



**MARCELO ARAÚJO JUNQUEIRA FERRAZ**

**SENSORIAMENTO REMOTO E INTELIGÊNCIA  
ARTIFICIAL NO MANEJO DAS CULTURAS DE MILHO E  
SORGO**

**LAVRAS-MG  
2023**

**MARCELO ARAÚJO JUNQUEIRA FERRAZ**

**SENSORIAMENTO REMOTO E INTELIGÊNCIA ARTIFICIAL NO MANEJO DAS  
CULTURAS DE MILHO E SORGO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Agronomia/Fitotecnia, área de concentração em Produção Vegetal, para obtenção do título de Mestre.

Prof. Dr. Renzo Garcia Von Pinho  
Orientador  
Prof. Dr. Adão Felipe dos Santos  
Coorientador

**LAVRAS-MG  
2023**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Ferraz, Marcelo Araújo Junqueira.

Sensoriamento remoto e inteligência artificial no manejo das  
culturas de milho e sorgo / Marcelo Araújo Junqueira Ferraz. -  
2023.

92 p.: il.

Orientador(a): Renzo Garcia Von Pinho.

Coorientador(a): Adão Felipe dos Santos.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2023.

Bibliografia.

1. Inteligência artificial. 2. Aprendizado de máquina. 3.  
Sensoriamento remoto. I. Von Pinho, Renzo Garcia. II. dos Santos,  
Adão Felipe. III. Título.

**MARCELO ARAÚJO JUNQUEIRA FERRAZ**

**SENSORIAMENTO REMOTO E INTELIGÊNCIA ARTIFICIAL NO MANEJO DAS  
CULTURAS DE MILHO E SORGO**

**REMOTE SENSING AND ARTIFICIAL INTELLIGENCE IN MAIZE AND  
SORGHUM CROP MANAGEMENT**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Agronomia/Fitotecnia, área de concentração em Produção Vegetal, para obtenção do título de Mestre.

**APROVADO** em 14 de julho de 2023.

Dr. Renzo Garcia Von Pinho

Dr. José Luiz de Andrade Rezende Pereira

Dr. Rouverson Pereira da Silva

UFLA

IFSULDEMINAS

UNESP

Prof. Dr. Renzo Garcia Von Pinho

Orientador

Prof. Dr. Adão Felipe dos Santos

Coorientador

**LAVRAS-MG**

**2023**

Primeiramente à Deus, fonte de sabedoria e amor infinitos, agradeço a sua presença constante em minha vida e benta Nhá Chica.

A toda minha família, ao meu pai Jocemar por todo apoio e confiança. Ao meu querido avô Marcelo (in memoriam).

A minha querida Marcela, pela dedicação, carinho, harmonia e amor.  
Aos meus grandes irmãos Gustavo e Gabriel que sempre estão ao meu lado, amigos e docentes que acreditaram e me deram incentivo.

**Dedico**

## AGRADECIMENTOS

A DEUS, por me guiar, me proporcionar força e convicção para continuar a missão que me foi concedida. Por cuidar e me preparar para um futuro desenhado por Ele. A Benta Nhá Chica, por me ouvir e abençoar todos os dias.

Ao meu pai Jocemar, por me mostrar a honestidade, dedicação, fé e humildade.

Aos meus irmãos, que foram verdadeiros amigos, sempre ao meu lado, me ouvirem, por todo incentivo, exemplo, amor, harmonia e respeito. A minha querida Marcela por todo apoio em todas as situações, companheirismo, dedicação, amor, carinho e respeito. Vocês são minha base. A toda minha família (Gil, Edmar e Sylmar) e queridos amigos, que me apoiaram e proporcionaram momentos inesquecíveis.

Aos meus grandes amigos, irmãos e colegas da Universidade Federal de Lavras em especial ao Dionatas Garcia, Thiago Orlando, Arsênio Mulhanga, Josias Reis, Mateus Piza, Pablo Arantes, Antônio de Carvalho. E Jader Faria, Nilton Leno, Leonardo Guedes, Salomão Valle, Elias Junior pelo companheirismo, compreensão e apoio por mais uma etapa.

À Universidade Federal de Lavras (UFLA), particularmente ao Programa de Pós Graduação em Agronomia/Fitotecnia, pela oportunidade de realizar um Mestrado de excelência. A todos os técnicos e servidores do Departamento de Agricultura Geral (DAG) da UFLA, em especial a secretária Marli dos Santos Túlio, pelo carinho, atenção, dedicação e amizade ao longo desta caminhada.

Ao orientador Prof. Dr. Renzo Garcia Von Pinho, agradeço pela oportunidade, apoio, incentivo e confiança.

Ao coorientador Prof. Dr. Adão Felipe dos Santos, agradeço pelos conhecimentos em Agricultura de Precisão, confiança, oportunidades, dedicação e atenção durante essa etapa. Foram fundamentais para o desenvolvimento deste trabalho.

Aos demais docentes do Programa de Pós Graduação em Agronomia/Fitotecnia da Universidade Federal de Lavras pelos ensinamentos transmitidos. E professores Adriano Bruzi, Silvino Moreira, José Luiz de Andrade e Alexandre de Carvalho por todo apoio e ajuda. Aos colegas da equipe do GEPAD pelo companheirismo e trabalhos em equipe, por toda troca de conhecimento, desenvolvimento pessoal e profissional.

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG), por proporcionar a bolsa de pós-graduação. A todos que de alguma forma contribuíram para a minha formação. **Meus sinceros agradecimentos.**

*“Só eu conheço os planos que tenho para você: prosperidade e não desgraça e um futuro cheio de esperança. Sou eu, o Senhor, quem está falando.”  
(Jeremias 29:11).*

## RESUMO

O sorgo, pertencente à família das gramíneas, é a cultura com maior tolerância à estresses ambientais entre os cereais. Por outro lado, o milho se destaca pela importante posição no agronegócio brasileiro e mundial. Recentemente, a expansão das tecnologias e inovações agrícolas, tem possibilitado o aumento de eficiência dos processos de produção. O sensoriamento remoto (SR) permite a coleta de informações da lavoura de forma não-destrutiva e remota, por meio de sensores embarcados em veículos aéreos não tripulados (UAV) e satélites. E diante de uma grande quantidade de dados gerados a cada safra, a inteligência artificial (IA) é uma alternativa eficiente para análise dos dados. Dessa forma, objetivou-se avaliar o emprego de técnicas de sensoriamento remoto e modelos de inteligência artificial no manejo das culturas de milho e sorgo. Para realizar a estimativa de produtividade de sorgo granífero em condições tropicais e definir a melhor época para estimar a produtividade, foram utilizados elevação do terreno e índices de vegetação (IVs) extraídos aos 30, 60, 90 e 120 dias após semeadura (DAS) como parâmetros de entrada para a Rede Neural Artificial (RNA) com arquitetura Multilayer Perceptron. O modelo com melhor desempenho ( $R^2 = 0,89$  e  $RMSE = 0,22 \text{ t ha}^{-1}$ ) apresentava como entrada os IVs CIgreen, SR, VARI, WDRVI e elevação do terreno aos 30 DAS. Obteve-se alta correlação ( $r = 0,95$ ) entre a produtividade observada e a estimada pelo modelo aos 30 DAS, demonstrando que nesse estágio inicial é o mais adequado para realizar a estimativa de produtividade de grãos de sorgo. Os dados da cultura do milho foram coletados por meio de UAV e satélite PlanetScope, combinadas com algoritmos de aprendizado de máquina para estimativa de altura de plantas. Para tanto, IVs NDVI, NDRE e GNDVI foram calculados a partir de imagens orbitais, enquanto que a altura baseada em UAV foi obtida por meio de modelos digitais de elevação (DEM). As imagens foram obtidas aos 20, 29, 37, 44, 50, 61 e 71 DAS e da mesma forma as avaliações manuais no campo. Os seguintes resultados foram obtidos: (1) a altura de planta derivada do DEM apresentou forte correlação com a altura manual de campo ( $r = 0,96$ ), NDVI ( $r = 0,80$ ), NDRE ( $r = 0,78$ ) e GNDVI ( $r = 0,81$ ). (2) O modelo de RF teve melhor desempenho ( $R^2 = 0,97$  e  $RMSE = 14,62 \text{ cm}$ ) quando utilizou NDVI, NDRE e GNDVI como entrada, seguido de KNN com precisão semelhante ( $R^2 = 0,97$  e  $RMSE = 14,68 \text{ cm}$ ).

**Palavras-chave:** Agricultura de precisão. Inteligência artificial. Aprendizado de máquina.



## ABSTRACT

Sorghum, belonging to the grass family, is the crop with the highest tolerance to environmental stress among cereals. On the other hand, corn stands out for its important position in Brazilian and world agribusiness. Recently, the expansion of agricultural technologies and innovations has made it possible to increase the efficiency of production processes. Remote sensing (SR) allows the collection of crop information in a non-destructive and remote way, through sensors on board unmanned aerial vehicles (UAV) and satellites. And in the face of a large amount of data generated each season, artificial intelligence (AI) is an efficient alternative for data analysis. Thus, the objective was to evaluate the use of remote sensing techniques and artificial intelligence models in the management of corn and sorghum crops. To estimate grain sorghum productivity under tropical conditions and define the best time to estimate productivity, terrain elevation and vegetation indices (VIs) extracted at 30, 60, 90 and 120 days after sowing (DAS) were used as input parameters for the Artificial Neural Network (ANN) with Multilayer Perceptron architecture. The model with the best performance ( $R^2 = 0.89$  and  $RMSE = 0.22 \text{ t ha}^{-1}$ ) had as input the IVs CIgreen, SR, VARI, WDRVI and land elevation at 30 DAS. A high correlation ( $r = 0.95$ ) was obtained between the observed yield and that estimated by the model at 30 DAS, demonstrating that this initial stage is the most suitable for estimating sorghum grain yield. Corn crop data were collected using UAV and PlanetScope satellite, combined with machine learning algorithms for plant height estimation. For this purpose, NDVI, NDRE and GNDVI IVs were calculated from orbital images, while the UAV-based height was obtained through digital elevation models (DEM). The images were obtained at 20, 29, 37, 44, 50, 61 and 71 DAS and in the same way the manual evaluations in the field. The following results were obtained: (1) plant height derived from the DEM showed a strong correlation with manual field height ( $r = 0.96$ ), NDVI ( $r = 0.80$ ), NDRE ( $r = 0.78$ ) and GNDVI ( $r = 0.81$ ). (2) The RF model performed better ( $R^2 = 0.97$  and  $RMSE = 14.62 \text{ cm}$ ) when using NDVI, NDRE and GNDVI as input, followed by KNN with similar precision ( $R^2 = 0.97$  and  $RMSE = 14.68 \text{ cm}$ ).

**Keywords:** Precision agriculture. Artificial intelligence. Machine learning.

## LISTA DE TABELAS

### CAPÍTULO 1

Tabela 1 – Estádios fenológicos da cultura do milho. ....	15
Tabela 2 – Bandas espectrais do PlanetScope. ....	21

### CAPÍTULO 2

Tabela 1 – Índices de Vegetação (IVs) para imagens de satélite. ....	45
Tabela 2 – Hiperparâmetros para desenvolvimento da rede neural artificial. ....	48
Tabela 3 – Modelos e combinações entre as variáveis de entrada. ....	49
Tabela 4 – Precisão ( $R^2$ ) e acurácia (RMSE) do treinamento e teste do modelo M2, M3 e M9 para estimativa de produtividade de sorgo. ....	51

### CAPÍTULO 3

Tabela 1 – Índices de Vegetação (IV) para imagens orbitais do PlanetScope. ....	75
Tabela 2 – Algoritmos de aprendizado de máquina implementados no estudo e hiperparâmetros. ....	76
Tabela 3 – Precisão ( $R^2$ ) e acurácia (RMSE) do treinamento e teste dos modelos para estimativa de altura de planta do milho. ....	78

## LISTA DE QUADROS

### CAPÍTULO 1

Quadro 1 – Descrição do aprendizado de máquina supervisionado e não supervisionado. ....	24
Quadro 2 – Característica da rede neural artificial tipo MultiLayer Perceptron. ....	28

## LISTA DE FIGURAS

### CAPÍTULO 1

Figura 1 – Etapas de crescimento 1, 2 e 3 da cultura do sorgo em função do número de dias após a semeadura. ....	17
Figura 2 – Modelo do primeiro neurônio artificial. ....	28
Figura 3 – A rede neural artificial MLP (A) e sua divisão em hiperplanos (B). ....	29

### CAPÍTULO 2

Figura 1 – Localização da área comercial em Campo do Meio, MG. ....	42
Figura 2 – Resultado da validação cruzada por krigagem (A e C) e mapa interpolado utilizando resolução de 10 x 10 m para 2019 (B) e 2020 (D), respectivamente. ....	44
Figura 3 – Correlação de Pearson ( $r$ ) entre a produtividade estimada pelos modelos e produtividade observada a campo no ano de 2019 (A) e 2020 (B). ....	52
Figura 4 – Correlação de Pearson ( $r$ ) entre a produtividade estimada pelos modelos e produtividade observada a campo para a união dos anos 2019 e 2020. ....	52
Figura 5 – Coeficiente de determinação ( $R^2$ ) dos modelos de RNA para os anos 2019 (A) e 2020 (B). ....	53

Figura 6 – Coeficiente de determinação ( $R^2$ ) dos modelos de RNA para o conjunto de dados dos dois anos agrícolas. ....	54
Figura 7 – Validação dos dados para o modelo M3. 30 (A), 60 (B), 90 (C) e 120 (D) dias após a semeadura referem-se aos dados do ano 2019. Enquanto 30 (E), 60 (F), 90 (G) e 120 (H) dias referem-se ao ano 2020. ....	56
Figura 8 – Validação dos dados para o modelo M9. 30 (A), 60 (B), 90 (C) e 120 (D) dias após a semeadura referem-se aos dados do ano 2019. Enquanto 30 (E), 60 (F), 90 (G) e 120 (H) dias referem-se ao ano 2020. ....	57
Figura 9 – Validação dos dados de dois anos agrícolas para aos modelos M2 (A) aos 30 dias após a semeadura e M3 referente aos 60 (B), 90 (C) e 120 (D) dias.....	58

### **CAPÍTULO 3**

Figura 1 – Resumo gráfico do estudo para estimar altura de planta usando IV e DEM baseado em UAV na cultura do milho. ....	72
Figura 2 – Localização da área experimental em Ijaci, MG.....	73
Figura 3 – Coeficientes de correlação de Pearson (r) entre os valores observados e estimados de altura de planta, para cada algoritmo e entrada de entrada.....	79
Figura 4 – Coeficiente de determinação ( $R^2$ ) (A) e raiz do erro quadrado médio (RMSE) (B) em centímetros dos algoritmos de ML implementados no estudo. ....	80
Figura 5 – Estimativa dos dados para os modelos RF e KNN. Referem-se as configurações de entrada: (1) UAV Height (A e B), (2) UAV Height + NDVI + NDRE + GNDVI (C e D) e (3) NDVI + NDRE + GNDVI (E e F).....	82

## SUMÁRIO

CAPÍTULO 1 INTRODUÇÃO GERAL.....	13
1 INTRODUÇÃO.....	13
2 REFERENCIAL TEÓRICO.....	14
2.1 Características morfológicas e fenológicas do milho.....	14
2.2 Características morfológicas e fenológicas do sorgo.....	16
2.3 Agricultura de Precisão.....	17
2.4 Sensoriamento Remoto na agricultura.....	19
2.4.1 Imagens de satélite - PlanetScope.....	21
2.4.2 Imagens aéreas obtidas por Veículo Aéreo não Tripulado.....	22
2.5 Inteligência Artificial aplicada à cultura anual.....	23
2.6 Algoritmos de aprendizado de máquina.....	25
2.7 Rede Neural Artificial (RNA).....	27
REFERÊNCIAS.....	30
CAPÍTULO 2 SENSORIAMENTO REMOTO E REDES NEURAI PARA ESTIMAR A PRODUÇÃO DE SORGO GRANÍFERO EM CONDIÇÕES TROPICAIS.....	39
1 INTRODUÇÃO.....	41
2 MATERIAL E MÉTODOS.....	42
2.1 Área de estudo.....	42
2.2 Coleta e pré-processamento de dados.....	43
2.3 Aquisição das imagens orbitais.....	44
2.4 Índices de Vegetação (IVs).....	45
2.5 Extração dos Índices de Vegetação e Produtividade.....	46
2.6 Análise dos dados.....	46
2.6.1 Divisão dos dados para treinamento e teste da rede neural.....	46
2.6.2 Desenvolvimento da Rede Neural Artificial.....	46
2.6.3 Arquitetura da rede neural.....	47
2.6.4 Pré-processamento dos parâmetros de entrada.....	49
2.6.5 Métricas para avaliação do modelo de rede neural.....	49
3 RESULTADOS.....	50
3.1 Comparação entre os modelos.....	50
3.2 Correlação entre os valores observados e estimados de produtividade.....	51
3.3 Desempenho da rede neural artificial.....	53
3.4 Validação do modelo.....	54
4 DISCUSSÃO.....	58
5 CONCLUSÃO.....	61
REFERÊNCIAS.....	62
CAPÍTULO 3 ALGORITMOS DE APRENDIZADO DE MÁQUINA NA ESTIMATIVA DA ALTURA DE PLANTA DE MILHO POR MEIO DE SENSORIAMENTO REMOTO E UAV .....	68
1 INTRODUÇÃO.....	70
2 MATERIAL E MÉTODOS.....	71
2.1 Área de estudo.....	72
2.2 Aquisição dos dados no campo.....	73
2.3 Aquisição e processamento de imagens.....	73

2.4	Extração dos índices de vegetação e modelo digital de elevação.....	74
2.5	Algoritmos de aprendizado de máquina para estimativa de altura de planta.....	76
2.6	Pré-processamento dos dados e Análise Estatística.....	77
3	RESULTADOS.....	77
3.1	Comparação entre os algoritmos de aprendizado de máquina .....	77
3.2	Correlação entre valores observados e estimados de altura .....	78
3.3	Desempenho dos modelos .....	80
3.4	Estimativa de altura de planta no campo .....	81
4	DISCUSSÃO.....	82
5	CONCLUSÃO.....	86
	REFERÊNCIAS .....	86

## **CAPÍTULO 1 INTRODUÇÃO GERAL**

### **1 INTRODUÇÃO**

A cultura do milho é originária do Continente Americano e explorada desde os primórdios da agricultura (AGUIRRE-MANCILLA et al., 2020). É um cereal de importância no cenário mundial, ocupando posição de destaque entre as espécies agrícolas exploradas, pois além de apresentar alto valor energético e inúmeras finalidades, contribui para a vitalidade da economia nacional (ARTUZO et al., 2019). Segundo a Conab (2023), para a safra 22/23 o Brasil tem uma área total de 22,2 milhões de hectares cultivados com milho, totalizando uma produção de 125,7 milhões de toneladas de grãos. Na região Sudeste do país, Minas Gerais é o maior produtor de milho com uma produção de 8 milhões de toneladas de grãos.

O sorgo, tal como o milho, é uma cultura pertencente à família das gramíneas e o quinto cereal mais cultivado no mundo, estando atrás do trigo, arroz, milho e a cevada. Também é uma cultura açucareira, sendo utilizada para produção de biocombustíveis, amido a partir de grãos de sorgo, açúcar e celulose de folhas e caules das plantas (YANG et al., 2021). Devido sua capacidade metabólica de minimizar os efeitos da alta temperatura e déficit hídrico, a cultura apresenta grande tolerância a altos níveis de radiação solar e uma alta taxa fotossintética, sendo a cultura com maior resistência entre os outros cereais (SOUZA et al., 2020). Nos últimos dez anos, a demanda pelo grão e forragem de sorgo promoveu uma expansão na área cultivada, de 85,4 mil hectares para 1,4 milhão de hectares e a produção próxima de 4,3 milhões de toneladas (Companhia Nacional de Abastecimento, 2023).

A expansão da área destinada à cultura, juntamente com as inovações agrícolas, favoreceu aumento na produtividade (ARTUZO et al., 2019), bem como têm possibilitado a otimização do sistema de produção e melhor eficiência das operações agrícolas, desde o monitoramento das lavouras até as recomendações (MOLIN et al., 2020). Nesse cenário que a Agricultura de Precisão (AP) surgiu como uma forma inovadora de analisar o campo baseado no georreferenciamento de dados nas lavouras, viabilizando tratar devidamente a variabilidade presente nos solos e culturas. As técnicas associadas à AP despertam crescente interesse no meio acadêmico e científico, devido à capacidade de gerenciamento da produção agrícola através do mapeamento da variabilidade espacial e temporal das áreas de manejo (SILVA; SILVA-MANN, 2020).

O mapeamento da variabilidade e monitoramento das culturas auxilia na tomada de decisão, melhor gestão dos recursos e o desenvolvimento sustentável. Para isso, o sensoriamento remoto (SR) tem se destacado devido à facilidade de adquirir informações em diferentes extensões de áreas e em curto espaço de tempo, facilitando a caracterização das variabilidades espacial e temporal dos campos de produção agrícola (SISHODIA et al., 2020). Os satélites orbitais e os veículos aéreos não tripulados (UAV's) são plataformas de SR, embarcados de sensores capazes de identificar assinaturas espectrais da interação entre a radiação eletromagnética (REM) e a planta. Além disso, essas repostas espectrais das plantas, levaram ao desenvolvimento de índices de vegetação (SILVA et al., 2021). Os índices de vegetação baseados nos valores de reflectância, são associados aos aspectos fisiológicos, fitossanitários e fitotécnicos das plantas (HENRIQUES et al., 2021).

Atualmente, a agricultura está passando por uma revolução facilitada principalmente pelos avanços nas tecnologias de informação e comunicação. Tecnologias emergentes, como Internet das Coisas (IoT), análise de Big Data e inteligência artificial (IA) são ferramentas promissoras utilizadas para otimizar operações e insumos agrícolas com o objetivo de aumentar a produção e reduzir insumos e perdas de rendimento. Bem como realizar a análise e coleta automatizada de dados para obter informações sobre as culturas (LINAZA et al., 2021; SISHODIA et al., 2020).

A IA tem impactado os setores agrícolas pelo potencial de atuação em todos os processos de produção, destacando a eficiência ao analisar grandes quantidades de dados. A tecnologia pode solucionar problemas do campo, auxiliar as tomadas decisão e melhorar o uso de insumos agrícolas (PINHEIRO et al., 2021). Portanto, realizar o monitoramento da cultura do milho e sorgo por meio de ferramentas eficientes e práticas, é uma perspectiva interessante no sistema de produção de áreas comerciais e nos campos experimentais. Diante do exposto, objetivou-se avaliar o emprego de técnicas de sensoriamento remoto e modelos de inteligência artificial nas culturas de milho e sorgo no Sul de Minas Gerais.

## **2 REFERENCIAL TEÓRICO**

### **2.1 Características morfológicas e fenológicas do milho**

O milho (*Zea mays* L.) é uma planta que pertence à família *Poaceae*. É uma planta herbácea e monoica, o seu ciclo é bastante variado, mas nas condições brasileiras, as

cultivares completam o seu ciclo em 110 a 180 dias (SILVA et al., 2021). Da emergência à colheita o ciclo pode ser descrito como: superprecoce, precoce, normal e tardio.

O milho possui raízes fasciculadas em que estão presentes raízes primárias e secundárias, adventícias e de suporte. As folhas são longas e lanceoladas, com nervura central em forma de canaleta, bem vigorosa, são invaginantes e inserem-se por nós do colmo, apresentando pilosidades. O colmo suporta as folhas e partes florais, além de servir como órgão de reserva. Sendo o milho planta monoica, as flores masculinas se agrupam numa panícula no topo da planta, enquanto que as femininas são constituídas pelas espigas. O florescimento ocorre aproximadamente de 50 a 100 dias após sementeira e é afetado principalmente pela temperatura (BORÉM et al., 2017).

Os estádios fenológicos surgiram pela necessidade de detalhar os eventos periódicos durante o desenvolvimento das plantas. Assim, o emprego de uma escala baseada nas mudanças morfológicas da planta e nos eventos fisiológicos oferece maior segurança no manejo (FANCELLI, 2017). A cultura do milho apresenta uma série de estádios fenológicos, divididos em fases vegetativa (V) e reprodutiva (R) (TABELA 1).

Tabela 1 – Estádios fenológicos da cultura do milho.	
Estádios vegetativos	Estádios reprodutivos
VE - Emergência	R1 - Florescimento
V1 - Primeira folha	R2 - Grão leitoso
V2 - Segunda folha	R3 - Grão pastoso
V3 - Terceira folha	R4 - Grão farináceo
V6 - Sexta folha	R5 - Grão farináceo duro
V9 - Nona folha	R6 - Maturidade fisiológica
V12 - Décima segunda folha	
V15 - Décima quinta folha	
V18 - Décima oitava folha	
VT - Pendoamento	

Fonte: Adaptado de Ritchie et al. (2003).

A fase vegetativa inicia-se com a emergência e é denominado de VE. Os demais estádios vegetativos são designados numericamente como V1, V2, etc., até V(n), em que n



representa o último estágio foliar antes do pendoamento (VT). Cada estágio vegetativo é caracterizado pelo número de folhas completamente expandidas (V1 a Vn). Terminada a fase vegetativa, inicia-se a fase reprodutiva, da mesma forma que a fase vegetativa é dividida em vários estágios, os quais dizem respeito basicamente, ao desenvolvimento do grão e de suas partes, iniciando com o estágio R1 (florescimento) e encerrando com o R6 (ponto de maturação fisiológica) (SILVA et al., 2021).

A planta de milho por apresentar a monoecia, possui os órgãos masculino e feminino separados, mas na mesma planta. É uma espécie alógama, ou seja, normalmente 97% da polinização é cruzada. A monoecia e alogamia são favorecidos pelo mecanismo denominado de protandria que corresponde à deiscência das anteras e à dispersão de grãos de pólen dois a três dias antes da emissão dos estilos-estigmas (CRUZ et al., 2008).

## **2.2 Características morfológicas e fenológicas do sorgo**

O sorgo (*Sorghum bicolor* L. Moench), originária do noroeste da África, é uma planta extraordinária produtora de energia com enorme utilidade em regiões muito quente e secas, onde o milho não consegue ter boas produtividades (SILVA et al., 2021). É o quinto cereal mais cultivado no mundo, integrando o grupo de cereais que correspondem a 85% de toda a energia consumida pelo homem (BORÉM et al., 2014). Também é uma cultura açucareira que pode ser utilizada para produção de biocombustíveis à base de plantas inteiras. Nos Estados Unidos grande parte do sorgo produzido é encaminhado para os sistemas de produção de etanol à base de grãos, importante matéria-prima alternativa para o futuro (YANG et al., 2021).

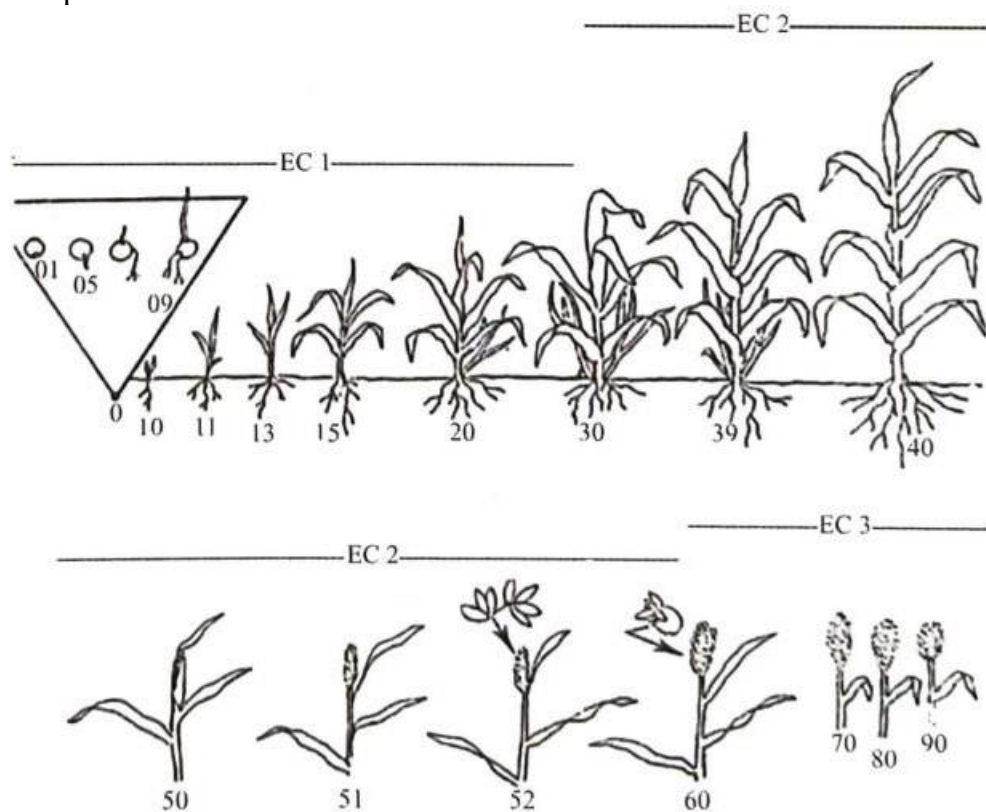
A planta do sorgo pertence à família *Poaceae*, gênero *Sorghum* é uma forrageira de mecanismo fotossintético C4, monoica e autógama. Sendo classificada quanto às características agronômicas: granífero, forrageiro, sacarino, pastejo e vassouras. E nos setores agropecuário e industrial, destaca-se pela sua capacidade energética, produtividade, alta digestibilidade, rica em açúcares para produção de bioetanol e biomassa (SILVA et al., 2021).

