

**UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
FACULDADE DE MEDICINA VETERINÁRIA E ZOOTECNIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA ANIMAL  
CURSO DE DOUTORADO**

**SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO E  
CARACTERIZAÇÃO DE CULTURAS DE INTERESSE  
ZOOTÉCNICO**

*Remote sensing in-identification and characterization of cultures of interest zootechnical*

**JULIANA OLIVEIRA BATISTOTI**

CAMPO GRANDE, MS

2023

BATISTOTI, J. O.	SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO E CARACTERIZAÇÃO DE CULTURAS DE INTERESSE ZOOTÉCNICO	2023
------------------	--	------

**JULIANA OLIVEIRA BATISTOTI**

# **SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO E CARACTERIZAÇÃO DE CULTURAS DE INTERESSE ZOOTÉCNICO**

*Remote sensing in-identification and characterization of cultures of interest zootechnical*

Tese apresentada ao Programa de Pós-graduação em  
Ciência Animal da Faculdade de Medicina  
Veterinária e Zootecnia da Universidade Federal de  
Mato Grosso do Sul, como requisito para obtenção do  
título de Doutor em Ciência Animal.

Área de concentração: Produção Animal.

Linha de pesquisa: Forragicultura e Pastagens.

Orientador: Prof. Dr. Alexandre Menezes Dias

Co-orientador: Prof. Dr. José Marcato Júnior/ Dra.  
Carolina Marques Costa Araujo

CAMPO GRANDE, MS

2023

### **Dedicatória**

A Deus, NOSSO SENHOR por me conceber à vida e zelar por ela;

A minha mãe Cleuza de Oliveira Alegre, pela dedicação, à minha educação;

Ao meu filho Arthur Batistoti Santana, que me fez mais forte desde seu nascimento.

Ao meu amado marido João Paulo Gomes de Santana Silva, por tamanha paciência, carinho, amor e companheirismo.

**Dedico!**



**Certificado de aprovação**

JULIANA OLIVEIRA BATISTOTI

**SENSORIAMENTO REMOTO NA IDENTIFICAÇÃO E CARACTERIZAÇÃO DE  
CULTURAS DE INTERESSE ZOOTÉCNICO**

**REMOTE SENSING IN-IDENTIFICATION AND CHARACTERIZATION OF CULTURES OF INTEREST  
ZOOTECHNICAL**

Tese apresentada à Universidade Federal de Mato Grosso do Sul, como requisito para obtenção do título de Doutora em Ciência Animal. Área de concentração: Produção Animal.

Aprovado em: 14-12-2023

BANCA EXAMINADORA:

---

Dr. Alexandre Menezes Dias  
(UFMS) – Presidente

---

Dra. Carolina Marques Costa  
(UFGD)

---

Dra. Eva Nara Oliveira Gomes  
(CONEAGRO)

---

Dr. Gelson dos Santos Difante  
(UFMS)

---

Dr. Jose Marcato Junior  
(UFMS)

---

Dra. Luciana Junges  
(SENAR MS)

---

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Carolina Marques Costa, Usuário Externo**, em 18/12/2023, às 15:45, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Alexandre Menezes Dias, Professor do Magisterio Superior**, em 18/12/2023, às 17:18, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **EVA NARA OLIVEIRA GOMES, Usuário Externo**, em 19/12/2023, às 09:38, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Gelson dos Santos Difante, Professor do Magisterio Superior**, em 19/12/2023, às 16:33, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **LUCIANA JUNGES, Usuário Externo**, em 22/01/2024, às 20:09, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA  
MÁXIMA  
NO MEC

UFMS  
É 10!!!



Documento assinado eletronicamente por **Jose Marcato Junior, Professor do Magisterio Superior**, em 23/01/2024, às 14:07, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufms.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4553291** e o código CRC **17322C6B**.

## AGRADECIMENTOS

A Deus, que orienta a minha vida, concedendo saúde, alegria, forças e vontade de não desistir os meus sonhos.

Ao meu amado marido João Paulo Gomes de Santana Silva, pela paciência, incentivo e muito amor.

A minha mãe Cleuza de Oliveira Alegre, pelo amor incondicional, apoio e dedicação para comigo e com meus estudos.

Ao meu orientador Prof. Dr. Alexandre Menezes Dias, pela orientação, paciência, humildade, profissionalismo, ensinamentos e incentivos na pesquisa, minha expressiva gratidão.

Aos meus coorientadores José Marcato Junior e Carolina Marques Costa Araujo, pela coorientação, atenção e todos conhecimentos compartilhados, vai a minha expressiva gratidão.

À Universidade Federal de Mato Grosso do Sul (UFMS) - Faculdade de Medicina Veterinária e Zootecnia (FAMEZ), pela oportunidade concebida e pela formação, meu muito obrigada.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pelo apoio financeiro durante todo o período de estudos e apoio para realização deste trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Aos professores do Programa de Pós-graduação em Ciência Animal, por todos os ensinamentos, carinho, paciência e profissionalismo, minha expressiva gratidão.

Aos grupos de Forragicultura e Pastagens e Grupo de Estudo em Forragicultura (GEFOR), Anderson Ramires Candido, Eva Nara Oliveira Gomes, Luciana Junges, Amarildo Pedro da Silva, Iesa Pereira, Pamela Kerlyane Tomaz, Fernanda de Kássia Gomes, Jessica da Silva Batista, Rafael de Oliveira Lima, Jéssica Rodrigues, Marislayne de Gusmão, Juliana Caroline Santana e Antonio Leandro, pela amizade, todos conhecimentos compartilhados, paciência, humildade, apoio moral e material, incentivos nas pesquisas. Minha imensa gratidão.

Aos secretários dos programas de Pós-graduação em Ciência Animal e Ciência Veterinária (FAMEZ-UFMS), Ricardo de Oliveira dos Santos e Fernando Diogo Patez, pelo café quentinho, por todo apoio e paciência, meu muito obrigada.

E a todos aqueles que, de forma direta ou indiretamente, contribuíram para o meu êxito pessoal e profissional, meu muito obrigado.

**Muito obrigada!**

BATISTOTI, J.O. Sensoriamento remoto na identificação e caracterização de culturas de interesse zootécnico. 2023. Tese (Doutorado) – Faculdade de Medicina Veterinária e Zootecnia, Universidade Federal de Mato Grosso do Sul, Campo Grande – MS.

## RESUMO

O objetivo deste estudo é fornecer uma revisão integrativa sobre a utilização do sensoriamento remoto na identificação e caracterização de culturas de interesse zootécnico; e avaliar a precisão no modelo YOLO-v8 na detecção de plantas de milho. O primeiro capítulo teve como objetivo identificar as principais tecnologias utilizadas na diferenciação para caracterização agrônômica de culturas. O protocolo de revisão foi desenvolvido em que os termos de busca foram previamente testados e baseados na estratégia PVO, onde população (P): culturas milho (*Zea mays*), milheto (*Pennisetum sp.*) e sorgo (*Sorghum bicolor*); as variáveis (V) de interesse: foram tecnologias utilizadas na obtenção de imagens e metodologias aplicadas ao processamento; resultados (O): variáveis agrônômicas e diferenciação). A questão norteadora foi: Quais as principais tecnologias utilizadas na diferenciação das culturas milho, sorgo e milheto para caracterização agrônômica? As bases de dados utilizadas foram Scopus (Elsevier), Web of Science (Coleção principal), Science Direct e CAB direct e a busca foi realizada até 14 de setembro de 2022. A pesquisa identificou 585 artigos de pesquisa; no entanto, apenas 35 foram considerados elegíveis e incluídos devido à sua robustez metodológica para extração de dados. A cultura mais utilizada foi o milho (80,00%). Dentre os estudos as plataformas de sensoriamento remoto mais utilizadas na obtenção de imagens foram as baseadas em VANT (74,28%). Os softwares de processamento das imagens mais utilizados foram Agisoft Metashape (37,14%). As variáveis agrônômicas (82,85%) foram mais abordadas, sendo elas biomassa, altura e produtividade. No segundo capítulo o objetivo foi avaliar o modelo YOLO-v8 na detecção de plantas de milho em estágio inicial de crescimento a fim de potencializar a produção da cultura. Um conjunto de dados foi construído para avaliar o método selecionado, foi utilizada uma proporção de 60% dos dados para treinamento (338 recortes de imagem), 20% para teste (113 recortes de imagem) e 20% para validação (113 recortes de imagem), totalizando 564 recortes de imagens e 39765 rótulos. O valor de mAP<sub>0,5</sub> encontrado neste estudo foi 90,5 %, indicando que o método YOLO-v8, constitui uma abordagem promissora para o desenvolvimento de ferramentas para a estimativa de plantas de milho, e o monitoramento agrícola.

**Palavras-chave:** biomassa, detecção de objetos, métodos de revisão, milheto, milho, produtividade, satélite, sensoriamento remoto, sorgo, tecnologia, VANT



## ABSTRACT

The objective of this study is to provide an integrative review on the use of remote sensing in the identification and characterization of crops of zotechnical interest; and evaluate the accuracy of the YOLO-v8 model in detecting corn plants. The first chapter aimed to identify the main technologies used in differentiation for agronomic characterization of crops. The review protocol was developed in which the search terms were previously tested and based on the PVO strategy, where population (P): corn (*Zea mays*), millet (*Pennisetum* sp.) and sorghum (*Sorghum bicolor*) crops; the variables (V) of interest: were technologies used to obtain images and methodologies applied to processing; results (O): agronomic variables and differentiation). The guiding question was: What are the main technologies used to differentiate corn, sorghum and millet crops for agronomic characterization? The databases used were Scopus (Elsevier), Web of Science (Main Collection), Science Direct and CAB direct and the search was carried out until September 14, 2022. The search identified 585 research articles; however, only 35 were considered eligible and included due to their methodological robustness for data extraction. The most used crop was corn (80.00%). Among the studies, the remote sensing platforms most used to obtain images were those based on UAVs (74.28%). The most used image processing software was Agisoft Metashape (37.14%). Agronomic variables (82.85%) were most addressed, namely biomass, height and productivity. In the second chapter, the objective was to evaluate the YOLO-v8 model in detecting corn plants in the initial growth stage in order to enhance crop production. A data set was constructed to evaluate the selected method, a proportion of 60% of the data was used for training (338 image clippings), 20% for testing (113 image clippings) and 20% for validation (113 image clippings), totaling 564 image clippings and 39765 labels. The mAP0.5 value found in this study was 90.5%, indicating that the YOLO-v8 method constitutes a promising approach for developing tools for estimating corn plants and agricultural monitoring.

**Keywords:** biomass, corn, millet, object detection, remote sensing, review methods, satellite, sorghum, technology, UAV, yield.

## LISTA DE ILUSTRAÇÕES

### **CAPÍTULO 1 - Sensoriamento remoto para diferenciação e previsão das características produtivas do milho, milheto e sorgo: uma revisão integrativa.**

Figura 1 Termos usados na busca e seus respectivos sinônimos .....28

Figura 2 Fluxograma MOHER et al., 2012.....30

### **CAPÍTULO 2 - Agricultura de precisão: detecção de plantas de milho usando YOLOv8 para monitoramento aprimorado de culturas**

Figura 1 Localização da área experimental.....47

Figura 2 Processamento da imagem.....49

Figura 3 Comparação das imagens da posição das plantas rotuladas (pontos azuis) e imagens da posição das plantas previstas (pontos vermelhos) .....51

Figura 4 Desafios encontrados pelo modelo: (a) dificuldade de detecção nas bordas e (b) dificuldade de detecção devido ao baixo contraste na imagem.....52.

## LISTA DE TABELAS

### **CAPÍTULO 1 - Sensoriamento remoto para diferenciação e previsão das características produtivas do milho, milheto e sorgo: uma revisão integrativa.**

Tabela 1 Descritores utilizados em cruzamento único na pesquisa de alta sensibilidade para recuperação dos estudos com sensoriamento remoto na identificação e caracterização de culturas de interesse zootécnico

Tabela 2 Estudos realizados com Milho ..... 31

Tabela 3 Estudos realizados com Sorgo ..... 32

Tabela 4 Estudos realizados com Milheto ..... **Erro! Indicador não definido.**2

### **CAPÍTULO 2 - Agricultura de precisão: detecção de plantas de milho usando YOLOv8 para monitoramento aprimorado de culturas**

**Tabela 1** Resultados da detecção realizada pelo YOLO-v8x.....

## SUMÁRIO

INTRODUÇÃO .....	16
REFERÊNCIAS .....	20
<b>CAPÍTULO 1 - SENSORIAMENTO REMOTO PARA DIFERENCIAÇÃO E PREVISÃO DAS CARACTERÍSTICAS PRODUTIVAS DO MILHO, MILHETO E SORGO: UMA REVISÃO INTEGRATIVA .....</b>	<b>24</b>
RESUMO .....	24
ABSTRACT .....	25
1. INTRODUÇÃO .....	26
2. MÉTODOS .....	27
3. RESULTADOS .....	29
4. DISCUSSÃO .....	32
4.1. Estudos com Satélites .....	34
4.2. Estudos com Veículos Aéreos não tripulados (VANT).....	34
5. CONCLUSÃO .....	36
6. AGRADECIMENTOS .....	36
7. REFERÊNCIAS .....	36
<b>CAPÍTULO 2 – AGRICULTURA DE PRECISÃO: DETECÇÃO DE PLANTAS DE MILHO USANDO YOLO-v8 PARA MONITORAMENTO APRIMORADO DE CULTURAS.....</b>	<b>43</b>
RESUMO .....	43
ABSTRACT .....	44
1. INTRODUÇÃO .....	45
2. MATERIAL E MÉTODOS .....	46
2.1. Área experimental .....	46
2.2. Aquisição de dados.....	47
2.3. Método de detecção de objetos .....	48
2.4. Métricas de avaliação .....	50
3. RESULTADOS E DISCUSSÃO.....	50
3.1. Resultados quantitativos.....	50
3.2. Resultados qualitativos.....	50
4. CONCLUSÃO .....	52
6. REFERÊNCIAS .....	53
<b>CAPÍTULO 3 – UMA ABORDAGEM DA RNC PARA CONTAR PLANTAS SIMULTANEAMENTE E DETECTAR LINHAS DE PLANTAÇÃO A PARTIR DE IMAGENS DE VANT.....</b>	<b>56</b>
RESUMO.....	57

<b>CONSIDERAÇÕES FINAIS .....</b>	<b>59</b>
<b>APÊNDICE A.....</b>	<b>60</b>
<b>PROTOCOLO DO ESTUDO DE REVISÃO INTEGRATIVA.....</b>	<b>60</b>

## INTRODUÇÃO

Segundo Booth *et al.*, (2016) a revisão de literatura facilita a validação de uma hipótese específica e auxiliando na seleção de ferramentas, instrumentos ou escalas pertinentes para a pesquisa. Este processo garante a identificação das lacunas nos estudos existentes, destaca tópicos inexplorados e ajuda na formulação de perguntas precisas para uma investigação mais abrangentes.

