever essa variável com relativa precisão. O mesmo ocorreu com a razão Ci/Ca, que demonstrou o melhor desempenho do modelo ( $R^2 = 82,50\%$ ,  $\text{RMSE}\% = 14,1\%$ ).

Essa alta capacidade preditiva para Ci e Ci/Ca é coerente com estudos que demonstram que essas variáveis estão fortemente correlacionadas com o conteúdo

de clorofila e a atividade fotossintética, características que podem ser detectadas por índices espectrais como o NDVI e o GNDVI (GITELSON et al., 2003).

Outras variáveis fisiológicas, como condutância estomática (gs) e transpiração (E), apresentaram desempenho intermediário, com  $R^2$  de 31,17% e 29,40%, respectivamente, e erros moderados (RMSE% de 20,2% e 19,2%). Esses valores indicam que a modelagem neural foi capaz de capturar parte da variação dessas variáveis, mas com precisão limitada.

Por outro lado, a temperatura foliar (Tleaf) teve um desempenho insatisfatório ( $R^2 = -223,28\%$  e RMSE% de 12,5%), sugerindo que os índices espectrais utilizados não foram eficazes para essa previsão. Estudos indicam que a inclusão de variáveis ambientais, como temperatura do ar e umidade relativa, poderia melhorar a precisão desse modelo (ZHU et al., 2020).

É possível observar que o modelo criado demonstra a impossibilidade de previsão das variáveis biométricas pelo método das redes neurais, apesar dos valores de RMSE % baixo em alguns casos, o valor negativo para o  $R^2$  % indica que o modelo não está conseguindo capturar a variabilidade do banco de dados apresentados.

Para as variáveis fisiológicas foi possível obter bons resultados para Ci e Ci/Ca, onde o Ci apresentou RMSE% 20,7% e  $R^2\%$  73,70%; e o Ci/Ca RMSE% 14,1% e  $R^2\%$  82,50%. O modelo apresentou bom desempenho para essas variáveis com um valor de  $R^2$  elevado, sugerindo que consegue capturar bem as mudanças. Esses dados sugerem com o modelo que as demais variáveis biométricas e fisiológicas precisam de ajustes adicionais para lidar com a baixa precisão, talvez testando um banco de dados mais robusto.

A precisão dos modelos preditivos pode ser afetada por diversos fatores, incluindo a quantidade e a qualidade das amostras utilizadas no treinamento e teste, além da complexidade dos algoritmos de aprendizado de máquina empregados. Uma melhora considerável na previsão pode ser conseguida com o uso do modelo de aprendizado de conjunto do que com o algoritmo de regressão linear simples (Barzin et al., 2020).

A maior sensibilidade das bandas B e R, observada nos modelos, reforça o papel dessas faixas no diagnóstico de alterações pigmentares associadas ao estresse, como já relatado por Gitelson et al. (2002) e Cotrozzi et al. (2020). No entanto, a predominância do GNDVI sobre o NDVI na previsão das variáveis biométricas difere de Girolamo-Neto et al. (2019), que verificaram melhor desempenho

do NDVI em canaviais. Essa divergência possivelmente decorre da arquitetura foliar do milho e da altura de voo utilizada neste trabalho (44 m), que proporcionou maior contraste espectral nas regiões de borda do infravermelho.

Os resultados da tabela 11 traz um resumo do desempenho dos três modelos de predição (RLM, RF e RN) aplicados às variáveis biométricas e fisiológicas do milho em competição com a braquiária.

Tabela 11. Resumo demonstrando o desempenho dos modelos de predição das variáveis biométricas e fisiológicas do milho em competição com a braquiária mostrando o coeficiente de regressão ( $R^2$ ) e a raiz do erro quadrado médio normalizado (RMSE%).

Variável	Modelo	$R^2$	RMSE%
<b>Biométricas</b>			
AP	Regressão Múltipla (RLM)	68	
	Randon Forest (RF)	54,67	6,8
	Rede Neural (RN)	-1064,70	0,343
NF	Regressão Múltipla (RLM)	61	
	Randon Forest (RF)	51,02	6,6
	Rede Neural (RN)	-169,19	0,156
DC	Regressão Múltipla (RLM)	12	
	Randon Forest (RF)	-17,24	8,4
	Rede Neural (RN)	-245,09	0,144
MFT	Regressão Múltipla (RLM)	17	
	Randon Forest (RF)	36,23	15,4
	Rede Neural (RN)	-777,29	0,569
MST	Regressão Múltipla (RLM)	59	
	Randon Forest (RF)	16,92	18,0
	Rede Neural (RN)	-38,43	0,233
MSF	Regressão Múltipla (RLM)	53	
	Randon Forest (RF)	48,79	12,5
	Rede Neural (RN)	-18,67	0,190
MSC	Regressão Múltipla (RLM)	60	
	Randon Forest (RF)	31,10	17,7
	Rede Neural (RN)	4,45	0,209
PROD.	Regressão Múltipla (RLM)	31	
	Randon Forest (RF)	1,76	46,7
	Rede Neural (RN)	-210,61	0,831
<b>Fisiológicas</b>			
A	Regressão Múltipla (RLM)	11	
	Randon Forest (RF)	11,75	20,2
	Rede Neural (RN)	-10,04	0,225
gs	Regressão Múltipla (RLM)	56	
	Randon Forest (RF)	48,08	18,4
	Rede Neural (RN)	31,17	0,202
Ci	Regressão Múltipla (RLM)	63	
	Randon Forest (RF)	72,51	21,1

	Rede Neural (RN)	73,70	0,207
	Regressão Múltipla (RLM)	71	
E	Randon Forest (RF)	51,61	15,9
	Rede Neural (RN)	29,40	0,192
	Regressão Múltipla (RLM)	47	
Tleaf	Randon Forest (RF)	47,36	5,0
	Rede Neural (RN)	-223,28	0,125
	Regressão Múltipla (RLM)	63	
Ci/Ca	Randon Forest (RF)	64,27	20,2
	Rede Neural (RN)	82,50	0,141

Altura de planta (AP – cm); Diâmetro de colmo (DC - mm); Número de folhas (NF); massa fresca das folhas (MFT); massa seca do caule (MSC); massa seca das folhas (MSF) e massa seca total (MST). taxa fotossintética líquida (A;  $\mu\text{mol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$ ), condutância estomática (gs;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), Carbono interno (Ci;  $\mu\text{mol CO}_2 \text{ mol}^{-1} \text{ ar}$ ) transpiração (E;  $\text{mol H}_2\text{O m}^{-2} \text{ s}^{-1}$ ), temperatura foliar (Tleaf; °C) e a relação carbono interno/carbono do ambiente (Ci/Ca).

As variáveis biométricas analisadas com os modelos tradicionais (RLM e RF) apresentou desempenho mais consistente e interpretável, enquanto as redes neurais mostraram mais instabilidade, com valores de  $R^2$  muitas vezes negativos. Demonstrando que a seleção de variáveis mais robusta pode melhorar os resultados dos modelos.

No entanto as variáveis fisiológicas apresentaram resultados melhores de predição, especialmente com os modelos RF e RN, indicando que essas variáveis são mais bem explicadas pelas variáveis espectrais utilizadas, inclusive demonstrando alto poder de predição para as variáveis Ci e Ci/Ca.