A cultura, morfológicamente, apresenta habilidade de dormência em períodos de seca, retomando seu crescimento após o restabelecimento das condições favoráveis. Possui colmo ereto, sistema radicular resistente com raízes seminais e adventícias, parte aérea constituída de folhas alternadas composta por bainha e limbo foliar na qual o número de folhas varia de 8 a

26. A inflorescência é denominada de panícula, com ramificações até as espiguetas, sendo uma sésil e outra pedicelada (SOUZA et al., 2020).

O ciclo do sorgo é dividido em três fases: vegetativa, reprodutiva e maturação do grão. A etapa de crescimento 1 (EC1) caracteriza-se pela germinação, aparecimento da plântula, crescimento das folhas e estabelecimento do sistema radicular fasciculado. A etapa de crescimento 2 (EC2) inicia-se quando o meristema apical se diferencia em um meristema floral e vai até a antese. A etapa de crescimento 3 (EC3) é definida pela maturação dos grãos e senescência das folhas (FIGURA 1) (VON PINHO et al., 2014).

Figura 1 – Etapas de crescimento 1, 2 e 3 da cultura do sorgo em função do número de dias após a semeadura.



Fonte: Von Pinho et al. (2014).

### 2.3 Agricultura de Precisão

O termo “agricultura de precisão” tem origem da desuniformidade presente nas lavouras com diferentes níveis de complexidade, sendo necessário o desenvolvimento de estratégias para gerenciar os problemas na propriedade (MOLIN et al., 2015). A agricultura de precisão (AP) é definida como um conjunto de ferramentas e tecnologias aplicadas para permitir um sistema de gerenciamento agrícola baseado na variabilidade espacial e temporal

da unidade produtiva, visando o aumento do retorno econômico e à redução do impacto ao ambiente (BRASIL, 2014).

Os conceitos de AP variam na literatura, mas Delavarpour et al. (2021) abrange outros componentes. A AP utiliza grandes fontes de dados que auxiliam os agricultores a tomar decisões com maior precisão, gerenciamento dos talhões, resultando em incrementos na produtividade e redução no uso de insumos agrícolas. Isso é possível através da coleta, análise e interpretação de dados de uma unidade produtiva, utilizando técnicas de Sensoriamento Remoto (SR), de veículo aéreo não tripulado (UAV) ou a nível orbital mediante a imagens de satélites (SILVA et al., 2021). A ascensão do uso de sensores embarcados e dos métodos de SR permitiram à agricultura a avaliação precoce, mais eficiente, objetiva e não destrutiva durante ciclo de desenvolvimento das culturas. Assim, o SR tem proporcionado a aquisição de dados em tempo real e em larga escala no campo, sendo considerado um dos alicerces da AP (VIAN et al., 2018).

A aplicação de equipamentos de alta tecnologia, como softwares, dispositivos e transmissão de dados em tempo real, permite coletar dados para o monitoramento e avaliação de unidades agrícolas. Posteriormente, realizar o planejamento dos manejos como a aplicação de fertilizantes e defensivos agrícolas, adequar o arranjo espacial, entre outros fatores da produção (SILVA; SILVA-MANN, 2020).

Assim, a agricultura de precisão é um sistema de gerenciamento agrícola, iniciado a partir de informações da lavoura e se conclui com a tomada de decisões. É uma forma de administrar o campo, considerando-se o fato que cada área da propriedade possui potenciais diferentes (BORGES et al., 2022). Ou seja, a AP compromete em aumentar a eficiência da produção e gestão da propriedade levando em consideração a variabilidade espacial existente nas lavouras. E, resolver desafios que os agricultores enfrentam diariamente como detecção e diagnóstico de doenças, controle de pragas eficiente, classificação da vegetação, estimativa de produtividade, aplicação de corretivos e fertilizantes (ZUALKERNAN et al., 2023).

Uma das práticas mais adotadas é o mapa de produtividade que fornece informações detalhadas para a visualização da variabilidade espacial e temporal das culturas (TREVISAN et al., 2020). Por ser um parâmetro de grande importância para a maioria das culturas agrícolas, analisar a variação espaço-temporal da produtividade é decisivo para iniciar um amplo diagnóstico e planejamento dos campos, através das unidades de gestão diferenciada (DAMIAN et al., 2020). No estudo de Jin et al. (2019), foi realizado mapeamento de

produtividade de milho usando dados de imagens orbitais e constataram que dados independentes do solo podem explicar mais que 70% da variabilidade nas estimativas de produção. Enquanto Rasmussen et al. (2019), fizeram na pré-colheita o mapeamento de plantas daninhas em cereais usando imagens de UAV, baseado nas diferenças de cor entre plantas daninhas verdes e cereais em fase de senescência.

#### **2.4 Sensoriamento Remoto na agricultura**

O termo sensoriamento remoto (SR) se refere à obtenção de informações à distância sobre a superfície terrestre, utilizando sensores embarcados em uma aeronave remotamente pilotada (UAV) ou satélites. Os dados são obtidos por sensores capazes de mensurar a reflexão e emissão da energia eletromagnética, está baseada na interação da radiação eletromagnética (REM) incidente com diferentes alvos na superfície da terra (QUEIROZ et al., 2020). Essas medidas são originadas do espectro refletido, que abrange a região do visível (0.4 – 0.7  $\mu\text{m}$ ), infravermelho próximo (0.7 – 1.3  $\mu\text{m}$ ) e infravermelho de ondas curtas (1.3 – 2.5  $\mu\text{m}$ ) (QUEIROZ et al., 2022).

A estimativa de parâmetros biofísicos e bioquímicos com alta acurácia e baixo custo são importantes para a evolução das práticas de manejo e do potencial produtivo de sistemas de produção dentro dos preceitos do SR. A precisão espacial na estimativa destas características por meio de imagens aéreas obtidas por UAV pode ajudar na avaliação do comportamento de genótipos, práticas de manejo e impactos de estresses bióticos e abióticos, contribuindo na tomada de decisão dos produtores (SILVA et al., 2022).

O emprego de imagens adquiridas por satélites tem grande utilidade na agricultura, no entanto, possui algumas limitações decorrentes da frequência na obtenção de imagens, da presença de nuvens, período de revisita sobre a área e nível de detalhamento (QUEIROZ et al., 2022). Por outro lado, o emprego de UAV, permite a obtenção de imagens aéreas com maior frequência, flexibilidade e com alta resolução, o que viabiliza o uso desta ferramenta no monitoramento das áreas agrícolas (MOLIN et al., 2020). As plataformas de SR, especialmente o UAV e métodos de processamento de imagens, têm sido intensamente explorados para a caracterização agrônômica das culturas anuais. A UAV destaca-se pela sua capacidade de obter melhores resoluções espaciais, espectrais e temporais em comparação com dados de satélite (MUHARAM et al., 2021).

As diferentes respostas das plantas aos eventos fenológicos são identificadas através da reflectância eletromagnética e os índices de vegetação permitem essa avaliação. A correlação entre os índices de vegetação e os parâmetros agronômicos é positiva e, se houver correlação, é possível realizar a estimativa, principalmente da produtividade da cultura (GIONGO et al., 2020). As características quantitativas das culturas variam espacialmente e temporalmente com o crescimento da vegetação, sendo importante a avaliação do ciclo. Dessa forma, o SR fornece observações frequentes das propriedades da superfície terrestre, possibilitando a caracterização agronômica e fenotípica das culturas (GAO; ZHANG, 2021).

Na agricultura, algumas das variáveis de interesse incluem as características morfológicas, bioquímicas e fisiológicas das culturas, propriedades do solo (umidade do solo, matéria orgânica, pH, drenagem) e topografia, e como eles variam no espaço e no tempo. Uma vez que nenhuma dessas características pode ser medida diretamente por SR, elas são frequentemente estimadas pela integração de medições espectrais com dados reais por meio de abordagens empíricas ou mecânicas ou uma combinação de ambas (KHANAL et al., 2020). O SR permite que seja realizado a coleta de informações das assinaturas espectrais do alvo de interesse e, posteriormente, associado aos parâmetros observados nas lavouras.

Da mesma maneira, a produtividade da cultura do milho e sorgo pode ser associado às informações obtidas pelo SR, conforme realizado por Yang et al. (2021) que usou modelos de crescimento com SR para estimar a produção de biomassa de sorgo. Para as culturas como o milho que são influenciadas pela temperatura do solo, principalmente na fase de germinação e estabelecimento inicial, pode ser realizado o mapeamento da umidade do solo através de sensores térmicos e auxiliar o manejo do sistema (BABAEIAN et al., 2018), adequação das atividades agrícolas de milho e sorgo aos recursos do solo (MUZIRA et al., 2021). Bem como o monitoramento dos estádios fenológicos das culturas (DIAO, 2020), estimativa de produtividade de milho e soja (KHAKI et al., 2021) e monitoramento da área de plantio de milho e arroz usando a banda espectral RedEdge (GUO; REN, 2023). Recentemente, a integração entre o SR e aprendizado de máquina permitiu coletar e processar grandes quantidades de dados em tempo real.

Para isso, a resolução espaço-temporal é um fator importante, uma vez que a plataforma de SR que possuir alta resolução espacial e período de revisita curto irá fornecer imagens com maior nível de detalhamento e capaz de monitorar a cultura. Nesse sentido,

satélites da plataforma PlanetScope apresentam alta resolução espacial e disponibilizam imagens diariamente.

#### 2.4.1 Imagens de satélite - PlanetScope

A plataforma PlanetScope é uma ferramenta consolidada para análise da superfície terrestre, particularmente no monitoramento de variáveis nas áreas agrícolas (TOVAR BLANCO et al., 2020). O PlanetScope possui uma constelação formada de 130 satélites Dove, com período de revisita diário, permitindo a obtenção de imagens multiespectrais (TRANSON et al., 2018). O sensor disponibiliza oito bandas espectrais no visível (Azul costeiro, Azul, Verde I, Verde, Amarelo e Vermelho), borda do vermelho (RedEdge) e infravermelho próximo (NIR) (TABELA 2). As imagens produzidas são ortorretificadas, com 3 metros de resolução espacial e resolução radiométrica de 12 bits (PLANET, 2023).

Tabela 2 – Bandas espectrais do PlanetScope.

Banda	Comprimento de onda (nm)
1 (Azul Costeiro)	431-452
2 (Azul)	465-515
3 (Verde I)	513-549
4 (Verde)	547-583
5 (Amarelo)	600-620
6 (Vermelho)	650-680
7 (RedEdge)	697-713
8 (NIR)	845-885

Fonte: Planet (2023).

A aplicação dessas imagens está crescendo na comunidade de sensoriamento remoto, em função de suas características e qualidade (FRAZIER; HEMINGWAY, 2021). E na agricultura está utilizado para a identificação de campos de milho usando classificador de aprendizado de máquina (ZHANG, L et al., 2020), associado a aprendizado profundo para a detecção de espécies de plantas invasoras (LAKE et al., 2022), estimativa de produção de milho para silagem (TUNCA et al., 2023), estimativa da produtividade de grãos de milho (LI

et al., 2022) e verificar o desempenho de índices de vegetação para estimativa de biomassa verde em feijoeiro (BARBOZA et al., 2023).

#### **2.4.2 Imagens aéreas obtidas por Veículo Aéreo não Tripulado**

Os Veículos Aéreos não Tripulados (UAVs) têm sido cada vez mais empregados como uma plataforma de observação de SR para aplicações próximas ao solo. Múltiplos rotores, asas fixas, UAVs híbridos e helicópteros não tripulados são as categorias de UAVs comumente usadas. Essa ferramenta tem sido amplamente utilizada como plataforma para SR, e os sensores embarcados por essas aeronaves desempenham um papel crítico na aquisição de dados. (ZHANG; ZHU, 2023).

A integração do SR em plataformas de UAV possibilita diversas aplicações práticas em AP no setor agrícola. Essas ferramentas disponibilizam técnicas que minimizam os custos operacionais, otimizam o uso de insumos e aumentam a produtividade agrícola, por meio do processamento de imagens aéreas adquiridas por sensores embarcados em UAV's (DELAVUAVOUR et al., 2021). A UAV fornece informações com elevada resolução espacial e temporal no monitoramento agrícola e, através de sensores RGB, é possível realizar a obtenção de dados com baixo custo. A sigla RGB indica as bandas espectrais na região do visível em que R (vermelho), G (verde) e B (azul) (QUEIROZ et al., 2022).

Nesse contexto, o processamento digital de imagens compreende um conjunto de técnicas que permite a extração de informações com alto nível de detalhamento, permitindo a identificação e a interpretação de padrões durante o ciclo de desenvolvimento da cultura do milho e do sorgo (SANTANA et al., 2019).

O monitoramento do crescimento das culturas é uma prática que fornece informações importante para entender a resposta das culturas às condições ambientais e às práticas agronômicas, bem como sua adaptabilidade (SISHODIA et al., 2020). Esse parâmetro é essencial para estimar a produtividade e biomassa do milho, assim, no estudo de Gao et al. (2022), foi proposto utilizar imagens RGB obtidas por UAV para realizar a localização e a estimativa de altura das plantas de milho no campo.

O UAV é um equipamento na qual pode ser acoplado diversos sensores e, um exemplo é o sensor hiperespectral que fornece um amplo espectro de informações sobre a cultura e são aplicadas para a estimativa de produtividade do milho (YANG, W et al., 2021). Assim como a estimativa e mapeamento da uniformidade de emergência do milho (VONG et al., 2022),

estimativa do teor de nitrogênio foliar (XU et al., 2021), fenotipagem de alto rendimento de plantas de milho (SU et al., 2019). E vale destacar a eficiência do UAV ao realizar o mapeamento de alturas de dossel através das nuvens de pontos fotogramétricas (ZHANG et al., 2021).

## **2.5 Inteligência Artificial aplicada à cultura anual**

A inteligência artificial (IA) é uma tecnologia que está integrada a agricultura de precisão, na qual as máquinas por meio de algoritmos são capazes de analisar e interpretar grande quantidade de dados e em velocidade superior à do ser humano (PINHEIRO et al., 2021). Essa técnica requer um conjunto de dados de treinamento para o aprendizado de máquina e, posteriormente, viabiliza modelos matemático com desempenho superior aos modelos convencionais (MOLIN et al., 2020).

Essa tecnologia realiza uma análise objetiva e precisa, fornecendo soluções aos agricultores e técnicos para muitos problemas ambíguos relacionados às culturas, além da possibilidade de automatizar e otimizar as etapas de produção da agricultura (GARCÍA-ARTEAGA et al., 2020). Os algoritmos fazem o reconhecimento de padrões utilizando dados de atributos morfológicos da cultura do milho, podendo realizar a classificação automática de grãos, produtividade de grãos, identificação de pragas e doenças, reconhecimento de deficiências nutricionais e o desenvolvimento de mapas de manejo na lavoura (PINTO et al., 2022).

O desenvolvimento de modelos e a simulação dinâmica das características biofísicas das culturas estão sendo amplamente aceitas para a pesquisa agrícola e acadêmica, justamente por ser uma forma contrária às abordagens puramente estatísticas. Dentre as vantagens da utilização de modelos, destacam-se a economia de tempo, trabalho e quantidade de recursos para o planejamento e tomada de decisões no setor agrícola (YANG et al., 2021).

A modelagem está sendo utilizada na simulação do crescimento e produtividade dessas culturas, gerando informações sobre a interação fisiológica e ambiente (BORGES et al., 2019). Além disso, um subconjunto específico da IA são as técnicas usadas para treinar máquinas em como aprender, o que origina uma nova estrutura conhecida como aprendizado de máquina (ML). Nesse contexto, o ML pode fornecer soluções em cenários onde um grande número de dispositivos simultaneamente requer acesso aos recursos da rede de forma



dinâmica, heterogênea e imprevisível, por exemplo, em comunicações internet das coisas (IoT) (BITHAS et al., 2019).

Em geral, ML é baseado na estrutura de reconhecimento de padrões e sua ideia principal é explorar a correlação entre um conjunto de dados e/ou boas sequências de ações passadas para se adaptar às mudanças ambientais sem qualquer tipo de intervenção humana. Claramente, a vantagem oferecida pela estrutura ML na operação de redes sem fio é que ela permitirá que os elementos da rede monitorem, aprendam e prevejam vários parâmetros relacionados à comunicação, como comportamento do canal sem fio, padrões de tráfego, contexto do usuário e localização dos dispositivos (REBALA et al., 2019). O ML apresenta duas principais categorias, o aprendizado supervisionado e não supervisionado (Quadro 1). E para isso os algoritmos de ML foram propostos como uma abordagem eficiente para analisar os dados provenientes do SR.

Quadro 1 – Descrição do aprendizado de máquina supervisionado e não supervisionado.

Aprendizado supervisionado	Aprendizado não supervisionado
No aprendizado supervisionado, os algoritmos usam conjuntos de dados, nos quais tanto a entrada quanto a saída desejada estão disponíveis. Portanto, esse tipo de algoritmo só pode ser empregado em cenários em que dados rotulados suficientes estejam disponíveis para serem explorados.	Os algoritmos de aprendizado não supervisionado também exigem que os dados estejam disponíveis para treinamento, que, no entanto, não incluem saída rotulada. Portanto, nesse tipo de aprendizado, o agrupamento ou descoberta de padrões é realizado nos dados disponíveis.

Fonte: Shah et al. (2020).

A ascensão da IA propõe a combinação de técnicas de processamento de imagens aéreas e orbitais com o ML, viabilizando a obtenção de dados fenotípicos, estimativa de produtividade e produção de biomassa de plantas de milho e sorgo (PINHEIRO et al., 2021). Imagens RGB e multiespectrais combinadas com aprendizado de máquinas são uma forma interessante de realizar a estimativa de parâmetros agrônômicos como altura de planta, teor de clorofila, contagem de plantas e produtividade (TU et al., 2021).

O ML é uma ferramenta frequentemente aplicada para interpretação e análise de dados de SR, por meio de diversos métodos (SCHEUNDERS et al., 2018). O levantamento do potencial produtivo e de outros aspectos fitotécnicos dessas culturas são essenciais a cada

safra, assim o emprego de técnicas de SR e IA associadas à sistemas inteligentes, são uma alternativa eficiente de assistência ao setor agrícola. Para isso, o ML possui diversos modelos de aprendizado como regressão, agrupamento, modelos bayesianos, baseados em instância, árvores de decisão, redes neurais artificiais, máquinas de vetores de suporte e aprendizado conjunto (LIAKOS et al., 2018).

A IA e a robótica estão desempenhando um papel fundamental para auxiliar ou substituir a intervenção manual no setor agrícola, que abrange um grande painel de aplicações. Por um lado, a robótica tem desempenhado um papel fundamental na produção e gestão agrícola, pelo que os robôs realizam várias operações de forma autônoma, como capinar, irrigar ou gerir plantas individuais (LINAZA et al., 2021). Zhang B et al. (2020) forneceram um resumo detalhado das garras robóticas de última geração, métodos de controle baseados em sensores, bem como suas aplicações em tarefas agrícolas robóticas durante o período da colheita. Toda essa tecnologia está reinventando a agricultura através da contribuição aos os agricultores nas tomadas de decisões, a produzir mais com menos recursos e melhorar a qualidade das colheitas (JAVOID et al., 2023).

## **2.6 Algoritmos de aprendizado de máquina**

A análise de dados vem ganhando força nos últimos anos, principalmente, por investigar mais a fundo o comportamento dos dados. A investigação ocorre a partir do uso de modelos complexos, passando por etapas decisivas, até chegar no resultado ideal, fugindo das análises tradicionais. A análise rápida dos dados, tomada de decisão rápida e os processos automatizados, além da alta acurácia e precisão, começaram a ganhar espaço dentro do setor agrícola, excepcionalmente quando utilizada a agricultura digital (SOOD; KUMAR; KUMAR, 2021).

Algoritmos de aprendizado de máquina como Linear Regression (LR), Random Forest (RF), K-Nearest Neighbor (KNN), Support Vector Machine (SVM) e Decision Tree (DT) são abordagens utilizadas por pesquisadores para realizar estimativas e previsões na agricultura. Cada algoritmo apresenta características e particularidades no modo de aplicação nos dados.

LR: A regressão linear é o algoritmo de regressão tradicional na qual a estimativa da variável dependente ocorre a partir da variável independente. O objetivo é estimar a relação entre as variáveis quantitativas de modo que o efeito da variável resposta (Y) possa ser estimado com base na modificação dos níveis do fator (X) (FORTHOFER, et al., 2007;

YETURU, 2020). Em estudo de Wei e Molin (2020), esse modelo foi utilizado para gerar uma equação global para estimar a produtividade de soja.

RF: Algoritmo de floresta aleatória é uma técnica de aprendizado máquina usado para classificação e regressão. Neste algoritmo, várias árvores criam uma floresta e cada árvore individual na floresta aleatória libera uma expectativa de classe, se transformando em uma estimativa do modelo (RANI et al., 2022; SHAUKAT et al., 2020). O algoritmo de RF obteve uma precisão de 91% e RMSE = 0,39 t ha<sup>-1</sup> com o conjunto de dados de Filippi et al. (2019), realizando rendimento das colheitas de culturas anuais. Usando RF para estimativa do grau de produtividade da cana-de-açúcar (CHAROEN-UNG; MITTRAPIYANURUK, 2018).

KNN: O algoritmo K-vizinhos mais próximos é um método aprendizado supervisionado usado para classificação e regressão. Isso ocorre através da identificação de valores baseado em instâncias e na classe da maioria dos K-vizinhos mais próximos em um conjunto de características. O cálculo da distância de um atributo de seus vizinhos é medido usando a distância euclidiana (SHAH et al., 2020; SHAUKAT et al., 2020) e assim os dados são agrupados com base na similaridade entre eles. Em um estudo de Feng et al. (2020), o algoritmo KNN obteve precisão de 87% ao usar imagens hiperespectrais para estimativa de produção de alfafa. Bem como encontrado por Osco et al. (2020), uma elevada acurácia ao realizar a estimativa da altura de planta de milho usando imagens baseadas em UAV.

SVM: O algoritmo de aprendizado de máquina supervisionado que pode ser empregado para fins de classificação e regressão. SVMs são baseados na ideia de encontrar um hiperplano que melhor divide um conjunto de dados, melhorando a separação entre as classes no espaço de características. A precisão na classificação de um ponto de dados pode ser potencializada ao aumentar a margem e as distâncias entre os hiperplanos. Os pontos de dados que estão na borda do hiperplano são chamados de pontos de vetor de suporte. Pode ser linear e não linear com base na função kernel (RANI et al., 2022; RASHEED; WAHID, 2021). Usando SVM (de base radial) para estimativa de produtividade de milho primavera através de dados de sensoriamento remoto, o algoritmo obteve acurácia maior que 97% (AHMAD et al., 2018). Juntamente com outros algoritmos, o SVM foi usado para estimar a produtividade e biomassa da cultura do arroz (ZHA et al., 2020).

DT: A árvore de decisão é um algoritmo de classificação que funciona com dados categóricos e numéricos. As árvores de decisão são estruturas semelhantes a árvores que tomam decisões baseadas em características dos dados de entrada, através de análises com

base em três nós (SHAH et al., 2020; SHAUKAT et al., 2020). Cada nó interno representa uma decisão baseada em um atributo, enquanto as folhas representam as classes ou valores previstos. Na agricultura, o algoritmo DT apresentou boa acurácia (RMSE = 281 kg/ha) ao realizar a estimativa de rendimento da colheita (BHATNAGAR; GOHAIN, 2019).

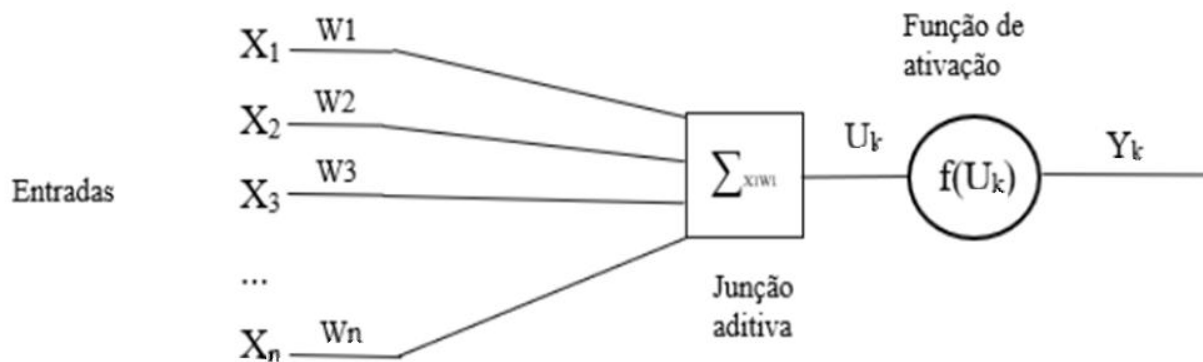
Existem outras abordagens para realizar a estimativa de parâmetros agronômicos, como utilizar um subconjunto do aprendizado de máquina conhecido por Rede Neural Artificial. Essa estrutura consiste em camadas que transformam os dados de entrada em informações que a próxima camada usa para realizar uma estimativa ou estimativa.

## **2.7 Rede Neural Artificial (RNA)**

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, sendo baseados em seu mecanismo de memorização e aprendizado através de algoritmos (GUPTA et al., 2020). A RNA consiste em camadas de entrada, ocultas e de saída com neurônios conectados (nós) para simular o cérebro humano. Os nós existentes processam e transmitem sinais de entrada para os próximos nós, ou seja, cada camada contém unidades que transformam os dados de entrada em informações que a próxima camada pode usar para executar uma determinada tarefa preditiva. As RNAs são modelos não lineares para reconhecimento de interações complexas entre as variáveis (MOHSENI-DARGAH et al., 2022) e com grande potencial na análise de dados (ABIODUN et al., 2018).

O neurônio artificial, atualmente utilizado, possui como estruturas os terminais de entrada (dendritos), recebendo os valores de  $X_1, X_2, \dots, X_n$ , e para simular as sinapses, os pesos,  $W_1, W_2, \dots, W_n$ , são atrelados aos valores de entradas, podendo ser valores positivos e negativos dependendo das sinapses anteriores e apenas um terminal de saída  $Y$  (axônio), dessa forma, o disparo ocorre por meio da soma dos valores de  $X_1W_1$  e a ativação do neurônio obtida por meio da função de ativação (FIGURA 2), que ativa ou não a saída a depender da soma ponderada das entradas (BRAGA et al., 2007).

Figura 2 – Modelo do primeiro neurônio artificial.



Fonte: Braga et al. (2007).

O avanço das pesquisas na área da inteligência computacional, possibilitou o desenvolvimento de redes capazes de solucionar diferentes problemas impostos, reconhecimento de padrões e previsões em muitos setores (ABIODUN et al., 2018). Dentre essas redes, a rede *MultiLayer Perceptron* (MLP) é frequentemente utilizada no setor agrícola, na qual apresentam importantes características de arquitetura e função (QUADRO 2).


Quadro 2 – Característica da rede neural artificial tipo *MultiLayer Perceptron*.

<i>MultiLayer Perceptron</i>	
1.	Uma ou mais camadas de entrada
2.	Neurônios de camadas intermediárias têm características similares aos de saída
3.	Padrões de entrada diferenciados em hiperplanos
4.	Melhor em problemas complexos

Fonte: Braga et al. (2007).

A MLP apresenta uma arquitetura complexa e a saída dos resultados atuam globalmente, formada a partir de todos os neurônios (FIGURA 3) (YU et al., 2011). Essa rede é mais utilizada na resolução de problemas, constituída de uma camada de entrada, camada oculta e de saída (KASHANINEJAD; DEHBHANI; KASHIRI, 2009).

Figura 3 – A rede neural artificial MLP (A) e sua divisão em hiperplanos (B).



Fonte: Yu et al. (2011).

RNA é uma técnica para ML que devido sua capacidade de classificação, regressão, agrupamento e reconhecimento de padrões, tornou-se relativamente competitivo em relação à regressão tradicional e aos modelos estatísticos convencionais (ROZNIK et al., 2022). Dessa forma, as redes neurais têm sido empregadas na agricultura desde de a análise de imagens das culturas a previsão de variáveis climáticas (GHORBANI et al., 2013). E são frequentemente utilizadas na estimativa de biomassa (ALI et al., 2017), na definição de manejo diferenciado por meio de atributos do solo (LEAL et al., 2015), estimativa da maturação de grãos (SOUZA et al., 2021), estimativa da produtividade (ABRAHAM et al., 2019; KAMIR; SOARES et al., 2015; WALDNER; HOCHMAN, 2020) e de produtividade agrícola (VAN KLOMPENBURG et al., 2020).