Segundo Broome (2000) há diversos tipos de revisões de literatura que normalmente são publicadas, variando em escopo, objetivo, amplitude, complexidade e organização do material, são elas as revisões abreviadas, revisões metodológicas ou teóricas, análises críticas, revisões críticas, revisões integrativas e meta-análises.

Soares *et al.*, (2014) define revisão integrativa como um tipo de revisão de literatura que agrupa achados de estudos elaborados por meio de metodologias distintas, possibilitando aos revisores resumir resultados sem prejudicar a origem epistemológica dos estudos incluídos. Segundo Souza *et al.*, (2017) a avaliação da qualidade metodológica é composta por seis fases: 1) identificação do tema e seleção da hipótese; 2) estabelecimento de critérios para inclusão e exclusão de estudo; 3) definição das informações a serem extraídas dos estudos selecionados; 4) avaliação dos estudos incluídos na revisão integrativa; 5) interpretação dos resultados e; 6) apresentação da revisão pela síntese do conhecimento.

O *Food Outlook* da FAO prevê uma produção global recorde de grãos grossos (milho, sorgo, milheto, centeio, cevada e aveia) para 2023, cerca de 1513 milhões de toneladas, um aumento de 3% se comparado ao ano anterior. Esse crescimento está concentrado nos Estados Unidos, Brasil e União Européia. A previsão é que a produção global de milho tenha um crescimento de 4,2%, atingindo 1212 milhões de toneladas. Já a produção mundial de sorgo pode chegar a 60 milhões de toneladas, um aumento de 6,3% em relação ao ano anterior (FAO, 2023). No Brasil o milheto é utilizado para silagem, cobertura do solo, forragem e cultura de grãos, com aproximadamente 5 milhões de hectares plantados (DE ASSIS *et al.*, 2018).

As previsões de rendimento das culturas normalmente são realizadas a campo, onde a planta inteira ou uma parte é cortada e amostrada. Porém esta é uma medição destrutiva que demanda tempo, além do custo elevado (ALEBELE *et al.*, 2020; BAO *et al.*, 2019; HAN *et al.*, 2017; LI *et al.*, 2016). Além do que, as informações obtidas pelas

medições a campo são limitadas a pequenas áreas geográficas, podendo limitar a aplicabilidade a toda a estação de crescimento e estimar a produção agrícola em grandes áreas é de suma importância a produção de alimentos (BAHRAMI *et al.*, 2022).

O sensoriamento remoto é capaz de fornecer dados de monitoramento e mapeamento em escalas espaciais e temporais de culturas, que são difíceis de obter com abordagens a campo (GUERINI FILHO *et al.*, 2020, MANSARAY *et al.*, 2020, BAGHDADI *et al.*, 2009; TAO *et al.*, 2020, VILJANEN *et al.*, 2018, EITEL *et al.*, 2016; JIAO *et al.*, 2014).

A princípio, os dados obtidos de sensoriamento remoto necessitavam de sensores caros montados em plataformas complexas, assim o levantamento e processamento dos dados eram difíceis e longos. O aprimoramento dos sensores e dispositivos de aquisição dos dados, aliado ao aperfeiçoamento das plataformas de levantamento expandiram o uso de veículos aéreos não tripulados (VANT) em pesquisas de campo (VONG *et al.*, 2021).

Segundo Osco *et al.*, (2021) a utilização de VANTs no mapeamento de superfície apresenta vantagens em relação a outros métodos de sensoriamento remoto aéreo, como voar em baixas altitudes, flexibilidade de coleta de dados, produz alto nível de detalhamento sobretudo com baixo custo operacional, tornando esse sistema de obtenção acessível para exploração tanto comercial quanto científica. Além da possibilidade de incorporação de diferentes sensores que são capazes de coletar dados em áreas de difícil acesso.

Estes avanços permitem que sensores baseados em VANT sejam aplicados na avaliação de culturas (AHMAD *et al.*, 2021) estimativa de biomassa (BATISTOTI *et al.*, 2019; KUMAR *et al.*, 2015; LITHERLAND *et al.*, 2005), detecção precoce de doenças (TERENTEV *et al.*, 2022), inventário florestal (PIRES *et al.*, 2022) e avaliação de desastres naturais (WEISER *et al.*, 2022).

Nos últimos anos no campo da visão computacional pesquisadores tem se empenhado para permitir que os computadores simulem eficientemente o sistema visual humano, com objetivo de capacita-los na identificação de objetos de interesse em imagens e vídeos (OJO; ZAHID, 2022). O campo da visão computacional é constituído por subcampos que integram a detecção de objetos (YANG; YU, 2021), classificação de imagens (HUSSAIN, 2023) e a segmentação de objetos (HAUPT; NOWARK, 2006).

A detecção de objetos é um subcampo que tem se destacado dentro do âmbito da visão computacional (DIWAN; ANIRUDH; TEMBHURNE, 2023). Apresenta avanços significativos, em virtude do rápido desenvolvimento de métodos de aprendizagem

profunda. A detecção de objetos pode ser classificada em duas abordagens principais, modelos de detecção de dois estágios e modelos de detecção de estágio único (WANG *et al.*, 2023).

Segundo Diwan *et al.*, (2023) os detectores de objetos de dois estágios são focados na seleção de regiões por meio de uma arquitetura complexa, já os detectores de estágio único se concentram na região espacial, detectando objetos por meio de uma arquitetura mais simples de uma vez só. Os modelos de estágio único apresentam um processamento mais rápido em comparação com os modelos de dois estágios, porém, tendem a apresentar uma precisão relativamente menor (WANG *et al.*, 2023).

Modelos de dois estágios mais conhecidos são o Mask R-CNN (HE *et al.*, 2017) e o Fast R-CNN (GIRSHICK, 2015), já os modelos de estágio único, os mais utilizados são o RetinaNet (LIN *et al.*, 2017), Single Shot MultiBox Detector (SSD) (LIU *et al.*, 2016) e o You Only Look Once (YOLO) (REDMON *et al.*, 2016).

O YOLO desde a sua criação por Redmon *et al.*, (2016) até os dias atuais (2023), foram lançados oito variantes, sendo a mais atual o YOLO-v8. Ao longo desse período a arquitetura do modelo sofreu alterações a fim de garantir eficiência, melhor rendimento e superioridade as versões anteriores (HUSSAIN, 2023). Com isso, associar o sensoriamento remoto aos detectores de objetos em tempo real podem trazer muito benefícios ao monitoramento da produção agrícola, aumentando a eficiência e a capacidade de resposta no processo.

Com isso o objetivo deste estudo foi fornecer uma revisão integrativa sobre a utilização do sensoriamento remoto na identificação e caracterização de culturas de interesse zootécnico; e avaliar a precisão no modelo YOLO-v8 na detecção de plantas de milho. O presente estudo apresenta em sua estrutura os resultados obtidos por meio de três artigos científicos, conforme segue:

Artigo 1: Sensoriamento remoto para diferenciação e previsão das características produtivas do milho, milheto e sorgo: uma revisão integrativa.

Artigo 2: Agricultura de precisão: detecção de plantas de milho usando YOLO-v8 para monitoramento aprimorado de culturas.

Artigo 3: Uma abordagem da RCN para contar plantas e detectar simultaneamente linhas de cultivo a partir de imagens de VANT

Ambos os artigos foram adaptados às normas de elaboração de dissertações e teses do Programa de Pós-graduação em Ciência Animal (PPGCA-FAMEZ/UFMS). Vale destacar que o Artigo 3 é um estudo realizado em parceria com a Faculdade de Medicina



Veterinária e Zootecnia/UFMS; Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia/UFMS; e Faculdade de Engenharia e Arquitetura e Urbanismo/Unoeste.

## REFERÊNCIAS

- AHMAD, U.; ALVINO, A.; MARINO, S. Remote Sensing. *Remote Sens.* 2021, 13, 4155, doi:10.3390/rs13204155.
- ALEBELE, Y.; ZHANG, X.; WANG, W.; YANG, G.; YAO, X. Estimation of Canopy Biomass Components in Paddy Rice from Combined Optical and SAR Data Using. *Remote Sens.* 2020, 12, 1–22, doi:doi:10.3390/rs12162564.
- BAGHDADI, N.; BOYER, N.; TODOROFF, P.; EL, M.; BÉGUÉ, A. Remote Sensing of Environment Potential of SAR Sensors TerraSAR-X , ASAR / ENVISAT and PALSAR / ALOS for Monitoring Sugarcane Crops on Reunion Island. *Remote Sens. Environ.* 2009, 113, 1724–1738, doi:10.1016/j.rse.2009.04.005.
- BAHRAMI, H.; MCNAIRN, H.; MAHDIANPARI, M. A Meta-Analysis of Remote Sensing Technologies and Methodologies for Crop Characterization. *Remote Sens.* 2022, 14, 1–47, doi:https://doi.org/ 10.3390/rs14225633.
- BAO, N.; LI, W.; GU, X.; LIU, Y. Biomass Estimation for Semiarid Vegetation and Mine Rehabilitation Using Worldview-3 And. *Remote Sens.* 2019, 11, 2855, doi:doi:10.3390/rs11232855.
- BATISTOTI, J.; MARCATO, J.; ÍTAVO, L.; MATSUBARA, E.; GOMES, E.; OLIVEIRA, B.; SOUZA, M.; SIQUEIRA, H.; FILHO, G.S.; AKIYAMA, T.; ET AL. Estimating Pasture Biomass and Canopy Height in Brazilian Savanna Using UAV Photogrammetry. *Remote Sens.* 2019, 11. doi: 10.3390/rs11202447
- BOOTH, A.; SUTTON, A.; PAPAIOANNOU, D. *Systematic Approaches to a Successful Literature Review*; 2016; Vol. 34; ISBN 9781473912458.
- BROOME, M.E. *Integrative Literature Reviews for the Development of Concepts 2000.* [https://www.researchgate.net/publication/238248432\\_Integrative\\_literature\\_reviews\\_for\\_the\\_development\\_of\\_concepts](https://www.researchgate.net/publication/238248432_Integrative_literature_reviews_for_the_development_of_concepts)
- DE ASSIS, R.L.; DE FREITAS, R.S.; MASON, S.C. PEARL MILLET PRODUCTION PRACTICES in Brazil: A REVIEW. *Exp. Agric.* 2018, 54. doi: 10.1017/S0014479717000333
- DIWAN, T.; ANIRUDH, G.; TEMBHURNE, J. V. Object Detection Using YOLO: Challenges, Architectural Successors, Datasets and Applications. *Multimed. Tools Appl.* 2022, 82, 9243–9275, doi:10.1007/s11042-022-13644-y.
- EITEL, J.U.H.; MAGNEY, T.S.; VIERLING, L.A.; GREAVES, H.E.; ZHENG, G. Remote Sensing of Environment An Automated Method to Quantify Crop Height and Calibrate Satellite-Derived Biomass Using Hypertemporal Lidar. *Remote Sens. Environ.* 2016, 187, 414–422, doi:10.1016/j.rse.2016.10.044.
- FAO FOOD OUTLOOK 2010; 2023; ISBN 3906570541.
- GIRSHICK, R. Fast R-CNN. *Proc. IEEE Int. Conf. Comput. Vis.* 2015, 2015 Inter, 1440–1448, doi:10.1109/ICCV.2015.169.

- GUERINI FILHO, M.; KUPLICH, T.M.; QUADROS, F.L.F. DE Estimating Natural Grassland Biomass by Vegetation Indices Using Sentinel 2 Remote Sensing Data. *Int. J. Remote Sens.* 2020, 41, 2861–2876, doi:10.1080/01431161.2019.1697004.
- HAN, J.; WEI, C.; CHEN, Y.; LIU, W.; SONG, P.; HUANG, J. Mapping Above-Ground Biomass of Winter Oilseed Rape Using High Spatial Resolution Satellite Data at Parcel Scale under Waterlogging Conditions. *Remote Sens.* 2017, 9, 238, doi:10.3390/rs9030238.
- HE, K.; GKIOXARI, G.; DÓLLAR, P.; GIRSHICK, R. Mask R-CNN Ar. 2017, doi:https://doi.org/10.48550/arXiv.1703.06870.
- HUSSAIN, M. YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines* 2023, 11, doi:10.3390/machines11070677.
- JIAO, X.; KOVACS, J.M.; SHANG, J.; MCNAIRN, H.; WALTERS, D.; MA, B. ISPRS Journal of Photogrammetry and Remote Sensing Object-Oriented Crop Mapping and Monitoring Using Multi-Temporal Polarimetric RADARSAT-2 Data. *ISPRS J. Photogramm. Remote Sens.* 2014, 96, 38–46, doi:10.1016/j.isprsjprs.2014.06.014.
- KUMAR, L.; SINHA, P.; TAYLOR, S.; ALQURASHI, A.F. Review of the Use of Remote Sensing for Biomass Estimation to Support Renewable Energy Generation. *J. Appl. Remote Sens.* 2015, 9, 097696, doi:10.1117/1.jrs.9.097696.
- LI, F.; ZENG, Y.; LUO, J.; MA, R.; WU, B. Modeling Grassland Aboveground Biomass Using a Pure Vegetation Index. *Ecol. Indic.* 2016, 62, 279–288, doi:10.1016/j.ecolind.2015.11.005.
- LIN, T.; GOYAL, P.; GIRSHICK, R.; HE, K.; DÓLLAR, P. Fine-Tuning Pretrained Multilingual BERT Model for Indonesian Aspect-Based Sentiment Analysis. 2020 7th Int. Conf. Adv. Informatics Concepts, Theory Appl. ICAICTA 2020 2017, 2980–2988, doi:https://doi.org/10.48550/arXiv.1708.02002.
- LITHERLAND, N.B.; THIRE, S.; BEAULIEU, A.D.; REYNOLDS, C.K.; BENSON, J.A.; DRACKLEY, J.K. Dry Matter Intake Is Decreased More by Abomasal Infusion of Unsaturated Free Fatty Acids than by Unsaturated Triglycerides. *J. Dairy Sci.* 2005, 88, 632–643, doi:10.3168/jds.S0022-0302(05)72727-2.
- LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGEDY, C.; REED, S.; FU, C.Y.; BERG, A.C. SSD: Single Shot MultiBox Detector. *Eccv 2016*, 1, 21–37, doi:10.1007/978-3-319-46448-0\_2.
- MANSARAY, L.R.; KANU, A.S.; YANG, L.; HUANG, J.; WANG, F. Evaluation of Machine Learning Models for Rice Dry Biomass Estimation and Mapping Using Quad-Source Optical Imagery. *GIScience Remote Sens.* 2020, 57, 785–796, doi:10.1080/15481603.2020.1799546.
- OJO, M.O.; ZAHID, A. Deep Learning in Controlled Environment Agriculture: A Review of Recent Advancements, Challenges and Prospects. *Sensors (Basel)*. 2022, 22, doi:10.3390/s22207965.