O desempenho superior da regressão linear múltipla nas variáveis biométricas está de acordo com Barzin et al. (2020), que observaram respostas lineares consistentes entre índices espectrais e produtividade de milho em estágios avançados do ciclo. Por outro lado, a maior eficiência das redes neurais na predição das variáveis fisiológicas confirma a capacidade dessas técnicas em modelar relações não lineares complexas, como também reportado por Liu et al. (2021) e Asaari et al. (2022). Essa complementaridade entre modelos evidencia que a integração de métodos paramétricos e não paramétricos pode aprimorar a acurácia das estimativas.

O desempenho distinto entre os modelos testados evidencia a importância da escolha do método estatístico conforme a natureza da variável. A regressão linear múltipla apresentou estabilidade e interpretabilidade para atributos biométricos, corroborando Han et al. (2019). Já as redes neurais artificiais, mais eficientes para prever variáveis fisiológicas como Ci e Ci/Ca, mostraram capacidade superior para capturar relações não lineares complexas, o que está em conformidade com Cotrozzi

et al. (2020). Essa complementaridade entre métodos paramétricos e não paramétricos também foi reportada por Ampatzidis e Partel (2019) e reforça o potencial de integração entre algoritmos para aplicações agrícolas.

A substituição de medições pontuais por estimativas espectrais representa um avanço metodológico significativo. Resultados semelhantes foram relatados por Brewer et al. (2022), que associaram condutância estomática e temperatura foliar obtidas por VANTs a indicadores de estresse hídrico com alto grau de correlação. Assim como em Guo et al. (2021), este estudo demonstra o potencial do uso de sensores multiespectrais em fenotipagem de alto rendimento, especialmente em sistemas consorciados de milho e braquiária.

## 2.4. CONCLUSÕES

Neste estudo, observou-se variações significativas na maioria dos atributos avaliados ao longo das fases de desenvolvimento do milho, evidenciando a eficiência do uso do espectro eletromagnético na avaliação do estado fisiológico das plantas. Os resultados demonstram o potencial de substituição das medições pontuais obtidas de aparelhos do tipo IRGA por interpretações espectrais de imagens capturadas por VANTs a 44 metros de altura, para a maioria das variáveis analisadas.

Os melhores desempenhos na predição das variáveis biométricas (altura de plantas – Ap, número de folhas – NF, massa seca da parte aérea – MSC e massa seca de folhas – MSF) foram alcançados pelos modelos de regressão linear múltipla, destacando-se a banda azul (B) e o índice GNDVI como os parâmetros de maior contribuição positiva.

Em relação às variáveis fisiológicas, o modelo linear múltiplo apresentou boa capacidade preditiva para a maioria dos parâmetros, exceto para a variável A (taxa fotossintética). Por outro lado, a rede neural artificial (RNA) obteve melhor desempenho na predição de Ci e Ci/Ca, indicando que, para dados espectrais obtidos em condições de campo, diferentes abordagens estatísticas podem apresentar desempenhos complementares, dependendo da variável analisada.

Entre as bandas da câmera multiespectral, as faixas vermelha (R) e azul (B) mostraram-se mais influentes nos modelos, enquanto, entre os índices espectrais, o GNDVI destacou-se na predição das variáveis biométricas e o NDVI nas variáveis fisiológicas.

Dessa forma, conclui-se que é possível estimar com eficiência variáveis biométricas e fisiológicas do milho por meio de métodos paramétricos e não paramétricos aplicados a dados espectrais. Essa abordagem permite reduzir a necessidade de medições pontuais em campo, representando um avanço na adoção de tecnologias não destrutivas e de alta precisão no monitoramento fisiológico de culturas agrícolas.

## 2.5. REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, V. B.; G. CECCON; LEITE, L. F. Morfologia e Produtividade de Híbridos de Milho Safrinha Solteiro e Consorciado com Braquiária. **Revista Brasileira de Milho e Sorgo**, v. 12, n. 2, p. 152–163, 30 ago. 2013.

ARAB, M.M.; YADOLLAHI, A.; EFTEKHARI, M.; AHMADI, H.; AKBARI, M.; KHORAMI, S.S. Modeling and Optimizing a New Culture Medium for In Vitro Rooting of G×N15 Prunus Rootstock using Artificial Neural Network-Genetic Algorithm. **Scientific Reports**, v.8, n.9977, 2018.

ASAARI, M. S. M.; MERTENS, S.; VERBRAEKEN, L.; DHONDT, S.; INZÉ, D.; BIKRAM, K.; SCHEUNDERS, P. Non-destructive analysis of plant physiological traits using hyperspectral imaging: A case study on drought stress. **Computers and Electronics in Agriculture**, v. 195, p. 106806, 2022.

AMPATZIDIS, Y.; PARTEL, V. Fenotipagem de alto rendimento baseada em UAV em citros utilizando imagens multiespectrais e inteligência artificial. **Sensoriamento remoto**, v. 11, n. 4, p. 410, 2019.

ATZBERGER, C. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013.

BARZIN, R.; PATHAK, R.; LOTFI, H.; VARCO, J.; BORA, GC. Use of UAS Multispectral Imagery at Different Physiological Stages for Yield Prediction and Input Resource Optimization in Corn. **Remote sensing**, v. 12, n. 15, p. 2392, 2020.

BERGAMASCHI, H.; MATZENAUER, R. O milho e o clima. Porto Alegre: Emater/RS-Ascar, 2014. 84 p.

BIANCHI, L.; GERMINO, G.H.; SILVA, M. de A. Adaptação das plantas ao déficit hídrico. **Acta Iguazu**, v. 5, n. 4, p. 15-32, 2016.

BORRÁS, L.; VITANTONIO-MAZZINI, L. N. Maize reproductive development and kernel set under limited plant growth environments. **Journal of Experimental Botany**, v. 69, n. 13, p. 3235-3243, 2018.

BREWER, K.; CLULOW, A.; SIBANDA, M.; GOKOOL, S.; ODINDI, J.; MUTANGA, O.; NAIKEN, V.; CHIMONYO, V. G.P.; MABHAUDHI, T. Estimativa da temperatura foliar do milho e condutância estomática como indicadores de estresse hídrico com base em imagens ópticas e térmicas adquiridas usando uma plataforma de Veículo Aéreo Não Tripulado (UAV). **Drones**, v. 6, n. 7, p. 169, 2022.

BOYD, R. A., GANDIN, A., COUSINS, A. B. Temperature responses of C4 photosynthesis: biochemical analysis of rubisco, phospho enol pyruvate carboxylase, and carbonic anhydrase in *Setaria viridis*. **Plant Physiology**, v. 169, n. 3, p. 1850-1861, 2015.

BRITO, M. E. B., DE ARAÚJO FILHO, G. D., WANDERLEY, J. A. C., DE MELO, A. S., DA COSTA, F. B., & FERREIRA, M. G. P. Crescimento, fisiologia e produção do milho doce sob estresse hídrico. *Bioscience Journal*, n. 29, v.5, 1244-1254, 2013.

CARVALHO, M. W. L., BASTOS, E. A., CARDOSO, M. J., DE ANDRADE JUNIOR, A. S., & DE SOUSA, C. A. F. Morfofisiologia do milho irrigado com e sem déficit hídrico sob diferentes arranjos de plantas na região meio-norte do Piauí. *Revista Cultura Agronômica*, v.31, n.1, 41, 2022.

CECCON, G.; SILVA, J. F. DA; NETO, A. L. N.; MAKINO, P. A.; SANTOS, A. DOS. Produtividade de milho safrinha em espaçamento reduzido com populações de milho e de *Brachiaria ruziziensis*. *Revista Brasileira de Milho e Sorgo, Sete Lagoas*, v. 13, n. 3, p. 326-335, 2014.