Por meio da integração entre dados de sensoriamento remoto de alta resolução e modelos de RNA foram empregados para estimativa da produção de milho (KHANAL et al., 2018), com base em mapas de propriedades do solo e séries temporais realizaram a estimativa de produtividade de milho (MA et al., 2021), produtividade de sorgo usando dados climáticos (SRIDHARA et al., 2020), implementaram TensorFlow com RNA para estimativa do peso de espigas de sorgo (ZANNOU; HOUNDCI, 2019), integrando modelos de crescimento para estimar produtividade de sorgo (YANG et al., 2021) e estimativa do crescimento de cana-de-açúcar (GHAZVINEI et al., 2018). Isso demonstra o potencial das diversas técnicas de ML empregadas na agricultura e a importância do desenvolvimento de mais pesquisas.

## REFERÊNCIAS

- ABIODUN, O. I; JANTAN, A; OMOLARA, A. E; DADA, K. V; MOHAMED, N. A; ARSHAD, H. State-of-the-art in artificial neural network applications: a survey. **Heliyon**, v. 4, n. 11, nov. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.heliyon.2018.e00938>.
- ABRAHAM, E. R; REIS, J. G. M. dos; TOLOI, R. C; SOUZA, A. E. de; COLOSSETTI, A. P. Estimativa da produção da soja brasileira utilizando redes neurais artificiais. **Agrarian**, v. 12, n. 44, p. 261-271, 12 out. 2019. Universidade Federal de Grande Dourados. <http://dx.doi.org/10.30612/agrarian.v12i44.9209>.
- AGUIRRE-MANCILLA, C. L; GODÍNEZ-GALÁN, R. Y; RAYA-PÉREZ, J. C; GUTIÉRREZ-BENICIO, G. M; RAMÍREZ-PIMENTEL, J. G; COVARRUBIAS-PRIETO, J; GARCÍA-RODRÍGUEZ, J. G. Protein content and quality of seeds in central mexican maize (*Zea mays*) accessions. **Revista de la Facultad de Ciencias Agrarias**, v. 52, n.1, p. 14–25, 2020.
- AHMAD, I; SAEED, U; FAHAD, M; ULLAH, A; RAHMAN, M. H. U; AHMAD, A; JUDGE, J. Yield Forecasting of Spring Maize Using Remote Sensing and Crop Modeling in Faisalabad-Punjab Pakistan. **Journal Of The Indian Society Of Remote Sensing**, v. 46, n. 10, p. 1701-1711, 7 ago. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12524-018-0825-8>.
- ALI, I; CAWKBELL, F; DWYER, E; GREEN, S. Modeling managed grassland biomass estimation by using multitemporal remote sensing data – a machine learning approach. **IEEE Journal of selected topics in applied Earth observations and remote sensing**, University College Cork, Ireland, 2017. DOI: <http://dx.doi.org/10.1109/JSTARS.2016.2561618>.
- ARTUZO, F. D; FOGUESATTO, C. R; DESSIMON MACHADO, J. A; DE OLIVEIRA, L; LEAL DE SOUZA, A. R. Brazilian production potential: A historical analysis of corn production. **Revista em Agronegocio e Meio Ambiente**, v. 12, n. 2, p. 515–540, 2019. DOI: 10.17765/2176-9168.2019v12n2p515-540.
- BABAEIAN, E; SADEGHI, M; FRANZ, T. E; JONES, S; TULLER, M. Mapping soil moisture with the OPTical TRAppezoid Model (OPTRAM) based on long-term MODIS observations. **Remote Sensing Of Environment**, v. 211, p. 425-440, jun. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2018.04.029>.
- BARBOZA, T. O. C; ARDIGUERI, M; SOUZA, G. F. C; FERRAZ, M. A. J; GAUDENCIO, J. R. F; SANTOS, A. F. dos. Performance of Vegetation Indices to Estimate Green Biomass Accumulation in Common Bean. **Agriengineering**, v. 5, n. 2, p. 840-854, 4 maio 2023. MDPI AG. <http://dx.doi.org/10.3390/agriengineering5020052>.
- BHATNAGAR, R; GOHAIN, G. B. Crop Yield Estimation Using Decision Trees and Random Forest Machine Learning Algorithms on Data from Terra (EOS AM-1) & Aqua (EOS PM-1) Satellite Data. **Studies In Computational Intelligence**, p. 107-124, 3 jul. 2019. Springer International Publishing. [http://dx.doi.org/10.1007/978-3-030-20212-5\\_6](http://dx.doi.org/10.1007/978-3-030-20212-5_6).
- BITHAS, P. S; MICHAILEDIS, E. T; NOMIKOS, N; VOUYIOUKAS, D; KANATAS, A. G. A Survey on Machine-Learning Techniques for UAV-Based Communications. **Sensors**, v. 19, n. 23, p. 5170, 26 nov. 2019. MDPI AG. <http://dx.doi.org/10.3390/s19235170>.

BORÉM, A; GALVÃO, J. C. C, PIMENTEL, M. A. **Milho, do plantio a colheita**, 2017.

BORÉM, A; PIMENTEL, L; PARRELLA, R. **Sorgo do plantio à colheita**. Viçosa: Ufv, 2014. 275 p.

BORGES, L. C; NASCIMENTO, A. dos R; MORGADO, C. M. A. Agricultura de precisão: ferramenta de gestão na rentabilidade e produtividade de grãos. **Scientific Electronic Archives**, v. 15, n. 3, 2022. DOI: 10.36560/15320221520.

BORGES, P. H. M; MENDOZA, Z. M. S. H; MORAIS, P. H. M. Redes neurales artificiales para estimar las pérdidas en la producción lechera. **Archivos de Zootecnia**, v. 68, n. 262, p. 206–212, 2019. DOI: 10.21071/az. v68i262.4138. Disponível em: <<http://www.uco.es/ucopress/az/index.php/az/article/view/4138>>.

BRAGA, A. P; CARVALHO, A. P. L. F; LUDEMIR, T. B. Redes neurais artificiais teoria e aplicações. **LTC**, 2º edição, 2007.

BRASIL. **Agricultura de Precisão**. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Brasília: Mapa/ACS, 2014. 21p. Disponível em: <[http://www.agricultura.gov.br/arq\\_editor/file/Desenvolvimento\\_Sustentavel/Agricultura- Precisao.pdf](http://www.agricultura.gov.br/arq_editor/file/Desenvolvimento_Sustentavel/Agricultura- Precisao.pdf)>.

CHAROEN-UNG, P; MITTRAPIYANURUK, P. Sugarcane Yield Grade Prediction Using Random Forest with Forward Feature Selection and Hyper-parameter Tuning. **Recent Advances In Information And Communication Technology 2018**, p. 33-42, 27 jun. 2018. Springer International Publishing. [http://dx.doi.org/10.1007/978-3-319-93692-5\\_4](http://dx.doi.org/10.1007/978-3-319-93692-5_4).

CONAB. Companhia Nacional de Abastecimento. Acompanhamento de safra Grãos: safra 2022/2023. Nono Levantamento, junho de 2023. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>.

CRUZ, J. C; KARAM, D; MONTEIRO, M. A. R; MAGALHÃES, P. C. **A cultura do milho**. Sete Lagoas: Embrapa Milho e Sorgo, 2008. 517 p.

DAMIAN, J. M; PIAS, O. H. de C; CHERUBIN, M. R; FONSECA, A. Z. da; FORNARI, E. Z; SANTI, A. L. Applying the NDVI from satellite images in delimiting management zones for annual crops. **Scientia Agricola**, v. 77, n. 1, p. 99-99, 2020. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1678-992x-2018-0055>.

DELAVUAVOUR, N; KOPARAN, C; NOWATZKI, J; BAJWA, S; SUN, X. A technical Study on UAV characteristics for precision agriculture applications and associated practical challenges. **Remote Sensing**, v. 13, n. 6, p. 1–25, 2021. DOI: 10.3390/rs13061204.

DIAO, C. Remote sensing phenological monitoring framework to characterize corn and soybean physiological growing stages. **Remote Sensing Of Environment**, v. 248, p. 111960, out. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2020.111960>.

FANCELLI, A. L. **Ecofisiologia, fenologia e implicações básicas de manejo**. Milho: do plantio à colheita. Tradução. Viçosa: Editora UFV, 2017.



- FENG, L; ZHANG, Z; MA, Y; DU, Q; WILLIAMS, P; DREWRY, J; LUCK, B. Alfalfa Yield Prediction Using UAV-Based Hyperspectral Imagery and Ensemble Learning. **Remote Sensing**, v. 12, n. 12, p. 2028, 24 jun. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12122028>.
- FILIPPI, P; JONES, E. J; WIMALATHUNGE, N. S; SOMARATHNA, P. D. S. N; POZZA, L. E; UGBAJE, S. U; JEPHCOTT, T. G; PATERSON, S. E; WHELAN, B. M; BISHOP, T. F. A. An approach to forecast grain crop yield using multi-layered, multi-farm data sets and machine learning. **Precision Agriculture**, v. 20, n. 5, p. 1015-1029, 8 jan. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-018-09628-4>.
- FORTHOFFER, R. N; LEE, E. S; HERNANDEZ, M. Linear Regression. **Biostatistics**, p. 349-386, 2007. Elsevier. <http://dx.doi.org/10.1016/b978-0-12-369492-8.50018-2>.
- FRAZIER, A. E; HEMINGWAY, B. L. A Technical Review of Planet Smallsat Data: practical considerations for processing and using planetscope imagery. **Remote Sensing**, v. 13, n. 19, p. 3930, 30 set. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13193930>.
- GAO, F; ZHANG, X. Mapping Crop Phenology in Near Real-Time Using Satellite Remote Sensing: Challenges and Opportunities. **Journal of Remote Sensing**, v. 2021, p. 1–14, 2021. DOI: 10.34133/2021/8379391.
- GAO, M; YANG, F; WEI, H; LIU, X. Individual Maize Location and Height Estimation in Field from UAV-Borne LiDAR and RGB Images. **Remote Sensing**, v. 14, n. 10, 2022. DOI: 10.3390/rs14102292.
- GARCÍA-ARTEAGA, J. J; ZAMBRANO-ZAMBRANO, J. J; ALCIVAR-CEVALLOS, R; ZAMBRANO-ROMERO, W. D. Predicción del rendimiento de cultivos agrícolas usando aprendizaje automático. **Revista Arbitrada Interdisciplinaria Koinonía**, v. 5, n. 2, p.144, 2020. DOI: 10.35381/r.k. v5i2.1013.
- GHAZVINEI, P. T; DARVISHI, H. H; MOSAVI, A; YUSOF, K. B W; ALIZAMIR, M; SHAMSHIRBAND, S; CHAU, K. W. Sugarcane growth prediction based on meteorological parameters using extreme learning machine and artificial neural network. **Engineering Applications Of Computational Fluid Mechanics**, v. 12, n. 1, p. 738-749, jan. 2018. Informa UK Limited. <http://dx.doi.org/10.1080/19942060.2018.1526119>.
- GHORBANI, M. A; KHATIBI, R; HOSSEINI, B; BILGILLI, M. Relative importance of parameters affecting wind speed prediction using artificial neural networks. **Theoretical And Applied Climatology**. 114, p. 107 – 114, 2013. <http://dx.doi.org/10.1007/s00704-012-0821-9>.
- GIONGO, P. R; ORLANDINI, J. D; ARANTES, B. H. T; GOMES, L. F; MORAES, V. H; COSTA, A. R. Da; RIBON, A. A. Predição de dados agronômicos em goiabeiras e separaçãode alvos por meio de Veículo Aéreo Não Tripulado. **Scientia Plena**, v. 16, n. 4, p. 1– 10, 2020. DOI: 10.14808/sci.plena.2020.040202.
- GUO, Y; REN, H. Remote sensing monitoring of maize and paddy rice planting area using GF-6 WFV red edge features. **Computers And Electronics In Agriculture**, v. 207, p. 107714, abr. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2023.107714>.
- GUPTA, N; KHOSRAVY, M; GUPTA, S; DEY, N; CRESPO, R. G. Lightweight Artificial Intelligence Technology for Health Diagnosis of Agriculture Vehicles: parallel evolving artificial neural networks by genetic algorithm. **International Journal Of Parallel**

**Programming**, v. 50, n. 1, p. 1-26, 3 jul. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10766-020-00671-1>.

HENRIQUES, H. J. R; SCHWAMBACH, D. A; FERNANDES, V. J. M; CORTEZ, J. W. Vegetation indices and their correlation with second-crop corn grain yield in Mato Grosso do Sul, Brazil. **Revista Brasileira de Milho e Sorgo**, v. 20, p. 13, 2021. DOI: 10.18512/rbms2021v20e1195. Disponível em: <<http://rbms.cnpms.embrapa.br/index.php/ojs/article/view/1195>>.

HOSS, D. F; DALUZ, G. L; LAJÚS, C. R; MORETTO, M. A; TREMEA, G. A. Multispectral aerial images for the evaluation of maize crops. **Ciencia e Agrotecnologia**, v. 44, p. 1–7, 2020. DOI: 10.1590/1413-7054202044004920.

JAVAID, M; HALEEM, A; KHAN, I. H; SUMAN, R. Understanding the potential applications of Artificial Intelligence in Agriculture Sector. **Advanced Agrochem**, v. 2, n. 1, p. 15-30, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.aac.2022.10.001>.

JIN, Z; AZZARI, G; YOU, C; TOMMASO, S. di; ASTON, S; BURKE, M; LOBELL, D. B. Smallholder maize area and yield mapping at national scales with Google Earth Engine. **Remote Sensing Of Environment**, v. 228, p. 115-128, jul. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2019.04.016>.

KAMIR, E; WALDNER, F; HOCHMAN, Z. Estimating wheat yields in Australia using climate records, satellite image time series and machine learning methods. **ISPRS Journal of photogrammetry and remote sensing**, 160, p. 124 – 135, 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2019.11.008>

KASHANINEJAD, M; DEHGHANI, A. A; KASHIRI, M. Modeling of wheat soaking using two artificial neural networks (MLP and RBF). **Journal of food engineering**, 91, p. 602 – 607, 2009. DOI:10.1016/j.jfoodeng.2008.10.012

KHAKI, S; PHAM, H; WANG, L. Simultaneous corn and soybean yield prediction from remote sensing data using deep transfer learning. **Scientific Reports**, v. 11, n. 1, 27 maio 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-021-89779-z>.

KHANAL, S; FULTON, J; KLOPFENSTEIN, A; DOURIDAS, N; SHEARER, S. Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield. **Computers And Electronics In Agriculture**, v. 153, p. 213-225, out. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2018.07.016>.

KHANAL, S; KC, K; FULTON, J. P; SHEARER, S; OZKAN, E. Remote Sensing in Agriculture—Accomplishments, Limitations, and Opportunities. **Remote Sensing**, v. 12, n. 22, p. 3783, 19 nov. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12223783>.

LAKE, T. A; RUNQUIST, R. D. Briscoe; MOELLER, David A. Deep learning detects invasive plant species across complex landscapes using Worldview-2 and Planetscope satellite imagery. **Remote Sensing In Ecology And Conservation**, v. 8, n. 6, p. 875-889, 13 jun. 2022. Wiley. <http://dx.doi.org/10.1002/rse2.288>.

LEAL, A. J. F; MIGUEL, E. P; BAIO, F. H. R; NEVES, D. de C; LEAL, U. A. S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, v. 74, n. 4, p. 436–444, 2015. DOI: 10.1590/1678-4499.0140.

LI, F; MIAO, Y; CHEN, X; SUN, Z; STUEVE, K; YUAN, F. In-Season Prediction of Corn Grain Yield through PlanetScope and Sentinel-2 Images. **Agronomy**, v. 12, n. 12, p. 3176, 15 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12123176>.

LINAZA, M. T; POSADA, J; BUND, J; EISERT, P; QUARTULLI, M; DOLLNER, J; PAGANI, A; OLAIZOLA, I. G; BARRIGUINHA, A; MOYSIADIS, T; LUCAT, L. Data-Driven Artificial Intelligence Applications for Sustainable Precision Agriculture. **Agronomy**, v. 11, n. 6, p. 1227, 17 jun. 2021. MDPI AG. <http://dx.doi.org/10.3390/agronomy11061227>.

MA, Y; ZHANG, Z; KANG, Y; OZDOGN, M. Corn yield prediction and uncertainty analysis based on remotely sensed variables using a Bayesian neural network approach. **Remote Sensing Of Environment**, v. 259, p. 112408, jun. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2021.112408>.

MOHSENI-DARGAH, M; FALAHATI, Z; DABIRMANESH, B; NASROLLAHI, P; KHAJEH, K. Machine learning in surface plasmon resonance for environmental monitoring. **Artificial Intelligence And Data Science In Environmental Sensing**, p. 269-298, 2022. Elsevier. <http://dx.doi.org/10.1016/b978-0-323-90508-4.00012-5>.

MOLIN, J. P.; AMARAL, L. R. do.; COLAÇO, A. F. **Agricultura de Precisão**. São Paulo:Oficina de Textos, 2015. 238 p.

MOLIN, J. P; BAZAME, H. C; MALDANER, L; DE PAULA CORREDO, L;

MARTELLO, M; CANATA, T. F. Agricultura de precisão e as contribuições digitais para a gestão localizada das lavouras. **Revista Ciencia Agronomica**, v. 51, n. 5, p. 1–10, 2020. DOI: 10.5935/1806-6690.20200088.

MUHARAM, F. M; NURULHUDA, K; ZULKAFI, Z; TARMIZI, M. A; ABDULLAH, A. N. H; HASHIM, M. F. C; ZAD, S. N. M; RADHWANE, D; ISMAIL, M. R. Uav-and random-forest-adaboost (Rfa)-based estimation of rice plant traits. **Agronomy**, v. 11, n.5, p. 1–28, 2021. DOI: 10.3390/agronomy11050915.

MUZIRA, N. M; MUSHORE, T. D; WUTA, M; MUTASA, C; MASHONJOWA, E. Land suitability analysis of Zimbabwe for the production of sorghum (*Sorghum -bicolor*) and maize (*Zea mays*) using a Remote Sensing and GIS based approach. **Remote Sensing Applications: Society and Environment**, v. 23, p. 100553, ago. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2021.100553>.

PINHEIRO, R. de M; GADOTTI, G. I; MONTEIRO, R. de C. M; BERNARDY, R. Inteligência artificial na agricultura com aplicabilidade no setor sementeiro. **Diversitas Journal**, v. 6, n. 3, p. 2984–2995, 2021. DOI: 10.48017/diversitas\_journal-v6i3-1857.

PINTO, A. A; ZERBATO, C; ROLIM, G. de S; BARBOSA JÚNIOR, M. R; SILVA, L. F. V. Da; OLIVEIRA, R. P. De. Corn grain yield forecasting by satellite remote sensing and machine-learning models. **Agronomy Journal**, 2022. DOI: 10.1002/agj2.21141. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/agj2.21141>.

PLANET. Planet Imagery Product Specification. 2023. Available online: <[https://assets.planet.com/marketing/PDF/Planet\\_Surface\\_Reflectance\\_Technical\\_White\\_Paper.pdf](https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf)>. Accessed on: 27 february 2023.

QUEIROZ, D. M. De; COELHO, A. L. de F.; VALENTE, D. S. M.; SCHUELLER, J. K. Sensors Applied to Digital Agriculture: A Review. **REVISTA CIÊNCIAAGRONÔMICA**, v. 51, n. 5, p. 1–15, 2020. DOI: 10.5935/1806-6690.20200086. Disponível em:<<http://ccarevista.ufc.br/seer/index.php/ccarevista/issue/archive>>.

QUEIROZ, D. M. de; VALENTE, D. S. M.; PINTO, F. de A. de C.; BORÉM, A. **Agricultura Digital**. 2. ed. Viçosa: UFV, 2022. 224 p.

RANI, A; KUMAR, N; KUMAR, J; SINHA, N. K. Machine learning for soil moisture assessment. **Deep Learning For Sustainable Agriculture**, p. 143-168, 2022. Elsevier. <http://dx.doi.org/10.1016/b978-0-323-85214-2.00001-x>.

RASHEED, F; WAHID, A. Learning style detection in E-learning systems using machine learning techniques. **Expert Systems With Applications**, v. 174, p. 114774, jul. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.eswa.2021.114774>.

REBALA, G; RAVI, A; CHURIWALA, S. Learning Models. **An Introduction to Machine Learning**, p. 19-23, 2019.

RITCHIE, S. W; HANWAY, J. J; BENSON, G. O. Como a planta de milho de milho se desenvolve. **Arquivo do Agrônomo Potafos**, Piracicaba, n. 103, p. 1- 20, set. 2003.

SANTANA, L. S; FERRAZ, G. e S; SANTOS, L. M; MACIEL, D. A; BARATA, R. A. P; REYNALDO, É. F; ROSSI, G. Vegetative vigor of maize crop obtained through vegetation indexes in orbital and aerial sensors images. **Revista Brasileira de Engenharia de Biosistemas**, v. 13, n. 3, p. 195–206, 2019. DOI:10.18011/bioeng2019v13n3p195-206.

SCHEUNDERS, P; TUIA, D; MOSER, G. Contributions of Machine Learning to Remote Sensing Data Analysis. *In: Comprehensive Remote Sensing*. Elsevier, 2018. v. 1–9p.199–243. DOI: 10.1016/B978-0-12-409548-9.10343-4.

SHAH, D; PATEL, S; BHARTI, S. K. Heart Disease Prediction using Machine Learning Techniques. **Sn Computer Science**, v. 1, n. 6, 16 out. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s42979-020-00365-y>.

SHAUKAT, K; LUO, S; VARADHARAJAN, V; HAMEED, I. A; XU, M. A Survey on Machine Learning Techniques for Cyber Security in the Last Decade. **Ieee Access**, v. 8, p. 222310-222354, 2020. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2020.3041951>.

SILVA, D. F. Da; GARCIA, P. H. De M; SANTOS, G. C. De L; FARIAS, I. M. S. C. De; PÁDUA, G. V. G. De; PEREIRA, P. H. B; SILVA, F. E. De; BATISTA, R. F; GONZAGA NETO, S; CABRAL, A. M. D. Características morfológicas, melhoramento genético e densidade de plantio das culturas do sorgo e do milho: uma revisão. **Research, Society and Development**, v. 10, n. 3, p. e12310313172, 2021. DOI: 10.33448/rsd-v10i3.13172.

SILVA, M. F; MACIEL, G. M; GALLIS, R. B. A; BARBOSA, R. L; VINICIUS, Q; REZENDE, W. S; SIQUIEROLI, A. C. S. High-throughput phenotyping by RGB and multispectral imaging analysis of genotypes in sweet corn. v. 40, n. 1, p. 92–98, 2022.

SILVA, W. de V. R. da; SILVA-MRNA, R. Agricultura de Precisão no Brasil: conjuntura atual, desafios e perspectivas. **Research, Society and Development**, v. 9, n. 11, p. e1979119603, 2020. DOI: 10.33448/rsd-v9i11.9603.

SISHODIA, R. P; RAY, R. L; SINGH, S. K. Applications of Remote Sensing in Precision Agriculture: a review. **Remote Sensing**, v. 12, n. 19, p. 3136, 24 set. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12193136>.

SOARES, F. C; ROBAINA, A. D; PEITER, M. X; RUSSI, J. L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, v. 45, n. 11, p. 1987-1993, nov. 2015. <http://dx.doi.org/10.1590/0103-8478cr20141524>.

SOOD, A; KUMAR, R. S; KUMAR, A. S. Artificial intelligence research in agriculture: a review. **Online information review: artificial intelligence in agriculture**, p. 01–22, 2021. DOI: <https://doi.org/10.1108/OIR-10-2020-0448>.

SOUZA, J. C. B; ALMEIDA, S. L. H; DE FILHO, A. L. de B; MONTELES, M. S; SILVA, L. B; SILVA, R. P. da. Uso de redes neurais para predição da maturação do amendoim com imagens de UAV. **South American Sciences Issn 2675-7222**, v. 2, n. 2, 30 set. 2021. South American Sciences. <http://dx.doi.org/10.52755/sas.v2iedesp2.129>.

SOUZA, W. LOPES, C. de; SILVA, L. G. da; SILVA, L. E. B; SILVA, R. L. V. da; LIMA, L. L. C; BRITO, D. R. Aspectos comparativos entre milho (*Zea mays* L.) e sorgo (*Sorghum bicolor* L. Moench): diferenças e semelhanças. **Diversitas Journal**, v. 5, n.4, p. 2337–2357, 2020. DOI: 10.17648/diversitas-journal-v5i4-891.

SRIDHARA, S; RAMESH, N; GOPAKKALI, P; DAS, B; VENKATAPPA, S; SANJIVIAIAH, S; SINGH, K. K; SINGH, P; EL-ANSARY, D; MAHMOUD, E; ELANSARY, H. O. Weather-Based Neural Network, Stepwise Linear and Sparse Regression Approach for Rabi Sorghum Yield Forecasting of Karnataka, India. **Agronomy**, v. 10, n. 11, p. 1645, 26 out. 2020. MDPI AG. <http://dx.doi.org/10.3390/agronomy10111645>.

SU, W; ZHANG, M; BIAN, D; LIU, Z; HUANG, J; WANG, W; WU, J; GUO, H. Phenotyping of Corn Plants Using Unmanned Aerial Vehicle (UAV) Images. **Remote Sensing**, v. 11, n. 17, p. 2021, 28 ago. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11172021>.

TOVAR BLANCO, A. L; LIZARAZO SALCEDO, I. A; RODRÍGUEZ ERASO, N. Estimación de biomasa aérea de *Eucalyptus grandis* y *Pinus* spp. usando imágenes Sentinel1A y Sentinel2A en Colombia. **Colombia forestal**, v. 23, n. 1, 2020. DOI: 10.14483/2256201X.14854. Disponível em: <https://revistas.udistrital.edu.co/index.php/colfor/article/view/14854>.

TRANSON, J; D'ANDRIMONT, R; MAUGNARD, A; DEFOURNY, P. Survey of hyperspectral Earth Observation applications from space in the Sentinel-2 context. **Remote Sensing**, v. 10, n. 2, p. 1–32, 2018. DOI: 10.3390/rs10020157.

TREVISAN, R. G; BULLOCK, D. S; MARTIN, N. F. Spatial variability of crop responses to agronomic inputs in on-farm precision experimentation. **Precision Agriculture**, v. 22, n. 2, p. 342-363, 7 maio 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-020-09720-8>.

TU, K; WEN, S; CHENG, Y; ZHANG, T; PAN, T; WANG, J; WANG, J; SUN, Q. A non-destructive and highly efficient model for detecting the genuineness of maize variety 'JINGKE 968' using machine vision combined with deep learning. **Computers and Electronics in Agriculture**, v. 182, n. February, p. 106002, 2021. <https://doi.org/10.1016/j.compag.2021.106002>.

- TUNCA, E; KOKSAL, E. S; TANER, S. Ç.. Silage maize yield estimation by using planetscope, sentinel-2A and landsat 8 OLI satellite images. **Smart Agricultural Technology**, v. 4, p. 100165, ago. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.atech.2022.100165>.
- VAN KLOMPENBURG, T; KASSAHUN, A; CATAL, C. Crop yield prediction using machine learning: a systematic literature review. **Computers And Electronics In Agriculture**, v. 177, p. 105709, out. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105709>.
- VIAN, A. L; BREDEMEIER, C; REGIS, P; DA, F; SANTI, A. L; PAZ, C; SILVA, D. A. Critical limits of ndvi for yield potential estimation in maize. April, 2018.
- VON PINHO, R. G; FIORINI, I. V. A; SANTOS, Á. de O. Botânica. In: BORÉM, A; PIMENTEL, L; PARRELLA, R. **Sorgo do plantio à colheita**. Viçosa: UFV, 2014. Cap. 2. p. 37-57.
- VONG, C. N; CONWAY, L. S; FENG, A; ZHOU, J; KITCHEN, N. R; SUDDUTH, K. A. Corn emergence uniformity estimation and mapping using UAV imagery and deep learning. **Computers And Electronics In Agriculture**, v. 198, p. 107008, jul. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2022.107008>.
- WEI, M. C. F; MOLIN, J. P. Soybean Yield Estimation and Its Components: a linear regression approach. **Agriculture**, v. 10, n. 8, p. 348, 11 ago. 2020. MDPI AG. <http://dx.doi.org/10.3390/agriculture10080348>.
- XU, X; FAN, L; LI, Z; MENG, Y; FENG, H; YANG, H; XU, B. Estimating Leaf Nitrogen Content in Corn Based on Information Fusion of Multiple-Sensor Imagery from UAV. **Remote Sensing**, v. 13, n. 3, p. 340, 20 jan. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13030340>.
- YANG, K. W; CHAPMAN, S; CUAVENTER, N; HAMMER, G; MCLEAN, G; ZHENG, B; CHEN, Y; DELP, E; MASJEDI, A; CRAWFORD, M; EBERT, D; HABIB, A; THOMPSON, A; WEIL, C; TUINSTRA, M. R. Integrating crop growth models with remote sensing for predicting biomass yield of sorghum. **In Silico Plants**, v. 3, n. 1, jan. 2021. Oxford University Press (OUP). <http://dx.doi.org/10.1093/insilicoplants/diab001>.
- YANG, W; NIGON, T; HAO, Z; PAIAO, G. D; FERNÁNDEZ, F. G; MULLA, D; YANG, C. Estimation of corn yield based on hyperspectral imagery and convolutional neural network. **Computers And Electronics In Agriculture**, v. 184, p. 106092, maio 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106092>.
- YETURU, K. Machine learning algorithms, applications, and practices in data science. **Handbook Of Statistics**, p. 81-206, 2020. Elsevier. <http://dx.doi.org/10.1016/bs.host.2020.01.002>.
- YU, H; XIE, T; PASZCZYNSKI, S; WILAMOWSKI, B. M. Advantages of radial basics function networks for dynamic system design. **IEEE Transactions on industrial electronics**, v. 58, n. 12, 2011. DOI: 10.1109/tie.2011.2164773.
- ZANNOU, J. G. N; HOUNJJI, V. R. Sorghum Yield Prediction using Machine Learning. **2019 3Rd International Conference On Bio-Engineering For Smart Technologies (Biosmart)**, abr. 2019. IEEE. <http://dx.doi.org/10.1109/biosmart.2019.8734219>.