OSCO, L.P.; MARCATO JUNIOR, J.; MARQUES RAMOS, A.P.; DE CASTRO JORGE, L.A.; FATHOLAH, S.N.; DE ANDRADE SILVA, J.; MATSUBARA, E.T.; PISTORI, H.; GONÇALVES, W.N.; LI, J. A Review on Deep Learning in UAV Remote Sensing. *Int. J. Appl. Earth Obs. Geoinf.* 2021, 102, doi: 10.1016/j.jag.2021.102456

PIRES, R.D.P.; OLOFSSON, K.; PERSSON, H.J.; LINDBERG, E.; HOLMGREN, J. ISPRS Journal of Photogrammetry and Remote Sensing Individual Tree Detection and Estimation of Stem Attributes with Mobile Laser Scanning along Boreal Forest Roads. *ISPRS J. Photogramm. Remote Sens.* 2022, 187, 211–224, doi:10.1016/j.isprsjprs.2022.03.004.

REDMON, J.; S., D.; GIRSHICH, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. *Joseph. ACM Int. Conf. Proceeding Ser.* 2016, doi:10.1145/3243394.3243692.

SOARES, C.B.; HOGA, L.A.K.; PEDUZZI, M.; SANGALETI, C.; YONEKURA, T.; SILVA, D.R.A.D. Integrative Review: Concepts and Methods Used in Nursing. *Rev. da Esc. Enferm.* 2014, 48, doi:10.1590/S0080-6234201400002000020.

SOUZA, L.M.; MARQUES-VIEIRA, C.M.A.; SEVERINO, S.S.P.; ANTUNES, A.. Metodologia de Revisão Integrativa Da Literatura Em Enfermagem. *Rev. Investig. em Enferm.* 2017, 17–26.

TAO, H.; FENG, H.; XU, L.; MIAO, M.; LI, H.L.; YUE, J.; LI, Z.; YANG, G.; YANG, X.; FAN, L. Estimation of Crop Growth Parameters Using UAV-Based Hyperspectral Remote Sensing Data. *Sensors (Switzerland)* 2020, 20, 1296, doi:10.3390/s20051296.

TERENTEV, A.; DOLZHENKO, V.; FEDOTOV, A. Current State of Hyperspectral Remote Sensing for Early Plant Disease Detection: A Review. *Sensors (Switzerland)* 2022, 22, 757, doi:https://doi.org/10.3390/s22030757.

VILJANEN, N.; HONKAVAARA, E. A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture* 2018, 8, 70, doi:10.3390/agriculture8050070.

VONG, A.; MATOS-CARVALHO, J.P.; TOFFANIN, P.; PEDRO, D.; AZEVEDO, F.; MOUTINHO, F.; GARCIA, N.C.; MORA, A. How to Build a 2D and 3D Aerial Multispectral Map?— All Steps Deeply Explained. *Remote Sens.* 2021, 13, 1–47, doi:https://doi.org/10.3390/rs13163227.

WANG, G.; CHEN, Y.; AN, P.; HONG, H.; HU, J.; HUANG, T. UAV-YOLOv8: A Small-Object-Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios. *Sensors* 2023, 23, doi:10.3390/s23167190.

WEISER, F.; BAUMANN, E.; JENTSCH, A.; MEDINA, M.; LU, M.; NOGALES, M.; BEIERKUHNLIN, C. Impact of Volcanic Sulfur Emissions on the Pine Forest Of forests 2022, 13, 299, doi:https://doi.org/ 10.3390/f13020299.

YANG, R.; YU, Y. Artificial Convolutional Neural Network in Object Detection and Semantic Segmentation for Medical Imaging Analysis. *Front. Oncol.* 2021, 11, 1–9, doi:10.3389/fonc.2021.638182.

## **CAPÍTULO 1 - SENSORIAMENTO REMOTO PARA DIFERENCIAÇÃO E PREVISÃO DAS CARACTERÍSTICAS PRODUTIVAS DO MILHO, MILHETO E SORGO: UMA REVISÃO INTEGRATIVA**

### **RESUMO**

O objetivo deste estudo foi identificar as principais tecnologias utilizadas na diferenciação para caracterização agrônômica de culturas de interesse zootécnico. O protocolo de revisão foi formulado com os termos de busca foram previamente testados e baseados na estratégia PVO para determinar a questão norteadora: população (P): culturas milho (*Zea mays*), milheto (*Pennisetum sp.*) e sorgo (*Sorghum bicolor*); as variáveis (V) de interesse: foram tecnologias utilizadas na obtenção de imagens e metodologias aplicadas ao processamento; resultados (O): variáveis agrônômicas e diferenciação). A questão norteadora foi a seguinte: quais as principais tecnologias utilizadas na diferenciação das culturas milho, sorgo e milheto para caracterização agrônômica? As bases de dados utilizadas foram Scopus (Elsevier), Web of Science (Coleção principal), Science Direct e CAB direct até 14 de setembro de 2022. A pesquisa identificou 585 artigos de pesquisa; no entanto, apenas 35 foram considerados elegíveis e incluídos devido à sua robustez metodológica para extração de dados. A cultura mais utilizada foi o milho (80%). Dentre os estudos as plataformas de sensoriamento remoto mais utilizadas na obtenção de imagens foram as baseadas em VANT (74,28%). O software de processamento das imagens mais utilizados foi Agisoft Metashape (37,14%). As variáveis agrônômicas (82,85%) foram mais abordadas nos artigos, sendo principais biomassa, altura e produtividade.

**Palavras-chave:** biomassa, culturas, produtividade, satélite, sensoriamento remoto, VANT

## ABSTRACT

The objective of this study was to identify the main technologies used in the differentiation for agronomic characterization of crops of zootechnical interest. The review protocol was formulated with search terms that were previously tested and based on the PVO strategy to determine the guiding question: population (P): crops corn (*Zea mays*), millet (*Pennisetum* sp.) and sorghum (*Sorghum bicolor*); the variables (V) of interest: were technologies used to obtain images and methodologies applied to processing; results (O): agronomic variables and differentiation). The guiding question was the following: what are the main technologies used to differentiate corn, sorghum and millet crops for agronomic characterization? The databases used were Scopus (Elsevier), Web of Science (Main Collection), Science Direct and CAB direct until September 14, 2022. The search identified 585 research articles; however, only 35 were considered eligible and included due to their methodological robustness for data extraction. The most used crop was corn (80%). Among the studies, the remote sensing platforms most used to obtain images were those based on UAVs (74.28%). The most used image processing software was Agisoft Metashape (37.14%). The agronomic variables (82.85%) were most covered in the articles, the main ones being biomass, height and productivity.

**Keywords:** biomass, crops, yield, satellite, remote sensing, UAV

## 1. INTRODUÇÃO

A produção e as exportações de milho do Brasil em 2021 atingiram 87 e 25 milhões de toneladas, respectivamente. Impulsionado pelo crescimento da produção de milho, o sorgo é outro grão que tende a registrar recorde na produção, com colheita de 2,1 milhões de toneladas (FAO, 2021). Já o milheto é muito utilizado como forragem, cobertura e cultura de grãos no Brasil, com aproximadamente 5 milhões de hectares semeados. O produto é utilizado na preparação de ração para animais e tem como principal vantagem ser mais resistente à estiagem (DE ASSIS *et al.*, 2018).

O sensoriamento remoto é um tema em alta nas pesquisas, em relação a aplicabilidade e casos de uso, em virtude da acessibilidade de conjunto de dados de sensoriamento remoto baseado em VANTs e satélites. Com isso estão sendo desenvolvidas pesquisas altamente ativas e multidisciplinares com o intuito de alcançar metodologias de aquisição capazes de monitorar e avaliar cenários do mundo real (JURADO *et al.*, 2022).

Essas tecnologias estão relacionadas a métodos eficientes e não destrutivos, que além de auxiliar com a distribuição precisa de plantas no campo, podem auxiliar no controle de plantas daninhas (SU, 2020), identificar e mitigar o efeito de doenças (IMAM *et al.*, 2022; SHAFI *et al.*, 2022), o que pode melhorar a eficácia dos pesticidas, mas também aumentar os benefícios econômicos e uso sustentável dos produtos agrícolas.

Avanços em sensoriamento remoto espacial podem ajudar a medir, modelar, mapear e monitorar culturas agrícolas de interesse zootécnico, fornecendo estimativas precisas da área de cultivo e rendimento agrícola (ANEECE & THENKABAIL, 2021).

No entanto, pouco se sabe sobre como o uso da interação de imagens com softwares de diferenciação das culturas podem contribuir para quantificar a produção a campo (LI *et al.*, 2022; MCFADDEN *et al.*, 2022, MAITAH *et al.*, 2021). A estimativa precisa do rendimento das culturas é essencial para otimizar a gestão agrônoma (produção de silagens e grãos), orientar o investimento e a formulação de políticas para reduzir a pobreza e melhorar a segurança alimentar (MAITAH *et al.*, 2021; ZHANG *et al.*, 2021).

O objetivo da revisão integrativa é apresentar as principais tecnologias utilizadas na diferenciação das culturas de milho, sorgo e milheto para caracterização agrônoma.



## 2. MÉTODOS

A revisão integrativa (RI) é uma estratégia que possibilita sintetizar achados provenientes de estudos primários desenvolvidos mediante desenhos de pesquisa diversos e requer análise de dados realizada de forma rigorosa (SOARES *et al.*, 2014; WHITTEMORE & KNAFL, 2005). Para realizar esta RI foi previamente desenvolvido um protocolo testado e aprimorado para garantir os procedimentos corretos de busca, extração, análise e transferência de dados para a produção de evidência científica de alto nível, por meio de uma estratégia de busca altamente sensível para responder ao objetivo proposto.

A questão norteadora foi baseada na estratégia mnemônica PVO (WHITTEMORE & KNAFL, 2005), onde população (P) foi composta pelas culturas de milho (*Zea mays*), milheto (*Pennisetum sp.*) e sorgo (*Sorghum bicolor*, as variáveis de interesse (V) foram tecnologias utilizadas na obtenção de imagens e metodologias aplicadas ao processamento, os resultados esperados (O, de “outcome”) foram variáveis agronômicas de diferenciação (dados de produtividade, altura, biomassa, número de plantas, identificação de plantas e linhas de semeadura).

Esta revisão incluiu artigos de pesquisa completos disponíveis nas bases de dados eletrônicas no formato de estudos experimentais bem desenhados, em qualquer idioma, sem limite temporal. Foram excluídos os documentos recuperados no formato de editoriais, cartas ao editor, resumos, opinião de especialistas, outras resenhas, correspondências, resenhas, teses e dissertações, resumos, palestras, livros ou capítulos de livros, e artigos que utilizaram sensoriamento proximal. Artigos duplicados foram considerados apenas uma vez.

O estudo foi considerado relevante quando: (i) foi utilizado milho, milheto ou sorgo; (ii) foi validado um software de identificação e combinação de dados espectrais e (iii) foi realizado teste de precisão do modelo - avaliação de desempenho do modelo para características produtivas e diferenciação das culturas (número de plantas, biomassa, detecção de plantas e avaliação das características agronômicas).

Os estudos foram identificados por meio de buscas eletrônicas de alta sensibilidade nas bases de dados Scopus (Elsevier), Web of Science (Coleção principal), Science Direct e CAB direct até 14 de setembro de 2022. Para acessar as bases de dados



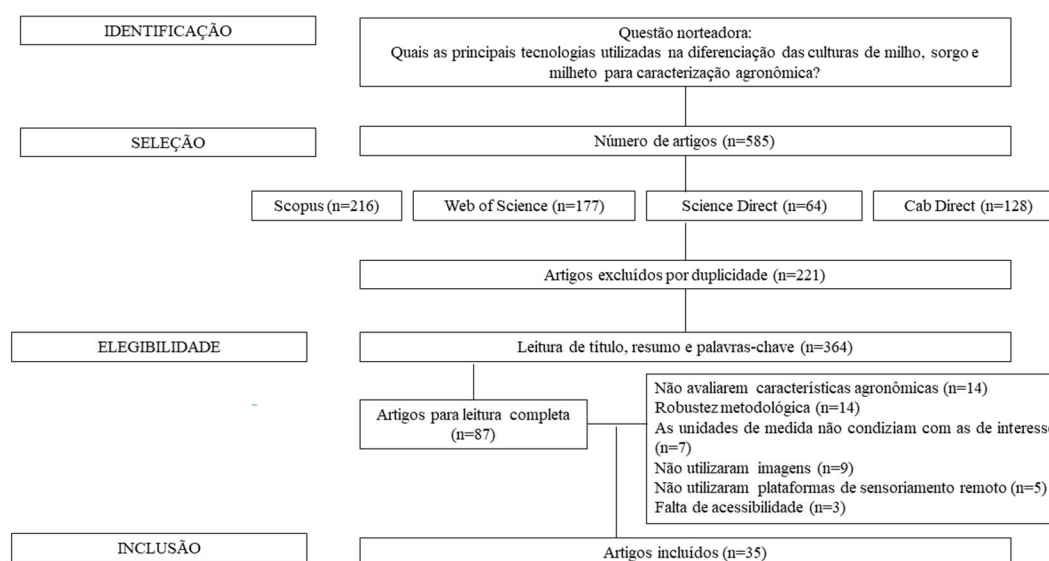
	OR "Mapira" OR "Massambala" OR "Mexoeira" OR "Massango" OR "Milho" OR "Sorgo" OR "Milheto" OR "玉米" OR "小米" OR "高粱"
	AND
Variáveis (V)	"Grazing management technologies" OR "Pasture management" OR "Pasture technology" OR "Grazing management" OR "Grazing ruminants" OR "Grazing intensity" OR "Frequency of grazing" OR "Grazing selectivity" OR "Fodder supply" OR "Light interception" OR "Leaf area index" OR "Canopy height" OR "Sward height" OR "Pasture height" OR "Ruler management" OR "Leaf area index" OR "Light intercept" OR "Precision agriculture" OR "Sward bulk density" OR "Available technology".
	AND
Resultados esperados (O)	"Productive performance" OR "Animal performance" OR "Weight gain" OR "Stocking rate" OR "Livestock performance" OR "Animal production" OR "Gain per hectare" OR "Body condition score" OR "Stocking rate" OR "DM intake" OR "Dry matter intake" OR "Animal consumption".

Um formulário para extração de dados foi desenvolvido especificamente para os fins deste estudo com a inclusão de informações sobre a identificação da publicação (autores, ano de publicação, título, DOI, revista, periódico, país e idioma), identificação das culturas (espécie, gênero, cultivar, idade, condições edafoclimáticas); e identificação das tecnologias utilizadas (imagens de satélite, VANT, celular, câmeras), softwares de diferenciação das culturas; eficiência da imagem/precisão  $R^2$ , variáveis de caracterização agrônômica analisadas).

A qualidade metodológica e o risco de viés nos estudos incluídos na amostra final desta RI foram avaliados por meio da aplicação do instrumento do Critical Skills Assessment Program – CASP 2018.