CECCON, G.; DA SILVA, J. F.; MAKINO, P. A.; NETO, A. L. N. Consórcio milho-braquiária com densidades populacionais da forrageira no centro-sul do Brasil. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v. 17, n. 1, p. 157-167, 2018.

CHIODEROLI, C. A., DE MELLO, L. M., GRIGOLLI, P. J., FURLANI, C. E., SILVA, J. O., & CESARIN, A. L. Atributos físicos do solo e produtividade de soja em sistema de consórcio milho e braquiária. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, p. 37-43, 2012.

COTROZZI, L., PERON, R., TUINSTRA, M. R., MICKELBART, M. V., & COUTURE, J. J. Spectral phenotyping of physiological and anatomical leaf traits related with maize water status. *Plant Physiology*, v.184, n.3, 1363-1377, 2020.

DAMM, A.; COGLIATI, S.; COLOMBO, R.; FRITSCH, L.; GENANGELI, A.; GENESIO, L.; HANUS, J.; PERESSOTTI, A.; RADEMSKE, P.; RASCHER, U.; SCHUETTEMAYER, D.; SIEGMANN, B.; STURM, J.; MIGLIETTA, F. Response times of remote sensing measured sun-induced chlorophyll fluorescence, surface temperature and vegetation indices to evolving soil water limitation in a crop canopy. **Remote Sensing of Environment**, v. 273, 2022.

DOS SANTOS, O. L.; PADOLFI, A. S.; RAMALDES, G. P. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica FAESA**, v.14, n.1, p.145-165, 2018.

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. 1-11, 2021.

EMBRAPA. **Manual de análises químicas de solos, plantas e fertilizantes**. Ed. DA SILVA, F. C. Brasília: EMBRAPA informação tecnológica, 2009.

FLOREANO, D.; WOOD, R.J. Science, technology and the future of small autonomous drones. **Nature**, v. 521, p. 460-466, 2015.

FREITAS, C. D.; PAMPLONA, J. D. P.; LINS, H. A.; SOUZA, M. D. F.; DOMBROSKI, J. L.; SILVA, D. V. Gaseous exchanges of corn and weeds under competition and water regimes. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 24, p. 465-473, 2020.

FLEXAS, J.; MEDRANO, H. Drought-inhibition of photosynthesis in C3 plants: stomatal and non-stomatal limitations revisited. **Annals of Botany**, Oxford, v. 89, n. 2, p. 183-189, 2002.

FREITAS, M.A.; SILVA, D.V.; PEREIRA, G.A.; SOUZA, W.M.; NUNES JR, J.; SILVA, A.A. Características fisiológicas do milho consorciado com diferentes arranjos de plantas de capim-maruca. **Advances in Weed Science**, v. 39, 2021.

GALON, L.; CONCENÇO, G.; TIRONI, S. P.; ROCHA, P. R. R.; SILVA, A. F.; ASPIAZÚ, I.; FERREIRA, E. A.; SILVA, A. A.; BORGES, E. T. Influence of brachiaria brizantha in physiological characteristics related to photosynthesis and efficient use of water in sugarcane. **Planta Daninha**, Viçosa, v. 29, p. 1037-1043, 2011.

GIROLAMO-NETO, C. D.; SANCHES, I. D. A.; NEVES, A. K.; PRUDENTE, V. H. R.; KÖRTING, T. S.; PICOLI, M. C. A.; ARAGÃO, L. E. O. E. C. D. Assessment of texture features for bermudagrass (*Cynodon dactylon*) detection in sugarcane plantations. **Drones**, v.3, n.2, p.36, 2019.

GITELSON, A. A.; ZUR, Y.; CHIVKUNOVA, O. B.; MERZLYAK, M.N. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochem Photobiol.** v. 75, p. 272–281, 2002.

GITELSON, A. A.; GRITZ, U.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, Amsterdam, v. 160, n. 3, p. 271-282, 2003.

GOMES, K. R.; AMORIM, A. V.; FERREIRA, F. J.; A FILHO, F. L.; LACERDA, C. F.; GOMES-FILHO, E. Respostas de crescimento e fisiologia do milho submetido a estresse salino com diferentes espaçamentos de cultivo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, p. 365-370, 2011.

GUO, W.; CARROLL, M. E.; SINGH, A.; SWETNAM, T. L.; MERCHANT, N., SARKAR, S.; ASHEESH, K. S.; GANAPATHYSUBRAMANIAN, B. UAS-based plant phenotyping for research and breeding applications. **Plant Phenomics**, v. 2021, 2021.

HAN, L.; YANG, G.; DAI, H.; XU, B.; YANG, H.; FENG, H.; LI, Z.; YANG, X. Modeling maize above-ground biomass based on machine learning approaches using UAV remote-sensing data. **Plant methods**, v. 15, n. 1, p. 1-19, 2019.

ISLAM, N.; RASHID, M. M.; WIBOWO, S.; WASIMI, S.; MORSHED, A.; XU, C.; MOORE, S. Machine learning based approach for Weed Detection in Chilli field using RGB images. *Advances in natural computation, fuzzy systems and knowledge discovery*. **Springer International Publishing**, p. 1097-1105, 2020.

JENSEN, J. R. Biophysical remote sensing. **Annals of the Association of American Geographers**, v. 73, n. 1, p. 111-132, 1983.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma perspectiva sobre recursos terrestres**. São José dos Campos: Parêntese, 2009.

KHAMIS, A. K.; ASLI, U. A.; SARJUNI, M. N. H.; JALAL, M. A.; KARIM, H. A. A.; SULAIMAN, S. Relationship between Photosynthetic Rate and Stomatal Conductance, Intercellular CO<sub>2</sub> Concentration, Transpiration Rate, Vapour Pressure Deficit and Photosynthetically Active Radiation in Sweet Corn (*Zea mays*). **Journal of Sustainable Natural Resources**, v. 1, n. 2, p. 1-8, 2020.

LAWSON, T.; BLATT, M. R. Stomatal size, speed, and responsiveness impact on photosynthesis and water use efficiency. **Plant Physiology**, *Rockville*, v. 164, n. 4, p. 1556-1570, 2014.

LEMOS, J. P.; GALVÃO, J. C. C.; SILVA, A. A.; FONTANETTI, A.; CORRÊA, M. L. P.; CECON, P. R. Morfofisiologia de plantas de milho em competição com picão-preto e trapoeraba submetidas a roçada. **Planta Daninha**, v. 30, p. 487-496, 2012.

Li, X., Feng, Y., Sun, X., Liu, W., Yang, W., Ge, X., & Jia, Y. Effects of various levels of water stress on morpho-physiological traits and spectral reflectance of maize at seedling growth stage. *Agronomy*, v.14, n9, p.2173, 2024.

LIU, S.; JIN, X.; NIE, C.; WANG, S.; YU, X.; CHENG, M.; SHAO, M.; WANG, Z; TUOHUTI, N.; BAI, Y. LIU, Y. Estimating leaf area index using unmanned aerial vehicle data: shallow vs. deep machine learning algorithms. **Plant Physiology**, v. 187, n. 3, p. 1551-1576, 2021.

LICHTENTHALER, H. K.; GITELSON, A.; LANG, M. Non-destructive determination of chlorophyll content of leaves of a green and an aurea mutant of tobacco by reflectance measurements. *J. Plant Physiol.* v. 148, p. 483–493, 1996.

LORENZETTI, J. G.; RODRIGUES, M. A.; DE PAIVA SOARES, A.; VIEIRA, C. R. Densidade de plantas e os efeitos nas características agronômicas, temperatura e umidade do solo em consórcio milho-braquiária. *Nativa*, v. 11, n. 1, p. 101-107, 2023.