ZHA, H; MIAO, Y; WANG, T; LI, Y; ZHANG, J; SUN, W; FENG, Z; KUSNIEREK, K. Improving Unmanned Aerial Vehicle Remote Sensing-Based Rice Nitrogen Nutrition Index Prediction with Machine Learning. **Remote Sensing**, v. 12, n. 2, p. 215, 8 jan. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12020215>.

ZHANG, B; XIE, Y; ZHOU, J; WANG, K; ZHANG, Z. State-of-the-art robotic grippers, grasping and control strategies, as well as their applications in agricultural robots: a review. **Computers And Electronics In Agriculture**, v. 177, p. 105694, out. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105694>.

ZHANG, H; BAUTERS, M; BOECKX, P; VAN OOST, K. Mapping Canopy Heights in Dense Tropical Forests Using Low-Cost UAV-Derived Photogrammetric Point Clouds and Machine Learning Approaches. **Remote Sensing**, v. 13, n. 18, p. 3777, 20 set. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13183777>.

ZHANG, L; LIU, Z; REN, T; LIU, D; MA, Z; TONG, L; ZHANG, C; ZHOU, T; ZHANG, X; LI, S. Identification of Seed Maize Fields With High Spatial Resolution and Multiple Spectral Remote Sensing Using Random Forest Classifier. **Remote Sensing**, v. 12, n. 3, p. 362, 22 jan. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12030362>.

ZHANG, Z; ZHU, L. A Review on Unmanned Aerial Vehicle Remote Sensing: platforms, sensors, data processing methods, and applications. **Drones**, v. 7, n. 6, p. 398, 15 jun. 2023. MDPI AG. <http://dx.doi.org/10.3390/drones7060398>.

ZUALKERNAN, I; ABUHANI, D. A; HUSSAIN, M. H; KHAN, J; ELMOHANDES, M. Machine Learning for Precision Agriculture Using Imagery from Unmanned Aerial Vehicles (UAVs): a survey. **Drones**, v. 7, n. 6, p. 382, 6 jun. 2023. MDPI AG. <http://dx.doi.org/10.3390/drones7060382>.

## **CAPÍTULO 2 SENSORIAMENTO REMOTO E REDES NEURAIIS PARA ESTIMAR A PRODUTIVIDADE DE SORGO GRANÍFERO EM CONDIÇÕES TROPICAIS**

### **RESUMO**

O uso de aprendizado de máquina e sensoriamento remoto para a estimativa da produtividade tem recebido destaque nos últimos anos. Nesse sentido, foram utilizados elevação do terreno e índices de vegetação extraídos em quatro épocas aos 30, 60, 90 e 120 dias após semeadura (DAS), para verificar o potencial de Rede Neural Artificial (RNA) na estimativa de produtividade de grãos de sorgo em condições tropicais. E definir a melhor época para estimar a produtividade em campo. Foram desenvolvidos dez modelos de RNA com arquitetura Multilayer Perceptron e implementado com a biblioteca Keras para estimar a produtividade de sorgo com índices de vegetação e elevação do terreno como entrada para a RNA. Os índices de vegetação CIgreen, SR, VARI, WDRVI e elevação do terreno tiveram melhor resultado (modelo M2), com  $R^2 = 0,89$  e  $RMSE = 0,22 \text{ t ha}^{-1}$  aos 30 DAS. Obteve-se boa correlação ( $r = 0,95$ ) entre a produtividade observada e a estimada pelos modelos aos 30 DAS, demonstrando que nesse estágio inicial é o mais adequado para realizar a estimativa de produtividade na cultura do sorgo, auxiliando a tomada de decisões no sistema de produção agrícola.

**Palavras-chave:** Inteligência Artificial. Multilayer Perceptron. Índice de vegetação. Elevação do terreno.



## ABSTRACT

The use of machine learning and remote sensing to estimate productivity has received attention in recent years. In this sense, terrain elevation and vegetation indices extracted in four times at 30, 60, 90 and 120 days after sowing (DAS) were used to verify the potential of Artificial Neural Network (ANN) in estimating sorghum grain productivity in tropical conditions. And define the best time to estimate productivity in the field. Ten ANN models were developed with Multilayer Perceptron architecture and implemented with the Keras library to estimate sorghum productivity with vegetation indices and terrain elevation as input to the ANN. The CIGreen, SR, VARI, WDRVI vegetation indices and land elevation had the best result (M2 model), with  $R^2 = 0.89$  and  $RMSE = 0.22 \text{ t ha}^{-1}$  at 30 DAS. A good correlation ( $r = 0.95$ ) was obtained between the productivity observed and that estimated by the models at 30 DAS, demonstrating that this initial stage is the most suitable for estimating productivity in the sorghum crop, helping decision-making in the agricultural production system.

**Keywords:** Artificial Intelligence. Multilayer Perceptron. Vegetation index. Land elevation.

## 1 INTRODUÇÃO

As técnicas de aprendizado de máquina utilizadas no monitoramento e estimativa de produtividade das culturas tem um impacto significativo na segurança alimentar mundial e desempenha um papel essencial nos mercados, políticas e tomadas de decisão nacionais e internacionais (MURUGANANTHAM et al., 2022). Para alcançar uma produção agrícola sustentável, o setor agrícola precisa empregar tecnologias como o sensoriamento remoto (JUNG et al., 2021; LI et al., 2022), inteligência artificial (ENGEN et al., 2021; SOUZA et al., 2022) e big data (BHAT; HUANG, 2021), fornecendo informações em larga escala e com precisão.

Monitorar e estimar a produtividade (MAZIS et al., 2020) é uma prática comum e geralmente realizada por observação manual e visitas in loco, mas, na maioria das vezes, estimar a produtividade da cultura no nível de campo tem sido trabalhoso, exigem muito tempo e difíceis de usar para fornecer informações sobre a variabilidade espacial da produtividade da cultura (LI et al., 2022). Grãos de cereais, como trigo, soja, milho e arroz são as principais culturas alimentares produzidas, mas sensíveis as mudanças climáticas. O sorgo é o quinto grão mais produzido no mundo e uma cultura resiliente e adaptabilidade às adversidades climáticas (MUNDIA et al., 2019). Em condições tropicas as temperaturas mais altas afetam a eficiência fotossintética da planta, diminuindo seu ciclo e reduz valor nutritivo dos grãos (CHADALAVADA et al., 2021). O que torna essencial obter informações confiáveis sobre a produtividade da cultura do sorgo para uma tomada de decisão efetiva.

O Sensoriamento Remoto (SR) pode ser usado para superar essas limitações e realizar estimativas em larga escala. Integradas com técnicas de aprendizado de máquina (ML), tem sido utilizada para lidar com o desafio de monitorar as culturas. Os algoritmos de ML permitem análise de grande volume de dados obtidos do SR, independente da complexibilidade, com rapidez e precisão (GARCÍA-MARTINEZ et al., 2020; OLIVEIRA et al., 2021; ROZNIK et al., 2022; SCHWALBERT et al., 2020).

Recentemente, estão sendo aplicados na agricultura para fornecer estimativa antecipada sobre a produtividade das culturas com base em vários fatores (ENGEN et al., 2021), promover estimativa da produtividade de grãos de milho e soja através de imagens orbitais de alta resolução (LI et al., 2022; SKAKUN et al., 2021), monitorar a variabilidade do campo de produção (KAYAD et al., 2019), aplicar redes neurais do tipo MLP e RBF para estimar a maturidade (SOUZA et al., 2022), estimar a biomassa com plataforma UAV e

imagens multiespectrais (BURNS et al., 2022; SHENDRYK et al., 2020), estimativa de produtividade em tempo real no trigo (LIAO et al., 2022), na cultura do feijão (JI et al., 2023), da batata-doce (TEDESCO et al., 2021).

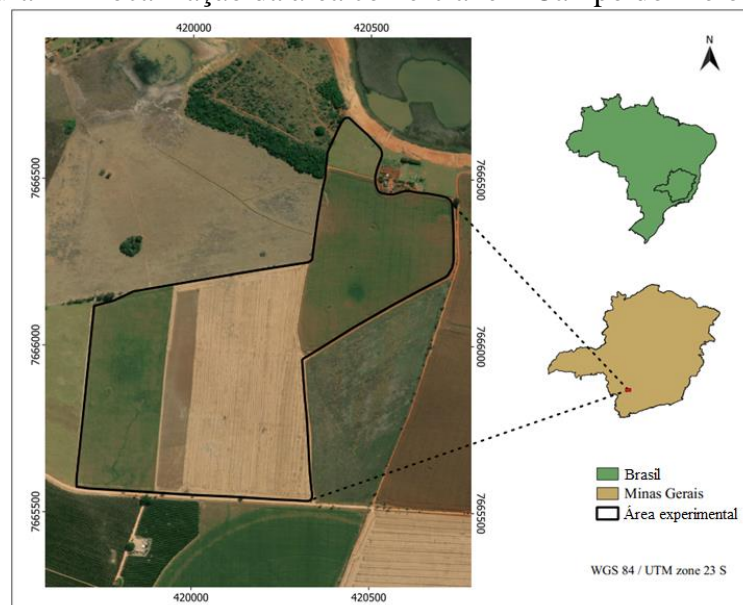
É importante que agricultores e pesquisadores continuem a adotar soluções inovadoras para o manejo de colheitas e alimentação da crescente população mundial. Neste estudo, dados reais de produtividade de sorgo de colhedoras em nível de campo, assim como imagens do satélite PlanetScope foram obtidos para a estimativa de produtividade de sorgo baseados em rede neural artificial. Assim, os objetivos deste estudo: (1) verificar o potencial de rede neural para estimar a produtividade de sorgo em condições tropicais, (2) indicar qual a melhor época para estimar a produtividade em campo por meio de índices de vegetação e elevação do terreno.

## 2 MATERIAL E MÉTODOS

### 2.1 Área de estudo

A área experimental de 56,7 hectares utilizada, está localizada em Campo do Meio, Minas Gerais, Brasil (FIGURA 1) ( $21^{\circ}6'18''$  S,  $45^{\circ}46'7''$  W). A região possui clima caracterizada como subtropical com invernos secos e verão quente (KOPPEN, 1928) e altitude média de 780 m. Neste estudo foram utilizados dados provenientes de duas safras agrícolas (2019, 2020) da cultura do sorgo (*Sorghum bicolor* L. Moench).

Figura 1 – Localização da área comercial em Campo do Meio, MG.



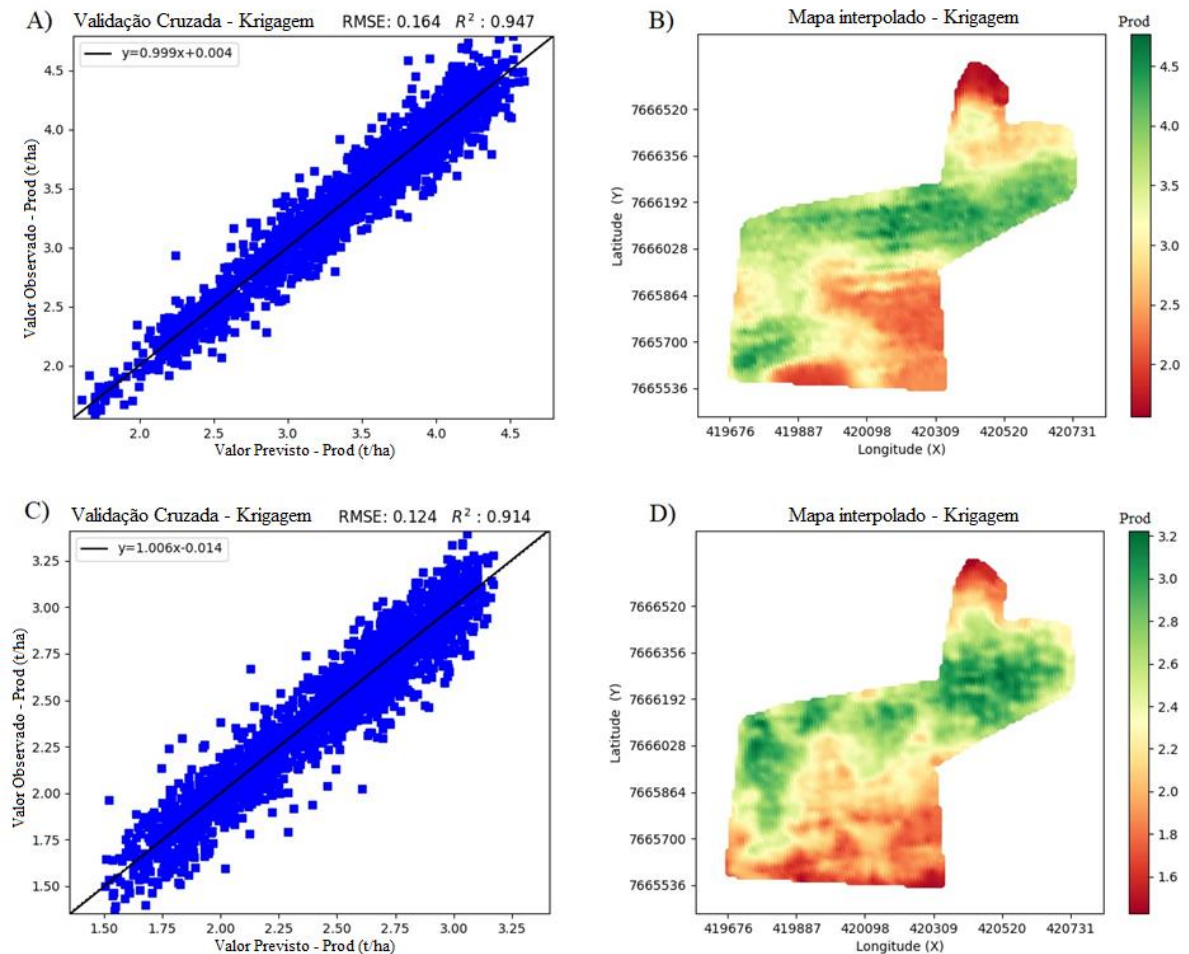
Fonte: Do autor (2023).

## 2.2 Coleta e pré-processamento de dados

Os dados de produtividade e topográfico foram obtidos por uma colhedora John Deere S540 equipada com monitor GS3, na qual gera mapas de produtividade ( $t\ ha^{-1}$ ) e de elevação (metros) através do posicionamento do sistema GNSS, sendo esse configurado um ponto a cada 3 segundos. Em março de 2019 a semeadura foi realizada utilizando a cultivar de sorgo granífero AS 4650, em abril de 2020 a semeadura foi realizada com a cultivar AS 4639, ambas de ciclo precoce. Em ambos os anos adotou espaçamento 70 cm e população de 200 mil plantas por hectare. Inicialmente os dados de produtividade de grãos foram corrigidos para 13% de umidade, no software QGIS 3.22 (QGIS Development Team, Trondheim, Norway, 2022).

Considerando que os mapas de produtividade gerados pela colhedora apresentam dados oriundos de erros operacionais e descalibração de sensores, procedeu com a filtragem do conjunto de dados através do software MapFilter conforme descrito por Maldaner e Molin (2022). Após filtragem, foi gerado mapa de produtividade a partir da interpolação dos pontos usando plugin SmartMap (PEREIRA et al., 2022). Cada mapa foi gerado usando o método de krigagem ordinária com resolução espacial de 10 m x 10 m. O ajuste dos parâmetros do semivariograma levou em consideração a variabilidade espacial dos dados, visando baixos valores da raiz do erro quadrado médio (RMSE) e valores próximos de 1 para o coeficiente de determinação ( $R^2$ ), seguido da validação cruzada para obter o melhor ajuste do modelo (FIGURA 2).

Figura 2 – Resultado da validação cruzada por krigagem (A e C) e mapa interpolado utilizando resolução de 10 x 10 m para 2019 (B) e 2020 (D), respectivamente.



Fonte: Do autor (2023).

### 2.3 Aquisição das imagens orbitais

Foram utilizados dados obtidos pelo sensor da plataforma PlanetScope CubeSat (Planet Labs Inc., California, United States) para as imagens de satélite. O PlanetScope é uma constelação de satélites constituída de diferentes tipos de sensores orbitais com alta resolução espacial e temporal. O PlanetScope possui mais de 130 satélites DOVE em órbita solar, possibilitando a coleta de dados diários em qualquer lugar do planeta com resolução espacial de 3 a 5 m e possuem quatro bandas espectrais: Azul (465-515 nm), Verde (547-586 nm), Vermelho (650-680 nm) e Infravermelho próximo (NIR) (845-885 nm) (ESA, 2023).

Para correção de imagem, a plataforma disponibiliza o produto PlanetScope Analytic Ortho Scene Surface Reflectance (SR – Nível 3B). Este produto é ortorretificado para todas as cenas, pode apresentar quatro ou oito bandas com imagens corrigidas geometricamente, radiometricamente, projetadas para projeção Universal Traverse Mercator (UTM) e calibradas

para o topo da radiação atmosférica, o que proporciona melhor qualidade na resposta espectral. As cenas são entregues como produtos visuais, radiação e reflectância de superfície (PLANET, 2023).

Foram utilizadas imagens do PlanetScope referentes aos 30, 60, 90 e 120 dias após a semeadura do sorgo (DAS) com intervalo de até dois dias. As datas foram definidas com base nos principais eventos fenológicos da cultura como estabelecimento da cultura (30 DAS), período de florescimento (60 DAS), enchimento de grãos (90 DAS) e maturidade fisiológica (120 DAS). Todas as imagens coletadas foram projetadas em WGS84-UTM zone 23S.

## 2.4 Índices de Vegetação (IVs)

Foram calculados seis IVs usando os dados de satélite (TABELA 1). Os valores médios dos IVs foram utilizados como entradas para criar os modelos e, conseqüentemente, verificar o potencial dos IVs para estimar a produtividade do sorgo no campo. Esses índices foram propostos porque são ferramentas promissoras na estimativa de parâmetros agrônômicos e comumente relacionados à biomassa da vegetação em diversas culturas.

Tabela 1 – Índices de Vegetação (IVs) para imagens de satélite.

IVs	Equação	Referências
<b>CIgreen</b>	$\left(\frac{NIR}{Verde}\right) - 1$	(GITELSON et al., 2003)
<b>GNDVI</b>	$\frac{(NIR - Verde)}{(NIR + Verde)}$	(GITELSON et al., 1996)
<b>NDVI</b>	$\frac{(NIR - Vermelho)}{(NIR + Vermelho)}$	(ROUSE et al., 1974)
<b>SR</b>	$\frac{NIR}{Vermelho}$	(JORDAN, 1969)
<b>VARI</b>	$\frac{(Verde - Vermelho)}{(Verde + Vermelho - Azul)}$	(GITELSON et al., 2002)
<b>WDRVI</b>	$\frac{(a * NIR - Vermelho)}{(a * NIR + Vermelho)}$	(GITELSON, 2004)

CIgreen: Índice da Clorofila; NDVI: Índice de Vegetação por Diferença Normalizada; GNDVI: Índice de Vegetação por Diferença Normalizada Verde; SR: Razão Simples; VARI: Índice Resistente à Atmosfera na Região do Visível; WDRVI: Índice de Vegetação Dinâmico de Amplo Alcance; \*a = 0,05 (Coeficiente de ponderação).

Fonte: Do autor, 2023.

## **2.5 Extração dos Índices de Vegetação e Produtividade**

No QGIS 3.22, foi gerado uma grade amostral para obtenção do valor médio de produtividade, elevação do terreno e índices de vegetação. O tamanho da grade adotado foi de 10 m x 10 m (100 m<sup>2</sup>) e um buffer de raio de 1 m, para minimizar os efeitos de sobreposição de pixels entre as grades, especialmente na extração de IV. Posteriormente, extraiu o valor médio de cada grade, obtendo 5600 pontos por data (30, 60, 90 e 120 DAS).

## **2.6 Análise dos dados**

### **2.6.1 Divisão dos dados para treinamento e teste da rede neural**

O treinamento da rede neural requer uma quantidade suficiente de dados para alcançar uma alta confiabilidade (SOUZA et al., 2022). Assim, foi utilizada a técnica de validação cruzada K-fold, que dividiu os dados aleatoriamente em K subconjuntos de tamanho igual (PHINZI et al., 2021). O modelo foi treinado em subconjuntos K-1 e testado no subconjunto restante. Este processo foi repetido K vezes (cinco), com cada subconjunto sendo usado como conjunto de teste exatamente uma vez.

A vantagem de usar a validação cruzada K-fold é a possibilidade de estimativa mais precisa do desempenho do modelo, pois usa todos os dados para treinamento e teste. Essa abordagem pode ajudar a reduzir o risco de overfitting, em que um modelo é muito complexo e se ajusta muito perto aos dados de treinamento, resultando em baixo desempenho em dados novos e não vistos. Essa técnica ajuda a garantir que o desempenho do modelo seja avaliado em uma amostra representativa dos dados e pode ajudar a identificar possíveis problemas com a capacidade de generalização do modelo (JAMES et al., 2013).

### **2.6.2 Desenvolvimento da Rede Neural Artificial**

Neste trabalho técnicas de modelagem de dados foram realizadas na qual um modelo de Rede Neural Artificial (RNA) com arquitetura Multilayer Perceptron (MLP), foi usado para estimar a produtividade do sorgo usando índices de vegetação e elevação do terreno. Foi implementado o Keras, uma biblioteca de rede neural escrita in Python 3.9 que fornece uma interface simplificada para definir, treinar e avaliar modelos complexos de RNA. Além disso, o Keras possui flexibilidade e compatibilidade com bibliotecas comuns de aprendizado de máquina, tornando-se ideal para o desenvolvimento de RNA em pesquisas científicas (CHOLLET, 2015; KERAS, 2015).

As Interfaces de Programação de Aplicativos (APIs) Keras oferece várias arquiteturas de rede neural predefinidas, como APIs Sequencial, que permite criar uma arquitetura MLP. As camadas adotadas foram do tipo Dense, na qual cada neurônio da camada está conectado a todos os neurônios da camada anterior e subsequente (KIM et al., 2022; YASHWANTH et al., 2020).

### **2.6.3 Arquitetura da rede neural**

A arquitetura da RNA foi elaborada para desenvolver um modelo de estimativa para produtividade do sorgo a campo, a partir de seis índices de vegetação, elevação do terreno e dois anos agrícolas. No presente estudo, a rede neural construída foi composta por três camadas densas. A primeira camada densa possui 24 neurônios com função de ativação Unidade Linear Retificada (ReLU), enquanto a segunda camada densa apresenta 30 neurônios com função de ativação ReLU e a terceira camada referente à saída, composta por 1 neurônio e função de ativação Linear. A dimensão de entrada para a primeira camada densa corresponde ao número de feições nos dados de entrada.

Os hiperparâmetros (TABELA 2) são configurações em uma rede neural que controlam seu comportamento de aprendizado, definidos antes do treinamento e permanecem fixas durante todo o processo de treinamento e podem impactar significativamente no desempenho da rede neural. Assim, alguns hiperparâmetros foram definidos no presente estudo. A função de perda de regressão usada foi a erro quadrático médio (MSE) entre as observações e previsões. O otimizador usado foi Estimativa de Momento Adaptativo (Adam) baseado na estimativa adaptativa de momentos de primeira e segunda ordem, com taxa de aprendizado de 0,01, algoritmo comumente utilizado para redes neurais. Assim como Kingma et al. (2014), esse método foi usado devido sua eficiência, requer pouca memória e adequado para resolução de problemas complexos e com banco de dados extensos. O algoritmo Adam é um otimizador mais avançado que pode ajustar de forma adaptativa a taxa de aprendizado durante o treinamento (KHAKI; WANG, 2019; SER; BATI, 2019). Ele calcula as taxas de aprendizado individuais para cada parâmetro com base nas estimativas do primeiro e segundo momentos dos gradientes. Isso pode levar a uma convergência mais rápida e a melhores resultados do que o Descida de Gradiente Estocástico (SGD).



Tabela 2 – Hiperparâmetros para desenvolvimento da rede neural artificial.

<b>Hiperparâmetros</b>	<b>Valor</b>
<b>Camadas ocultas</b>	3
<b>Neurônios por camada</b>	24-30-1
<b>Função de ativação</b>	ReLU
<b>Número de épocas</b>	90
<b>Otimizador</b>	Adam
<b>Taxa de aprendizado</b>	0,01
<b>Função de perda</b>	MSE

ReLU: Unidade Linear Retificada; Adam: Estimativa de Momento Adaptativo; MSE: Erro Quadrático Médio.

Fonte: Do autor (2023).

O número de épocas é o número de vezes que o modelo realiza interações em todo o conjunto de dados de treinamento durante o processo, dessa forma, foi determinado 90 épocas para o treinamento da rede. Também foi implementado na rede a parada antecipada, em 0,01, na qual o treinamento é interrompido se a métrica MSE monitorada não melhorar, permitindo a rede convergir com maior eficiência.

A estrutura da rede neural, algoritmo de treinamento e os hiperparâmetros associados foram ajustados para selecionar o melhor desempenho, com base na minimização MSE. Para as entradas foram determinadas algumas interações entre os índices de vegetação e elevação do terreno. Enquanto para saída foi a produtividade prevista ( $t\ ha^{-1}$ ). A combinação de cada modelo foi definida a partir da seleção aleatória dos IVs e os dez modelos com melhor desempenho ( $R^2 > 0,60$  e  $RMSE < 0,35$ ) foram utilizados para estimar a produtividade de sorgo (TABELA 3).

Tabela 3 – Modelos e combinações entre as variáveis de entrada.

<b>Modelo</b>	<b>Variáveis</b>
<b>M1</b>	Todos IVs + Elevação do terreno
<b>M2</b>	CIgreen + SR + VARI + WDRVI + Elevação do terreno
<b>M3</b>	CIgreen + SR + VARI + Elevação do terreno
<b>M4</b>	GNDVI + NDVI + WDRVI + Elevação do terreno
<b>M5</b>	CIgreen + GNDVI + VARI + Elevação do terreno
<b>M6</b>	CIgreen + GNDVI + NDVI + Elevação do terreno
<b>M7</b>	CIgreen + NDVI + VARI + Elevação do terreno
<b>M8</b>	GNDVI + NDVI + VARI + Elevação do terreno
<b>M9</b>	CIgreen + SR + WDRVI + Elevação do terreno
<b>M10</b>	CIgreen + GNDVI + NDVI + WDRVI + Elevação do terreno

Fonte: Do autor (2023).

#### 2.6.4 Pré-processamento dos parâmetros de entrada

A normalização de dados é um processo de transformação dos dados que apresentem valores muito discrepantes entre uma variável e outra. O objetivo é garantir que todas as variáveis tenham a mesma escala e distribuição de valores, contribuindo igualmente para o desenvolvimento do modelo, minimizando o domínio entre variáveis. Assim, foi realizado a transformação dos dados para média zero e desvio padrão 1, através do método StandardScaler da biblioteca Scikit-learn. Esse redimensionamento dos valores entre 0 e 1, melhora o desempenho de algoritmos de otimização Adam (PEDREGOSA et al., 2011; SCIKIT-LEARN, 2011; ZAMRI et al., 2022).

#### 2.6.5 Métricas para avaliação do modelo de rede neural

O desempenho dos modelos foi avaliado com base em duas abordagens estatísticas, RMSE e  $R^2$ , conforme as equações 2 e 3, respectivamente. Essas métricas certificam a confiabilidade dos dados obtidos através das estimativas das variáveis. Além disso, foi realizado uma análise de correlação de Pearson ( $p < 0,05$ ) entre os valores observados e estimados de produtividade de grãos.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \quad (2)$$

$$R^2 = \frac{SQR}{SQT} \quad (3)$$

### 3 RESULTADOS

#### 3.1 Comparação entre os modelos

Os modelos com valores de  $R^2$  menores que 0,60 e RMSE maiores que 0,35 foram descartados. Entre todas as variáveis de entrada testadas para a plataforma do satélite PlanetScope, a maior precisão ( $R^2 = 0,84$  e  $RMSE = 0,15 \text{ t ha}^{-1}$ ) foi quando utilizou o modelo M3, combinação entre os índices de vegetação CIgreen, SR, VARI e elevação do terreno aos 120 DAS de 2020. Para o M9 aos 30 DAS de 2019 foi encontrado um nível de precisão semelhante ( $R^2 = 0,82$  e  $RMSE = 0,27 \text{ t ha}^{-1}$ ), mas com uma combinação diferente entre IVs (CIgreen-WDRVI-SR) e elevação do terreno. Por outro lado, o M3 e M9 aos 90 DAS de 2019 tiveram uma precisão ( $R^2$ ) de 0,64 e 0,62, respectivamente.