### 3. RESULTADOS

Foram encontrados 792 documentos, 207 não eram artigos científicos, restando 585 artigos científicos. Dentre os documentos encontrados no formato de artigos científicos 216 foram encontrados na base de dados Scopus, 177 na Web of Science, 64 no Science Direct e 128 no Cab Direct. 221 artigos foram excluídos por duplicidade. Resultando em 364 artigos para a leitura de título, resumo e palavras-chave. Desse total apenas 87 artigos foram selecionados para leitura na íntegra e 35 foram incluídos nesta revisão devido aos critérios de elegibilidade e qualidade metodológica (Figura 2)



**Figura 2** Fluxograma MOHER *et al.*, 2012

Foram recuperados estudos publicados de 2015 a 2022, 91,42 % foram publicados nos últimos 5 anos, os estudos incluídos foram realizados nos Estados Unidos (10), de China (4), Brasil (3), Senegal (3), Espanha (2), Canadá (2), Austrália (2), Zimbábue (2), Japão (1), Arábia Saudita (1), México (1), Áustria (1), Bielorrússia (1), Itália (1), Tanzânia e Quênia (1), publicados em inglês (97,15%) e chinês (2,85%).

Houve grande variabilidade na duração dos experimentos, com avaliações pontuais à avaliações de 14 anos. Dentre as espécies estudadas, 28 trabalhos utilizaram milho (*Zea mays*) (Tabela 2), 4 utilizaram sorgo (*Sorghum bicolor*) (Tabela 3) e 3 milheto (*Pennisetum glaucum*) (Tabela 4). A maioria dos trabalhos avaliaram as espécies forrageiras em dois ou mais estágios de crescimento (54,14%), sendo os mais utilizados, os estádios vegetativos V2 (25,71%) e V4 (22,85%).

As plataformas mais utilizadas na obtenção de imagens foram as baseadas em veículos aéreos não tripulados (VANT) (74,28%) e satélites (25,72%). Os softwares de processamento das imagens mais utilizados foram Agisoft Metashape (37,14%) e Pix4D (22,85%), para extração dos dados de estimativas utilizados os mais diversos índices de vegetação e para identificação métodos aplicados ao aprendizado de máquina. As variáveis agronômicas (82,85%) mais abordadas foram biomassa, altura da planta e produtividade (Tabela 1, 2 e 3).

**Tabela 2** Estudos realizados com Milho

Plataformas	Pesquisas	Variáveis
VANT	(MARESMA <i>et al.</i> , 2016)	Altura da planta e produtividade
	(LIU <i>et al.</i> , 2021)	Altura da planta
	(LU <i>et al.</i> , 2021)	Altura da planta e cobertura de dossel
	(BALLESTEROS <i>et al.</i> , 2018)	Biomassa
	(DOS SANTOS <i>et al.</i> , 2020)	Biomassa
	(DOS SANTOS <i>et al.</i> , 2021)	Biomassa, altura e produtividade
	(GBODJO; <i>et al.</i> , 2021)	Biomassa e produtividade de grãos
	(MYSLYVA <i>et al.</i> , 2021)	Biomassa
	(ALZADJALI <i>et al.</i> , 2021)	Detecção de pendão
	(VONG <i>et al.</i> , 2022)	Estimativa e mapeamento da uniformidade de emergência
	(VARELA <i>et al.</i> , 2018)	Identificação de plantas
	(SHUAIBING <i>et al.</i> , 2018)	Número e identificação de plantas
	(SHIRZADIFAR <i>et al.</i> , 2020)	Número e distância entre plantas
	(GARCÍA-MARTÍNEZ <i>et al.</i> , 2020)	Número de plantas
	(VONG <i>et al.</i> , 2021b)	Número de plantas
	(RODENE <i>et al.</i> , 2022)	Peso de grãos
	(OSCO <i>et al.</i> , 2021a)	Posições de plantas individuais e linhas de plantio
(GRACIA-ROMERO <i>et al.</i> , 2018)	Produtividade de grãos	
(BUCHAILLOT <i>et al.</i> , 2019)	Produtividade	

	(IWASAKI <i>et al.</i> , 2019)	Produtividade da planta inteira e grãos, teores de MS da planta inteira e do grão
<b>Satélites</b>	(VESCOVO <i>et al.</i> , 2016)	Altura do dossel
	(DONG <i>et al.</i> , 2017)	Biomassa
	(GAHROUEI <i>et al.</i> , 2020)	Biomassa
	(PATIL <i>et al.</i> , 2015)	Produtividade
	(HE <i>et al.</i> , 2018)	Produtividade
	(JIN <i>et al.</i> , 2019)	Produtividade
	(ZHANG <i>et al.</i> , 2021)	Produtividade
	(KAYAD <i>et al.</i> , 2021)	Produtividade
	(KHANAL <i>et al.</i> , 2021)	Produtividade de grãos

**Tabela 3** Estudos realizados com Sorgo

<b>Plataformas</b>	<b>Pesquisas</b>	<b>Variáveis</b>
<b>VANT</b>	(CHILUWAL <i>et al.</i> , 2018)	Biomassa da parte aérea e produtividade de grãos
	(LI <i>et al.</i> , 2022)	Biomassa fresca e seca, altura da planta
	(GONZALO-MARTÍN; <i>et al.</i> , 2021)	Deteção de panículas
	(ZHAO <i>et al.</i> , 2021)	Deteção de planta e panícula

**Tabela 4** Estudos realizados com Milheto

<b>Plataformas</b>	<b>Pesquisas</b>	<b>Variáveis</b>
<b>VANT</b>	(ROUPSARD <i>et al.</i> , 2020)	Biomassa
<b>Satélite</b>	(GBODJO; <i>et al.</i> , 2021)	Biomassa e produtividade de grãos
	(LEROUX <i>et al.</i> , 2020)	Produtividade

#### 4. DISCUSSÃO

Os estudos incluídos nesta revisão apresentaram elevado grau de confiabilidade por serem estudos bem planejados. Uma vez que todas as fases de triagem incluíram mais de um revisor para potencializar o reconhecimento dos estudos relevantes.

A maioria dos estudos excluídos na fase de elegibilidade, quando os revisores leram título, resumo e palavras-chave, não apresentaram resultados de produtividade, utilizaram outras culturas que não eram de interesse desta revisão, além de estudos que utilizaram bancos de dados e modelagem.

Entre os estudos incluídos nesta revisão é possível observar que 80 % foram realizados com a cultura do milho, visto que, é um dos cereais tropicais mais cultivado (SHIRZADIFAR *et al.*, 2020), este fato ilustra a variabilidade de lugares que avaliaram essa cultura em seus estudos são eles EUA ( RODENE *et al.*, 2022; VONG *et al.*, 2021, 2022; ALZADJALI *et al.*, 2021; KHANAL *et al.*, 2021; SHIRZADIFAR *et al.*, 2020; HE *et al.*, 2018; VARELA *et al.*, 2018;), China (LIU *et al.*, 2021; LU *et al.*, 2021; SHUAIBING *et al.*, 2018; ZHANG *et al.*, 2021), Brasil (DOS SANTOS *et al.*, 2020, 2021; OSCO *et al.*, 2021a), Espanha (BALLESTEROS *et al.*, 2018; MARESMA *et al.*, 2016), México (GARCÍA-MARTÍNEZ *et al.*, 2020), Zimbabwe (BUCHAILLOT *et al.*, 2019; GRACIA-ROMERO *et al.*, 2018), Japão (IWASAKI *et al.*, 2019), Bielorrússia (MYSLYVA *et al.*, 2021), Canadá ( GAHROUEI *et al.*, 2020; DONG *et al.*, 2017;), Tanzânia e Quênia (JIN *et al.*, 2019), Itália (KAYAD *et al.*, 2021), Áustria (VESCOVO *et al.*, 2016) e Arábia Saudita (PATIL *et al.*, 2015). O maior número de trabalhos realizados EUA pode ser explicado por sua alta produção, sendo que na última safra 21/22 produziu 382,89 milhões de toneladas (USDA, 2022).

A cultura do sorgo é originária de regiões tropicais e subtropicais da África, segundo Smith e Frederiksen 2000) adaptada a climas áridos, semiáridos, subúmidos e úmidos o que justifica a realização dos trabalhos no EUA ( LI *et al.*, 2022; CHILUWAL *et al.*, 2018;) e Austrália (GONZALO-MARTÍN *et al.*, 2021; ZHAO *et al.*, 2021) possuem clima Cfa e Dfa respectivamente segundo a classificação Köppen.

Já os estudos que avaliaram a cultura do milheto foram realizados no Senegal (GBODJO *et al.*, 2021; LEROUX *et al.*, 2020; ROUPSARD *et al.*, 2020), os estudos foram realizados em na bacia do amendoim que segundo Rroupsard *et al.*, (ROUPSARD *et al.*, 2020) é uma das principais zonas agroecológicas dominada pela agricultura familiar e agricultura de sequeiro. A cultura do milheto desempenha um papel essencial para a segurança alimentar em regiões áridas da África Subsaariana e Índia, onde o plantio de outras culturas seria inviável (DEBIEU *et al.*, 2017).

#### 4.1. Estudos com Satélites

A acessibilidade de imagens multitemporais de satélites em alta resolução possibilita o monitoramento de cenários de grande proporção do mundo real (JURADO *et al.*, 2022). Essas imagens podem ser obtidas por diferentes satélites, sendo os mais utilizados nos estudos incluídos nesta revisão os Sentinel 1 e 2 (GBODJO *et al.*, 2021; KAYAD *et al.*, 2021; LEROUX *et al.*, 2020; JIN *et al.*, 2019;) e Landsat 5,7 e 8 ( LEROUX *et al.*, 2020; HE *et al.*, 2018; DONG *et al.*, 2017).

Dentre esses estudos realizados utilizando imagens de satélites, a maioria avaliaram produtividade da cultura (GBODJO *et al.*, 2021; KAYAD *et al.*, 2021; PATIL *et al.*, 2015; ZHANG *et al.*, 2021; JIN *et al.*, 2019; HE *et al.*, 2018) e produtividade do grão (KHANAL *et al.*, 2021; LEROUX *et al.*, 2020). Além de biomassa ( LEROUX *et al.*, 2020; GAHROUEI *et al.*, 2020; DONG *et al.*, 2017;) e altura da planta (VESCOVO *et al.*, 2016).

Houve grande variabilidade na precisão dos modelos utilizados no processamento das imagens, para a avaliação de rendimento da cultura, o menor valor encontrado foi no estudo de Jin *et al.*, (2019) no qual encontraram  $R^2=0,39$ , segundo o autor esse tipo de mapeamento realizado nos países africanos Tanzânia e Quênia foi desafiador devido à presença de nuvens durante todo o período e as paisagens locais heterogêneas. Já He *et al.*, (2018) encontraram melhores valores para o rendimento anual  $R^2=0,82$ , quando compararam dados de produção durante o período de 2008 a 2015.

Os estudos mais precisos avaliaram o rendimento da cultura, os melhores valores encontrados para  $R^2$  foram 0,87 (GAHROUEI *et al.*, 2020) e 0,98 (DONG *et al.*, 2017), ambos os trabalhos foram realizados com milho no Canadá.

Os estudos realizados com imagens de satélite apresentaram maiores períodos de avaliação se comparados aqueles realizados com imagens de VANT, os mais longos foram os estudos realizados por He *et al.*,(2018) e Kayad *et al.*, (2021), que avaliaram o rendimento da cultura por 8 e 14 anos, respectivamente. Isso se deve a disponibilidade de imagens em alta resolução retroativos.

#### 4.2. Estudos com Veículos Aéreos não tripulados (VANT)



Os VANTs possuem a capacidade de transportar sistemas de imagens leves, impactando de forma positiva em estudos recentes, Jurado *et al.*, (2022) sintetizaram em sua revisão os sensores multiespectrais disponíveis. Segundo os autores o incremento da resolução espacial e no número de imagens sobrepostas capturadas possibilitam o desenvolvimento de técnicas a partir de imagens para reconstrução 3D.

Segundo Deng *et al.*, (2018) novas plataformas e sensores estão com melhores precisões das medições espectrais e com isso diminui o ruído oriundo das diversas camadas da atmosfera e aumentando a cobertura do modelo por inúmeros pontos de vista com maiores resoluções espaciais.

Houve maior variedade entre os dados analisados em comparação aos estudos realizados com imagens derivadas de satélites. Os estudos consideraram além de variáveis agrônomicas (RODENE *et al.*, 2022; LI *et al.*, 2022; LIU *et al.*, 2021; LU *et al.*, 2021; MYSLYVA *et al.*, 2021; VONG *et al.*, 2021; ROUPSARD *et al.*, 2020; SHIRZADIFAR *et al.*, 2020; GARCÍA-MARTÍNEZ *et al.*, 2020; DOS SANTOS *et al.*, 2020, 2021; IWASAKI *et al.*, 2019; BUCHAILLOT *et al.*, 2019; BALLESTEROS *et al.*, 2018; SHUAIBING *et al.*, 2018; CHILUWAL *et al.*, 2018; GRACIA-ROMERO *et al.*, 2018; MARESMA *et al.*, 2016;) outras características, tais como identificação de linhas de plantio (OSCO *et al.*, 2021a), distância entre plantas (SHIRZADIFAR *et al.*, 2020), identificação de plantas (ZHAO *et al.*, 2021; SHUAIBING *et al.*, 2018; VARELA *et al.*, 2018; , pendões de milho (ALZADJALI *et al.*, 2021), panículas (GONZALO-MARTÍN *et al.*, 2021; ZHAO *et al.*, 2021) e uniformidade de emergência (VONG *et al.*, 2022). As características essas que podem afetar diretamente na produtividade da cultura.

Em relação a precisão dos modelos abordados, os estudos que utilizaram VANTs apresentaram em sua maioria valores de  $R^2$  acima de 70%. O melhor  $R^2$  encontrado foi no estudo realizado por Santos *et al.*, (2021) avaliando altura ( $R^2=0,96$ ) em Minas Gerais - BR. Já para as variáveis de identificação e caracterização valores de precisão mais elevados (97,64%) foram encontrados por Alzadjali *et al.*, (2021), no estudo realizado para detectar pendões de milho no Nebraska – EUA.

### **4.3.Limitações e sugestões para trabalhos futuros**

A maioria dos artigos encontrados utilizando dados de sensoriamento remoto, os resultados não possuíam padronização nas unidades de medidas. Outro fato que chama atenção é o número reduzido de trabalhos utilizando sorgo e milho.

## 5. CONCLUSÃO

A plataforma de sensoriamento remoto mais utilizada para obtenção de imagens nos estudos apresentados foi com VANTs. O milho foi a cultura de interesse zootécnico mais estudada. Dentre as variáveis de interesse, a produtividade foi a mais discutida.

O sensoriamento remoto é uma ferramenta promissora na tomada de decisão e no gerenciamento da produção, uma vez que são capazes de identificar a variabilidade espacial e temporal em culturas de interesse zootécnico.

## 6. AGRADECIMENTOS

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico(CNPq) e a Universidade Federal de Mato Grosso do Sul.