LOPES, J. P., MACHADO, E. C., DEUBER, R., & MACHADO, R. S. Análise de crescimento e trocas gasosas na cultura de milho em plantio direto e convencional. *Bragantia*, v. 68, p. 839-848, 2009.

MACEDO, F. L., NÓBREGA, H., DE FREITAS, J. G., RAGONEZI, C., PINTO, L., ROSA, J., & PINHEIRO DE CARVALHO, M. A. Estimation of productivity and above-ground biomass for corn (*Zea mays*) via vegetation indices in Madeira Island. *Agriculture*, v.13 n.6, p.1115, 2023.

MADANI, B.; MIRSHEKARI, A.; IMAHORI, Y. Physiological responses to stress. In: Postharvest physiology and biochemistry of fruits and vegetables. **Woodhead Publishing**, p. 405-423, 2019.

MARTINS, G. D.; SILVA, O. F. D.; CARMO, G. J. D. S.; CASTOLDI, R.; SANTOS, L.; CHARLO, H. C. D. O. Estimation of biometric, physiological, and nutritional variables in lettuce seedlings using multispectral images. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 25, p. 689-695, 2021.

MAKINO, P. A. Desempenho agrônomo e fisiológico de milho em arranjos de plantas, com e sem braquiária, no verão e outono-inverno. Orientador: Gessi Ceccon, 2018. Tese (Doutorado em Agronomia) - Universidade Federal de Grande Dourados, Dourados, 2018. Disponível em: <https://repositorio.ufgd.edu.br/jspui/bitstream/prefix/476/1/PriscilaAkemiMakino.pdf> acesso: 27 nov. 2022, às 09:44

MAKINO, P. A.; CECCON, G.; FACHINELLI, R. Produtividade e teor de nutrientes em populações de milho safrinha solteiro e consorciado com braquiária. *Revista Brasileira de Milho e Sorgo*, v. 18, n. 2, p. 206-220, 2019.

MEDRANO, H. et al. Regulation of photosynthesis of C3 plants in response to progressive drought: stomatal conductance as a reference parameter. **Annals of Botany**, Oxford, v. 89, n. 7, p. 895-905, 2002.

MEROTTO JR, A.; BREDEMEIER, C.; VIDAL, R. A.; GOULART, I. C. G. D. R.; BORTOLI, E. D.; ANDERSON, N. L. Reflectance indices as a diagnostic tool for weed control performed by multipurpose equipment in precision agriculture. **Planta Daninhas**, v. 30, p. 437-447, 2012.

OLIVEIRA, RA; NASI, R.; NIEMELÄINEN, O.; NYHOLM, L.; ALHONOJA, K.; KAIVOSOJA, J.; JAUHAINEN, L.; VILJANEN, N.; NEZAMI, S.; MARKELIN, L. Estimadores de aprendizado de máquina para a quantidade e qualidade de pastos usados para produção de silagem usando espectrometria de imagem baseada em drones e fotogrametria. *Sensoriamento Remoto do Meio Ambiente*, v.246, p.1-20, 2020.

PEÑA-BARRAGÁN, J. M.; KELLY, M.; DE CASTRO, A.I.; LÓPEZ-GRANADOS, L. Object-based approach for crop row characterization in UAV images for site-specific weed management. **Proc. GEOBIA**, v. 1, p. 426-430, 2012.

PEÑA, J. M; TORRES-SÁNCHEZ, F.; CASTRO, A. I.; KELLY, M; LÓPEZ-GRANADOS, F. Weed Mapping in Early- Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. **PloS one**, v. 8, n. 10, p. e77151, 2013.

QGIS. Geographic Information System QGIS - Open Source Geospatial Foundation Project Versão 3.16, 2019. Disponível em: <<http://qgis.osgeo.org>>. Acesso em: 22 de abril de 2023

RAZA, A.; CHARAGH, S.; SADAQAT, N.; JIN, W. Arabidopsis thaliana: Model plant for the study of abiotic stress responses. **The Plant Family Brassicaceae: Biology and Physiological Responses to Environmental Stresses**, p.129-180, 2020.

REZENDE, A. V.; DO PRADO, R. A. T.; FAUSTINO, T. F.; FLORENTINO, L. A.; DIAS, N. C.; DOS SANTOS, P. C. D. O. Potencial agrônômico e valor nutritivo de forrageiras

implantadas na integração com a cultura do milho. **Research, Society and Development**, v. 11, n. 4, 2022.

RODRIGUES, O. L.; GALVÃO, J. C. C.; FERREIRA, E. A.; SILVA, D. V.; SANTOS, M. V., FERREIRA, L. R.; & FELIPE, R. S. Physiologic characteristics of corn and *Urochloa brizantha* (Hochst. ex A. Rich.) RD Webster in intercropping cultivation. **Chilean journal of agricultural research**, v. 74, n. 3, p. 257-262, 2014.

RONAY, I.; EPHRATH, J. E.; EIZENBERG, H.; BLUMBERG, D. G.; MAMAN, S. Hyperspectral reflectance and indices for characterizing the dynamics of crop–weed competition for water. **Remote Sensing**, v. 13, n. 3, 513, 2021.

SANTOS, H. G. DOS; JACOMINE, P. K. T.; ANJOS, L. H. C. DOS; OLIVEIRA, V. A. DE; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. DE; ARAUJO FILHO, J. C. DE; OLIVEIRA, J. B. DE; CUNHA, T. J. F. **Sistema brasileiro de classificação do solo**. 5. ed. Brasília: Embrapa, 2018.

SANTOS, Claiton. **Monitoramento aéreo e diagnóstico de plantas daninhas de difícil controle no sudoeste goiano**, 2019. Disponível em: <https://repositorio.ifgoiano.edu.br/handle/prefix/610>.

SILVA, D. V. **Efeitos da densidade populacional da braquiária sobre as características fisiológicas e produtivas do milho e da forrageira em consórcio**. Orientador: Tocio Sedyama, 2014. Tese (Doutorado em Fitotecnia) – Universidade Federal de Viçosa, Viçosa, 2014. Disponível em: <https://www.locus.ufv.br/bitstream/123456789/1240/1/texto%20completo.pdf> acesso: 26 nov. 2022, às 9:43

SILVA, D. V.; PEREIRA, G. A. M.; FREITAS, M. A. M. D.; SILVA, A. A. D.; SEDIYAMA, T.; SILVA, G. S.; FERREIRA, L. R.; CECON, P. R. Produtividade e teor de nutrientes do milho em consórcio com braquiária. **Ciência Rural**, v45, n.8, p.1394–1400, 2015.

SOUSA, D. M. G. de; LOBATO, E. **Cerrado: correção do solo e adubação**. 2. ed. Brasília: Embrapa, 2004.

TAKASU, A. T.; RODRIGUES, R. A. F.; GOES, R. J.; ARF, O.; HAGA, K. I. Desempenho agronômico do milho sob diferentes arranjos populacionais e espaçamento entrelinhas. **Agrarian**, Dourados, v. 7, n. 23, p. 34-41, 2013.

USDA - UNITED STATES DEPARTMENT OF AGRICULTURE. Grain: World Markets and Trade. Disponível em: <<https://apps.fas.usda.gov/psdonline/app/index.html#/app/advQuery>>. Acesso em: 20 out. 2022.