Também foi feito a união dos dados de 2019 com 2020, aumentando a quantidade de amostras para o treinamento da RNA. O M3 novamente apresentou o melhor desempenho para 60, 90 e 120 DAS. Em contrapartida, o M2 foi o melhor para 30 DAS ( $R^2 = 0,89$  e  $RMSE = 0,22 \text{ t ha}^{-1}$ ) e isso pode ter sido influenciado pelo arranjo dos índices de vegetação CIgreen, SR, VARI, WDRVI e elevação do terreno.

Nesta pesquisa, os modelos de RNA desenvolvidos expõem boa acurácia e precisão para estimar a produtividade da cultura do sorgo utilizando sensoriamento remoto orbital combinados com dados de elevação do terreno proveniente da colhedora. Baseado na acurácia e precisão, o M9 apresentou melhor desempenho do que os demais nos períodos de 30 e 60 DAS dos anos 2019 e 2020, enquanto M3 teve melhor resultado aos 90 e 120 DAS de 2019 e 2020. Já para união dos dados, o M2 foi o melhor resultado para 30 DAS e M3 para demais dias após semeadura (TABELA 4).

Tabela 4 – Precisão ( $R^2$ ) e acurácia (RMSE) de treinamento e teste dos modelos M2, M3 e M9 para estimativa de produtividade de sorgo.

Modelo	DAS	ANO	Estrutura da RNA	Treinamento		Teste	
				RMSE (t ha <sup>-1</sup> )	R <sup>2</sup>	RMSE (t ha <sup>-1</sup> )	R <sup>2</sup>
M2	30	2019 + 2020		0.23	0.88	0.22	0.89
M3	60	2019 + 2020		0.28	0.82	0.28	0.82
M3	90	2019 + 2020		0.29	0.80	0.29	0.81
M3	120	2019 + 2020		0.27	0.83	0.25	0.85
M3	90	2019		0.36	0.64	0.35	0.64
M3	90	2020	24:30:1	0.18	0.76	0.18	0.76
M3	120	2019		0.34	0.68	0.33	0.71
M3	120	2020		0.15	0.83	0.15	0.84
M9	30	2019		0.26	0.82	0.27	0.82
M9	30	2020		0.16	0.80	0.16	0.81
M9	60	2019		0.34	0.67	0.35	0.66
M9	60	2020		0.18	0.75	0.17	0.75

Fonte: Do autor (2023).

### 3.2 Correlação entre os valores observados e estimados de produtividade

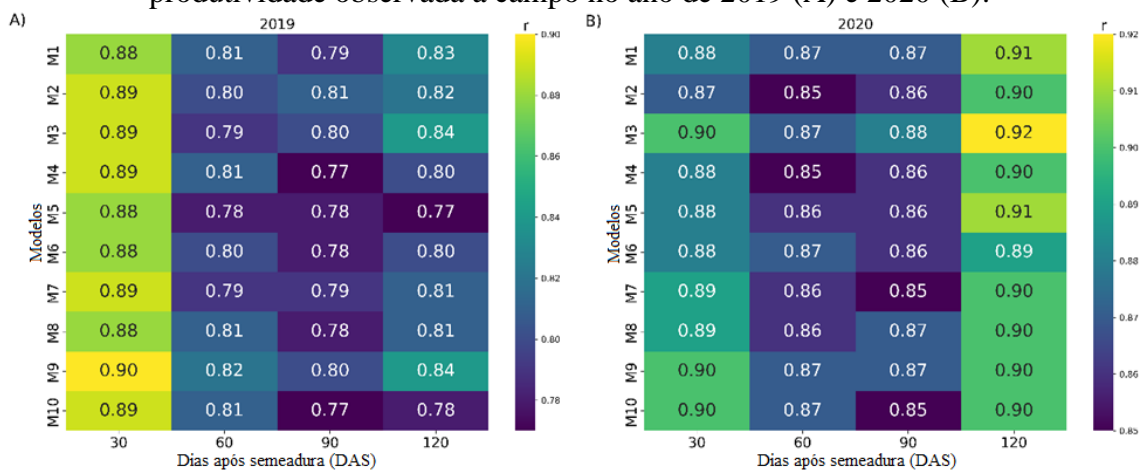
A análise de correlação de Pearson ( $r$ ) foi realizada entre a produtividade estimada pelos modelos e a produtividade observada de sorgo em cada época (FIGURA 3). Todas as combinações apresentaram correlação significativa e positiva com a produtividade estimada de sorgo ( $p < 0,05$ ), principalmente aos 30 e 120 DAS. O  $r$  variou de 0,78 a 0,90 no ano 2019 (A) e no ano 2020 (B) o  $r$  variou de 0,85 a 0,92 (FIGURA 3). E para a união dos dados, o  $r$  variou de 0,88 a 0,95 (FIGURA 4).

Os valores de correlação foram diferentes entre os anos, isso pode ser consequência da cultivar AS 4639 usada em 2020. A cultivar de sorgo AS 4639 apresenta dry-down rápido após a maturidade fisiológica, o que resulta em folhas mais reflexivas nas regiões visíveis e próximas do infravermelho do espectro eletromagnético. As maiores correlações ocorreram aos 30 e 120 DAS, destacando o M9 ( $r = 0,90$ ) e M3 ( $r = 0,92$ ) nos anos 2019 e 2020

respectivamente. Bem como para a união dos anos em que M2 aos 30 DAS teve maior precisão ( $r = 0,95$ ).


No geral, a análise de correlação apresentou que aos 30 e 120 DAS são melhores na estimativa de produtividade de sorgo. Com base na análise de exatidão e precisão, os melhores modelos para estimar produtividade são encontrados quando os índices de vegetação CIGreen, VARI, WDRVI, SR e elevação do terreno são usados como parâmetros de entrada no RNA.

Figura 3 – Correlação de Pearson ( $r$ ) entre a produtividade estimada pelos modelos e produtividade observada a campo no ano de 2019 (A) e 2020 (B).



Fonte: Do autor (2023).

Figura 4 – Correlação de Pearson ( $r$ ) entre a produtividade estimada pelos modelos e produtividade observada a campo para a união dos anos 2019 e 2020.

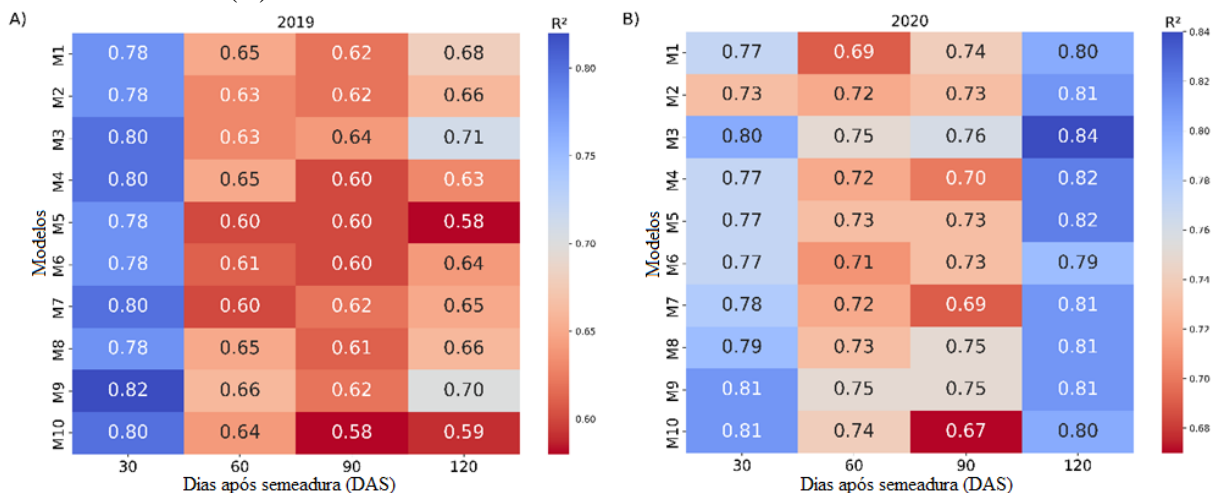


Fonte: Do autor (2023).

### 3.3 Desempenho da rede neural artificial

Dez modelos foram utilizados cada um com um arranjo entre os IVs e elevação do terreno e esses foram selecionados considerando os valores de RMSE e  $R^2$  na etapa de validação (FIGURAS 5 e 6). A estrutura de RNA utilizada foi composta por três camadas ocultas, na qual a primeira camada apresentava 24 neurônios, segunda camada com 30 neurônios e a camada de saída com 1 neurônio. Os modelos M9 e M3 apresentaram melhor desempenho, apontando que os índices de vegetação CIgreen, VARI, WDRVI, SR e elevação do terreno podem ser variáveis eficientes para o desenvolvimento de uma RNA capaz de estimar a produtividade de sorgo, auxiliando o produtor na tomada de decisão e monitoramento da lavoura.

Figura 5 – Coeficiente de determinação ( $R^2$ ) dos modelos de RNA para os anos 2019 (A) e 2020 (B).




Fonte: Do autor (2023).

Dentre os quatro períodos (30, 60, 90 e 120 DAS) o M9 e M3 foram os modelos que se destacaram com base na acurácia e precisão. Para o M9 aos 30 e 60 DAS foi onde a performance do modelo foi melhor, com valores de  $R^2 = 0,82$  e  $0,75$ , respectivamente. Por outro lado, o M3 que também apresentou resultados similares, obteve melhor desempenho aos 90 e 120 DAS ( $R^2 = 0,76$  e  $0,84$ , respectivamente). Apesar dos modelos serem diferentes, esses resultados sugerem que em estádios de desenvolvimento mais iniciais (30 e 60 DAS), o modelo que utiliza como entrada o WDRVI é mais indicado para estimativa da produtividade de sorgo em regiões tropicais. Por outro lado, quando as plantas já estão em estádios mais

avanzados (90 e 120 DAS), modelo que tem como entrada o VARI apresenta melhor performance.

Para os dados que reúne as duas safras (2019 e 2020) o M2 obteve melhor desempenho ( $R^2 = 0,89$ ) aos 30 DAS enquanto o M3 apresentou melhor desempenho aos 120 DAS ( $R^2 = 0,85$ ) (FIGURA 6). Assim, a quantidade de dados pode ajudar a melhorar a acurácia e precisão de uma RNA devido a maior obtenção de informações e padrões, permitindo que a rede aprenda e generalize melhor. Além disso, as imagens de alta resolução temporal do PlanetScope (ROY et al., 2021), pode ter influenciado no bom desempenho dos modelos na estimativa de produtividade.

Figura 6 – Coeficiente de determinação ( $R^2$ ) dos modelos de RNA para o conjunto de dados dos dois anos agrícolas.



Fonte: Do autor (2023).

### 3.4 Validação do modelo

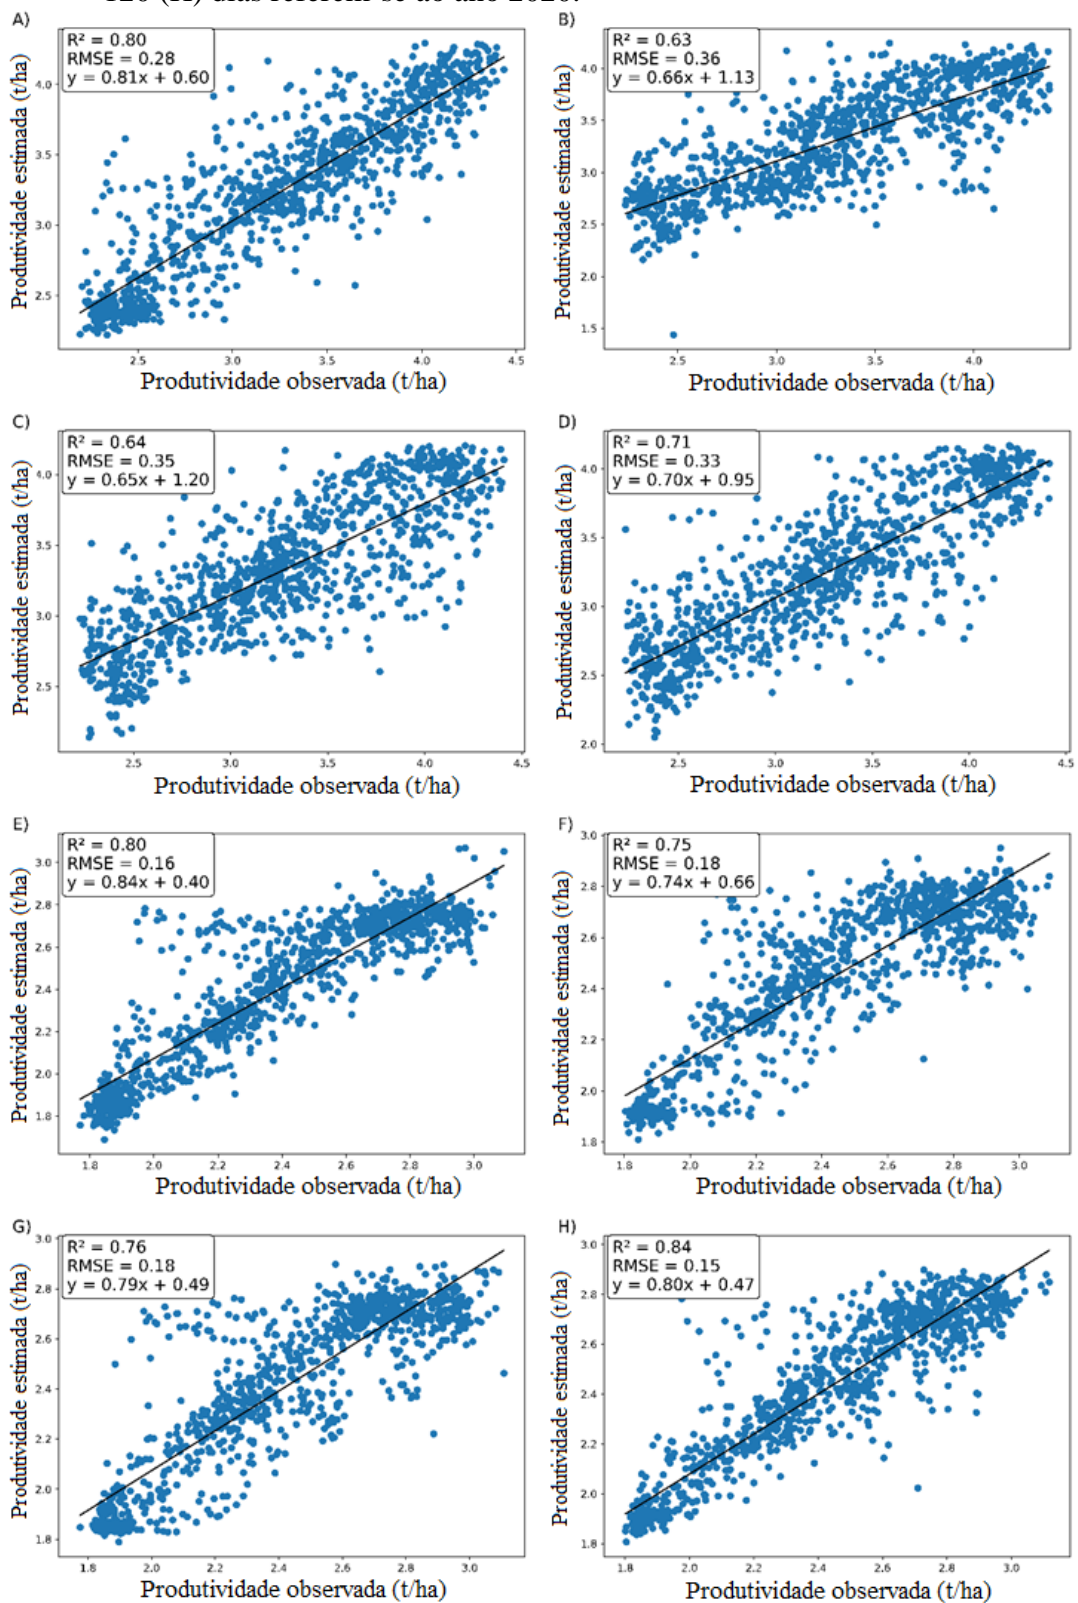
O desempenho dos modelos em cada estágio de crescimento e para o conjunto de dados de 2019 e 2020, aponta que os modelos M3 e M9 são semelhantes para estimar a produtividade da cultura do sorgo (FIGURAS 7, 8 e 9). O modelo M9 foi apontado como o melhor aos 30 e 60 DAS, enquanto M3 para 90 e 120 DAS dos anos 2019 e 2020. Assim, quando usado o conjunto de dados dos dois anos, o M2 teve bom desempenho aos 30 DAS e M3 para demais DAS. Vale ressaltar que aos 120 DAS de 2020 foram observados aumentos

significativos em  $R^2$  em todos os modelos de estimativa de produtividade, com valores de RMSE de 0,15 a 0,16 t ha<sup>-1</sup> de sorgo.

Da mesma forma, foi observado que para o conjunto de dados dos dois anos, que aos 30 DAS teve os valores de  $R^2$  mais altos e RMSE mais baixos para M2 e M3. O momento para estimar a produtividade de sorgo foi mais cedo, no início de desenvolvimento da cultura, o que pode ser influenciado por diversos fatores até o final do ciclo. Além disso, estimar a produtividade aos 30 DAS é um grande desafio porque a cultura ainda está em seus estágios iniciais de crescimento. Os valores de produtividade previstos foram linearmente correlacionados com os valores de produtividade observados, destacando a relação consistente dos dados aos 30 DAS.

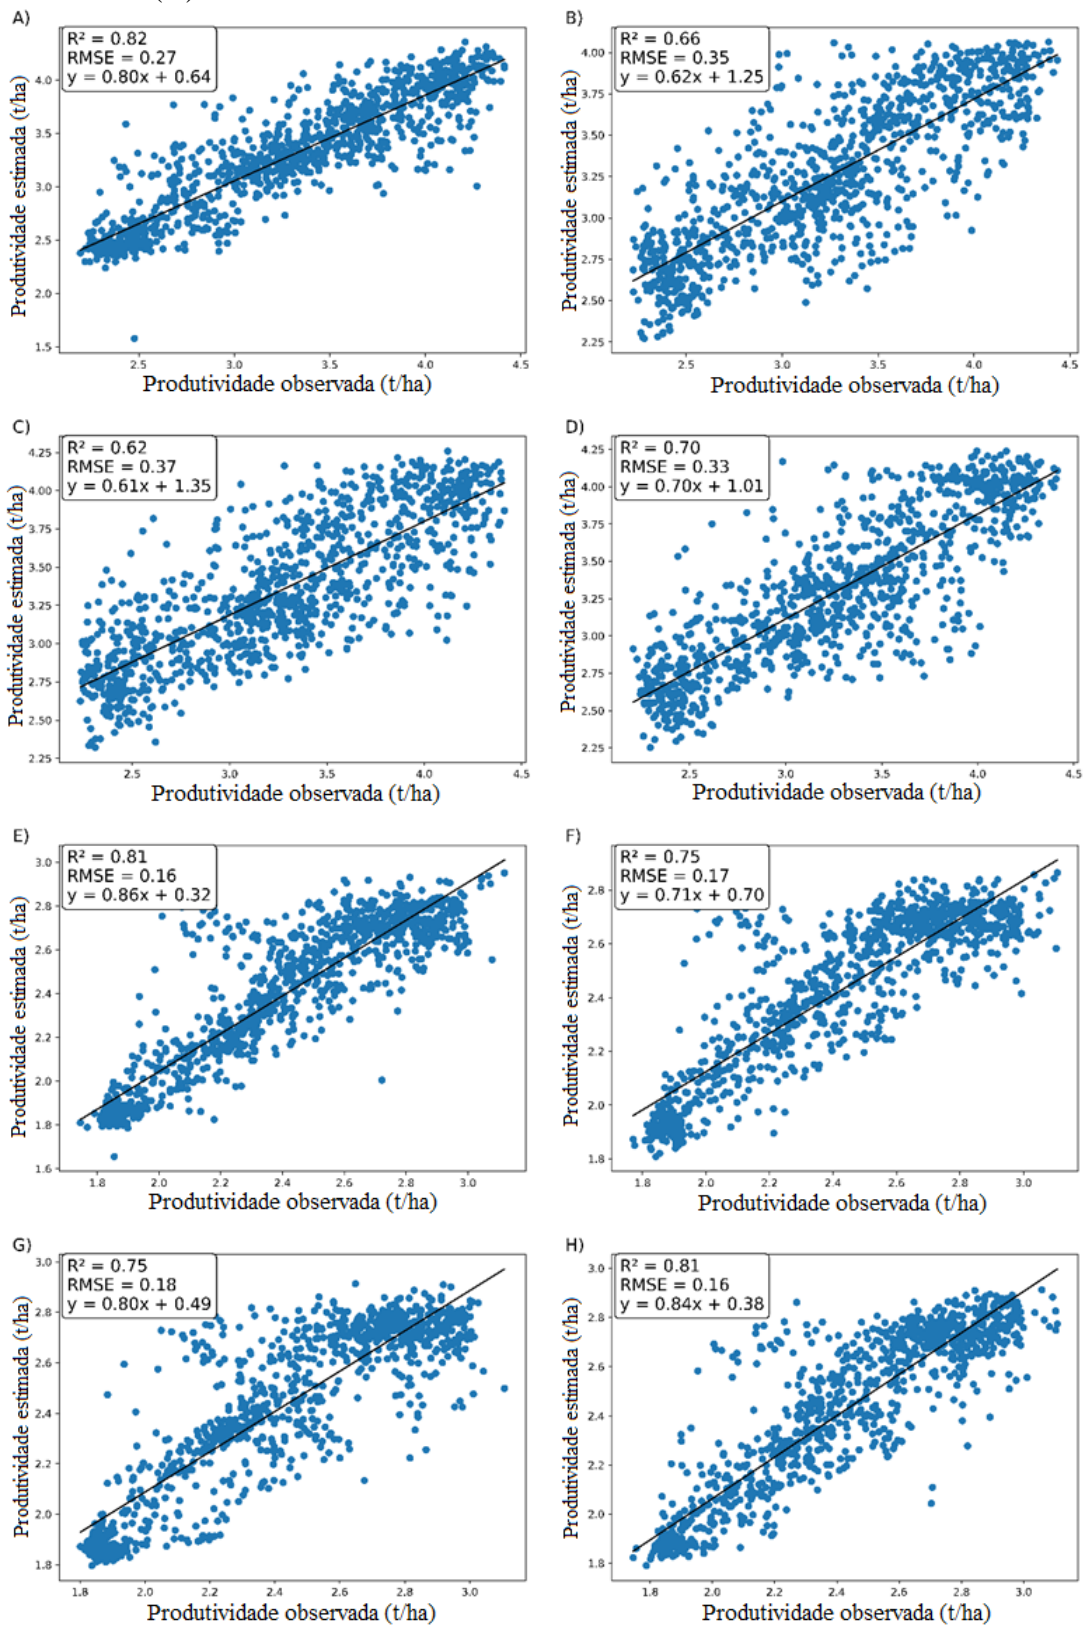


Figura 7 – Validação dos dados para o modelo M3. 30 (A), 60 (B), 90 (C) e 120 (D) dias após a semeadura referem-se aos dados do ano 2019. Enquanto 30 (E), 60 (F), 90 (G) e 120 (H) dias referem-se ao ano 2020.



Fonte: Do autor (2023).

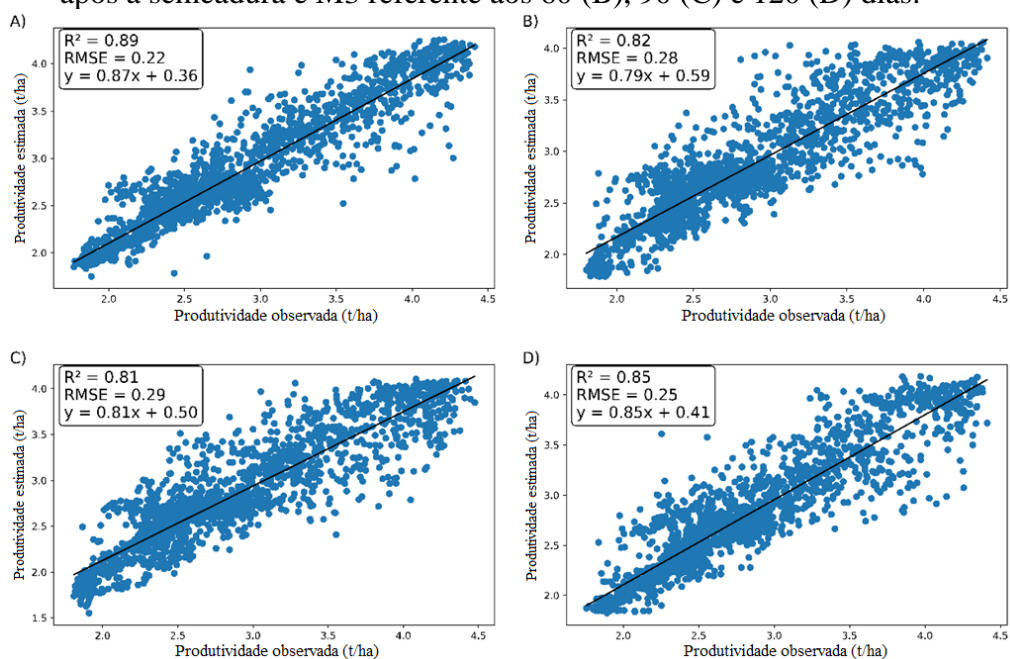
Figura 8 – Validação dos dados para o modelo M9. 30 (A), 60 (B), 90 (C) e 120 (D) dias após a semeadura referem-se aos dados do ano 2019. Enquanto 30 (E), 60 (F), 90 (G) e 120 (H) dias referem-se ao ano 2020.



Fonte: Do autor (2023).

Vale destacar como o M3 teve um bom desempenho aos 60, 90 e 120 DAS (FIGURA 9). O modelo apresentou um valor médio de  $R^2 = 0,84$  e de  $RMSE = 0,26 \text{ t ha}^{-1}$ . Ao comparar a estimativa de produtividade de sorgo e os resultados de validação de ambos estágios de crescimento, observou-se que o modelo M3 resultou no melhor desempenho na estimativa de produtividade de sorgo do que os demais modelos. A qualidade de estimar foi maior na fase inicial de desenvolvimento da cultura, durante o período de crescimento vegetativo e diminuiu após a fase de adubação de cobertura. Novamente teve um ligeiro aumento durante a etapa de crescimento final do sorgo, em que é definida pela maturação dos grãos e senescência das folhas.

Figura 9 – Validação dos dados de dois anos agrícolas para aos modelos M2 (A) aos 30 dias após a semeadura e M3 referente aos 60 (B), 90 (C) e 120 (D) dias.



Fonte: Do autor (2023).

## 4 DISCUSSÃO

A maioria dos estudos usaram algoritmos de aprendizado de máquina (ML) para estimar a produtividade de grãos em diversas culturas pouco antes da maturidade fisiológica e colheita dos grãos (ENGEN et al., 2021; MURUGANANTHAM et al., 2022; SKAKUN et al., 2021; SOUZA et al., 2022). Para isso, o sensoriamento remoto baseia-se na relação entre as fases de desenvolvimento da planta e as respostas espectrais dos tecidos vegetais. O grande

desafio é desenvolver um modelo preciso e acurado de RNA capaz de estimar a produtividade a campo, principalmente na época mais adequada. Dessa forma, a estimativa antecipada é importante para melhorar a tomada de decisões na agricultura bem como a organização da mão de obra, colheita, transporte, gerenciamento de suprimentos e maior eficiência no uso de insumos agrícolas (LI et al., 2022).

Atualmente IVs estão sendo aplicados na estimativa de produtividade das culturas por fornecerem informações valiosas sobre superfície foliar e estrutura do dossel, principalmente os IVs compostos por bandas do vermelho, RedEdge e NIR como o NDVI, NDRE, SAVI, WDRVI (CAO et al., 2020; LI et al., 2022; SKAKUN et al., 2021; SOUZA et al., 2022; THEAU et al., 2021;). Alguns estudos utilizaram IVs para estimar a produtividade por meio de modelos de regressão (JI et al., 2021; LIU et al., 2019), podendo ter baixo desempenho devido a complexibilidade dos dados. Assim, neste estudo foram extraídas informações das imagens do PlanetScope em quatro épocas no ciclo do sorgo e utilizado modelo de rede neural artificial.