## 7. REFERÊNCIAS

- AHMAD, U.; ALVINO, A.; MARINO, S. Remote Sensing. **Remote Sensing**, v. 13, p. 4155, 2021.
- ALEBELE, Y.; ZHANG, X.; WANG, W.; YANG, G.; YAO, X. Estimation of Canopy Biomass Components in Paddy Rice from Combined Optical and SAR Data Using. **Remote Sensing**, v. 12, p. 1–22, 2020.
- ALZADJALI, A.; ALALI, M. H.; VEERANAMPALAYAM SIVAKUMAR, A. N.; DEOGUN, J. S.; SCOTT, S.; SCHNABLE, J. C.; SHI, Y. Maize Tassel Detection From UAV Imagery Using Deep Learning. **Frontiers in Robotics and AI**, v. 8, n. June, p. 1–15, 2021.
- ANEECE, I.; THENKABAIL, P. S. Classifying crop types using two generations of hyperspectral sensors (Hyperion and DESIS) with machine learning on the cloud. **Remote Sensing**, v. 13, n. 22, 2021.
- BAGHDADI, N.; BOYER, N.; TODOROFF, P.; EL, M.; BÉGUÉ, A. Remote Sensing

of Environment Potential of SAR sensors TerraSAR-X , ASAR / ENVISAT and PALSAR / ALOS for monitoring sugarcane crops on Reunion Island. **Remote Sensing of Environment**, v. 113, n. 8, p. 1724–1738, 2009. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2009.04.005>>.

BAHRAMI, H.; MCNAIRN, H.; MAHDIANPARI, M. A Meta-Analysis of Remote Sensing Technologies and Methodologies for Crop Characterization. **Remote Sensing**, v. 14, p. 1–47, 2022.

BALLESTEROS, R.; ORTEGA, J. F.; HERNANDEZ, D.; DEL CAMPO, A.; MORENO, M. A. Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 72, 2018.

BAO, N.; LI, W.; GU, X.; LIU, Y. Biomass Estimation for Semiarid Vegetation and Mine Rehabilitation Using Worldview-3 and. **Remote Sensing**, v. 11, p. 2855, 2019.

BATISTOTI, J.; MARCATO, J.; ÍTAVO, L.; MATSUBARA, E.; GOMES, E.; OLIVEIRA, B.; SOUZA, M.; SIQUEIRA, H.; FILHO, G. S.; AKIYAMA, T.; GONÇALVES, W.; LIESENBERG, V.; LI, J.; DIAS, A. **Estimating pasture biomass and canopy height in Brazilian Savanna using UAV photogrammetry** Remote Sensing MDPI AG, 1 out. 2019.

BUCHAILLOT, M. L.; GRACIA-ROMERO, A.; VERGARA-DIAZ, O.; ZAMAN-ALLAH, M. A.; TAREKEGNE, A.; CAIRNS, J. E.; PRASANNA, B. M.; ARAUS, J. L.; KEFAUVER, S. C. Evaluating maize genotype performance under low nitrogen conditions using RGB UAV phenotyping techniques. **Sensors (Switzerland)**, v. 19, n. 8, 2019.

CHERUBIN, M. R.; DAMIAN, J. M.; TAVARES, T. R.; TREVISAN, R. G.; COLAÇO, A. F.; EITELWEIN, M. T.; MARTELLO, M.; INAMASU, R. Y.; PIAS, O. H. de C.; MOLIN, J. P. Precision Agriculture in Brazil : The Trajectory of 25 Years of Scientific Research. **Agriculture**, v. 12, p. 1882, 2022.

CHILUWAL, A.; BHEEMANAHALLI, R.; PERUMAL, R.; ASEBEDO, A. R.; BASHIR, E.; LAMSAL, A.; SEBELA, D.; SHETTY, N. J.; KRISHNA JAGADISH, S. V. Integrated aerial and destructive phenotyping differentiates chilling stress tolerance during early seedling growth in sorghum. **Field Crops Research**, v. 227, p. 1–10, 1 out. 2018.

DE ASSIS, R. L.; DE FREITAS, R. S.; MASON, S. C. **PEARL MILLET PRODUCTION PRACTICES in Brazil: A REVIEW** Experimental Agriculture 2018.

DEBIEU, M.; KANFANY, G.; LAPLAZE, L. Pearl Millet Genome: Lessons from a Tough Crop. **Trends in Plant Science**, v. 22, n. 11, p. 911–913, 1 nov. 2017.

DENG, L.; MAO, Z.; LI, X.; HU, Z.; DUAN, F.; YAN, Y. UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, p. 124–136, 1 dez. 2018.

DONG, T.; LIU, J.; QIAN, B.; JING, Q.; CROFT, H.; CHEN, J.; WANG, J.; HUFFMAN, T.; SHANG, J.; CHEN, P. Deriving Maximum Light Use Efficiency from Crop Growth Model and Satellite Data to Improve Crop Biomass Estimation. **IEEE Journal of**

**Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 1, 2017.

DOS SANTOS, R. A.; FILGUEIRAS, R.; MANTOVANI, E. C.; FERNANDES-FILHO, E. I.; ALMEIDA, T. S.; VENANCIO, L. P.; DA SILVA, A. C. B. **Surface reflectance calculation and predictive models of biophysical parameters of maize crop from RG-NIR sensor on board a UAV** *Precision Agriculture* 2021.

DOS SANTOS, R. A.; MANTOVANI, E. C.; FILGUEIRAS, R.; FERNANDES-FILHO, E. I.; DA SILVA, A. C. B.; VENANCIO, L. P. Actual evapotranspiration and biomass of maize from a red-green-near-infrared (RGNIR) sensor on board an unmanned aerial vehicle (UAV). **Water (Switzerland)**, v. 12, n. 9, p. 1–20, 2020.

EITEL, J. U. H.; MAGNEY, T. S.; VIERLING, L. A.; GREAVES, H. E.; ZHENG, G. Remote Sensing of Environment An automated method to quantify crop height and calibrate satellite-derived biomass using hypertemporal lidar. **Remote Sensing of Environment**, v. 187, p. 414–422, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.10.044>>.

FAO. Food and Agriculture Organization of the United Nations (FAO). **Food Outlook**, n. November, p. 1207–1213, 2021. Disponível em: <<https://doi.org/10.4060/cb7491en>>.

GARCÍA-MARTÍNEZ, H.; FLORES-MAGDALENO, H.; KHALIL-GARDEZI, A.; ASCENCIO-HERNÁNDEZ, R.; TIJERINA-CHÁVEZ, L.; VÁZQUEZ-PEÑA, M. A.; MANCILLA-VILLA, O. R. Digital count of corn plants using images taken by unmanned aerial vehicles and cross correlation of templates. **Agronomy**, v. 10, n. 4, 2020.

GBODJO, Y. J. E.; IENCO, D.; LEROUX, L. Benchmarking statistical modelling approaches with multi-source remote sensing data for millet yield monitoring: a case study of the groundnut basin in central Senegal. **International Journal of Remote Sensing**, v. 42, n. 24, 2021.

GONZALO-MARTÍN, C.; GARCÍA-PEDRERO, A.; LILLO-SAAVEDRA, M. Improving deep learning sorghum head detection through test time augmentation. **Computers and Electronics in Agriculture**, v. 186, 2021.

GRACIA-ROMERO, A.; VERGARA-DÍAZ, O.; THIERFELDER, C.; CAIRNS, J. E.; KEFAUVER, S. C.; ARAUS, J. L. Phenotyping conservation agriculture management effects on ground and aerial remote sensing assessments of maize hybrids performance in Zimbabwe. **Remote Sensing**, v. 10, n. 2, 2018.

GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS, F. L. F. De. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. **International Journal of Remote Sensing**, v. 41, n. 8, p. 2861–2876, 17 abr. 2020. Disponível em: <<https://doi.org/10.1080/01431161.2019.1697004>>.

HAN, J.; WEI, C.; CHEN, Y.; LIU, W.; SONG, P.; HUANG, J. Mapping Above-Ground Biomass of Winter Oilseed Rape Using High Spatial Resolution Satellite Data at Parcel Scale under Waterlogging Conditions. **Remote Sensing**, v. 9, p. 238, 2017.

HE, M.; KIMBALL, J. S.; MANETA, M. P.; MAXWELL, B. D.; MORENO, A.; BEGUERÍA, S.; WU, X. Regional crop gross primary productivity and yield estimation using fused landsat-MODIS data. **Remote Sensing**, v. 10, n. 3, 2018.

IMAM, S. B. S.; ALSULTAN, R. O.; ALBDAH, D. A.; ALMULHIM, G. K.; ALSHAIKHMUBARAK, N. H. Design and Development of a CNN Model Based

Android Application for Detection of Plant Leaf Diseases In-Home Grown Plants in Saudi Arabia. *In*: GUNJAN, V. K.; ZURADA, J. M. **Modern Approaches in Machine Learning & Cognitive Science: A Walkthrough**. Cham: Springer International Publishing, 2022. p. 393–401.

IWASAKI, K.; TORITA, H.; ABE, T.; URAIKE, T.; TOUZE, M.; FUKUCHI, M.; SATO, H.; IIJIMA, T.; IMAOKA, K.; IGAWA, H. Spatial pattern of windbreak effects on maize growth evaluated by an unmanned aerial vehicle in Hokkaido, northern Japan. **Agroforestry Systems**, v. 93, n. 3, 2019.

JIAO, X.; KOVACS, J. M.; SHANG, J.; MCNAIRN, H.; WALTERS, D.; MA, B. ISPRS Journal of Photogrammetry and Remote Sensing Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. **ISPRS JOURNAL OF PHOTOGRAMMETRY AND REMOTE SENSING**, v. 96, p. 38–46, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2014.06.014>>.

JIN, Z.; AZZARI, G.; YOU, C.; DI TOMMASO, S.; 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, 2019.

JURADO, J. M.; LÓPEZ, A.; PÁDUA, L.; SOUSA, J. J. Remote sensing image fusion on 3D scenarios: A review of applications for agriculture and forestry. **International Journal of Applied Earth Observation and Geoinformation**, v. 112, n. June, 2022.

KAYAD, A.; SOZZI, M.; GATTO, S.; WHELAN, B.; SARTORI, L.; MARINELLO, F. Ten years of corn yield dynamics at field scale under digital agriculture solutions: A case study from North Italy. **Computers and Electronics in Agriculture**, v. 185, 2021.

KHANAL, S.; KLOPFENSTEIN, A.; KC, K.; RAMARAO, V.; FULTON, J.; DOURIDAS, N.; SHEARER, S. A. Assessing the impact of agricultural field traffic on corn grain yield using remote sensing and machine learning. **Soil and Tillage Research**, v. 208, p. 104880, 1 abr. 2021.

KUMAR, L.; SINHA, P.; TAYLOR, S.; ALQURASHI, A. F. Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 097696, 2015.

LEROUX, L.; FALCONNIER, G. N.; DIOUF, A. A.; NDAO, B.; GBODJO, J. E.; TALL, L.; BALDE, A. A.; CLERMONT-DAUPHIN, C.; BÉGUÉ, A.; AFFHOLDER, F.; ROUPSARD, O. Using remote sensing to assess the effect of trees on millet yield in complex parklands of Central Senegal. **Agricultural Systems**, v. 184, 2020.

LI, F.; ZENG, Y.; LUO, J.; MA, R.; WU, B. Modeling grassland aboveground biomass using a pure vegetation index. **Ecological Indicators**, v. 62, p. 279–288, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.ecolind.2015.11.005>>.

LI, J.; SCHACHTMAN, D. P.; CREECH, C. F.; WANG, L.; GE, Y.; SHI, Y. Evaluation of UAV-derived multimodal remote sensing data for biomass prediction and drought tolerance assessment in bioenergy sorghum. **Crop Journal**, v. 10, n. 5, p. 1363–1375, 2022a. Disponível em: <<https://doi.org/10.1016/j.cj.2022.04.005>>.

LI, J.; SCHACHTMAN, D. P.; CREECH, C. F.; WANG, L.; GE, Y.; SHI, Y. Evaluation of UAV-derived multimodal remote sensing data for biomass prediction and drought tolerance assessment in bioenergy sorghum. **The Crop Journal**, v. 10, n. 5, p. 1363–1375, 1 out. 2022b.

LITHERLAND, N. B.; THIRE, S.; BEAULIEU, A. D.; REYNOLDS, C. K.; BENSON, J. A.; DRACKLEY, J. K. Dry matter intake is decreased more by abomasal infusion of unsaturated free fatty acids than by unsaturated triglycerides. **Journal of Dairy Science**, v. 88, n. 2, p. 632–643, 2005. Disponível em: <[http://dx.doi.org/10.3168/jds.S0022-0302\(05\)72727-2](http://dx.doi.org/10.3168/jds.S0022-0302(05)72727-2)>.

LIU, F.; HU, P.; ZHENG, B.; DUAN, T.; ZHU, B.; GUO, Y. A field-based high-throughput method for acquiring canopy architecture using unmanned aerial vehicle images. **Agricultural and Forest Meteorology**, v. 296, p. 108231, 15 jan. 2021.

LU, J.; CHENG, D.; GENG, C.; ZHANG, Z.; XIANG, Y.; HU, T. Combining plant height, canopy coverage and vegetation index from UAV-based RGB images to estimate leaf nitrogen concentration of summer maize. **Biosystems Engineering**, v. 202, 2021.

MAITAH, M.; MALEC, K.; GE, Y.; GEBELTOVÁ, Z.; SMUTKA, L.; BLAŽEK, V.; PÁNKOVÁ, L.; MAITAH, K.; MACH, J. Assessment and Prediction of Maize Production Considering Climate Change by Extreme Learning Machine in Czechia. **Agronomy**, v. 11, n. 11, 2021.

MANSARAY, L. R.; KANU, A. S.; YANG, L.; HUANG, J.; WANG, F. Evaluation of machine learning models for rice dry biomass estimation and mapping using quad-source optical imagery. **GIScience & Remote Sensing**, v. 57, n. 6, p. 785–796, 17 ago. 2020. Disponível em: <<https://doi.org/10.1080/15481603.2020.1799546>>.

MARESMÁ, Á.; ARIZA, M.; MARTÍNEZ, E.; LLOVERAS, J.; MARTÍNEZ-CASASNOVAS, J. A. Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (*zea mays* l.) from a standard uav service. **Remote Sensing**, v. 8, n. 12, 2016.

MCFADDEN, J. R.; ROSBURG, A.; NJUKI, E. Information inputs and technical efficiency in midwest corn production: evidence from farmers' use of yield and soil maps. **American Journal of Agricultural Economics**, v. 104, n. 2, 2022.

MYSLYVA, T.; SHELJUTA, B.; BUSHUEVA, V. USE OF MEDIUM AND HIGH-RESOLUTION REMOTE SENSING DATA AND MARKOV CHAINS FOR FORECASTING PRODUCTIVITY OF NON-CONVENTIONAL FODDER CROPS. v. LXIV, n. 1, p. 478–485, 2021.

OSCO, L. P.; DOS SANTOS DE ARRUDA, M.; GONÇALVES, D. N.; DIAS, A.; BATISTOTI, J.; DE SOUZA, M.; GOMES, F. D. G.; RAMOS, A. P. M.; DE CASTRO JORGE, L. A.; LIESENBERG, V.; LI, J.; MA, L.; MARCATO, J.; GONÇALVES, W. N. A CNN approach to simultaneously count plants and detect plantation-rows from UAV imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 174, p. 1–17, 1 abr. 2021a.