VIAN, A. L., SANTI, A. L., AMADO, T. J. C., CHERUBIN, M. R., SIMON, D. H., DAMIAN, J. M., & BREDEMEIER, C. Variabilidade espacial da produtividade de milho irrigado e sua correlação com variáveis explicativas de planta. **Ciência Rural**, v. 46, p. 464-471, 2016.

VILFAN, N.; VAN DER TOL, C.; YANG, P.; WYBER, R.; MALENOVSKÝ, Z.; ROBINSON, S.A.; VERHOEF, W. Extending Fluspect to simulate xanthophyll driven leaf reflectance dynamics. **Remote Sensing Environment**. v. 211, p. 345–356, 2018.

WANG, W., LI, M. Y., ZHOU, R., MO, F., KHAN, A., BATOOL, A., ZHANG, W., LU, J., ZHU, Y., WANG, B., YANG, Y., WANG, J., TAO, X., XIONG, Y. C. Leaf senescence, nitrogen remobilization, and productivity of maize in two semiarid intercropping systems. *European Journal of Agronomy*, 150, 126943, 2023.

ZHAO, J., BEDOUSSAC, L., SUN, J., CHEN, W., LI, W., BAO, X., WERF, W. V. D., LI, L. Competition-recovery and overyielding of maize in intercropping depend on species temporal complementarity and nitrogen supply. *Field Crops Research*, v.292, p.108820, 2023.

ZHANG, Y. et al. Estimation of vegetation photosynthetic capacity from space-based measurements of chlorophyll fluorescence for terrestrial biosphere models. **Global Change Biology**, Hoboken, v. 20, n. 12, p. 3727-3742, 2014.

ZHU, J.; TREMBLAY, N.; LIANG, Y. Comparing SPAD and atLEAF values for chlorophyll assessment in crop species. **Canadian Journal of Soil Science**, Ottawa, v. 92, n. 4, p. 645-648, 2012.

ZHU, J.; ELE, W.; YAO, J.; YU, Q.; XU, C.; HUANG, H.; MHAE, B.; JANDUG, C. Spectral reflectance characteristics and chlorophyll content estimation model of quercus aquifolioides leaves at different altitudes in Sejila Mountain. **Applied Science**, v.10, n. 10, p.3636, 2020.

ZUBLER, A. V.; YOON, J. Proximal methods for plant stress detection using optical sensors and machine learning. **Biosensors**, v. 10, n. 12, p. 193, 2020.

## 2.6 APÊNDICE

Tabela 1. Dados coletados em campos das avaliações biométrica do milho.

Trat.	Leit.	Bloco	Ap	NF	DC	MFT	MST	MSF	MSC	MSE	Prod
20	1	1	268	13	1,81	492	102	30	62	10	409
10	1	1	250	13	1,57	361	71	24	42	4	907
5	1	1	276	13	1,70	416	84	28	50	6	1322
0	1	1	254	13	1,50	392	81	24	49	8	1271
10	1	2	276	13	1,60	413	85	26	52	7	991
5	1	2	280	13	1,91	438	88	27	53	8	1027
20	1	2	284	14	1,91	617	115	32	66	17	1133
0	1	2	272	13	1,67	443	93	36	50	7	1133
5	1	3	269	13	1,83	589	112	34	66	12	611
20	1	3	261	13	1,79	410	84	25	51	7	971
0	1	3	274	13	1,72	426	87	30	50	7	924
10	1	3	253	12	1,52	297	69	25	40	4	613
10	1	4	259	12	1,64	410	93	29	54	10	1111
0	1	4	274	13	1,84	434	90	28	55	7	1131
5	1	4	271	12	1,78	427	83	25	50	8	1371
20	1	4	264	13	1,82	466	103	28	63	12	781
20	1	5	259	12	1,57	330	70	23	42	5	782
5	1	5	274	13	1,77	456	95	29	55	12	950
10	1	5	258	12	1,48	317	66	23	39	4	1097
0	1	5	262	12	1,80	430	100	28	58	13	555
0	1	6	274	13	1,88	500	100	32	62	7	1056
10	1	6	253	12	2,03	349	73	26	45	3	1168
20	1	6	262	12	1,75	413	80	28	48	4	846
5	1	6	254	13	1,57	298	70	23	42	4	561

Tabela 2. Dados coletados em campos das avaliações Fisiológica do milho.

Trat.	Leitura	Bloco	A	gs	Ci	Trmmol	Tleaf	Ci/Ca
0	1	1	42,609	0,239	79,343	4,817	32,680	0,140
5	1	1	39,883	0,211	63,525	4,529	32,728	0,114
10	1	1	35,417	0,182	53,591	4,149	31,873	0,137
20	1	1	35,584	0,190	66,629	4,558	31,763	0,174
0	1	2	30,904	0,184	101,538	4,910	36,309	0,213
5	1	2	30,787	0,177	89,621	4,086	33,619	0,207
10	1	2	37,719	0,207	75,805	4,409	32,918	0,132
20	1	2	35,201	0,219	100,401	5,041	34,770	0,166
0	1	3	33,334	0,211	48,329	5,024	37,747	0,186
5	1	3	46,424	0,228	33,782	5,778	38,041	0,168
10	1	3	24,801	0,182	21,743	4,612	37,808	0,201
20	1	3	40,577	0,187	17,104	4,648	37,475	0,209
0	1	4	34,292	0,167	41,855	4,004	34,476	0,253
5	1	4	34,354	0,177	54,429	4,289	35,170	0,263
10	1	4	30,783	0,156	51,377	3,808	34,199	0,199
20	1	4	41,355	0,220	57,680	4,881	35,342	0,233

0	1	5	39,113	0,224	85,980	4,737	36,425	0,222
5	1	5	32,699	0,175	63,027	4,376	36,549	0,184
10	1	5	39,962	0,239	92,642	5,590	36,295	0,263
20	1	5	35,622	0,243	116,275	5,662	35,924	0,203
0	1	6	33,552	0,188	81,316	4,667	37,041	0,249
5	1	6	37,351	0,203	66,753	4,878	37,035	0,241
10	1	6	41,843	0,235	77,460	5,676	36,998	0,263
20	1	6	42,068	0,213	46,450	5,243	37,051	0,339
0	2	1	37,886	0,354	187,558	7,679	31,683	0,493
5	2	1	32,558	0,290	185,602	6,504	31,421	0,484
10	2	1	44,243	0,416	190,053	8,368	30,513	0,503
20	2	1	29,588	0,316	220,453	6,560	30,101	0,572
0	2	2	32,988	0,277	170,836	6,517	32,750	0,446
5	2	2	35,888	0,328	178,624	7,418	32,415	0,468
10	2	2	32,077	0,279	179,205	6,462	32,094	0,467
20	2	2	38,552	0,378	199,152	8,188	32,195	0,523
0	2	3	44,364	0,408	185,629	8,701	32,944	0,491
5	2	3	46,471	0,404	171,946	8,520	32,569	0,457
10	2	3	39,217	0,329	171,861	7,853	33,644	0,452
20	2	3	43,854	0,414	190,097	8,698	32,672	0,503
0	2	4	42,316	0,313	144,028	7,552	34,140	0,380
5	2	4	43,393	0,372	173,561	8,376	34,032	0,459
10	2	4	44,679	0,366	160,720	8,164	33,664	0,426
20	2	4	43,172	0,354	166,263	8,034	34,153	0,439
0	2	5	44,793	0,368	162,161	8,506	34,358	0,430
5	2	5	47,209	0,376	156,002	8,789	34,442	0,415
10	2	5	43,815	0,384	173,860	8,937	34,534	0,461
20	2	5	41,769	0,335	161,340	8,021	34,504	0,426
0	2	6	46,819	0,397	168,853	8,720	33,913	0,449
5	2	6	47,724	0,451	187,587	10,355	34,729	0,500
10	2	6	45,678	0,349	144,325	8,368	34,611	0,383
20	2	6	43,938	0,363	161,194	8,387	34,445	0,427
0	3	1	30,856	0,312	212,169	6,074	28,588	0,551
5	3	1	21,239	0,300	262,289	5,786	28,459	0,673
10	3	1	21,985	0,407	267,269	6,379	27,482	0,686
20	3	1	19,191	0,252	252,372	4,520	27,358	0,646
0	3	2	29,658	0,260	188,568	5,522	29,397	0,490
5	3	2	28,893	0,310	218,717	6,206	28,983	0,567
10	3	2	28,885	0,277	203,975	5,576	28,826	0,529
20	3	2	32,201	0,311	196,967	6,338	29,187	0,512
0	3	3	38,186	0,304	163,848	6,536	29,969	0,430
5	3	3	36,008	0,313	183,288	6,375	29,325	0,479
10	3	3	39,863	0,299	152,511	6,415	30,114	0,400
20	3	3	35,869	0,320	184,582	6,595	29,589	0,482
0	3	4	46,048	0,321	129,880	7,367	31,271	0,345
5	3	4	44,924	0,334	143,657	7,824	31,827	0,380