Os IVs quando utilizados em conjunto para o desenvolvimento de modelos de estimativa, são capazes de aumentar a precisão dos mesmos. Além disso, um amplo banco de dados e técnicas de aprendizado de máquina podem favorecer a acurácia do modelo (AKBARIAN et al., 2022; AZADBAKHT et al., 2022; KAYAD et al., 2019; KHAKI et al., 2019; ZAMRI et al., 2022). Foi utilizado RNA tipo MLP em 10 modelos compostos da combinação entre os IVs CIgreen, GNDVI, NDVI, SR, VARI, WRDVI e elevação do terreno. O desempenho do modelo foi verificado por meio do  $R^2$  e RMSE e os melhores modelos (M2, M3 e M9) compostos pelos IVs CIgreen, WDRVI, SR e VARI, dando destaque para as bandas espectrais do verde, vermelho e NIR.

Segundo os valores apresentados pelas métricas estatísticas a melhor época para estimativa de produtividade da cultura do sorgo foi no início do estágio vegetativo, o M9 aos 30 DAS com  $R^2 = 0,82$  e  $RMSE = 0,27 \text{ t ha}^{-1}$  (FIGURA 5). O que difere do estudo proposto por Liao et al. (2022) que tentou realizar a estimativa da variabilidade da produtividade dentro do campo de trigo durante os estágios iniciais de desenvolvimento, no entanto, resultou na redução da capacidade de generalizar e dificultou a estimativa de produtividade nos estágios iniciais. Isso pode ter ocorrido pelo uso de imagens orbitais com baixa resolução temporal, interferindo na obtenção de informações da área. Neste estudo, foram utilizadas imagens de alta resolução temporal (diariamente) o que proporciona maior capacidade de detecção de

mudanças nas características da superfície vegetal (ROZNIK et al., 2022; SANTOS et al., 2021; ZHOU et al., 2022). Além disso, no estágio inicial foi usado como entrada o índice WDRVI, onde o coeficiente de ponderação de 0,05 aumentou a correlação com a fração de vegetação, devido sua sensibilidade às mudanças na área foliar e reduz a saturação do solo (CAO et al., 2020; GARCÍA-MARTÍNEZ et al., 2020). Além de que é evidenciado por Gitelson et al. (2003) relações lineares entre o WRDVI e indicadores de crescimento vegetal.

Por outro lado, o M3 aos 120 DAS obteve uma precisão semelhante com  $R^2 = 0,84$  e  $RMSE = 0,15 \text{ t ha}^{-1}$  (FIGURA 5). Esse período correspondente ao final do estágio reprodutivo e se aproximando da maturidade fisiológica da cultura, na qual ocorre o processo de dry-down que pode influenciar diretamente na resposta espectral da planta. Inicialmente, a refletância espectral da superfície foliar das plantas é maior nas regiões verde, vermelho e RedEdge do espectro eletromagnético. Esse aumento na refletância pode ser atribuído à perda de água das folhas, o que aumenta a quantidade de espaço de ar dentro da folha e diminui a absorção de luz pela folha (LI et al., 2014; MAZIS et al., 2020). À medida que o processo de dry-down continua, a refletância na região do NIR diminui (GITELSON et al., 2002), ocasionando uma redução na quantidade de luz espalhada pela superfície foliar. Assim, o índice VARI possui melhor correlação com estágios de desenvolvimento mais avançados da cultura, como visto no estudo de JI et al. (2023) na qual o VARI tem correlação mais forte nos estágios de enchimento de grãos. Influenciando diretamente no bom desempenho do modelo.

Ao utilizar o banco de dados das duas safras (2019 e 2020) houve aumento considerável do ajuste do modelo e M2 obteve o melhor desempenho com  $R^2 = 0,89$  e  $RMSE = 0,22 \text{ t ha}^{-1}$  aos 30 DAS (FIGURA 6). Isso pode ter ocorrido devido a maior quantidade de dados que foram utilizados para treinamento do modelo, proporcionando melhor capacidade de generalização e reconhecimento de padrões (AKBARIAN et al., 2022; AZADBAKHT et al., 2022; ZAMRI et al., 2022). Vale ressaltar que o M2 tem como variáveis de entrada os IVs CIgreen, WDRVI, SR, VARI e elevação do terreno e nas duas safras foram utilizados duas cultivares de sorgo granífero de ciclo precoce e com características agrônômicas semelhantes.

Os modelos M2, M3 e M9 mostraram uma alta correlação com os IV CIgreen, WDRVI, SR, VARI para estimar a produtividade de sorgo e podem melhorar o desempenho a partir de dados de futuras safras. A variável elevação do terreno possibilitou aumentar a capacidade de estimativa dos modelos, combinado com os IVs. Assim como Ramos et al. (2020) descreve que modelos de RNA tem melhor precisão para estimar a produtividade de

milho quando os índices de vegetação, índices de textura e dados de elevação são combinados.

No estudo de Segarra et al. (2020), foi incorporado características topográficas para explorar possíveis relações da estimativa de produção de grãos e demonstraram que 20% da variação espacial observada no campo foi representada pela topografia da área. E dados topográficos como a altitude afetam diretamente as propriedades físico-químicas do solo. Essas informações podem ser geradas através do Modelo Digital de Elevação (DEM) e usadas para estimar produtividade das culturas (BOORI et al., 2023; FRANZ et al., 2020; SEGARRA et al., 2020; SERELE et al., 2000). Neste estudo foram usados dados de elevação obtidos diretamente pelo receptor GNSS embarcado a colhedora, por ser uma alternativa mais rápida e leituras realizada em tempo real.

Portanto, este estudo demonstrou o potencial de índices de vegetação e elevação do terreno usando RNA para estimar a produtividade do sorgo durante o período inicial de desenvolvimento da cultura. E destacar a importância de realizar mais pesquisas sobre a variabilidade dos campos de sorgo e uso de IVs e características topográficas para estimar a produtividade.

## 5 CONCLUSÃO

Este estudo demonstrou que a rede neural artificial MLP pode ser utilizada na estimativa de produtividade de sorgo a campo em condições tropicais. A estimativa de produtividade de sorgo com maior precisão e acurácia foi entregue pelos modelos M2, M3 e M9 que utilizam os índices de vegetação CIGreen, SR, VARI, WDRVI combinados com elevação do terreno. O modelo M9 aos 30 DAS obteve  $R^2 = 0,82$  e  $RMSE = 0,27 \text{ t ha}^{-1}$ , enquanto o M3 foi melhor aos 120 DAS com  $R^2 = 0,84$  e  $RMSE = 0,15 \text{ t ha}^{-1}$ . No entanto, ao utilizar o banco de dados de dois anos agrícolas (2019 e 2020) o M2 apresentou o melhor desempenho aos 30 DAS para estimar a produtividade de sorgo com  $R^2 = 0,89$  e um  $RMSE = 0,22 \text{ t ha}^{-1}$ .

Em resumo, um bom ajuste entre os dados observados a campo e estimados pelo modelo aos 30 DAS usando IV e elevação do terreno. Isso demonstra que o estágio inicial de desenvolvimento é o mais adequado para realizar a estimativa de produtividade na cultura do sorgo. Mais estudos são necessários para verificar a capacidade de estimativa de RNA usando índices de vegetação e características topográficas.

## REFERÊNCIAS

- AKBARIAN, S; XU, C; WANG, W; GINNS, S; LIM, S. Sugarcane yields prediction at the row level using a novel cross-validation approach to multi-year multispectral images. **Computers And Electronics In Agriculture**, v. 198, p. 107024, jul. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2022.107024>.
- AZADBAKHT, M; ASHOURLOO, D; AGHIGHI, H; HOMAYOUNI, S; SHAHRABI, H. S; MATKAN, A; RADIOM, S. Alfalfa yield estimation based on time series of Landsat 8 and PROBA-V images: an investigation of machine learning techniques and spectral-temporal variáveis. **Remote Sensing Applications: Society and Environment**, v. 25, p. 100657, jan. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2021.100657>.
- BATRA, K; GANDHI, P. (2022). Artificial Neural Network-Based Model for the Prediction of Evaporation in Agriculture. In: Sanyal, G., Travieso-González, C.M., Awasthi, S., Pinto, C.M.A., Purushothama, B.R. (eds) *InteANNtional Conference on Artificial Intelligence and Sustainable Engineering. Lecture Notes in Electrical Engineering*, vol 836. **Springer**, Singapore. [https://doi.org/10.1007/978-981-16-8542-2\\_46](https://doi.org/10.1007/978-981-16-8542-2_46).
- BHAT, S. A; HUANG, Nen-Fu. Big Data and AI Revolution in Precision Agriculture: survey and challenges. **Ieee Access**, v. 9, p. 110209-110222, 2021. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2021.3102227>.
- BOORI, M. S; CHOUDHARY, KI; PARINGER, R; KUPRIYANOV, A. Machine learning for yield prediction in Fergana valley, Central Asia. **Journal Of The Saudi Society Of Agricultural Sciences**, v. 22, n. 2, p. 107-120, fev. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.jssas.2022.07.006>.
- BURNS, B. W; GREEN, V. S; HASHEM, A. A; MASSEY, J. H; SHEW, A. M; ADVIENTO-BORBE, M. A. A; MILAD, M. Determining nitrogen deficiencies for maize using various remote sensing indices. **Precision Agriculture**, v. 23, n. 3, p. 791-811, 1 jan. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-021-09861-4>.
- CAO, Y; LI, G. L; LUO, Y. K; PAN, Q; ZHANG, S. Y. Monitoring of sugar beet growth indicators using wide-dynamic-range vegetation index (WDRVI) derived from UAV multispectral images. **Computers And Electronics In Agriculture**, v. 171, p. 105331, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105331>.
- CHADALAVADA, K; KUMARI, B. D. R; KUMAR, T. S. Sorghum mitigates climate variability and change on crop yield and quality. **Planta**, v. 253, n. 5, 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00425-021-03631-2>.
- CHOLLET, F. (2015). Keras (Version 2.3.1) [Computer software]. GitHub. <https://github.com/keras-team/keras>.
- ENGEN, M; SANDO, E; SJOLANDER, B. L. O; ARENBERG, S; GUPTA, R; GOODWIN, M. Farm-Scale Crop Yield Prediction from Multi-Temporal Data Using Deep Hybrid Neural

Networks. **Agronomy**, v. 11, n. 12, p. 2576, 18 dez. 2021. MDPI AG. <http://dx.doi.org/10.3390/agronomy11122576>.

ESA, European Space Agency. **PlanetScope**. 2023. Available online: <https://earth.esa.int/eogateway/missions/planetscope>. Accessed on: 27 february 2023.

FRANZ, T. E; POKAL, S; GIBSON, J. P; ZHOU, Y; GHOLIZADEH, H; TENORIO, F. A; RUDNICK, D; HEEREN, D; MCCABE, M; ZILIANI, M. The role of topography, soil, and remotely sensed vegetation condition towards predicting crop yield. **Field Crops Research**, v. 252, p. 107788, jul. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.fcr.2020.107788>.

GARCÍA-MARTÍNEZ, H; FLORES-MAGDALENO, H; ASCENCIO-HERNÁNDEZ, R; KHALIL-GARDEZI, A; TIJERINA-CHÁVEZ, L; MANCILLA-VILLA, O. R; VÁZQUEZ-PEÑA, M. A. Corn Grain Yield Estimation from Vegetation Indices, Canopy Cover, Plant Density, and a Neural Network Using Multispectral and RGB Images Acquired with Unmanned Aerial Vehicles. **Agriculture**, v. 10, n. 7, p. 277, 8 jul. 2020. MDPI AG. <http://dx.doi.org/10.3390/agriculture10070277>.

GITELSON, A. A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **JouANNI Plant Physiology**, v.161, p.165-173, 2004.

GITELSON, A. A; GRITZ, Y; MERZLYAK, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **JouANNI of Plant Physiology**. 2003, 160, 271–282.

GITELSON, A. A; KAUFMAN, Y. J; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, n.3, p.289-298, Dec 1996. DOI. 10.1016/S0034-4257(96)00072-7.

GITELSON, A. A; KAUFMAN, Y. J; STARK, R; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing Of Environment**, v. 80, n. 1, p. 76-87, abr. 2002. Elsevier BV. [http://dx.doi.org/10.1016/s0034-4257\(01\)00289-9](http://dx.doi.org/10.1016/s0034-4257(01)00289-9).

GITELSON, A. A; VIÑA, A; ARKEBAUER, T. J; RUNDQUIST, D. C; KEYDAN, G; LEAVITT, B. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, mar. 2003. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2002gl016450>.

JAMES, G; WITTEN, D; HASTIE, T; TIBSHIRANI, R. (2013). An introduction to statistical learning: with applications in R (1st ed.). Springer.

JI, Y; LIU, R; XIAO, Y; CUI, Y; CHEN, Z; ZONG, X; YANG, T. Faba bean above-ground biomass and bean yield estimation based on consumer-grade unmanned aerial vehicle RGB images and ensemble learning. **Precision Agriculture**, 28 fev. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-023-09997-5>.



JI, Z; PAN, Y; ZHU, X; WANG, J; LI, Q. Prediction of Crop Yield Using Phenological Information Extracted from Remote Sensing Vegetation Index. **Sensors**, v. 21, n. 4, p. 1406, 17 fev. 2021. MDPI AG. <http://dx.doi.org/10.3390/s21041406>.

JORDAN, C. F. (1969). Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. **Ecology**, 50(4), 663–666. doi:10.2307/1936256.

JUNG, J; MAEDA, M; CHANG, A; BHANDARI, M; ASHAPURE, A; LANDIVAR-BOWLES, J. The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. **Current Opinion In Biotechnology**, v. 70, p. 15-22, ago. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.cobio.2020.09.003>.

KAYAD, A; SOZZI, M; GATTO, S; MARINELLO, F; PIROTTI, F. Monitoring Within-Field Variability of Corn Yield using Sentinel-2 and Machine Learning Techniques. **Remote Sensing**, v. 11, n. 23, p. 2873, 3 dez. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11232873>.

KERAS, 2015. Available online: <<https://keras.io>>. Accessed on: 27 february 2023.

KHAKI, S; WANG, L. Crop Yield Prediction Using Deep Neural Networks. **Frontiers In Plant Science**, v. 10, 22 maio 2019. Frontiers Media SA. <http://dx.doi.org/10.3389/fpls.2019.00621>.

KIM, S; WIMMER, H; KIM, J. Analysis of Deep Learning Libraries: keras, pytorch, and mxnet. **Ieee/Acis 20Th InteANNtional Conference On Software Engineering Research, Management And Applications**, 25 maio 2022. IEEE. <http://dx.doi.org/10.1109/sera54885.2022.9806734>.

KINGMA, D. P; BA, J. Adam: a method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014. ArXiv. <http://dx.doi.org/10.48550/ARXIV.1412.6980>.

LI, F; MIAO, Y; CHEN, X; SUN, Z; STUEVE, K; YUAN, F. In-Season Prediction of Corn Grain Yield through PlanetScope and Sentinel-2 Images. **Agronomy**, v. 12, n. 12, p. 3176, 15 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12123176>.

LI, L; ZHANG, Q; HUANG, D. A Review of Imaging Techniques for Plant Phenotyping. **Sensors**, v. 14, n. 11, p. 20078-20111, 24 out. 2014. MDPI AG. <http://dx.doi.org/10.3390/s141120078>.

LIAO, C; WANG, J; SHAN, B; SONG, Y; HE, Y; DONG, T. Near real-time yield forecasting of winter wheat using Sentinel-2 imagery at the early stages. **Precision Agriculture**, 2 dez. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-022-09975-3>.

LIU, Y; LIU, Si; LI, J; GUO, X; WANG, Sn; LU, J. Estimating biomass of winter oilseed rape using vegetation indices and texture metrics derived from UAV multispectral images. **Computers And Electronics In Agriculture**, v. 166, p. 105026, nov. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2019.105026>.

MAZIS, A; CHOUDHURY, S. das; MORGAN, P. B; STOERGER, V; HILLER, J; GE, Y; AWADA, T. Application of high-throughput plant phenotyping for assessing biophysical traits and drought response in two oak species under controlled environment. **Forest Ecology And Management**, v. 465, p. 118101, jun. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.foreco.2020.118101>.

MUNDIA, C. W; SECCHI, S; AKAMANI, K; WANG, G. A Regional Comparison of Factors Affecting Global Sorghum Production: the case of North America, Asia and Africa Sahel. **Sustainability**, v. 11, n. 7, p. 2135, 10 abr. 2019. MDPI AG. <http://dx.doi.org/10.3390/su11072135>.

MURUGANANTHAM, P; WIBOWO, S; GRANDHI, S; SAMRAT, N. H; ISLAM, N. A Systematic Literature Review on Crop Yield Prediction with Deep Learning and Remote Sensing. **Remote Sensing**, v. 14, n. 9, p. 1990, 21 abr. 2022. MDPI AG. <http://dx.doi.org/10.3390/rs14091990>.

OLIVEIRA, M. F. de; SANTOS, A. F. dos; KAZAMA, E. H.; ROLIM, G. de S; SILVA, R. P. da. Determination of application volume for coffee plantations using artificial neural networks and remote sensing. **Computers And Electronics In Agriculture**, v. 184, p. 106096, mai. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106096>.

PEDREGOSA, F; VAROQUAUX, G; GRAMFORT, A; MICHEL, V; THIRION, B; GRISEL, O; BLONDEL, M; MÜLLER, A; NOTHMAN, J; LOUPPE, G. Scikit-learn: machine learning in python. **Arxiv**, 2012. <http://dx.doi.org/10.48550/ARXIV.1201.0490>.

PHINZI, K; ABRIHA, D; SZABÓ, S. Classification Efficacy Using K-Fold Cross-Validation and Bootstrapping Resampling Techniques on the Example of Mapping Complex Gully Systems. **Remote Sensing**, v. 13, n. 15, p. 2980, 28 jul. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13152980>.

PLANET. Planet Imagery Product Specification. 2023. Available online: <[https://assets.planet.com/marketing/PDF/Planet\\_Surface\\_Reflectance\\_Technical\\_White\\_Paper.pdf](https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf)>. Accessed on: 27 february 2023.

QGIS Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation Project. 2012. Available online: <<http://qgis.osgeo.org>> Accessed on: 27 february 2023.

RAMOS, A. P. M; OSCO, L. P; FURUYA, D. E. G; GONÇALVES, W. N; SANTANA, D. C; TEODORO, L. P. R; SILVA JUNIOR, C. A. da; CAPRISTO-SILVA, G. F; LI, J; BAIO, F. H. R. A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. **Computers And Electronics In Agriculture**, v. 178, p. 105791, nov. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105791>.

ROUSE, J. W; HAAS, R. H; SCHEEL, J. A; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In Proceedings of the Third Earth Resource Technology Satellite (ERTS) Symposium, Washington, DC, USA, 10–14 December 1974.

ROY, D. P; HUANG, H; HOUBORG, R; MARTINS, V. S. A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. **Remote Sensing Of Environment**, v. 264, p. 112586, out. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2021.112586>.

ROZNIK, M; BOYD, M; PORTH, L. Improving crop yield estimation by applying higher resolution satellite NDVI imagery and high-resolution cropland masks. **Remote Sensing Applications: Society and Environment**, v. 25, p. 100693, jan. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2022.100693>.

SANTOS, A. F. dos; CORRÊA, L. N; LACERDA, L. N; TEDESCO-OLIVEIRA, D; PILON, C; VELLIDIS, G; SILVA, R. P. da. High-resolution satellite image to predict peanut maturity variability in commercial fields. **Precision Agriculture**, v. 22, n. 5, p. 1464-1478, 16 mar. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-021-09791-1>.

SEGARRA, J; GONZÁLEZ-TORRALBA, J; ARANJUELO, Í; ARAUS, J. L; KEFAUVER, S. C. Estimating Wheat Grain Yield Using Sentinel-2 Imagery and Exploring Topographic Variáveis and Rainfall Effects on Wheat Performance in Navarre, Spain. **Remote Sensing**, v. 12, n. 14, p. 2278, 15 jul. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12142278>.

SER, G; BATI, C. T. Determining the best model with deep neural networks: keras application on mushroom data. **Yüzüncü Yil Üniversitesi JouANNI of Agricultural Sciences**, p. 406-417, 30 set. 2019. Yuzuncu Yil Universitesi Tarim Bilimleri Dergisi. <http://dx.doi.org/10.29133/yyutbd.505086>.

SERELE, C. Z; GWYN, Q. H. J; BOISVERT, J. B; PATTEY, E; MCLAUGHLIN, N; DAOUST, G. Corn yield prediction with artificial neural network trained using airborne remote sensing and topographic data. **Igarss 2000. Ieee 2000 International Geoscience And Remote Sensing Symposium. Taking The Pulse Of The Planet: The Role of Remote Sensing in Managing the Environment**. Proceedings (Cat. No.00CH37120), Honolulu, Hi, Eua, 2000. IEEE. <http://dx.doi.org/10.1109/igarss.2000.860527>.

SCHWALBERT, R. A; AMADO, T; CORASSA, G; POTT, L. P; PRASAD, P. V. V; CIAMPITTI, I. A. Satellite-based soybean yield forecast: integrating machine learning and weather data for improving crop yield prediction in southern brazil. **Agricultural And Forest Meteorology**, v. 284, p. 107886, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.agrformet.2019.107886>.

SCIKIT-LEARN, 2011. Available online: < <https://scikit-learn.org/stable/>>. Accessed on: 27 february 2023.

SKAKUN, S; KALECINSKI, N. I; BROWN, M. G. L; JOHNSON, D. M; VERMOTE, E. F; ROGER, Jean-Claude; FRANCH, B. Assessing within-Field Corn and Soybean Yield Variability from WorldView-3, Planet, Sentinel-2, and Landsat 8 Satellite Imagery. **Remote Sensing**, v. 13, n. 5, p. 872, 26 fev. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13050872>.

SOUZA, J. B. C; ALMEIDA, S. L. H. de; OLIVEIRA, M. F. de; SANTOS, A. F. dos; BRITO FILHO, A. L. de; MENESES, M. D; SILVA, R. P. da. Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. **Agronomy**, v. 12, n. 7, p. 1512, 24 jun. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12071512>.

TEDESCO, D; OLIVEIRA, M. F. de; SANTOS, A. F. dos; SILVA, E. H. C; ROLIM, G. de S; SILVA, R. P. da. Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons. **European Journal Of Agronomy**, v. 129, p. 126337, set. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.eja.2021.126337>.

THEAU, J; LAUZIER-HUDON, E; AUBE, L; DEVILLERS, N. Estimation of forage biomass and vegetation cover in grasslands using UAV imagery. **PLoS ONE** 16(1): e0245784. <<https://doi.org/10.1371/journal.pone.0245784>>.

YASHWANTH, M; CHANDRA, M. L; PALLAVI, K; SHOWKAT, D; KUMAR, P. S. Agriculture Automation using Deep Learning Methods Implemented using Keras. **2020 Ieee InteANNtional Conference For Innovation In Technology (Inocon)**, 6 nov. 2020. IEEE. <http://dx.doi.org/10.1109/inocon50539.2020.9298415>.

ZAMRI, N; PAIRAN, M. A; AZMAN, W. N. A. W; ABAS, S. S; ABDULLAH, L; NAIM, S; TARMUDI, Z; GAO, M. A comparison of unsupervised and supervised machine learning algorithms to predict water pollutions. **Procedia Computer Science**, v. 204, p. 172-179, 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.procs.2022.08.021>.

ZHOU, X; LI, Y; SUN, Y; SU, Y; LI, Y; YI, Y; LIU, Y. Research on Dynamic Monitoring of Grain Filling Process of Winter Wheat from Time-Series Planet Imageries. **Agronomy**, v. 12, n. 10, p. 2451, 10 out. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12102451>.

### **CAPÍTULO 3 ALGORITMOS DE APRENDIZADO DE MÁQUINA NA ESTIMATIVA DA ALTURA DE PLANTA DE MILHO POR MEIO DE SENSORIAMENTO REMOTO E UAV**

#### **RESUMO**

O monitoramento aéreo da cultura do milho tem sido realizado por plataformas como UAV e satélite em diversas etapas do ciclo de desenvolvimento das plantas. Os dados coletados de forma remota e combinadas com algoritmos de aprendizado de máquina aumentam o poder de tomada de decisão dos produtores, especialmente quando se pensa em avaliação de altura de plantas. Nesse sentido, o objetivo geral foi verificar o potencial do uso de imagens de satélite de alta resolução e câmera RGB acoplada a um UAV na estimativa de altura de plantas de milho por meio de algoritmos de aprendizado de máquina. Para tanto, índices de vegetação (NDVI, NDRE e GNDVI) foram calculados a partir de imagens do PlanetScope, enquanto que a estimativa de altura utilizando UAV foi realizada por meio de modelos digitais de elevação (DEM). As imagens para ambos, satélite e UAV, foram adquiridas aos 20, 29, 37, 44, 50, 61 e 71 DAS e no mesmo dia em que se realizou a medição manual das plantas no campo. Os seguintes resultados foram obtidos: (1) a altura de planta do milho derivada do DEM baseado em imagens de UAV apresentou forte correlação com a altura manual de campo ( $r = 0,96$ ), com os índices de vegetação NDVI ( $r = 0,80$ ), NDRE ( $r = 0,78$ ) e GNDVI ( $r = 0,81$ ). (2) Neste estudo os modelos derivados dos algoritmos RF, KNN e DT apresentaram boa acurácia e precisão para estimar altura de planta no campo, utilizando informações de sensoriamento remoto orbital e extraídas do modelo digital baseado em UAV. (3) As maiores correlações entre os valores de altura observada e estimada foram obtidas pelo modelo de RF ( $r = 0,99$ ) e KNN ( $r = 0,99$ ). (4) O modelo de RF teve melhor desempenho ( $R^2 = 0,97$  e RMSE = 14,62 cm) quando utilizou NDVI, NDRE e GNDVI como entrada, seguido de KNN com precisão semelhante ( $R^2 = 0,97$  e RMSE = 14,68 cm). Este estudo demonstrou a viabilidade de imagens baseadas em UAV, sensoriamento remoto orbital e diferentes algoritmos de aprendizado de máquina para estimar a altura de planta no campo com precisão, tempo hábil e auxiliar os produtores a monitorar o crescimento da cultura do milho.

**Palavras-chave:** *Zea mays* L. Inteligência artificial. Crescimento de planta. Floresta aleatória.

## ABSTRACT

Aerial monitoring of corn crops has been carried out by platforms such as UAVs and satellites at different stages of the plant development cycle. Data collected remotely and combined with machine learning algorithms increase the decision-making power of producers, especially when considering plant height assessment. In this sense, the general objective was to verify the potential of using high-resolution satellite images and an RGB camera coupled to a UAV in estimating the height of corn plants using machine learning algorithms. For this purpose, vegetation indices (NDVI, NDRE and GNDVI) were calculated from PlanetScope images, while height estimation using UAV was performed using digital elevation models (DEM). The images for both satellite and UAV were acquired at 20, 29, 37, 44, 50, 61 and 71 DAS and on the same day that the manual measurement of plants in the field was performed. The following results were obtained: (1) corn plant height derived from DEM based on UAV images showed strong correlation with manual field height ( $r = 0.96$ ), with NDVI vegetation indices ( $r = 0.80$ ), NDRE ( $r = 0.78$ ) and GNDVI ( $r = 0.81$ ). (2) In this study, the models derived from the RF, KNN and DT algorithms showed good accuracy and precision to estimate plant height in the field, using information from orbital remote sensing and extracted from the UAV-based digital model. (3) The highest correlations between observed and estimated height values were obtained by the RF model ( $r = 0.99$ ) and KNN ( $r = 0.99$ ). (4) The RF model performed better ( $R^2 = 0.97$  and RMSE = 14.62 cm) when using NDVI, NDRE and GNDVI as input, followed by KNN with similar precision ( $R^2 = 0.97$  and RMSE = 14.68 cm). This study demonstrated the feasibility of UAV-based imaging, orbital remote sensing, and different machine learning algorithms to estimate plant height in the field accurately, in a timely manner, and help growers monitor corn crop growth.

**Keywords:** *Zea mays* L. Artificial intelligence. Plant growth. Random forest.

## 1 INTRODUÇÃO

O milho (*Zea mays* L.) é uma das culturas mais produzidas e versáteis no mundo, representa um alimento que atende as necessidades nutricionais de milhões de pessoas e animais (DU et al., 2022). Apesar disso, fatores como vigor do dossel, estado nutricional, adaptabilidade e o crescimento das plantas podem afetar na produtividade final. Esses fatores, associados com a variabilidade ambiental e genética pode afetar na altura de plantas (LUO et al., 2021).

A estimativa eficiente da altura de plantas é importante para a avaliação do potencial de crescimento do milho, pois auxilia o produtor no monitoramento e fornece informações sobre o desenvolvimento das plantas para a tomada de decisão, quanto às práticas de manejo no campo. Nos últimos anos, abordagens alternativas baseadas em sensoriamento remoto, imagens em veículo aéreo não tripulado (UAV) e aprendizado de máquina (ML) estão sendo amplamente utilizados na agricultura (JUNG et al., 2021; LI et al., 2022; SCHWALBERT et al. 2020; SOUZA et al., 2022). Portanto, uma estimativa rápida e eficaz da altura de milho em larga escala e o monitoramento dinâmico do crescimento (LIU et al., 2021) são essenciais para melhorar as estratégias de manejo da cultura (JI et al., 2023), facilitar as avaliações em campos de competição de cultivares e tomada de decisão dos agricultores.