OSCO, L. P.; MARCATO JUNIOR, J.; MARQUES RAMOS, A. P.; DE CASTRO JORGE, L. A.; FATHOLAH, S. N.; DE ANDRADE SILVA, J.; MATSUBARA, E. T.; PISTORI, H.; GONÇALVES, W. N.; LI, J. **A review on deep learning in UAV remote sensing** *International Journal of Applied Earth Observation and Geoinformation* Elsevier B.V., 1 out. 2021b.

PATIL, V. C.; AL-GAADI, K. A.; MADUGUNDU, R.; TOLA, E. H. M.; MAREY, S.; ALDOSARI, A.; BIRADAR, C. M.; GOWDA, P. H. Assessing agricultural water productivity in desert farming system of Saudi Arabia. **IEEE Journal of Selected Topics**

in **Applied Earth Observations and Remote Sensing**, v. 8, n. 1, 2015.

PIRES, R. D. P.; OLOFSSON, K.; PERSSON, H. J.; LINDBERG, E.; HOLMGREN, J. ISPRS Journal of Photogrammetry and Remote Sensing Individual tree detection and estimation of stem attributes with mobile laser scanning along boreal forest roads. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 187, n. March, p. 211–224, 2022. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2022.03.004>>.

REISI GAHROUEI, O.; MCNAIRN, H.; HOSSEINI, M.; HOMAYOUNI, S. Estimation of Crop Biomass and Leaf Area Index from Multitemporal and Multispectral Imagery Using Machine Learning Approaches. **Canadian Journal of Remote Sensing**, v. 46, n. 1, 2020.

RODENE, E.; XU, G.; PALALI DELEN, S.; ZHAO, X.; SMITH, C.; GE, Y.; SCHNABLE, J.; YANG, J. A UAV-based high-throughput phenotyping approach to assess time-series nitrogen responses and identify trait-associated genetic components in maize. **The Plant Phenome Journal**, v. 5, n. 1, p. 1–12, 2022.

ROUPSARD, O.; AUDEBERT, A.; NDOUR, A. P.; CLERMONT-DAUPHIN, C.; AGBOHESSOU, Y.; SANOU, J.; KOALA, J.; FAYE, E.; SAMBAKHE, D.; JOURDAN, C.; LE MAIRE, G.; TALL, L.; SANOGO, D.; SEGHERI, J.; CURNAC, L.; LEROUX, L. How far does the tree affect the crop in agroforestry? New spatial analysis methods in a Faidherbia parkland. **Agriculture, Ecosystems and Environment**, v. 296, 2020.

SHAFI, U.; MUMTAZ, R.; SHAFIQ, Z.; ZAIDI, S. M. H.; KAIFI, M. O.; MAHMOOD, Z.; ZAIDI, S. A. R. **Wheat rust disease detection techniques: a technical perspective** *Journal of Plant Diseases and Protection* 2022.

SHIRZADIFAR, A.; MAHARLOOEI, M.; BAJWA, S. G.; ODUOR, P. G.; NOWATZKI, J. F. Mapping crop stand count and planting uniformity using high resolution imagery in a maize crop. **Biosystems Engineering**, v. 200, 2020.

SHUAIBING, L.; GUIJUN, Y.; CHENGQUAN, Z.; HAITAO, J.; HAIKUAN, F.; BO, X. 0 引 言 □. 2018.

SOARES, C. B.; HOGA, L. A. K.; PEDUZZI, M.; SANGALETI, C.; YONEKURA, T.; SILVA, D. R. A. D. Integrative review: Concepts and methods used in nursing. **Revista da Escola de Enfermagem**, v. 48, n. 2, 2014.

SU, W. H. **Advanced machine learning in point spectroscopy, rgb-and hyperspectral-imaging for automatic discriminations of crops and weeds: A review** *Smart Cities* 2020.

TAO, H.; FENG, H.; XU, L.; MIAO, M.; LI, H. L.; YUE, J.; LI, Z.; YANG, G.; YANG, X.; FAN, L. Estimation of Crop Growth Parameters Using UAV-Based Hyperspectral Remote Sensing Data. **Sensors (Switzerland)**, v. 20, p. 1296, 2020.

TERENTEV, A.; DOLZHENKO, V.; FEDOTOV, A. Current State of Hyperspectral Remote Sensing for Early Plant Disease Detection : A Review. **Sensors (Switzerland)**, v. 22, p. 757, 2022.

USDA. **World agricultural production**. Disponível em: <<https://apps.fas.usda.gov/psdonline/circulars/production.pdf>>. Acesso em: 18 nov. 2022.

VARELA, S.; DHODDA, P. R.; HSU, W. H.; PRASAD, P. V. V.; ASSEFA, Y.;

- PERALTA, N. R.; GRIFFIN, T.; SHARDA, A.; FERGUSON, A.; CIAMPITTI, I. A. Early-season stand count determination in Corn via integration of imagery from unmanned aerial systems (UAS) and supervised learning techniques. **Remote Sensing**, v. 10, n. 2, 2018.
- VESCOVO, L.; GIANELLE, D.; DALPONTE, M.; MIGLIETTA, F.; CAROTENUTO, F.; TORRESAN, C. Hail defoliation assessment in corn (*Zea mays* L.) using airborne LiDAR. **Field Crops Research**, v. 196, 2016.
- VILJANEN, N.; HONKAVAARA, E. A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model , Images and Vegetation Indices Captured by a Drone. **Agriculture**, v. 8, p. 70, 2018.
- VONG, A.; MATOS-CARVALHO, J. P.; TOFFANIN, P.; PEDRO, D.; AZEVEDO, F.; MOUTINHO, F.; GARCIA, N. C.; MORA, A. How to Build a 2D and 3D Aerial Multispectral Map?— All Steps Deeply Explained. **Remote Sensing**, v. 13, p. 1–47, 2021a.
- 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, 1 jul. 2022.
- VONG, C. N.; CONWAY, L. S.; ZHOU, J.; KITCHEN, N. R.; SUDDUTH, K. A. Early corn stand count of different cropping systems using UAV-imagery and deep learning. **Computers and Electronics in Agriculture**, v. 186, p. 106214, 1 jul. 2021b.
- WEISER, F.; BAUMANN, E.; JENTSCH, A.; MEDINA, M.; LU, M.; NOGALES, M.; BEIERKUHNLIN, C. Impact of Volcanic Sulfur Emissions on the Pine Forest of forests, v. 13, p. 299, 2022.
- WHITTEMORE, R.; KNAFL, K. The integrative review : updated methodology. n. Broome 1993, p. 546–553, 2005.
- ZHANG, L.; ZHANG, Z.; LUO, Y.; CAO, J.; XIE, R.; LI, S. Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning. **Agricultural and Forest Meteorology**, v. 311, 2021.
- ZHAO, Y.; ZHENG, B.; CHAPMAN, S. C.; LAWS, K.; GEORGE-JAEGGLI, B.; HAMMER, G. L.; JORDAN, D. R.; POTGIETER, A. B. Detecting Sorghum Plant and Head Features from Multispectral UAV Imagery. **Plant Phenomics**, v. 2021, 2021.



## **CAPÍTULO 2 – AGRICULTURA DE PRECISÃO: DETECÇÃO DE PLANTAS DE MILHO USANDO YOLO-v8 PARA MONITORAMENTO APRIMORADO DE CULTURAS**

### **RESUMO**

A cultura do milho apresenta ciclo vegetativo de curto (105 a 180 dias) e o uso de ferramentas que facilitem a rápida tomada de decisões e o monitoramento da cultura em tempo real são essenciais para garantir a produtividade da cultura. O objetivo foi avaliar o método de detecção de objetos combinado com imagens RGB obtidas por Veículo Aéreo Não Tripulado (VANT) para a identificação de plantas de milho em estágio V3. O método avaliado foi o YOLO-v8. Um conjunto de dados foi construído para avaliar o método selecionado, foi utilizada uma proporção de 60% dos dados para treinamento (338 recortes de imagem), 20% para teste (113 recortes de imagem) e 20% para validação (113 recortes de imagem), totalizando 564 recortes de imagens e 39765 rótulos. O valor de mAP<sub>0,5</sub> encontrado neste estudo foi 90,5 %, indicando que o método YOLO-v8 constitui uma abordagem promissora para o desenvolvimento de ferramentas para a estimativa da população de plantas de milho, bem como o monitoramento agrícola.

**Palavras-chave:** aprendizagem profunda, detecção de objetos, processamento de imagem, sensoriamento remoto, visão computacional

## ABSTRACT

Corn crops have a short vegetative cycle (105 to 180 days) and the use of tools that facilitate rapid decision-making and real-time crop monitoring are essential to guarantee crop productivity. The objective was to evaluate the object detection method combined with RGB images obtained by Unmanned Aerial Vehicle (UAV) for the identification of corn plants in the V3 stage. The method evaluated was YOLO-v8. A data set was constructed to evaluate the selected method, a proportion of 60% of the data was used for training (338 image clippings), 20% for testing (113 image clippings) and 20% for validation (113 image clippings), totaling 564 image clippings and 39765 labels. The mAP0.5 value found in this study was 90.5%, indicating that the YOLO-v8 method constitutes a promising approach for developing tools for corn plant population estimation, as well as agricultural monitoring.

**Key-words:** Computer vision, deep learning, image processing, object detection, remote sensing,

## 1. INTRODUÇÃO

A produção de milho na safra 22/23 foi de 1,154.99 milhões de toneladas, os maiores produtores de milho são Estado Unidos responsáveis por 30% (348.37) da produção, seguido da China com 24% (277.20) e Brasil com 12% (137.00) (USDA, 2023). No Brasil para a próxima safra 23/24 a CONAB (2023) prevê uma redução de 5 % na área plantada e uma produção de aproximadamente 119 milhões de toneladas.

O milho é uma cultura que se adapta a diversos ambientes devido suas características morfológicas e botânicas. Seu ciclo vegetativo varia de acordo com o genótipo da planta, no Brasil o ciclo das cultivares utilizadas varia de 105 a 180 dias, período entre semeadura e a colheita (Borém *et al.*, 2017)

Considerando o breve ciclo torna-se necessário a utilização de ferramentas que possibilitem uma tomada rápida de decisão a fim de antecipar interferências na produtividade da cultura, como por exemplo no estudo realizado por Liu e Wang (2019) em que usaram um sistema de monitoramento para detecção em tempo real de grãos de milho quebrados a fim de ajustar a colheitadeira e assim otimizar a colheita.

A visão computacional orienta as máquinas a entender, compreender e analisar em alta qualidade o conteúdo visual (Morris 2004). Segundo Diwan *et al.*, (2022) a detecção de objetos é um subcampo relevante dentro do âmbito da visão computacional. Diversos modelos de aprendizado profundo e aprendizado de máquina são utilizados no processo de detecção de objetos.

Os modelos utilizados na detecção de objetos podem ser classificados em dois tipos: 1) detectores de objetos de dois estágios e 2) detectores de estágio único (DIWAN *et al.*, 2022). Os detectores de dois estágios dividem o processo de detecção em regressão e classificação para obtenção da saída (DU *et al.*, 2020). Apesar de fornecer alta precisão o custo computacional é alto, tornando o processo pouco vantajoso para implantação em tempo real. Com isso a detecção de objetos em estágio único vem ganhando força, uma vez que unem os dois processos, possibilitando a regressão e classificação por meio de uma única passagem, reduzindo o custo computacional (Sultana *et al.*, 2020).

Dentre os detectores de estágio único, o YOLO (You Only Look Once), vem se destacando em virtude de sua leveza, precisão e fácil implementação (HUSSAIN, 2023) O YOLO foi lançado em 2015 por Redmon *et al.*, (2016) Segundo Hussain (2023), desde a sua criação até o ano de 2023 foram lançadas oito variantes de YOLO, sendo o mais recente o YOLO-v8.

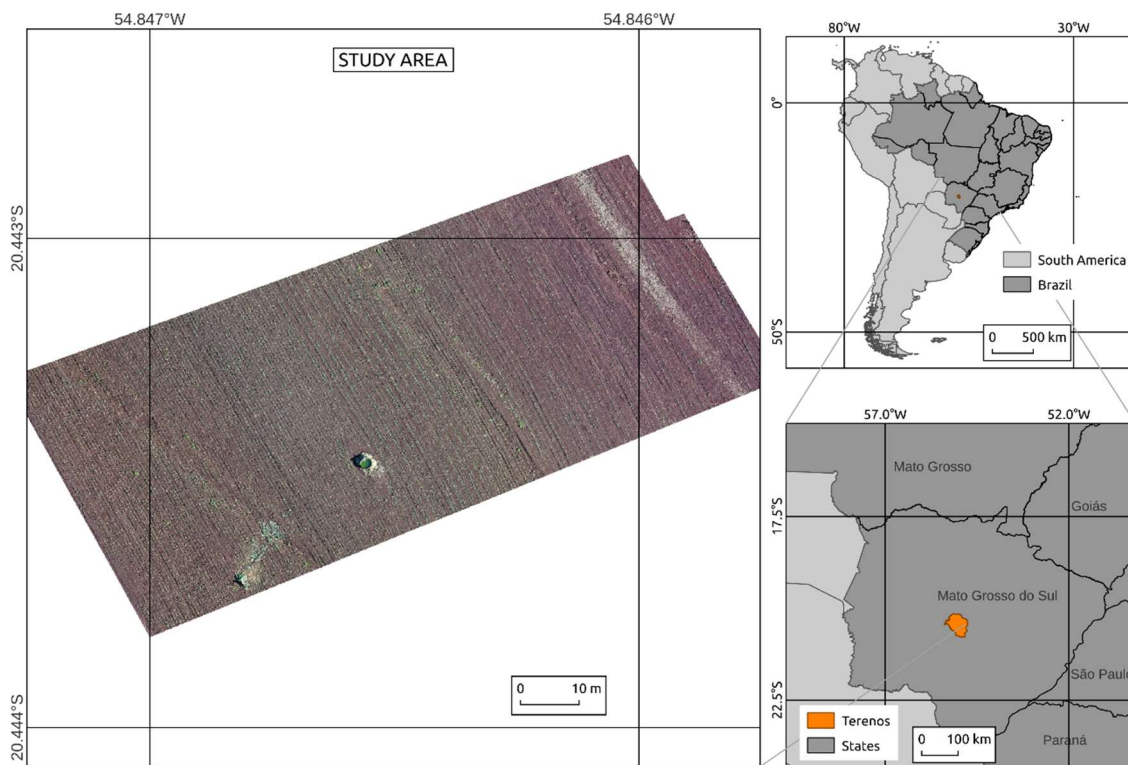
Estudos realizados anteriormente mostram o potencial dos detectores de objetos na detecção de chamas (CAO *et al.*, 2023; XU *et al.*, 2023), navios (HU *et al.*, 2021; SUN *et al.*, 2021; YE *et al.*, 2022; ZHU *et al.*, 2021), de maçãs (TIAN *et al.*, 2019), morangos (WANG *et al.*, 2022), tomates (LIU *et al.*, 2020), doenças e pragas em tomate (LIU; WANG, 2020), de pragas em pomares (TIAN *et al.*, 2023) e estufas agrícolas na China (LI *et al.*, 2020).