10	3	4	38,530	0,331	178,294	7,201	30,648	0,468
20	3	4	47,762	0,298	101,512	7,585	32,725	0,270
0	3	5	54,488	0,361	110,980	9,255	33,800	0,298
5	3	5	53,371	0,372	123,019	9,308	33,260	0,330
10	3	5	44,068	0,297	117,844	8,016	33,883	0,311
20	3	5	49,374	0,339	124,951	8,406	32,854	0,332
0	3	6	56,945	0,395	121,219	9,726	33,628	0,326
5	3	6	48,386	0,312	106,548	8,471	34,311	0,284
10	3	6	44,111	0,263	90,810	7,302	34,181	0,240
20	3	6	49,354	0,297	90,760	8,049	34,188	0,241
0	4	1	32,572	0,523	261,104	10,551	30,266	0,682
5	4	1	33,087	0,318	203,193	6,148	29,521	0,529
10	4	1	27,948	0,497	273,736	7,852	28,535	0,709
20	4	1	19,020	0,606	297,265	7,454	27,607	0,763
0	4	2	43,013	0,342	159,019	8,699	32,498	0,420
5	4	2	30,664	0,365	215,090	8,589	31,799	0,559
10	4	2	32,395	0,330	209,054	7,826	31,288	0,545
20	4	2	36,225	0,285	160,523	7,561	32,487	0,420
0	4	3	23,153	0,227	196,433	6,784	34,062	0,507
5	4	3	48,253	0,307	104,779	8,269	32,949	0,279
10	4	3	34,737	0,294	174,331	8,657	34,215	0,456
20	4	3	33,569	0,324	195,256	8,741	33,191	0,510
0	4	4	35,908	0,286	162,970	8,388	34,241	0,427
5	4	4	33,340	0,263	159,932	7,939	34,594	0,417
10	4	4	39,291	0,340	174,508	9,452	33,923	0,459
20	4	4	26,903	0,259	202,000	7,800	34,621	0,523
0	4	5	33,494	0,246	145,373	7,367	34,992	0,380
5	4	5	42,461	0,317	144,832	8,770	34,378	0,383
10	4	5	34,787	0,264	146,735	7,497	34,893	0,384
20	4	5	31,152	0,234	152,577	7,001	34,663	0,397
0	4	6	30,874	0,307	195,115	8,248	34,424	0,509
5	4	6	33,895	0,286	171,847	9,224	35,962	0,450
10	4	6	31,906	0,259	165,546	7,977	35,375	0,432
20	4	6	40,605	0,294	133,230	8,980	35,428	0,352

Tabela 3. Dados coletados em campos das avaliações espectrais do milho.

Trat.	Leitura	Bloco	B	G	R	NIR	NE	NDVI	GNDVI	SR
0	1	1	0,060	0,114	0,131	0,225	0,163	0,263	0,325521	1,714627
5	1	1	0,057	0,111	0,115	0,235	0,157	0,342	0,359396	2,041292
10	1	1	0,057	0,111	0,117	0,236	0,159	0,337	0,358791	2,017696
20	1	1	0,056	0,111	0,112	0,242	0,158	0,367	0,369642	2,159967
0	1	2	0,056	0,112	0,110	0,239	0,160	0,370	0,361562	2,175667
5	1	2	0,059	0,114	0,128	0,229	0,165	0,283	0,332844	1,790139
10	1	2	0,060	0,114	0,132	0,226	0,164	0,265	0,328666	1,720889
20	1	2	0,056	0,111	0,112	0,238	0,160	0,360	0,36202	2,125252
0	1	3	0,053	0,105	0,108	0,226	0,152	0,351	0,365669	2,083973

5	1	3	0,054	0,109	0,107	0,234	0,156	0,370	0,365887	2,176124
10	1	3	0,054	0,106	0,109	0,230	0,152	0,357	0,369827	2,111381
20	1	3	0,055	0,108	0,113	0,228	0,156	0,339	0,356623	2,02351
0	1	4	0,058	0,111	0,119	0,230	0,160	0,318	0,349305	1,932657
5	1	4	0,059	0,112	0,122	0,225	0,161	0,295	0,334654	1,837891
10	1	4	0,057	0,109	0,114	0,231	0,157	0,338	0,356509	2,018911
20	1	4	0,057	0,109	0,115	0,225	0,157	0,322	0,346636	1,951956
0	1	5	0,059	0,113	0,132	0,226	0,165	0,261	0,335576	1,707303
5	1	5	0,058	0,112	0,124	0,230	0,164	0,302	0,345612	1,863472
10	1	5	0,059	0,113	0,129	0,235	0,167	0,291	0,347877	1,821073
20	1	5	0,058	0,112	0,121	0,229	0,162	0,307	0,342717	1,887761
0	1	6	0,059	0,112	0,132	0,227	0,163	0,265	0,340144	1,722716
5	1	6	0,057	0,111	0,113	0,230	0,156	0,339	0,349749	2,025532
10	1	6	0,056	0,107	0,122	0,225	0,156	0,296	0,353686	1,839014
20	1	6	0,056	0,109	0,112	0,233	0,154	0,351	0,363622	2,083072
0	2	1	0,039	0,114	0,042	0,412	0,152	0,817	0,566548	9,909109
5	2	1	0,041	0,114	0,041	0,441	0,151	0,831	0,589545	10,84161
10	2	1	0,046	0,118	0,054	0,419	0,158	0,773	0,559915	7,816222
20	2	1	0,046	0,123	0,047	0,459	0,163	0,813	0,578109	9,669725
0	2	2	0,040	0,105	0,048	0,384	0,142	0,777	0,571461	7,960246
5	2	2	0,041	0,110	0,045	0,403	0,147	0,798	0,571896	8,909942
10	2	2	0,043	0,114	0,043	0,429	0,151	0,816	0,581276	9,882603
20	2	2	0,036	0,100	0,038	0,399	0,136	0,826	0,599599	10,4837
0	2	3	0,038	0,102	0,043	0,389	0,141	0,802	0,584085	9,077484
5	2	3	0,042	0,111	0,045	0,417	0,148	0,804	0,580875	9,192269
10	2	3	0,039	0,106	0,044	0,394	0,148	0,800	0,575117	8,981795
20	2	3	0,038	0,107	0,041	0,423	0,147	0,824	0,595099	10,38678
0	2	4	0,045	0,115	0,050	0,407	0,153	0,780	0,559191	8,090164
5	2	4	0,039	0,109	0,042	0,421	0,147	0,819	0,587439	10,06199
10	2	4	0,040	0,109	0,046	0,404	0,149	0,795	0,57531	8,744833
20	2	4	0,039	0,113	0,040	0,421	0,142	0,827	0,577739	10,54253
0	2	5	0,043	0,125	0,058	0,421	0,171	0,759	0,541726	7,303845
5	2	5	0,042	0,113	0,046	0,411	0,152	0,799	0,568381	8,935662
10	2	5	0,039	0,108	0,044	0,407	0,149	0,805	0,580358	9,249365
20	2	5	0,044	0,122	0,047	0,433	0,165	0,803	0,559817	9,168214
0	2	6	0,046	0,118	0,051	0,414	0,157	0,782	0,556987	8,178961
5	2	6	0,037	0,095	0,036	0,368	0,126	0,823	0,589307	10,27525
10	2	6	0,042	0,111	0,051	0,396	0,157	0,772	0,560355	7,757352
20	2	6	0,038	0,103	0,037	0,417	0,140	0,838	0,602573	11,36978
0	3	1	0,047	0,118	0,048	0,424	0,154	0,798	0,564911	8,91581
5	3	1	0,043	0,103	0,041	0,426	0,137	0,823	0,610869	10,31289
10	3	1	0,042	0,099	0,038	0,393	0,131	0,824	0,598857	10,33778
20	3	1	0,047	0,109	0,044	0,441	0,147	0,819	0,603209	10,04385
0	3	2	0,046	0,105	0,052	0,375	0,137	0,756	0,563174	7,190824
5	3	2	0,043	0,099	0,045	0,393	0,132	0,796	0,59609	8,785815
10	3	2	0,047	0,108	0,048	0,407	0,143	0,788	0,581887	8,450641