Estudos anteriores utilizaram UAV embarcado com sensores vermelho-verde-azul (RGB) (CHE et al., 2020; GILLIOT et al., 2020), sensores multiespectrais (OSCO et al., 2020), hiperespectrais (TAO et al., 2020) e sistema lidar (GUO et al., 2019; LOU et al., 2021) para estimativa de altura de planta da cultura. A câmera RGB além de ter acessibilidade e simplicidade operacional (JI et al., 2023), pode fornecer modelos digitais de superfície do solo na qual são extraídas informações sobre a altura da vegetação presente (YU et al., 2021; ZHANG et al., 2018). No entanto, o índice de vegetação (IV), que possui uma relação direta com as características estruturais e respostas espectrais do dossel (QIAO et al., 2022), tem sido pouco usado na estimativa de altura de planta para cultura do milho. No setor agrícola outra tendência importante é o emprego de ML, que melhorou de forma geral a eficiência na análise do grande volume de dados e obteve precisão na estimativa de parâmetros agronômicos (LIAKOS et al., 2018; SOUZA et al., 2022; YOOSEFZADEH-NAJAFABADI et al., 2021).

Muitas técnicas de regressão como a tradicional regressão linear quando aplicado a uma determinada quantidade de dados de entrada, pode encontrar problemas com a

complexibilidade dos dados e multicolinearidade entre as variáveis preditoras (CORTE et al., 2020; LI et al., 2021). Por outro lado, as regressões baseadas em algoritmos de ML, como Random Forest (RF), K-Nearest Neighbor (KNN), Support Vector Machine (SVM) e Decision Trees (DT) são modelos mais precisos e destinados a solucionar problemas com interações complexas como estimar parâmetros agrônômicos importantes em uma variedade de culturas (FENG et al., 2020; GARCIA et al., 2020; LIU et al., 2023; LUO et al., 2021; RODRIGUEZ-PUERTA et al., 2020). Contudo, os algoritmos de ML dependem de um único modelo de estimativa e são propensos a superestimar de acordo com dados de treinamento limitados, como KNN, SVM e RF (JI et al., 2023). Para isso, fazer o tratamento prévio dos dados de entrada através da normalização, usar amplo banco de dados (ZAMRI et al., 2022) e divisão dos dados usando técnica de K-fold (PHINZI et al., 2021) podem minimizar os efeitos do super e subajustamento durante o treinamento e melhorar a capacidade de generalização dos modelos.


Assim, neste estudo, índices de vegetação obtidos de imagens do PlanetScope e modelos digitais de elevação (DEM) baseados em imagens de UAV, foram implementados com algoritmos de ML em linguagem Python para estimativa de altura de planta no campo. Dessa forma, os objetivos deste estudo foram: (1) estimar altura de planta no campo usando aprendizado de máquina, (2) verificar o potencial de índices de vegetação e modelo digital de elevação como parâmetros de entrada para os algoritmos de ML e (3) indicar qual o melhor algoritmo para estimar a altura de planta.

## **2 MATERIAL E MÉTODOS**

Na Figura 1 é apresentado o resumo gráfico do fluxo de trabalho utilizado neste estudo, em que foi utilizado um UAV embarcado de sensor RGB e imagens de satélite de alta resolução. As imagens da cultura do milho foram obtidas na mesma data das avaliações em campo e para reduzir interferências nas imagens, os voos com UAV foram realizados próximo ao meio-dia. A partir das imagens de UAV foram gerados os modelos digitais de elevação (DEM) no qual as alturas de planta foram derivadas e os índices de vegetação foram extraídos de imagens orbitais. Posteriormente, implementado no modelo de aprendizado de máquina (ML) para estimar altura de planta a campo.



Figura 1 – Resumo gráfico do estudo para estimar altura de planta usando IV e DEM baseado em UAV na cultura do milho.

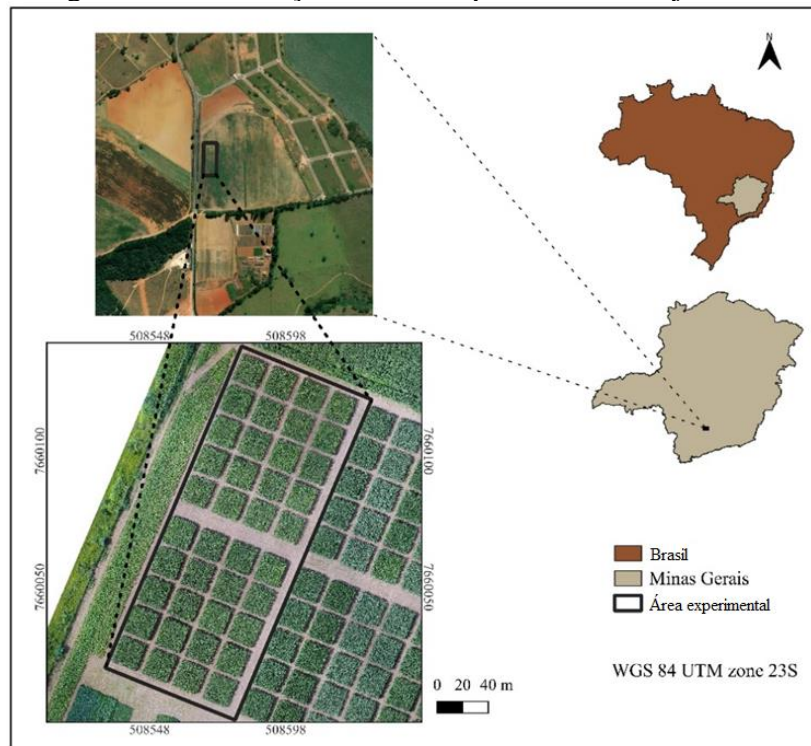


Fonte: Do autor (2023).

## 2.1 Área de estudo

A área de estudo utilizada está localizada em Ijaci, Minas Gerais, Brasil (FIGURA 2) ( $21^{\circ}09'40''$  S,  $44^{\circ}55'03''$  W). A região possui clima caracterizado como subtropical de invernos secos e verão quente (Cwa), com temperatura média de  $20.9^{\circ}\text{C}$  e precipitação anual  $1325\text{ mm}$  (KOPPEN, 1928) e altitude média de  $842\text{ m}$ . Neste estudo foram utilizados dados provenientes da cultura do milho (*Zea mays* L.) na safra agrícola 2021/2022. A área foi dividida em 40 parcelas de 10 por 10 m ( $100\text{ m}^2$ ), a semeadura realizada no dia 11 de outubro de 2021 com milho de ciclo precoce, folha semi-ereta e espaçamento entre linhas de 60 cm.

Figura 2 – Localização da área experimental em Ijaci, MG.



Fonte: Do autor (2023).

## 2.2 Aquisição dos dados no campo

A altura de planta a campo foi obtida manualmente com auxílio de uma trena aos 20, 29, 37, 44, 50, 61 e 71 dias após semeadura (DAS). As parcelas eram constituídas de 16 linhas com espaçamento de 60 cm, das quais as quatro linhas centrais foram amostradas para evitar efeito de bordadura. Foram realizadas medidas de altura em centímetros de 15 plantas em cada parcela experimental, a partir da superfície do solo até a inserção da folha bandeira (Adaptado de FOLONI et al., 2014). Em 40 parcelas foram obtidas 600 amostras para cada data e um conjunto de 4200 amostras para a avaliação de altura de planta no campo até primeiro estágio reprodutivo (R1) da cultura. Todas as avaliações foram realizadas para monitorar o crescimento do milho e validar a aplicação de IV e DEM para estimar a altura de planta usando aprendizado de máquina.

## 2.3 Aquisição e processamento de imagens

As imagens foram adquiridas por meio de duas plataformas, um UAV modelo Phantom 4 (SZ DJI Technology Co., Shenzhen, China) acoplado de uma câmera RGB (modelo FC330, DJI, Shenzhen, China) e o sensor da plataforma PlanetScope CubeSat

(Planet Labs Inc., California, United States) para as imagens de satélite. As imagens orbitais foram utilizadas para a extração de índices de vegetação (IV) e as imagens do UAV para geração do DEM.

Os voos e imagens de satélite foram coletadas nos mesmos dias que foram realizadas as avaliações manuais de altura de planta no campo. O plano de voo foi realizado pelo software Pix4D Capture (Versão 4.13.1, Pix4d SA, Prilly, Suíça), com sobreposição frontal de 80% e lateral de 75%, altura de voo de 40 m, com câmera RGB perpendicular ao solo e distância de amostra de solo (GSD) de 1.09 cm por pixel. Nove pontos de controle no solo (GCP) foram distribuídos uniformemente dentro do campo para obter referências geográficas precisas (HE et al., 2018) e melhorar a precisão da extração das informações da cultura. Os valores de coordenadas geográficas dos pontos foram coletados através de equipamento com GPS e correção de sinal via Real Time Kinematic (RTK).

Os DEMs foram gerados no software Pix4D Mapper (Versão 4.5, Pix4d SA, Prilly, Suíça), na qual seguiu um fluxo de trabalho de processamento incluindo: alinhamento de imagens, construção da nuvem densa de pontos, do ortomosaico e do modelo digital de superfície para cada data.

Para as imagens orbitais, a plataforma PlanetScope permite a coleta de dados diários com resolução espacial de 3 a 5 m e possuem oito bandas espectrais: Coastal Blue (431-452 nm), Blue (465-515 nm), Green I (513-549 nm), Green (547-583 nm), Yellow (600-620 nm), Red (650-680 nm), RedEdge (697-713 nm) e Near-infrared (NIR) (845-885 nm) (ESA, 2023). A plataforma disponibiliza o produto PlanetScope Analytic Ortho Scene Surface Reflectance (SR – Nível 3B), imagem ortorretificada com correção geométrica, radiométrica, projetada para projeção Universal Traverse Mercator (UTM) e calibrada para o topo da radiância atmosférica. A imagem final é disponibilizada com a radiância, reflectância da superfície e formato GeoTiff (PLANET, 2023). Devido às condições climáticas para o período das avaliações, principalmente a presença de nuvens na região, foram utilizadas imagens do PlanetScope com intervalo máximo de três dias de variação.

## **2.4 Extração dos índices de vegetação e modelo digital de elevação**

Os índices de vegetação (IVs) foram calculados a partir dos valores de refletância das imagens orbitais do PlanetScope (TABELA 1), no software QGIS 3.22.15 (QGIS Development Team, Trondheim, Norway, 2023). Dentro de cada parcela de 100 m<sup>2</sup>, foi

gerado um buffer negativo de 1.0 m reduzindo o efeito da borda nos valores de reflectância das plantas. Em seguida, foi gerado 15 pontos aleatórios dentro do buffer e utilizado o Point Sampling Tool (JURGIEL, 2020) plugin para atribuir os valores raster de cada IV aos pontos amostrados nas parcelas. Esses índices foram definidos por apresentarem correlação com características biofísicas das culturas como a biomassa, vigor do dossel e teor de clorofila (BARBOZA et al., 2023; TEDESCO et al., 2021).

Tabela 1 – Índices de Vegetação (IV) para imagens orbitais do PlanetScope.

<b>IV</b>	<b>Equação</b>	<b>Referência</b>
<b>NDVI</b>	$\frac{(NIR - Vermelho)}{(NIR + Vermelho)}$	(ROUSE et al., 1974)
<b>NDRE</b>	$\frac{(NIR - Borda\ do\ vermelho)}{(NIR + Borda\ do\ vermelho)}$	(GITELSON; MERZYAK, 1994)
<b>GNDVI</b>	$\frac{(NIR - Verde)}{(NIR + Verde)}$	(GITELSON et al., 1996)

NDVI: Índice de Vegetação por Diferença Normalizada; NDRE: Índice da borda do vermelho por Diferença Normalizada; GNDVI: Índice de Vegetação por Diferença Normalizada Verde.

Fonte: Do autor (2023).

Para obter os valores de altura de planta baseados no UAV foi calculado o DEM (Equação 1) de cada data, considerando o primeiro voo realizado no dia da semeadura do milho como o modelo digital do terreno (DTM). E para os 20, 29, 37, 44, 50, 61 e 71 DAS as imagens foram processadas e gerados os modelos digitais de superfície (DSM) (LETSOIN et al., 2023; TREVISAN et al., 2023; WANG et al., 2019; YU et al., 2021; ZHANG et al., 2018). Em seguida, no software QGIS 3.22.15 os modelos digitais foram submetidos a equação 1 e resultou no DEM para as datas.

$$DEM = DSM - DTM \quad (1)$$

A partir do ortomosaico, a porção referente ao solo e a vegetação foram segmentados através da classificação supervisionada usando Dzetsaka Classification Tool plugin (KARASIAK, 2020), no software QGIS 3.22.15, conforme utilizado no estudo de Cavalcanti et al. (2023). Apenas com a porção vegetal vetorizado, foi feito recorte no raster DEM e, assim, removendo a porção solo do modelo digital de elevação. Dentro de cada parcela

experimental, os mesmos 15 pontos foram utilizados para obter os valores de altura por meio do Point Sampling Tool plugin.

## 2.5 Algoritmos de aprendizado de máquina para estimativa de altura de planta

Os valores dos IVs (NDVI, NDRE e GNDVI) e altura de planta baseado no DEM de UAV (UAV Height) foram utilizados como entradas para os algoritmos de ML frequentemente utilizados e, posteriormente, verificar o desempenho dos algoritmos Linear Regression (LR), Random Forest (RF), K-Nearest Neighbor (KNN), Support Vector Machine (SVM) e Decision Trees (DT) para estimar a altura de planta no campo (TABELA 2).

Para todos os modelos, três configurações de entrada de dados foram definidas: entrada 1 (UAV Height), entrada 2 (UAV Height + NDVI + NDRE + GNDVI) e entrada 3 (NDVI + NDRE + GNDVI). Além disso, a validação cruzada K-fold foi implementada para garantir que o conjunto de dados fosse comparado igualmente, possibilitando a estimativa mais precisa e consequentemente reduzir risco de overfitting (JAMES et al., 2013). A técnica K-fold divide os dados aleatoriamente em K subconjuntos de tamanho igual (PHINZI et al., 2021) e no presente estudo o treinamento foi realizado K vezes (cinco), em cada subconjunto de dados. Para implementação de algoritmos de ML foi utilizada a linguagem Python 3.11 (PYTHON Software Foundation, 2023).

Tabela 2 – Algoritmos de aprendizado de máquina implementados no estudo e hiperparâmetros.

<b>Algoritmos</b>	<b>Hiperparâmetros</b>	<b>Referências</b>
LR	None	(NUTT; BATSELL, 1973)
RF	n_estimators=250, criterion=squared_error	(BREIMAN, 2001)
KNN	n_neighbors=100, weights=distance	(COVER; HART, 1967)
SVM	kernel=rbf, C=18, tol=0.001	(CORTES; VAPNIK, 1995)
DT	criterion=squared_error, splitter=best, min_samples_split=2	(ROKACH; MAIMON, 2005)

Fonte: Do autor (2023).

## 2.6 Pré-processamento dos dados e Análise Estatística

A normalização de dados é um processo de transformação dos dados que apresentem valores muito discrepantes entre uma variável e outra. O objetivo é garantir que todas as variáveis tenham a mesma escala e distribuição de valores, contribuindo igualmente para o desenvolvimento do modelo, minimizando o domínio entre variáveis. Assim, foi realizado a transformação dos dados para média zero e desvio padrão 1, através do método `StandardScaler` da biblioteca `Scikit-learn` (PEDREGOSA et al., 2011; SCIKIT-LEARN, 2011; ZAMRI et al., 2022).

O desempenho dos algoritmos para a estimativa de altura de planta foi avaliado através de três métricas estatísticas: o coeficiente de determinação ( $R^2$ ) (Equação 2), raiz do erro quadrado médio (RMSE) (Equação 3). Todas as análises estatísticas envolvidas neste estudo foram realizadas usando linguagem Python 3.11.

$$R^2 = \frac{SQR}{SQT} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (3)$$

## 3 RESULTADOS

### 3.1 Comparação entre os algoritmos de aprendizado de máquina

Para comparar a capacidade dos algoritmos de ML na estimativa de altura de planta no campo foram definidas três configurações de entrada (entradas 1, 2 e 3) (TABELA 3). No geral, os modelos apresentaram melhor desempenho quando usado de entrada a altura de UAV e os IVs.

Entre as abordagens de aprendizado de máquina, os modelos de RF e KNN se destacaram em função da precisão e acurácia superior aos demais algoritmos testados para estimativa de altura de planta, com uma ligeira diferença de RMSE. O modelo de SVM ( $R^2 = 0.95$  e  $RMSE = 19.39$  cm) teve melhor precisão para com a entrada 1, enquanto para a entrada 2 e 3 a maior precisão foi quando se utilizou o modelo de RF ( $R^2 = 0.97$  e  $RMSE = 15.07$  cm e  $R^2 = 0.97$  e  $RMSE = 14.62$  cm, respectivamente). O modelo de DT obteve desempenho similar ao RF e KNN e para a entrada 3 apresentou melhor precisão ( $R^2 = 0.97$  e  $RMSE = 16.26$  cm). Por outro lado, o tradicional modelo de LR obteve baixa acurácia e precisão ( $R^2 =$

0,74 e RMSE = 44,13 cm) quando utilizado a entrada 3. Isso pode ter ocorrido devido a linha de tendência linear utilizada no modelo, não se ajustando aos dados de IVs.

Neste estudo, os modelos derivados dos algoritmos RF, KNN e DT apresentaram boa acurácia e precisão para estimar altura de planta no campo, utilizando informações de sensoriamento remoto orbital e extraídas do modelo digital baseado em UAV. Vale destacar que o modelo de RF e KNN (RMSE = 14,62 e 14,66 cm, respectivamente) apresentaram os menores erros quando utilizado a entrada 3.

Tabela 3 – Precisão ( $R^2$ ) e acurácia (RMSE) do treinamento e teste dos modelos para estimativa de altura de planta do milho.

Algoritmo	Entrada	Treinamento		Teste	
		$R^2$	RMSE (cm)	$R^2$	RMSE (cm)
LR	1	0,93	24,56	0,93	23,56
	2	0,93	22,71	0,94	21,33
	3	0,74	45,01	0,74	44,13
RF	1	0,94	24,49	0,94	22,02
	2	0,97	16,49	0,97	15,07
	3	0,97	15,76	0,97	14,62
KNN	1	0,95	18,74	0,95	20,59
	2	0,97	14,10	0,97	16,55
	3	0,97	11,84	0,97	14,66
SVM	1	0,95	17,81	0,95	19,39
	2	0,95	15,86	0,95	18,76
	3	0,87	30,86	0,88	32,02
DT	1	0,94	19,76	0,94	22,29
	2	0,98	15,60	0,97	16,98
	3	0,97	14,84	0,97	16,26

Fonte: Do autor (2023).

### 3.2 Correlação entre valores observados e estimados de altura


O coeficiente de correlação de Pearson ( $r$ ) para as relações entre as informações obtidas pela plataforma UAV e satélite foram positivamente correlacionadas com altura

manual de planta coletada no campo. Entre a altura de planta estimada pelos modelos e observada de milho tiveram correlação significativa ( $p < 0,05$ ) para as três configurações de entrada, principalmente os modelos de RF e KNN (FIGURA 3).

O  $r$  variou de 0,96 a 0,98 na entrada 1 e de 0,86 a 0,99 para as demais configurações de entrada. Os valores de correlação foram semelhantes entre os modelos RF, KNN e DT, visto que o  $r$  obtido pelos modelos de SVM diminuiu ligeiramente ( $r = 0,94$ ) e os LR apresentaram os menores valores de  $r$ . O modelo LR tem melhor desempenho quando os dados possuem relação linear e na entrada 3, a presença dos IVs pode ter influenciado nessa menor precisão dos modelos.

Vale destacar as maiores correlações obtidas pelos modelos de RF ( $r = 0,99$ ) e KNN ( $r = 0,99$ ) na entrada 3. No geral, a análise de correlação permite apontar que os modelos de RF foram os melhores para estimar altura de planta no campo. E baseado na análise de dependência linear entre os valores estimados e observados de altura, os melhores modelos para estimativa de altura de planta são encontrados quando utilizado altura baseada UAV e índices de vegetação como parâmetros de entrada para o aprendizado de máquina.

Figura 3 – Coeficientes de correlação de Pearson ( $r$ ) entre os valores observados e estimados de altura de planta, para cada algoritmo e entrada de entrada.






### 3.3 Desempenho dos modelos

O desempenho dos modelos para estimativa de altura de planta de milho usando as três configurações de entrada foi analisado através dos valores de RMSE e  $R^2$  (FIGURA 4). Três modelos foram estabelecidos para cada algoritmo de ML, de acordo com as configurações de entrada. Os modelos de RF e KNN apresentaram melhor desempenho quando utilizado a entrada 3 como parâmetro de entrada, evidenciando que os índices de vegetação NDVI, NDRE e GNDVI podem ser características eficientes em modelos para estimar a altura de planta de milho. Para a entrada 1 (UAV Height) o melhor desempenho foi entregue pelo modelo SVM e na entrada 2 (UAV Height x NDVI x NDRE x GNDVI) o modelo RF.

Figura 4 – Coeficiente de determinação ( $R^2$ ) (A) e raiz do erro quadrado médio (RMSE) (B) em centímetros dos algoritmos de ML implementados no estudo.



Fonte: Do autor (2023).

O modelo RF teve maior precisão e acurácia na entrada 3 e 2 ( $R^2 = 0,97$ ) com valores de RMSE = 14,62 e 15,07 cm, respectivamente. Enquanto o modelo KNN obteve desempenho semelhante na entrada 3, com  $R^2 = 0,97$  e RMSE = 14,66 cm. Esses resultados indicam que os índices de vegetação NDVI, NDRE e GNDVI podem ser utilizados para estimativa de altura de planta desde que sejam integrados a esses algoritmos de ML. Já na entrada 1 o modelo de SVM resultou na maior precisão e acurácia ( $R^2 = 0,95$  e RMSE = 19,39 cm).

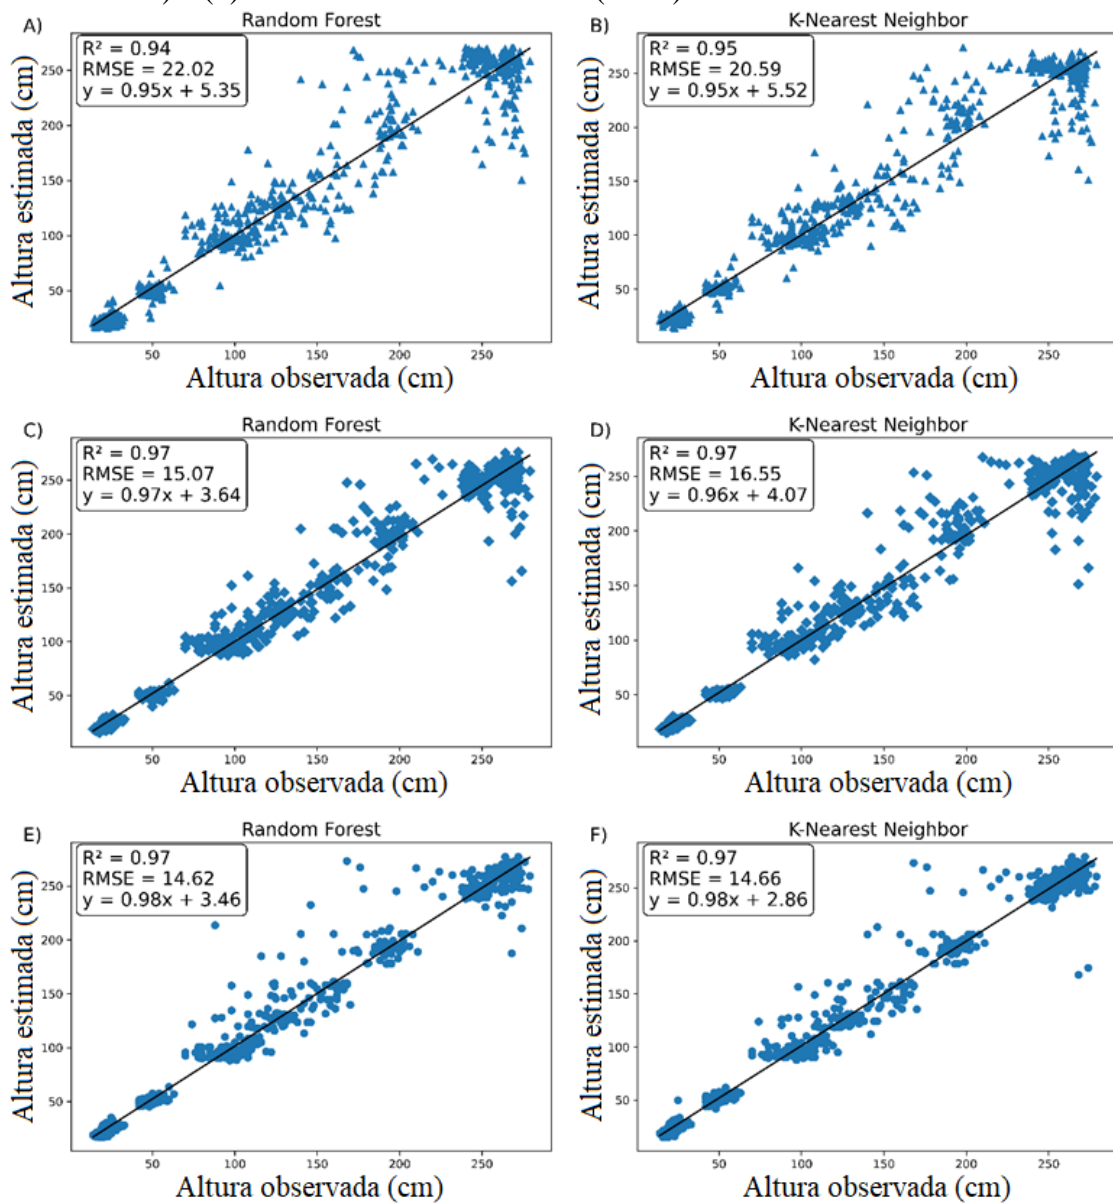
Por outro lado, os modelos de LR apresentaram um bom desempenho para as entradas 1 ( $R^2 = 0,93$ ) e 2 ( $R^2 = 0,94$ ), ressaltando que essas duas configurações possuem como entrada a altura baseada em UAV. Já para entrada 3, que contém os três IVs, o modelo LR ( $R^2 = 0,74$  e  $RMSE = 44,13$  cm) teve a pior precisão, com redução de 21% na precisão, demonstrando que o método tradicional de regressão linear não se ajusta bem a dados não lineares. Bem como encontrado por Yu et al. (2022), os modelos RF, SVM e KNN podem obter melhor precisão que a Regressão Linear pois são capazes de extrair com maior eficiência informações de dados não lineares e multicolinearidade entre as características preditoras.

### **3.4 Estimativa de altura de planta no campo**

Considerando os valores de precisão e acurácia dos modelos de estimativa de altura de planta baseado nas quatro variáveis de entrada (UAV Height, NDVI, NDRE e GNDVI), os algoritmos RF e KNN são semelhantes e capazes de estimar altura de planta no campo com erros similares (FIGURA 5). O modelo de RF teve melhor desempenho na entrada 2 e 3, enquanto o modelo de KNN obteve precisão muito próxima ao RF na entrada 3. Vale enfatizar a maior precisão e acurácia em comparação aos demais modelos estimadores, que o RF apresentou  $R^2 = 0,97$  e  $RMSE = 14,62$  cm. Além disso, esses mesmos algoritmos obtiveram desempenho similar quando utilizado os IVs (entrada 3), com diferença de 0,04 cm de RMSE entre os dois.

De forma geral, a altura de planta aos 71 DAS (estádio R1) observado no campo foi de 255,48 cm, enquanto para os modelos de RF e KNN a altura estimada foi de 255,39 cm e 256,89 cm, respectivamente. Os resultados (FIGURA 5) mostram que os modelos de estimação usando as variáveis NDVI, NDRE e GNDVI obtiveram maior precisão e acurácia de estimativa do que usando as demais configurações de entrada. Dessa forma, a estimativa de altura de milho pode ser realizada usando os algoritmos RF e KNN, através de um modelo geral e preferencialmente quando a cultura chegar ao estágio R1, no qual a planta atinge o máximo crescimento.

Figura 5 – Estimativa dos dados para os modelos RF e KNN. Referem-se as configurações de entrada: (1) UAV Height (A e B), (2) UAV Height + NDVI + NDRE + GNDVI (C e D) e (3) NDVI + NDRE + GNDVI (E e F).



Fonte: Do autor (2023).

#### 4 DISCUSSÃO

Nos últimos anos, o uso de imagens de UAV, sensoriamento orbital e índices de vegetação, bem como o aprendizado de máquina, vem recebendo destaque por ser uma tecnologia que reduz o impacto de avaliações destrutivas, economiza tempo e esforço no monitoramento da taxa de crescimento das culturas (LIAKOS et al., 2018; LIU et al., 2021; RUEDA-AYALA et al., 2019; WANG et al., 2019).