Na cultura do milho foram relatados estudos utilizando detectores de objetos na detecção de pragas (YANG *et al.*, 2023), contagem e localização de grãos na espiga (HOBBS *et al.*, 2021), detecção de ferrugem nas folhas da cultura (LENG *et al.*, 2023) e detecção e contagem da inflorescência do milho (PU *et al.*, 2023). Com isso, a pesquisa foi conduzida para testar o modelo YOLO-v8 na detecção de plantas de milho em estágio inicial de crescimento a fim de potencializar a produção da cultura. Assim objetivou-se avaliar a precisão no modelo YOLO-v8 na detecção da população de plantas de milho.

## **2. MATERIAL E MÉTODOS**

### **2.1. Área experimental**

O estudo foi realizado na Fazenda Escola da Universidade Federal de Mato Grosso do Sul, localizada no município de Terenos - Mato Grosso do Sul (MS), Brasil (latitude 20°26'34.31"S, longitude 54°50'27.86"W, altitude 530.7 m). O milho foi semeado em uma área de aproximadamente 0,74 hectares com espaçamento de 30 x 50 cm, resultando em 4 a 5 plantas.m<sup>2</sup>.



**Figura 1** Localização da área experimental

## 2.2. Aquisição de dados

As imagens da cultura do milho foram coletadas utilizando Phantom 4 Advanced (ADV), usando uma câmera RGB equipada com um sensor CMOS de 20 megapixels. As imagens foram capturadas com sobreposições longitudinais e laterais de 80% e 60%, respectivamente. Os voos foram realizados por dois dias a uma altura de 50 m mediante aprovação do Departamento de Controle do Espaço Aéreo (DECEA), responsável pelo espaço aéreo brasileiro.

Foram consideradas plantas em estágio vegetativo V3. As imagens obtidas foram processadas com software comercial Pix4D. Este software foi usado para otimização de parâmetros internos e externos, gerando nuvens de pontos com base no método SfM (Structure-From-Motion) e geração de ortofotos utilizando o método MVS (Multi-View Stereo). O processo de rotulagem manual das plantas (ground Truth) foi realizado com o QGis.

O ortomosaico obtido foi dividido em imagens de 256 x 256 pixels, obtidas de forma totalmente aleatória de cada ortomosaico, com proporção de 60% para treinamento (338 recortes de imagem), 20% para teste (113 recortes de imagem) e 20% para validação (113 recortes de imagem), totalizando 564 recortes de imagens e 39765 rótulos.

### 2.3. Método de detecção de objetos

Inicialmente, foram geradas quatro versões de datasets, os quais se diferenciam em alguns pré-processamentos e ações para aumentos de dados realizados no conjunto de treino. O primeiro dataset gerou um total de 1240 imagens, em que 1014 imagens foram para treinamento, 113 imagens para a validação e também 113 imagens para teste, onde os principais processamentos das imagens foram rotações e cortes aleatórios.

No segundo e no terceiro datasets foram geradas 4663 imagens, onde 4296 foram direcionadas para o treinamento, 254 imagens para validação e 113 imagens para o teste. Nesses conjuntos de dados foram aplicados mais processamentos das imagens, como a aplicação de ruídos em 3% dos pixels no segundo e em 8% no terceiro dataset, a separação das imagens em pedaços menores, conhecido como Tile, de duas linhas e duas colunas, e recortes bem pequenos e aleatórios nas imagens para melhorar a acurácia em situações que o objeto alvo está ofuscado.

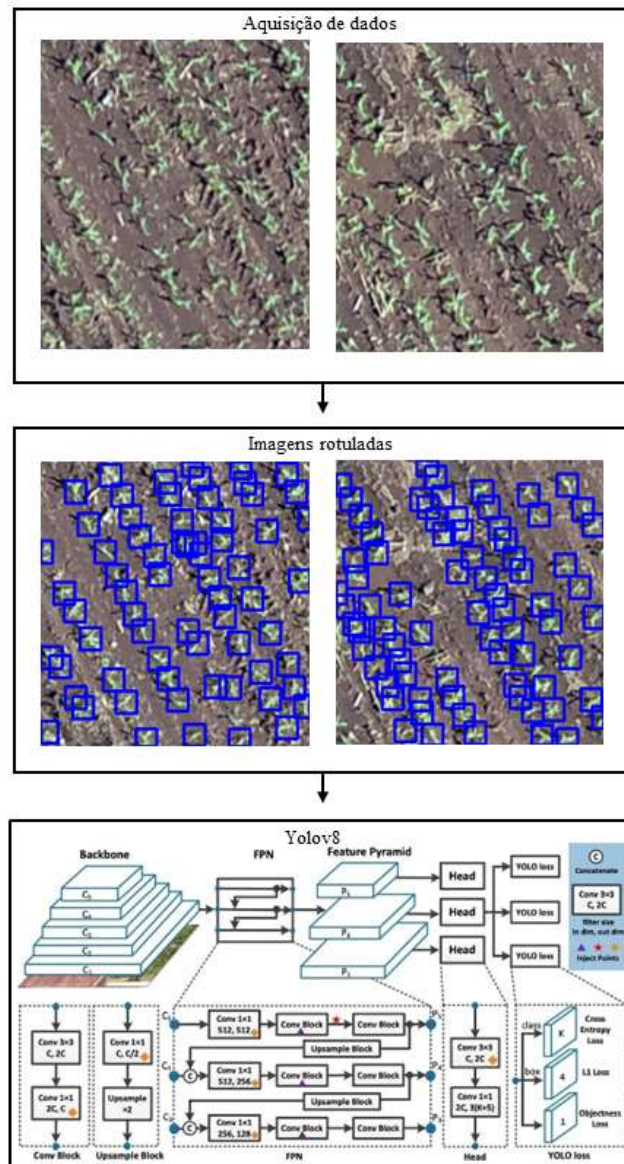
O quarto dataset gerado apenas foi removido o Tile e todos os outros processamentos foram iguais ao terceiro, o que resultou em 1119 imagens para o treinamento, e para este caso, 68 imagens para validação, e conjunto de teste permaneceu com a mesma quantidade de imagens que os datasets anteriores.

A YOLO-v8 (<https://github.com/ultralytics/ultralytics>), é a mais recente versão do YOLO, lançado pela Ultralytics em janeiro de 2023, oferece um otimizado desempenho em termos de velocidade e precisão. O YOLO-v8 oferece suporte a uma série de tarefas da Inteligência Artificial (IA) de visão, incluindo rastreamento, classificação, segmentação de pose, detecção e segmentação. Essa flexibilidade permite com que seus usuários aproveitem seus recursos em diferentes plataformas de hardware (JOCHER *et al.*, 2023).

Para este trabalho, foi utilizado o modelo pré-treinado mais robusto, conhecido como YOLO-v8x devido a presença de mais parâmetros, o que permitiu um melhor desempenho nos treinos realizados. Com isso, foram realizados quatro treinamentos usando os datasets que foram descritos anteriormente, para obter uma melhor avaliação da acurácia do modelo dependendo das condições impostas em cada um.

Em cada treinamento, foram garantidos que os tamanhos das imagens usadas teriam tamanho de 256x256 pixels e todos foram treinados por 100 épocas, os outros hiperparâmetros foram deixados conforme a documentação padrão da YOLO-v8 (<https://docs.ultralytics.com/modes/train/>).

Os experimentos foram conduzidos em um computador com AMD Ryzen 9 5900x CPU @ 3.70GHz x 12, 32GB de memória RAM e uma NVIDIA GeForce RTX 3060 Lite Hash Rate (5120 Compute Unified Device Architecture - CUDA cores and 12GB vRAM) e o sistema operacional Ubuntu 22.04. Além disso, foram usados os editores de código, Visual Studio Code (<https://code.visualstudio.com/>) e Google Colab (<https://colab.google/>) para modificar e realizar os treinamentos propostos.



**Figura 2.** Processamento da imagem

## 2.4. Métricas de avaliação

A métrica de avaliação utilizada para medir a precisão do método proposto foi  $mAP_{0,5}$  (*Mean Average Precision*). Para estimar a precisão e a recuperação, foi calculado IoU (*Intersection Over Union*) que é dada pela sobreposição entre caixas delimitadoras previstas e verdadeira básica, dividida pela área de união entre elas. Na detecção de objetos, uma detecção correta (Verdadeiro Positivo) é considerada para  $IoU \geq 0,5$ , e uma detecção errada (Falso Positivo) para  $IoU < 0,5$  (DOS SANTOS *et al.*, 2019).

## 3. RESULTADOS E DISCUSSÃO

### 3.1. Resultados quantitativos

Na tabela 1 estão apresentados os resultados de precisão das caixas delimitadoras, recall e a  $mAP_{0,5}$  para os conjuntos de imagens utilizados na validação e no teste. O recall é dado pela razão entre o número de amostras positivas previstas corretamente pelo modelo e o número de amostras positivas que realmente apareceram. É possível observar que os valores da precisão das caixas delimitadoras, recall e  $mAP_{0,5}$  apresentados tanto na validação (84,8%, 91,7% e 91,1%) quanto no teste (84,7%, 91,8% e 90,5%) são bem similares, indicando o ótimo desempenho de detecção pelo modelo já na fase de validação. O valor de  $mAP_{0,5}$  (90,5%) encontrado neste estudo é semelhante aos encontrados por Pu *et al.*, (2023), quando avaliaram o desempenho de quatro variantes do YOLO na detecção de inflorescência de plantas de milho, os valores de  $mAP_{0,5}$  variaram de 89,10% a 94,71%.


**Tabela 1.** Resultados da detecção realizada pelo YOLO-v8x

Conjunto de imagens	Caixa delimitadoras	Recall	$mAP_{0,5}$
Validação	84,8%	91,7%	91,1%
Teste	84,7%	91,8%	90,5%

### 3.2. Resultados qualitativos


Nas figuras apresentadas a seguir, os pontos azuis representam a posição das plantas rotuladas manualmente e os pontos vermelhos a posição das plantas previstas. É possível observar que o método YOLO-v8 atingiu um alto desempenho na detecção de objetos pequenos, aqui representados pelas plantas de milho em estágio inicial de desenvolvimento (Figura 3).





**Figura 3.** Comparação das imagens da posição das plantas rotuladas (pontos azuis) e imagens da posição das plantas previstas (pontos vermelhos)

Ao avaliar o desempenho do modelo YOLO-v8, um desafio notável surgiu em sua capacidade de detectar efetivamente plantas de milho situadas nas bordas das imagens. Outra dificuldade encontrada pelo modelo na detecção, quando apresentado com imagens exibindo contraste mínimo entre o objeto de interesse e o fundo, dificultando sua capacidade de identificar com precisão o alvo (Figura 4). O mesmo foi relatado por Liu e Wang (2019) e Wang *et al.*, (2023) que observaram que a presença de um fundo complexo na imagem representa um obstáculo para a detecção de objetos, devido à obstrução do objeto de interesse, atrapalhando a detecção precisa. Segundo Liu *et al.* (2019) esses problemas surgem porque as caixas delimitadoras se aproximam da verdade básica. A inclusão de pixels de fundo nas previsões geralmente dificulta a precisão do modelo. Com isso, os erros de localização resultam da interferência de fundo nas previsões e da dificuldade em distinguir objetos semelhantes.



**Figura 4.** Desafios encontrados pelo modelo: (a) dificuldade de detecção nas bordas e (b) dificuldade de detecção devido ao baixo contraste na imagem.

#### 4. CONCLUSÃO

O método YOLO-v8, constitui uma abordagem promissora para o desenvolvimento de ferramentas para a estimativa de plantas de milho, bem como o monitoramento agrícola.

#### 5. AGRADECIMENTOS

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Universidade Federal de Mato Grosso do Sul.

## 6. REFERÊNCIAS

- BORÉM, A.; GALVÃO, J. C. C.; PIMENTEL, M. A.; Milho: do plantio à colheita. 2 ed atual e ampl.- Viçosa(MG) Ed. UFV, 2017.
- CAO, X.; SU, Y.; GENG, X.; WANG, Y. YOLO-SF: YOLO for Fire Segmentation Detection. **IEEE Access**, v. 11, n. October, p. 111079–111092, 2023.
- CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da safra brasileira: Grãos, décimo segundo levantamento 2022/23. **12º Levantamento**, v. 10, p. 1–111, 2023. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>.
- DIWAN, T.; ANIRUDH, G.; TEMBHURNE, J. V. Object detection using YOLO: challenges, architectural successors, datasets and applications. **Multimedia Tools and Applications**, v. 82, n. 6, p. 9243–9275, 2022.
- DOS SANTOS, A. A.; MARCATO JUNIOR, J.; ARAÚJO, M. S.; DI MARTINI, D. R.; TETILA, E. C.; SIQUEIRA, H. L.; AOKI, C.; ELTNER, A.; MATSUBARA, E. T.; PISTORI, H.; FEITOSA, R. Q.; LIESENBERG, V.; GONÇALVES, W. N. Assessment of CNN-based methods for individual tree detection on images captured by RGB cameras attached to UAVS. **Sensors (Switzerland)**, v. 19, n. 16, p. 1–11, 2019.
- DU, L.; ZHANG, R.; WANG, X. Overview of two-stage object detection algorithms. **Journal of Physics: Conference Series**, v. 1544, n. 1, 2020.
- HOBBS, J.; KHACHATRYAN, V.; ANANDAN, B. S.; HOVHANNISYAN, H.; WILSON, D. Broad Dataset and Methods for Counting and Localization of On-Ear Corn Kernels. **Frontiers in Robotics and AI**, v. 8, n. May, p. 1–11, 2021.
- HU, J.; ZHI, X.; SHI, T.; ZHANG, W.; CUI, Y.; ZHAO, S. Pag-yolo: A portable attention-guided yolo network for small ship detection. **Remote Sensing**, v. 13, n. 16, 2021.
- HUSSAIN, M. YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. **Machines**, v. 11, n. 7, 2023.
- LENG, S.; MUSHA, Y.; YANG, Y.; FENG, G. CEMLB-YOLO: Efficient Detection

Model of Maize Leaf Blight in Complex Field Environments. **Applied Sciences (Switzerland)**, v. 13, n. 16, 2023.

LI, M.; ZHANG, Z.; LEI, L.; WANG, X.; GUO, X. Agricultural greenhouses detection in high-resolution satellite images based on convolutional neural networks: Comparison of faster R-CNN, YOLO v3 and SSD. **Sensors (Switzerland)**, v. 20, n. 17, p. 1–14, 2020.

LIU, G.; NOUAZE, J. C.; MBOUEMBE, P. L. T.; KIM, J. H. YOLO-tomato: A robust algorithm for tomato detection based on YOLOv3. **Sensors (Switzerland)**, v. 20, n. 7, p. 1–20, 2020.

LIU, J.; WANG, X. Tomato Diseases and Pests Detection Based on Improved Yolo V3 Convolutional Neural Network. **Frontiers in Plant Science**, v. 11, n. June, p. 1–12, 2020.