20	3	2	0,043	0,099	0,043	0,378	0,130	0,795	0,58573	8,753733
0	3	3	0,044	0,092	0,051	0,341	0,121	0,741	0,576454	6,712543
5	3	3	0,048	0,111	0,045	0,426	0,143	0,810	0,587204	9,510097
10	3	3	0,046	0,108	0,047	0,396	0,141	0,787	0,572499	8,4074
20	3	3	0,043	0,095	0,046	0,377	0,128	0,782	0,596433	8,164192
0	3	4	0,049	0,103	0,052	0,395	0,138	0,769	0,585869	7,664905
5	3	4	0,047	0,101	0,047	0,399	0,135	0,789	0,597475	8,48492
10	3	4	0,045	0,102	0,045	0,389	0,137	0,792	0,585284	8,619419
20	3	4	0,048	0,113	0,048	0,420	0,150	0,797	0,575231	8,842477
0	3	5	0,044	0,105	0,046	0,384	0,140	0,787	0,569203	8,372939
5	3	5	0,040	0,095	0,043	0,372	0,126	0,792	0,592605	8,620705
10	3	5	0,048	0,104	0,049	0,397	0,138	0,781	0,584383	8,151313
20	3	5	0,043	0,105	0,039	0,425	0,141	0,830	0,604412	10,79438
0	3	6	0,049	0,108	0,053	0,389	0,140	0,760	0,565822	7,32893
5	3	6	0,046	0,105	0,051	0,364	0,141	0,754	0,551142	7,14411
10	3	6	0,045	0,103	0,049	0,389	0,141	0,777	0,581572	7,958508
20	3	6	0,046	0,101	0,048	0,371	0,137	0,771	0,571405	7,745571
0	4	1	0,036	0,087	0,037	0,314	0,119	0,787	0,564107	8,409467
5	4	1	0,036	0,082	0,034	0,321	0,112	0,810	0,593915	9,511922
10	4	1	0,031	0,072	0,026	0,292	0,098	0,834	0,602873	11,07635
20	4	1	0,028	0,064	0,016	0,280	0,082	0,892	0,626527	17,51736
0	4	2	0,034	0,079	0,036	0,292	0,107	0,781	0,573274	8,113889
5	4	2	0,032	0,074	0,026	0,289	0,096	0,836	0,593695	11,19602
10	4	2	0,026	0,061	0,011	0,280	0,078	0,926	0,64406	25,92628
20	4	2	0,032	0,073	0,030	0,279	0,097	0,806	0,585039	9,292753
0	4	3	0,032	0,070	0,032	0,273	0,094	0,789	0,59359	8,493828
5	4	3	0,028	0,067	0,014	0,279	0,083	0,908	0,612094	20,63914
10	4	3	0,034	0,085	0,036	0,307	0,115	0,792	0,566891	8,606839
20	4	3	0,031	0,071	0,024	0,295	0,094	0,850	0,610616	12,29721
0	4	4	0,034	0,074	0,028	0,283	0,095	0,818	0,586331	9,989381
5	4	4	0,035	0,079	0,031	0,317	0,106	0,823	0,599146	10,29978
10	4	4	0,028	0,065	0,016	0,273	0,086	0,887	0,614088	16,6741
20	4	4	0,038	0,091	0,035	0,330	0,125	0,807	0,566452	9,361148
0	4	5	0,035	0,080	0,039	0,281	0,112	0,756	0,556814	7,194895
5	4	5	0,030	0,070	0,026	0,269	0,094	0,823	0,588575	10,30954
10	4	5	0,036	0,082	0,035	0,301	0,111	0,792	0,572668	8,612079
20	4	5	0,029	0,069	0,021	0,286	0,092	0,865	0,612874	13,84184
0	4	6	0,028	0,064	0,029	0,239	0,086	0,783	0,57893	8,223836
5	4	6	0,036	0,085	0,038	0,296	0,118	0,773	0,553649	7,809046
10	4	6	0,032	0,075	0,032	0,270	0,104	0,787	0,565059	8,386741
20	4	6	0,035	0,082	0,035	0,302	0,113	0,794	0,572071	8,708843

## SCRIT PARA REGRESSÃO LINEAR MULTIPLA

```

importa pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
import statsmodels.api as sm
from sklearn import metrics
from sklearn.preprocessing import StandardScaler # Importando o StandardScaler

# Carregando os dados a partir de um arquivo Excel
df = pd.read_excel(r'C:\Users\javel\OneDrive\Documentos\Doutorado\Tese
daninhas\Dados milho\Biometrico_precoce.xlsx')

# Visualizando os dados
print(df.head())

# Selecionando variáveis preditoras (espectrais) e variáveis alvo (fisiológicas)
X = df[['R', 'G', 'B', 'NIR', 'NE', 'NDVI', 'GNDVI', 'SR']]
Y = df[['Ap', 'NF', 'DC', 'MFT', 'MST', 'MSF', 'MSC', 'MSE', 'Prod']]

# Função para eliminar variáveis usando eliminação reversa
def backward_elimination(X, y, significance_level=0.05):

# Adicionando constante ao modelo
X_with_const = sm.add_constant(X)
model = sm.OLS(y, X_with_const).fit()
while True:

# Obtendo os valores p das variáveis
p_values = model.pvalues[1:] # Ignorando o intercepto
max_p_value = p_values.max() # Valor p máximo

# Se o valor p máximo for maior que o nível de significância, remover a variável
if max_p_value > significance_level:
    excluded_variable = p_values.idxmax() # Obter o nome da variável a ser
excluída
    X = X.drop(columns=[excluded_variable])
    print(f'Excluindo {excluded_variable} com p-value {max_p_value:.4f}')
    model = sm.OLS(y, sm.add_constant(X)).fit() # Reajustar o modelo
else:
    break

return X, model

# Iterar sobre cada variável alvo
for target in Y.columns:
    print(f"\n--- Analisando variável: {target} ---")