Os algoritmos RF, KNN, SVM e DT baseadas em aprendizado de máquina são ferramentas promissoras para otimizar e podem promover maior eficiência na estimativa de altura de planta nos campos de milho, principalmente em larga escala. O banco de dados foi composto por informações de altura extraídas de modelos digitais de elevação baseado em UAV e de índices de vegetação do satélite PlanetScope aos 20, 29, 37, 44, 50, 61 e 71 dias após a semeadura da cultura. Os modelos resultantes das três configurações de entrada (entrada 1, 2 e 3) foram avaliados com base nos valores de  $R^2$ , RMSE e correlação de Pearson entre altura de planta observada e estimada. O melhor desempenho foi observado pelo modelo de RF ( $R^2 = 0,97$  e RMSE = 14,62 cm) seguido do modelo de KNN ( $R^2 = 0,97$  e RMSE = 14,66 cm) (FIGURA 4), usando como entrada os índices de vegetação NDVI, NDRE e GNDVI. Isso mostra a importância dos IVs na estimativa dessa variável agrônômica (OSCO et al., 2020).

O modelo de RF obteve a maior acurácia (RMSE = 14,66 cm) em relação aos demais algoritmos, o que faz necessário utilizar um diferente banco de dados para tornar o modelo mais robusto e generalista. Neste estudo, observou-se como o algoritmo RF e KNN tem proporcionado resultados precisos para estimativa de altura, assim como outros estudos que aplicaram esses algoritmos para estimativa de alturas de milho e soja a partir de LiDAR e UAV (LUO et al., 2021) e de milho usando modelo tridimensional (CHE et al., 2020), estimativa de crescimento de milho verão usando modelos digitais (ZHAO et al., 2023), estimativa de biomassa baseado em dados UAV (WANG et al., 2020), estimar o índice de área foliar (DU et al., 2022) e estimar a produção de feijão usando imagens RGB de UAV (JI et al., 2023). E além de usar o algoritmo RF, o perceptron multicamadas (MLP) pode ser incrementado para estimar altura da planta com base em imagens RGB de UAV (LIU et al., 2021).

Diversos estudos utilizaram o UAV como plataforma de sensoriamento remoto devido suas vantagens de flexibilidade, alta resolução espaço-temporal, alta taxa de sobreposição, baixo custo e mais acessível (ZHOU et al., 2020). Dessa forma, foi proposto neste estudo extrair informações de altura através de modelos digitais de elevação baseado em UAV em sete datas durante o crescimento da cultura do milho, compreendendo dados do início do estágio vegetativo até R1.

Técnicas fotogramétricas são usadas para construir modelos digitais da superfície terrestre e realizar medições geométricas a partir de imagens de UAV (BAI et al., 2022;

GILLIOT et al., 2020; KRAUS; WALDHAUSL, 1998; TAO et al., 2020). Após o processamento das imagens aéreas, conforme citado anteriormente, o modelo digital de elevação (DEM) obtido pela diferença entre o modelo digital de superfície e do terreno, foi utilizado para extraí as informações de altura da cultura do milho. Os resultados deste estudo para a estimativa de altura de planta são semelhantes aos resultados encontrados por Hu et al. (2018) e Zhang et al. (2018), demonstrando que o DEM foi uma variável consistente e segura para estimar altura da vegetação. Contudo, no início do crescimento da cultura do milho, a altura da planta no campo era maior que a altura extraída do DEM, indicando uma tendência dos modelos digitais em subestimar as alturas.

A possível causa desse fato pode ser a forma que foi realizada a avaliação manual, já que considera a altura do dossel como a distância vertical entre a inserção da folha bandeira e a superfície do solo. Além disso, os pontos da nuvem densificada gerados pelas imagens de UAV podem capturar toda a informação de altura na superfície, incluindo estruturas morfológicas inferiores da planta. Isso também foi encontrado por Niu et al. (2019), usaram imagens UAV RGB para extrair a altura de plantas de milho e ao fazer a comparação com a altura observada no campo, os valores estimados foram relativamente inferiores. A razão desse efeito pode ter sido a limitação da precisão da nuvem de pontos densificada, em detectar o ponto mais da planta de milho (WALTER et al., 2019). Uma alternativa para melhorar a qualidade das informações extraídas do DEM, é distribuir mais GCPs dentro da área de estudo, minimizando o erro do modelo e melhorando a precisão espacial (HE et al., 2018).

Vale enfatizar que neste estudo, nos estádios iniciais de desenvolvimento da cultura os valores de altura da planta obtidos pelo UAV não representaram a altura observado no campo, mostrando que o modelo geral pode apresentar baixo desempenho se aplicados no início do ciclo do milho. No entanto, nos estádios posteriores até R1, o modelo pode apresentar maior precisão e acurácia na estimativa de altura, em função dos dados terem sidos coletados a partir dos 20 até 71 DAS. Isso também foi relatado por Trevisan et al. (2023) na qual o modelo obteve melhor desempenho quando foi utilizado os dados coletados até e incluindo a floração ( $R^2 = 0,85$ ), realizando a estimativa de altura de aveia preta através de DMS e IVs baseados em RGB. Além disso, a falta de fechamento do dossel pode ter provocado valores de altura da planta subestimados nos estádios iniciais, já que o modelo digital tem que considerar as informações contidas no nível da folha. Portanto, imagens com baixa resolução espacial pode apresentar valores não representativos da área (GEIPEL et al., 2014).

O grande desafio de estimar altura de planta em larga escala é encontrar um método eficiente e preciso. Dessa forma, este estudo propôs incrementar dados de índices de vegetação, do DEM e diferentes algoritmos de ML para estimativa de altura de planta. E com os resultados obtidos pelo modelo de RF ( $R^2 = 0,97$ , RMSE = 14,62 cm e  $r = 0,99$ ) pode ser uma alternativa satisfatória para posteriormente substituir as avaliações realizadas manualmente no campo, que tradicionalmente é realizada de forma manual no campo com auxílio de uma régua ou trena para as culturas comerciais de porte curto como milho, soja, arroz e trigo (HU et al., 2018).

Quando apenas os dados dos índices de vegetação (entrada 3) foram usadas como entrada para os modelos, os valores de RMSE dos modelos de RF e KNN foram menores em relação as outras duas configurações de entrada e obtiveram melhor acurácia que no resultado encontrado por Osco et al. (2020) que os modelos de RF (RMSE = 16,7 cm) e KNN (RMSE = 19,4 cm) apresentaram bons desempenhos apenas no conjunto de dados de IVs. Bem como apresentado por Teodoro et al. (2021), ao realizarem a estimativa de altura da planta de soja usando aprendizado de máquina, observaram que o modelo de RF superou os demais (SVM e LR) considerando apenas os IVs como parâmetros de entrada, dentre os índices, o NDVI, NDRE e GNDVI também usados no presente trabalho.

Logo, quando a altura de planta de UAV foi combinada aos IVs (entrada 2) houve um ligeiro incremento de 3% e 11% nos valores de RMSE para os algoritmos RF e KNN, respectivamente (FIGURA 5). De modo similar, foi observado redução de 33% (RF) e 29% (KNN) na acurácia quando utilizado somente a altura de planta de UAV como entrada (entrada 1). Os algoritmos RF e KNN apresentaram bom desempenho pois se adequam a dados com padrões complexos e não lineares. Especialmente o RF que é menos propenso a ocorrência de overfitting (LIU et al., 2023).

Os resultados obtidos pelos modelos de LR demonstrou melhor desempenho que os encontrados no estudo de Li et al. (2016), na qual usaram imagens de UAV e regressão linear para as medições de campo ( $R^2 = 0,88$ ) e forte correlação entre altura observado e estimada. Porém, ao usar os índices de vegetação como entrada neste trabalho, o LR teve a menor precisão e acurácia ( $R^2 = 0,74$  e RMSE = 44,13 cm) quando comparado com os demais algoritmos. Isso pode ter ocorrido em função do modelo LR não apresentar flexibilidade com dados não paramétricos, o que dificulta capturar a não linearidade e complexidade dos dados (YU et al., 2021), resultando em baixo desempenho nas estimativas.

## 5 CONCLUSÃO

De modo geral, este estudo demonstrou a viabilidade de imagens baseadas em UAV, sensoriamento remoto orbital e diferentes algoritmos de aprendizado de máquina para estimar a altura de planta no campo com precisão. Além disso, os resultados obtidos indicam que plataforma UAV com câmera RGB pode ser uma alternativa para as avaliações de altura realizadas manualmente no campo e produtores e pesquisadores podem utilizar esse tipo de tecnologia para o monitoramento do crescimento da cultura do milho.

Os algoritmos RF e KNN tiveram o desempenho semelhante e uma assimilação com as configurações de entrada para  $R^2$ , RMSE e  $r$  entre os valores observados e estimados para a característica agrônômica altura de planta. Neste estudo, o algoritmo RF teve melhor desempenho ( $R^2 = 0,97$  e RMSE = 14,62 cm) seguido do algoritmo KNN ( $R^2 = 0,97$  e RMSE = 14,66 cm) ao considerar somente os índices de vegetação NDVI, NDRE e GNDVI como parâmetros de entrada. Da mesma forma ocorreu quando utilizado a configuração composta por UAV Height e IVs, o algoritmo RF teve boa precisão e acurácia ( $R^2 = 0,97$  e RMSE = 15,07 cm). E quando usado somente a UAV Height como entrada, o modelo de SVM obteve precisão de  $R^2 = 0,95$  e RMSE = 19,39 cm. Os IVs NDVI, NDRE e GNDVI derivados de imagens do PlanetScope tiveram correlação significativa com altura de planta de milho ( $r = 0,80$ ,  $r = 0,78$  e  $r = 0,81$ , respectivamente).

## REFERÊNCIAS

- BAI, D; LI, D; ZHAO, C; WANG, Z; SHAO, M; GUO, B; LIU, Y; WANG, Q; LI, J; GUO, S; WANG, R; LI, Y; QIU, L; JIN, X. Estimation of soybean yield parameters under lodging conditions using RGB information from unmanned aerial vehicles. **Frontiers In Plant Science**, v. 13, 2022. Frontiers Media SA. <http://dx.doi.org/10.3389/fpls.2022.1012293>.
- BARBOZA, T. O. C; ARDIGUERI, M; SOUZA, G. F. C; FERRAZ, M. A. J; GAUDENCIO, J. R. F; SANTOS, A. F. dos. Performance of Vegetation Indices to Estimate Green Biomass Accumulation in Common Bean. **Agriengineering**, v. 5, n. 2, p. 840-854, 4 maio 2023. MDPI AG. <http://dx.doi.org/10.3390/agriengineering5020052>.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001. Springer Science and Business Media LLC. <http://dx.doi.org/10.1023/a:1010933404324>.
- CAVALCANTI, V. P; SANTOS, A. F. dos; RODRIGUES, F. A; TERRA, W. C; ARAUJO, R. C; RIBEIRO, C. R; CAMPOS, V. P; RIGOBELLO, E. C; MEDEIROS, F. H. V; DÓRIA, J. Use of RGB images from unmanned aerial vehicle to estimate lettuce growth in root-knot

nematode infested soil. **Smart Agricultural Technology**, v. 3, p. 100100, fev. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.atech.2022.100100>.

CORTE, A. P. D; SOUZA, D. V; REX, F. E; SANQUETTA, C. R; MOHAN, M; SILVA, C. A; ZAMBRANO, A. M. A; PRATA, G; ALMEIDA, D. R. A. de; TRAUTENMULLER, J. W; KLAUBERG, C; MORAES, A. de; SANQUETTA, M. N; WILKINSON, B; BROADBENT, E. N. Forest inventory with high-density UAV-Lidar: machine learning approaches for predicting individual tree attributes. **Computers And Electronics In Agriculture**, v. 179, p. 105815, dez. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105815>.

CORTES, C; VAPNIK, V. Support-Vector Networks. **Machine Learning**, v. 20, n. 3, p. 273-297, 1995. Springer Science and Business Media LLC. <http://dx.doi.org/10.1023/a:1022627411411>.

COVER, T; HART, P. Nearest neighbor pattern classification. **Ieee Transactions On Information Theory**, v. 13, n. 1, p. 21-27, jan. 1967. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tit.1967.1053964>.

CHE, Y; WANG, Q; XIE, Z; ZHOU, L; LI, S; HUI, F; WANG, X; LI, B; MA, Y. Estimation of maize plant height and leaf area index dynamics using an unmanned aerial vehicle with oblique and nadir photography. **Annals Of Botany**, v. 126, n. 4, p. 765-773, 20 maio 2020. Oxford University Press (OUP). <http://dx.doi.org/10.1093/aob/mcaa097>.

DU, L; YANG, H; SONG, X; WEI, N; YU, C; WANG, W; ZHAO, Y. Estimating leaf area index of maize using UAV-based digital imagery and machine learning methods. **Scientific Reports**, v. 12, n. 1, 24 set. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-022-20299-0>.

ESA, European Space Agency. PlanetScope. 2023. Available online: <https://earth.esa.int/eogateway/missions/planetscope>. Accessed on: 27 february 2023.

FENG, L; ZHANG, Z; MA, Y; DU, Q; WILLIAMS, P; DREWRY, J; LUCK, B. Alfalfa Yield Prediction Using UAV-Based Hyperspectral Imagery and Ensemble Learning. **Remote Sensing**, v. 12, n. 12, p. 2028, 24 jun. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12122028>.

FOLONI, J. S. S; CALONEGO, J. C; CATUCHI, T. A; BELLEGGIA, N. A; TIRITAN, C. S; BARBOSA, A. de M. Cultivares de milho em diferentes populações de plantas com espaçamento reduzido na safrinha. **Revista Brasileira de Milho e Sorgo**, v. 13, n. 3, p. 312-325, 2014. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/128140/1/cultivares-de-milho.pdf>. Accessed on: 9 abr. 2023.

GARCIA, E. M; ALBERTI, M. G; ÁLVAREZ, A. A. A. Measurement-While-Drilling Based Estimation of Dynamic Penetrometer Values Using Decision Trees and Random Forests. **Applied Sciences**, v. 12, n. 9, p. 4565, 30 abr. 2022. MDPI AG. <http://dx.doi.org/10.3390/app12094565>.



GEIPEL, J; LINK, J; CLAUPEIN, W. Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System. **Remote Sensing**, v. 6, n. 11, p. 10335-10355, 27 out. 2014. MDPI AG. <http://dx.doi.org/10.3390/rs61110335>.

GILLIOT, J. M; MICHELIN, J; HADJARD, D; HOUOT, S. An accurate method for predicting spatial variability of maize yield from UAV-based plant height estimation: a tool for monitoring agronomic field experiments. **Precision Agriculture**, v. 22, n. 3, p. 897-921, 20 out. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-020-09764-w>.

GITELSON, A. A; KAUFMAN, Y. J; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, n.3, p.289-298, Dec 1996. DOI. 10.1016/S0034-4257(96)00072-7.

GITELSON, A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. **Journal Of Photochemistry And Photobiology B: Biology**, v. 22, n. 3, p. 247-252, mar. 1994. Elsevier BV. [http://dx.doi.org/10.1016/1011-1344\(93\)06963-4](http://dx.doi.org/10.1016/1011-1344(93)06963-4).

GUO, T; FANG, Y; CHENG, T; TIAN, Y; ZHU, Y; CHEN, Q; QIU, X; YAO, X. Detection of wheat height using optimized multi-scan mode of LiDAR during the entire growth stages. **Computers And Electronics In Agriculture**, v. 165, p. 104959, out. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2019.104959>.

HE, F; ZHOU, T; XIONG, W; HASHEMINNASAB, S; HABIB, A. Automated Aerial Triangulation for UAV-Based Mapping. **Remote Sensing**, v. 10, n. 12, p. 1952, 4 dez. 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10121952>.

HU, P; CHAPMAN, S. C; WANG, X; POTGIETER, A; DUAN, T; JORDAN, D; GUO, Y; ZHENG, B. Estimation of plant height using a high throughput phenotyping platform based on unmanned aerial vehicle and self-calibration: example for sorghum breeding. **European Journal Of Agronomy**, v. 95, p. 24-32, abr. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.eja.2018.02.004>.

JAMES, G; WITTEN, D; HASTIE, T; TIBSHIRANI, R. (2013). An introduction to statistical learning: with applications in R (1st ed.). Springer.

JI, Y; LIU, R; XIAO, Y; CUI, Y; CHEN, Z; ZONG, X; YANG, T. Faba bean above-ground biomass and bean yield estimation based on consumer-grade unmanned aerial vehicle RGB images and ensemble learning. **Precision Agriculture**, 28 fev. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-023-09997-5>.

JUNG, J; MAEDA, M; CHANG, A; BHANDARI, M; ASHAPURE, A; LANDIVAR-BOWLES, J. The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. **Current Opinion In Biotechnology**, v. 70, p. 15-22, ago. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.copbio.2020.09.003>.

JURGIEL, B. (2020). Point Sampling Tool [Github repository]. Available online: <<https://github.com/borysiasty/pointsamplingtool>>.

KARASIAK, N. (2020). dzetsaka: Classification tool [Github repository]. Available online: <<https://github.com/nkarasiak/dzetsaka/>>.

KRAUS, K; WALDHAUSL, P. **Manuel de photogrammétrie: principes et procédés fondamentaux**. Paris: Hermes, 1998.

LETSOIN, S. M. A; GUTH, D; HERAK, D; PURWESTRI, R. C. Analysing Maize Plant Height Using Unmanned Aerial Vehicle (UAV) RGB based on Digital Surface Models (DSM). **Iop Conference Series: Earth and Environmental Science**, v. 1187, n. 1, p. 012028, 1 maio 2023. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/1187/1/012028>.

LI, F; MIAO, Y; CHEN, X; SUN, Z; STUEVE, K; YUAN, F. In-Season Prediction of Corn Grain Yield through PlanetScope and Sentinel-2 Images. **Agronomy**, v. 12, n. 12, p. 3176, 15 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12123176>.

LI, M; ZHAO, J; YANG, X. Building a new machine learning-based model to estimate county-level climatic yield variation for maize in Northeast China. **Computers And Electronics In Agriculture**, v. 191, p. 106557, dez. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106557>.

LI, W; NIU, Z; CHEN, H; LI, D; WU, M; ZHAO, W. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system. **Ecological Indicators**, v. 67, p. 637-648, ago. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.ecolind.2016.03.036>.

LIAKOS, K; BUSATO, P; MOSHOU, D; PEARSON, S; BOCHTIS, D. Machine Learning in Agriculture: a review. **Sensors**, v. 18, n. 8, p. 2674, 14 ago. 2018. MDPI AG. <http://dx.doi.org/10.3390/s18082674>.

LIU, B; LIU, Y; HUANG, G; JIANG, X; LIANG, Y; YANG, C; HUANG, L. Comparison of yield prediction models and estimation of the relative importance of main agronomic traits affecting rice yield formation in saline-sodic paddy fields. **European Journal Of Agronomy**, v. 148, p. 126870, ago. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.eja.2023.126870>.

LIU, W; LI, Y; LIU, J; JIANG, J. Estimation of Plant Height and Aboveground Biomass of *Toona sinensis* under Drought Stress Using RGB-D Imaging. **Forests**, v. 12, n. 12, p. 1747, 10 dez. 2021. MDPI AG. <http://dx.doi.org/10.3390/f12121747>.

LUO, S; LIU, W; ZHANG, Y; WANG, C; XI, X; NIE, S; MA, D; LIN, Y; ZHOU, G. Maize and soybean heights estimation from unmanned aerial vehicle (UAV) LiDAR data. **Computers And Electronics In Agriculture**, v. 182, p. 106005, mar. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106005>.

NIU, Y; ZHANG, L; ZHANG, H; HAN, W; PENG, X. Estimating Above-Ground Biomass of Maize Using Features Derived from UAV-Based RGB Imagery. **Remote Sensing**, v. 11, n. 11, p. 1261, 28 maio 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11111261>.

NUTT, A. T; BATSELL, R. R. (1973). Multiple linear regression: A realistic reflector. *Data Analysis*, 19, 21.

OSCO, L. P; MARCATO JUNIOR, J; RAMOS, A. P. M; FURUYA, D. E. G; SANTANA, D. C; TEODORO, L. P. R; GONÇALVES, W. N; BAIIO, F. H. R; PISTORI, H; SILVA JUNIOR, C. A. da; TEODORO, P. E. Leaf Nitrogen Concentration and Plant Height Prediction for Maize Using UAV-Based Multispectral Imagery and Machine Learning Techniques. **Remote Sensing**, v. 12, n. 19, p. 3237, 5 out. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12193237>.

PHINZI, K; ABRIHA, D; SZABÓ, S. Classification Efficacy Using K-Fold CrossValidation and Bootstrapping Resampling Techniques on the Example of Mapping Complex Gully Systems. **Remote Sensing**, v. 13, n. 15, p. 2980, 28 jul. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13152980>.

PLANET. Planet Imagery Product Specification. 2020. Available online: <[https://assets.planet.com/marketing/PDF/Planet\\_Surface\\_Reflectance\\_Technical\\_White\\_Paper.pdf](https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf)>. Accessed on: 27 february 2023.

PYTHON Software Foundation. Python Language Site: Documentation, 2023. Página de documentação. Available online: < <https://docs.python.org/pt-br/3/reference/index.html>>. Accessed on: 27 february 2023.

QIAO, L; GAO, D; ZHAO, R; TANG, W; AN, L; LI, M; SUN, H. Improving estimation of LAI dynamic by fusion of morphological and vegetation indices based on UAV imagery. **Computers And Electronics In Agriculture**, v. 192, p. 106603, jan. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106603>.

QGIS Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation Project. 2023. Available online: <<http://qgis.osgeo.org>>. Accessed on: 27 february 2023.

RODRIGUEZ-PUERTA, F; PONCE, R. A; PÉREZ-RODRÍGUEZ, F; ÁGUEDA, B; MARTÍN-GARCÍA, S; MARTÍNEZ-RODRIGO, R; LIZARRALDE, I. Comparison of Machine Learning Algorithms for Wildland-Urban Interface Fuelbreak Planning Integrating ALS and UAV-Borne LiDAR Data and Multispectral Images. **Drones**, v. 4, n. 2, p. 21, 11 jun. 2020. MDPI AG. <http://dx.doi.org/10.3390/drones4020021>.

ROKACH, L; MAIMON, O. Decision Trees. **Data Mining And Knowledge Discovery Handbook**, p. 165-192, 2005. Springer-Verlag. [http://dx.doi.org/10.1007/0-387-25465-x\\_9](http://dx.doi.org/10.1007/0-387-25465-x_9).

ROUSE, J. W; HAAS, R. H; SCHEEL, J. A; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In Proceedings of the Third Earth Resource Technology Satellite (ERTS) Symposium, Washington, DC, USA, 10–14 December 1974.

RUEDA-AYALA, V; PENA, J; HoGLIND, M; BENGOCHEA-GUEVARA, J; ANDOJAR, D. Comparing UAV-Based Technologies and RGB-D Reconstruction Methods for Plant Height and Biomass Monitoring on Grass Ley. **Sensors**, v. 19, n. 3, p. 535, 28 jan. 2019. MDPI AG. <http://dx.doi.org/10.3390/s19030535>.

SCHWALBERT, R. A; AMADO, T; CORASSA, G; POTT, L. P; PRASAD, P. V. V; CIAMPITTI, I. A. Satellite-based soybean yield forecast: integrating machine learning and weather data for improving crop yield prediction in southern Brazil. **Agricultural And Forest Meteorology**, v. 284, p. 107886, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.agrformet.2019.107886>.

SOUZA, J. B. C; ALMEIDA, S. L. H. de; OLIVEIRA, M. F. de; SANTOS, A. F. dos; BRITO FILHO, A. L. de; MENESES, M. D; SILVA, R. P. da. Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. **Agronomy**, v. 12, n. 7, p. 1512, 24 jun. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12071512>.

TAO, H; FENG, H; XU, L; MIAO, M; YANG, G; YANG, X; FAN, L. Estimation of the Yield and Plant Height of Winter Wheat Using UAV-Based Hyperspectral Images. **Sensors**, v. 20, n. 4, p. 1231, 24 fev. 2020. MDPI AG. <http://dx.doi.org/10.3390/s20041231>.

TEDESCO, D; OLIVEIRA, M. F. de; SANTOS, A. F. dos; SILVA, E. H. C; ROLIM, G. de S; SILVA, R. P. da. Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons. **European Journal Of Agronomy**, v. 129, p. 126337, set. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.eja.2021.126337>.

TEODORO, P. E; TEODORO, L. P. R; BAIIO, F. H. R; SILVA JUNIOR, C. A. da; SANTOS, R. G. dos; RAMOS, A. P. M; PINHEIRO, M. M. F; OSCO, L. P; GONÇALVES, W. N; CARNEIRO, A. M; JUNIOR, J. M; PISTORI, H; SHIRATSUCHI, L. S. Predicting Days to Maturity, Plant Height, and Grain Yield in Soybean: a machine and deep learning approach using multispectral data. **Remote Sensing**, v. 13, n. 22, p. 4632, 17 nov. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13224632>.

TREVISAN, L. R; BRICHI, L; GOMES, T. M; ROSSI, F. Estimating Black Oat Biomass Using Digital Surface Models and a Vegetation Index Derived from RGB-Based Aerial Images. **Remote Sensing**, v. 15, n. 5, p. 1363, 28 fev. 2023. MDPI AG. <http://dx.doi.org/10.3390/rs15051363>.

WALTER, J. D. C; EDWARDS, J; MCDONALD, G; KUCHEL, H. Estimating Biomass and Canopy Height With LiDAR for Field Crop Breeding. **Frontiers In Plant Science**, v. 10, 26 set. 2019. Frontiers Media SA. <http://dx.doi.org/10.3389/fpls.2019.01145>.

WANG, D; WAN, B; LIU, J; SU, Y; GUO, Q; QIU, P; WU, X. Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery. **International Journal Of Applied Earth Observation And Geoinformation**, v. 85, p. 101986, mar. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2019.101986>.

WANG, X; ZHANG, R; SONG, W; HAN, L; LIU, X; SUN, X; LUO, M; CHEN, K; ZHANG, Y; YANG, H; YANG, G; ZHAO, Y; ZHAO, J. Dynamic plant height QTL revealed in maize through remote sensing phenotyping using a high-throughput unmanned aerial vehicle (UAV). **Scientific Reports**, v. 9, n. 1, 5 mar. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-019-39448-z>.

YOOSEFZADEH-NAJAFABADI, M; EARL, H J; TULPAN, D; SULIK, J; ESKANDARI, M. Application of Machine Learning Algorithms in Plant Breeding: predicting yield from hyperspectral reflectance in soybean. **Frontiers In Plant Science**, v. 11, p. 9-99, 12 jan. 2021. Frontiers Media SA. <http://dx.doi.org/10.3389/fpls.2020.624273>.

YU, D; ZHA, Y; SUN, Z; LI, J; JIN, X; ZHU, W; BIAN, J; MA, L; ZENG, Y; SU, Z. Deep convolutional neural networks for estimating maize above-ground biomass using multi-source UAV images: a comparison with traditional machine learning algorithms. **Precision Agriculture**, v. 24, n. 1, p. 92-113, 2 jul. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11119-022-09932-0>.

YU, J; WANG, J; LEBLON, B. Evaluation of Soil Properties, Topographic Metrics, Plant Height, and Unmanned Aerial Vehicle Multispectral Imagery Using Machine Learning Methods to Estimate Canopy Nitrogen Weight in Corn. **Remote Sensing**, v. 13, n. 16, p. 3105, 6 ago. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13163105>.

ZAMRI, N; PAIRAN, M. A; AZMAN, W. N. A. W; ABAS, S. S; ABDULLAH, L; NAIM, S; TARMUDI, Z; GAO, M. A comparison of unsupervised and supervised machine learning algorithms to predict water pollutions. **Procedia Computer Science**, v. 204, p. 172-179, 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.procs.2022.08.021>.

ZHANG, H; SUN, Y; CHANG, L; QIN, Y; CHEN, J; QIN, Y; DU, J; YI, S; WANG, Y. Estimation of Grassland Canopy Height and Aboveground Biomass at the Quadrat Scale Using Unmanned Aerial Vehicle. **Remote Sensing**, v. 10, n. 6, p. 851, 31 maio 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10060851>.

ZHAO, J; PAN, F; XIAO, X; HU, L; WANG, X; YAN, Y; ZHANG, S; TIAN, B; YU, H; LAN, Y. Summer Maize Growth Estimation Based on Near-Surface Multi-Source Data. **Agronomy**, v. 13, n. 2, p. 532, 12 fev. 2023. MDPI AG. <http://dx.doi.org/10.3390/agronomy13020532>.

ZHOU, L; GU, X; CHENG, S; YANG, G; SHU, M; SUN, Q. Analysis of Plant Height Changes of Lodged Maize Using UAV-LiDAR Data. **Agriculture**, v. 10, n. 5, p. 146, 1 maio 2020. MDPI AG. <http://dx.doi.org/10.3390/agriculture10050146>.