LIU, L.; OUYANG, W.; WANG, X.; FIEGUTH, P.; CHEN, J.; LIU, X.; PIETIKÄINEN, M. Deep Learning for Generic Object Detection: A Survey. **International Journal of Computer Vision**, v. 128, n. 2, p. 261–318, 2019.

PU, H.; CHEN, X.; YANG, Y.; TANG, R.; LUO, J.; WANG, Y.; MU, J. Tassel-YOLO: A New High-Precision and Real-Time Method for Maize Tassel Detection and Counting Based on UAV Aerial Images. **Drones**, v. 7, n. 8, 2023.

REDMON, J.; S., D.; GIRSHICH, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection Joseph. **ACM International Conference Proceeding Series**, 2016.

SUN, Z.; LENG, X.; LEI, Y.; XIONG, B.; JI, K.; KUANG, G. Bifa-yolo: A novel yolo-based method for arbitrary-oriented ship detection in high-resolution sar images. **Remote Sensing**, v. 13, n. 21, 2021.

TIAN, Y.; WANG, S.; LI, E.; YANG, G.; LIANG, Z.; TAN, M. MD-YOLO: Multi-scale Dense YOLO for small target pest detection. **Computers and Electronics in Agriculture**, v. 213, n. December 2022, 2023.

TIAN, Y.; YANG, G.; WANG, Z.; WANG, H.; LI, E.; LIANG, Z. Apple detection during different growth stages in orchards using the improved YOLO-V3 model. **Computers and Electronics in Agriculture**, v. 157, n. October 2018, p. 417–426, 2019.

UNITED STATES DEPARTMENT OF AGRICULTURE. USDA. p. 1–43, 2023. Disponível em: <<https://apps.fas.usda.gov/psdonline/app/index.html#/app/downloads>>.

WANG, G.; CHEN, Y.; AN, P.; HONG, H.; HU, J.; HUANG, T. UAV-YOLOv8: A Small-Object-Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios. **Sensors**, v. 23, n. 16, 2023.

WANG, Y.; YAN, G.; MENG, Q.; YAO, T.; HAN, J.; ZHANG, B. DSE-YOLO: Detail semantics enhancement YOLO for multi-stage strawberry detection. **Computers and Electronics in Agriculture**, v. 198, n. March, p. 107057, 2022. Disponível em: <<https://doi.org/10.1016/j.compag.2022.107057>>.

YANG, S.; XING, Z.; WANG, H.; DONG, X.; GAO, X.; LIU, Z.; ZHANG, X.; LI, S.; ZHAO, Y. Maize-YOLO: A New High-Precision and Real-Time Method for Maize Pest Detection. **Insects**, v. 14, n. 3, 2023.

YE, J.; YUAN, Z.; QIAN, C.; LI, X. CAA-YOLO: Combined-Attention-Augmented YOLO for Infrared Ocean Ships Detection. **Sensors**, v. 22, n. 10, p. 1–23, 2022.

ZHU, H.; XIE, Y.; HUANG, H.; JING, C.; RONG, Y.; WANG, C. DB-YOLO: A duplicate bilateral YOLO network for multi-scale ship detection in SAR images. **Sensors**, v. 21, n. 23, p. 1–15, 2021.

**CAPÍTULO 3 – UMA ABORDAGEM DA RNC PARA CONTAR  
PLANTAS SIMULTANEAMENTE E DETECTAR LINHAS DE  
PLANTAÇÃO A PARTIR DE IMAGENS DE VANT**

O artigo a seguir foi publicado no periódico  
ISPRS Journal of Photogrammetry and Remote  
Sensing (ISSN 0924-2716)  
<https://doi.org/10.1016/j.isprsjprs.2021.01.024>

## RESUMO

O mapeamento preciso de terras agrícolas é um pré-requisito importante para a agricultura de precisão, pois auxilia na gestão do campo, na previsão de rendimento e no gerenciamento ambiental. As culturas são sensíveis aos padrões de plantio e algumas tem a capacidade limitada de compensar as lacunas dentro de uma linha. A imagem óptica com sensores montados em Veículos Aéreos Não Tripulados (VANT) é uma opção econômica para capturar imagens cobrindo terras agrícolas hoje em dia. No entanto, a inspeção visual de tais imagens pode ser uma tarefa difícil e tendenciosa, especificamente para detectar plantas e linhas numa só etapa. Assim, o desenvolvimento de uma arquitetura capaz de extrair simultaneamente plantas de plantas individualmente e linhas de plantação a partir de imagens de VANT é ainda uma exigência importante para apoiar a gestão de sistemas agrícolas. Neste artigo, propomos um novo método de aprendizagem profunda baseado numa Rede Neural Convolutiva (CNN) que simultaneamente detecta e geolocaliza linhas de plantação enquanto conta suas plantas considerando configurações de plantação altamente densas. A configuração experimental foi avaliada num campo de milho (*Zea mays* L.) com diferentes fases de crescimento (ou seja, plantas recentemente plantadas e plantas maduras). Ambos os conjuntos de dados caracterizam diferentes cenários de densidade de plantas, em diferentes locais, com diferentes tipos de culturas, e a partir de diferentes sensores e datas. Este esquema foi utilizado para provar a robustez da abordagem proposta, permitindo uma discussão mais alargada do método. Foi implementada uma arquitetura de dois ramos no nosso método CNN, em que a informação obtida dentro da linha de plantação é atualizada no ramo de detecção de plantas e retroalimentada para o ramo da linha; que são depois refinados por um método de refinamento em várias fases. Nos conjuntos de dados de plantações de milho (com ambas as fases de crescimento - jovem e madura), a nossa abordagem produziu um erro absoluto médio (MAE) de 6,224 plantas por fragmento de imagem, um erro relativo médio (MRE) de 0,1038, valores de precisão e de recordação de 0,856 e 0,905, respetivamente, e uma medida F igual a 0,876. Estes resultados foram superiores aos resultados de outras redes profundas (HRNet, Faster R-CNN e RetinaNet) avaliadas com a mesma tarefa e conjunto de dados. Para a detecção de linhas de plantio, a nossa abordagem obteve pontuações de precisão, recuperação e medida F de 0,913, 0,941 e 0,925, respetivamente. O método proposto alcançou o desempenho mais avançado para a contagem e geolocalização de plantas e linhas de plantas em imagens de VANT de diferentes tipos de culturas. O método aqui proposto pode ser aplicado em futuros

modelos de tomada de decisão e pode contribuir para a gestão sustentável dos sistemas agrícolas.

**Palavras-chave:** Agricultura de precisão, aprendizagem profunda, detecção de objetos, detecção remota e imagens de VANT



## CONSIDERAÇÕES FINAIS

Observa-se um crescimento na utilização de revisões de literatura na Zootecnia, evidenciando-se como uma ferramenta crucial para identificar lacunas e direcionar estudos futuros. Assim, neste estudo, por meio de uma revisão integrativa, sintetizamos e descrevemos os principais resultados encontrados na utilização de imagens obtidas por sensoriamento remoto para identificar características agronômicas das culturas do milho, milho e sorgo.

Devido à sua grande importância econômica mundial, a cultura do milho tem sido amplamente estudada e destacada em diversas pesquisas. Em relação à obtenção de imagens, o Veículo Aéreo Não Tripulado (VANT) é a forma mais utilizada devido à sua praticidade, disponibilidade de diversos sensores e versatilidade de montagem em várias configurações. Uma ferramenta promissora tanto na tomada de decisão quanto no gerenciamento da produção agrícola. Nos estudos encontrados as características produtivas foram frequentemente objeto de análise e discussão.

Muito ainda precisa ser estudado em relação às culturas do milho e sorgo, devido à sua rusticidade e excelente qualidade nutricional, podendo representar alternativas viáveis ao uso do milho na alimentação animal.

Outro tema muito em alta nas pesquisas é a utilização dos detectores de objetos em tempo real, devido ao seu rápido processamento, permitindo o acesso a respostas ágeis. Estes modelos, quando associados a imagens obtidas por sensoriamento remoto de cultivos, possibilitam identificar e antecipar interferências e garantir uma gestão mais eficaz, contribuindo para a produtividade e sustentabilidade das culturas agrícolas.

Sem dúvida, a realização de pesquisas voltadas para a associação de tecnologias de imagens com a produção agrícola tem o potencial de impulsionar o desenvolvimento sustentável do agronegócio. Essa abordagem poderá promover uma gestão mais precisa e eficiente, permitindo o uso mais racional dos recursos naturais, aumentando a produtividade e reduzindo os impactos ambientais.

## APÊNDICE A

### PROTOCOLO DO ESTUDO DE REVISÃO INTEGRATIVA

**Título:** Sensoriamento remoto para diferenciação e previsão das características produtivas do milho, milheto e sorgo: uma revisão integrativa

**Objetivo:** Sintetizar as tecnologias utilizadas na diferenciação das culturas de milho, milheto e sorgo para caracterização agrônômica a partir de estudos primários publicados nas bases de dados.

**Questão norteadora:** Quais são as principais tecnologias utilizadas na diferenciação das culturas de milho, milheto e sorgo para caracterização agrônômica?

#### **Estratégia PVO para formular a questão de pesquisa:**

P - Milho, milheto e sorgo (população/contexto)

V - Tecnologias utilizadas na obtenção de imagens e metodologias aplicadas ao processamento (variáveis de interesse)

O - Variáveis agrônômicas e diferenciação (resultados)

#### **Estratégia de Busca**

- Banco de dados 1: SCOPUS (Elsevier)
- Banco de dados 2: Web of Science (coleção principal)
- Banco de dados 3: Science Direct (Elsevier)
- Banco de dados 4: CAB direct

#### **Descritores:**

#1 "Corn" OR "Maize" OR "Millet" OR "Sorghum" OR "Zea mays" OR "Pennisetum" OR "Sorghum bicolor" OR "Milho-zaburro" OR "Mapira" OR "Massambala" OR "Mexoeira" OR "Massango" OR "Milho" OR "Sorgo" OR "Milheto" OR "玉米" OR "小米" OR "高粱"

#2 "Deep learning" OR "UAV" OR "Unmanned aerial vehicle" OR "RPA" OR "Remotely piloted aircraft" OR "HTP" OR "Transformers" OR "Precision Agriculture" OR "Drone" OR "Satellite Image" OR "Technified Agriculture" OR "Algorithms"

#3 "Number of plants" OR "Forage mass" OR "Species differentiation" OR "Agronomic characterization" OR "Productivity"

**Cruzamento dos descritores:**

Único: #1 AND #2 AND #3

**Busca nas bases de dados:**

SCOPUS:

TITLE-ABS-KEY ( "Corn" OR "Maize" OR "Millet" OR "Sorghum" OR "Zea mays" OR "Pennisetum" OR "Sorghum bicolor" OR "Milho-zaburro" OR "Mapira" OR "Massambala" OR "Mexoeira" OR "Massango" OR "Milho" OR "Sorgo" OR "Milheto" OR "玉米" OR "小米" OR "高粱" ) AND TITLE-ABS-KEY ( "Deep learning" OR "UAV" OR "Unmanned aerial vehicle" OR "RPA" OR "Remotely piloted aircraft" OR "HTP" OR "Transformers" OR "Precision Agriculture" OR "Drone" OR "Satellite Image" OR "Technified Agriculture" OR "Algorithms" ) AND TITLE-ABS-KEY ( "Number of plants" OR "Forage mass" OR "Species differentiation" OR "Agronomic characterization" OR "Productivity" )

WEB OF SCIENCE

TS="Corn" OR "Maize" OR "Millet" OR "Sorghum" OR "Zea mays" OR "Pennisetum" OR "Sorghum bicolor" OR "minho-zaburro" OR "makira" OR "massambaba" OR "meixoeira" OR "massagno" OR "minho" OR "Sorgo" OR "mileto" OR "玉米" OR "小米" OR "高粱" (Topic) and "Deep learning" OR "UAV" OR "Unmanned aerial vehicle" OR "RPA" OR "Remotely piloted aircraft" OR "HTP" OR "Transformers" OR "Precision Agriculture" OR "Drone" OR "Satellite Image" OR "Technified Agriculture" OR "Algorithms" (Topic) and "Number of plants" OR "Forage mass" OR "Species differentiation" OR "Agronomic characterization" OR "Productivity" (Topic)

SCIENCE DIRECT:

("Zea mays" OR "Pennisetum" OR "Sorghum bicolor") AND ( "Deep learning" OR "UAV" OR "RPA" OR "HTP") AND ("Productivity" OR "Number of plants")

CAB direct:

ab:("Corn" OR "Maize" OR "Millet" OR "Sorghum" OR "Zea mays" OR "Pennisetum" OR "Sorghum bicolor" OR "Milho-zaburro" OR "Mapira" OR "Massambala" OR "Mexoeira" OR "Massango" OR "Milho" OR "Sorgo" OR "Milheto" OR "玉米" OR "小米" OR "高粱") AND ab:("Deep learning" OR "UAV" OR "Unmanned aerial vehicle" OR "RPA" OR "Remotely piloted aircraft" OR "HTP" OR "Transformers" OR "Precision Agriculture" OR "Drone" OR "Satellite Image" OR "Technified Agriculture" OR "Algorithms") AND ab:("Number of plants" OR "Forage mass" OR "Species differentiation" OR "Agronomic characterization" OR "Productivity")

#### **Seleção de estudos Critérios de inclusão:**

Artigos de pesquisa completos disponíveis na íntegra nas bases de dados no formato de estudos experimentais bem delineados. Estudos em qualquer idioma. Sem prazo.

Critérios de exclusão: editoriais, cartas ao editor, resumos, opinião de especialistas, outras resenhas, correspondência, resenhas, capítulos de livros, teses e dissertações, resumos, palestras, livros ou capítulos de livros e artigos que utilizaram sensoriamento proximal.

Artigos duplicados serão considerados apenas uma vez.

#### **Teste de Relevância**

O teste de relevância (Olsen, 1995) foi realizado com três avaliadores previamente treinados.

### **Estratégia para coleta de dados e síntese de estudos**

Instrumento que contém informações sobre a identificação da publicação (título do artigo, DOI, autores, país, idioma e ano de publicação), nome da revista científica, aspectos metodológicos do estudo (descrição do estudo realizado, período experimental, variáveis analisadas e resultados encontrados), as tecnologias aplicadas, a precisão do modelo utilizado e conclusões.

### **Avaliação metodológica dos estudos**

A avaliação da qualidade metodológica das pesquisas será avaliada pelo instrumento CASP por desempenho metodológico.

### **Resultados da pesquisa concluídos até 14 de setembro de 2022**

Base de Dados	Cruzamento	Tipo do documento	Artigos encontrados
SCOPUS	Único	Artigo de pesquisa	216
Web of Science	Único	Artigo de pesquisa	177
Science Direct	Único	Artigo de pesquisa	64
CAB direct	Único	Artigo de pesquisa	128
Total			585

### **Referências**

Olsen, J., 1995. Meta-analysis or Collaborative Studies. *Journal of Occupational and Environmental Medicine* 37, 897-902. doi:10.1097/00043764-199508000-00002.