```

```
X_selected, final_model = backward_elimination(X, Y[target]) # Passando uma
coluna de cada vez
```

```
# Exibindo os resultados finais do modelo
print("\n--- Modelo Final ---")
print(final_model.summary())

# Construindo a equação do modelo
equation = f"{target} = {final_model.params[0]:.4f}" # Intercepto
for variable in X_selected.columns:
    equation += f" + ({final_model.params[variable]:.4f} * {variable})"

print("\n--- Equação do Modelo ---")
print(equation)

# Obtendo o R2
r_squared = final_model.rsquared
print(f"\n--- R2 do Modelo ---")
print(f"R2 = {r_squared:.4f}")

# Dividindo os dados em conjunto de treino e teste
X_train, X_test, Y_train, Y_test = train_test_split(X_selected, Y[target],
test_size=0.2, random_state=42)

# Normalizar os dados
scaler = StandardScaler()

# Verifique se X_train contém dados válidos antes de normalizar
if X_train is None or X_train.empty:
    print("Erro: o conjunto de treino X_train está vazio ou inválido.")
else:
    X_train = scaler.fit_transform(X_train)
    X_test = scaler.transform(X_test)

# Criando o modelo de regressão linear com as variáveis selecionadas
linear_model = LinearRegression()
linear_model.fit(X_train, Y_train)

# Fazendo previsões
Y_pred = linear_model.predict(X_test)

# Avaliando o modelo
print(f"\n--- Avaliação para {target} ---")
print("Coeficientes:", linear_model.coef_)
print("Intercepto:", linear_model.intercept_)
print("Erro absoluto médio:", metrics.mean_absolute_error(Y_test, Y_pred))
print("Erro quadrático médio:", metrics.mean_squared_error(Y_test, Y_pred))
print("Raiz do erro quadrático médio:", np.sqrt(metrics.mean_squared_error(Y_test,
Y_pred)))
```

```

# Gráfico de comparação
plt.scatter(Y_test, Y_pred)
plt.xlabel('Valores reais')
plt.ylabel('Valores previstos')
plt.title(f'Valores reais vs Valores previstos para {target}')
plt.plot([Y_test.min(), Y_test.max()], [Y_test.min(), Y_test.max()], 'k--', lw=2)
plt.show()

```

### SCRIPT PARA RANDOM FOREST

```

import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, r2_score
import numpy as np

# 1. Carregar os Dados do Excel
df = pd.read_excel(r'C:\Users\javel\OneDrive\Documentos\Doutorado\Tese
daninhas\Dados milho\Biometrico_precoce.xlsx')

# Ver os primeiros dados para confirmar a leitura correta
print("Primeiros 5 registros da tabela:")
print(df.head())

# 2. Pré-processamento dos Dados
# Tentar converter cada coluna para numérico e substituir os valores não numéricos
pela média da coluna
for column in df.columns:
    try:
        df[column] = pd.to_numeric(df[column])
    except ValueError:
        # Se houver erro na conversão, substituir os valores não numéricos pela média
da coluna
        df[column] = pd.to_numeric(df[column], errors='coerce').fillna(df[column].mean())

# Selecionar variáveis preditoras (bandas espectrais) e alvo (características
fisiológicas)
X = df[['R', 'G', 'B', 'NIR', 'NE', 'NDVI', 'GNDVI', 'SR']]
y_columns = ['Ap', 'NF', 'DC', 'MFT', 'MST', 'MSF', 'MSC', 'MSE', 'Prod']

# Dividir os dados em conjuntos de treino e teste
X_train, X_test, y_train, y_test = train_test_split(X, df[y_columns], test_size=0.2,
random_state=42)

# Normalizar os dados
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

```

### # 3. Treinar e Avaliar o Modelo de Floresta Aleatória para Cada Característica Fisiológica

```

for y_column in y_columns:
    # Definir o modelo de floresta aleatória
    model = RandomForestRegressor(n_estimators=100, random_state=42)

    # Treinar o modelo
    model.fit(X_train, y_train[y_column])

    # Avaliar o modelo
    y_pred = model.predict(X_test)
    mse = mean_squared_error(y_test[y_column], y_pred)
    rmse = np.sqrt(mse)
    r2 = r2_score(y_test[y_column], y_pred)
    r2_percentage = r2 * 100

    # Calcular RMSE normalizado
    y_mean = np.mean(y_test[y_column])
    rmse_normalized = rmse / y_mean

    # Importância das variáveis
    feature_importances = model.feature_importances_

    print(f'\nModelo para {y_column}:')
    print(f' Mean Squared Error: {mse}')
    print(f' Root Mean Squared Error (RMSE): {rmse}')
    print(f' RMSE Normalizado: {rmse_normalized}')
    print(f' R^2 Score: {r2} ({r2_percentage:.2f}%)')
    print(' Importância das Variáveis:')
    for feature, importance in zip(['R', 'G', 'B', 'NIR', 'NE', 'NDVI', 'GNDVI', 'SR'],
feature_importances):
        print(f' {feature}: {importance:.4f}')

```

### SCRIPT PARA REDES NEURAIAS

```

import pandas as pd
import numpy as np
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from sklearn.metrics import mean_squared_error, r2_score

# Carregando os dados do Excel
df=pd.read_excel(r'C:\Users\javel\OneDrive\Documentos\Doutorado\Tese
daninhas\Dados milho\Milho_precoce.xlsx')

```

```

# Selecionando as variáveis predictoras (bandas espectrais e índices)
X = df[['R', 'G', 'B', 'NIR', 'NE', 'NDVI', 'GNDVI', 'SR']].values
# Selecionando as variáveis alvo (características fisiológicas)
y = df[['A', 'gs', 'Ci', 'Trmmol', 'Tleaf', 'Ci/Ca']].values
# Criando o modelo de rede neural
model = Sequential()
# Camada oculta com 2 neurônios e 8 entradas (R, G, B, NIR, NE, NDVI, GNDVI, SR)
model.add(Dense(2, input_dim=8, activation='relu'))
# Camada de saída com 6 neurônios (um para cada variável fisiológica)
model.add(Dense(6, activation='linear'))
# Compilando o modelo
model.compile(optimizer='adam', loss='mean_squared_error')
# Treinando o modelo
model.fit(X, y, epochs=100, batch_size=32)
# Fazendo previsões nos dados de entrada
y_pred = model.predict(X)
# Calculando o RMSE para cada variável fisiológica
rmse = np.sqrt(mean_squared_error(y, y_pred, multioutput='raw_values'))
# Calculando o RMSE normalizado (RMSE%) para cada variável fisiológica
rmse_percent = (rmse / np.mean(y, axis=0)) * 100
# Calculando o R2 (coeficiente de determinação)
r2 = r2_score(y, y_pred, multioutput='raw_values')
# Exibindo os resultados
for i, col in enumerate(['Photo', 'Cond', 'Ci', 'Trmmol', 'Tleaf', 'Ci/Ca']):
    print(f"{col} - RMSE: {rmse[i]:.4f}, RMSE%: {rmse_percent[i]:.2f}%, R2: {r2[i]:.4f}")

```