

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CÂMPUS DE CHAPADÃO DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

JOÃO LUCAS GOUVEIA DE OLIVEIRA

**SENSOR MULTIESPECTRAL E APRENDIZAGEM DE MÁQUINA  
PARA CLASSIFICAÇÃO DE HÍBRIDOS DE MILHO IRRIGADO**

CHAPADÃO DO SUL – MS

2023

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CAMPUS DE CHAPADÃO DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

JOÃO LUCAS GOUVEIA DE OLIVEIRA

**SENSOR MULTIESPECTRAL E APRENDIZAGEM DE MÁQUINA  
PARA CLASSIFICAÇÃO DE HÍBRIDOS DE MILHO IRRIGADO**

Orientador: Prof. Dr. Job Teixeira de Oliveira

Dissertação apresentada à  
Universidade Federal de Mato  
Grosso do Sul, como parte dos  
requisitos para obtenção do título de  
Mestre em Agronomia, área de  
concentração: Produção Vegetal.

CHAPADÃO DO SUL – MS

2023



Serviço Público Federal  
Ministério da Educação  
Fundação Universidade Federal de Mato Grosso do Sul



## PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

### CERTIFICADO DE APROVAÇÃO

**DISCENTE:** João Lucas Gouveia de Oliveira

**ORIENTADOR:** Dr. Job Teixeira de Oliveira

**TÍTULO:** Sensor multiespectral e aprendizagem de máquina para classificação de híbridos de milho irrigado

#### AVALIADORES:

Prof. Dr. Job Teixeira de Oliveira

Prof. Dr. Fabio Henrique Rojo Baio

Prof. Dr. Fernando Franca da Cunha

Chapadão do Sul, 30 de agosto de 2023.

NOTA  
MÁXIMA  
NO MEC

\*\*\*\*\*  
UFMS  
É 10!!!  
\*\*\*\*\*



Documento assinado eletronicamente por **Job Teixeira de Oliveira, Professor do Magisterio Superior**, em 30/08/2023, às 14:35, 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 **Fabio Henrique Rojo Baio, Professor do Magisterio Superior**, em 30/08/2023, às 14:37, 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 **Fernando França da Cunha, Usuário Externo**, em 30/08/2023, às 22:46, 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](#).

**DEDICATÓRIA**

Dedico este trabalho a minha família, responsáveis por me ensinar os verdadeiros valores que devemos buscar e me fornecem as ferramentas necessárias para construir o meu caminho através do estudo e do trabalho. Esses que foram exímios professores ao ministrarem perfeitas aulas práticas sobre a vida, exemplos de integridade, generosidade, dedicação e fé. A vocês expresso minha imensa admiração.

## AGRADECIMENTOS

Destaco inicialmente meu agradecimento a Deus, pelo seu amor e pelas maravilhas que faz em minha vida, suas bênçãos são grandiosas e tudo o que tenho a agradecer vem d'Ele.

Tenho infinitas razões para agradecer minha mãe Luzani Carneiro Gouveia Vasconcelos, que de forma incansável me acompanhou a distância ao lado do meu padrasto Rônei Queiroz Vasconcelos. Vocês me ensinam diariamente o que é o amor e cuidado, são minha imensa fonte de admiração, este caminho que eu tenho percorrido não seria possível sem a orientação de vocês.

Harmoniosamente combinada com amor, carinho e coragem, minha avó Maria Iracema Fontoura, sempre com seu abraço forte capaz de me fornecer apoio inabalável, dona de um coração bondoso e meu maior exemplo de generosidade.

Exalto também a minha tia, Sandra Oliveira da Silva com seu carinho e amor influenciam profundamente a minha vida. Sou grato pelo tempo que me acolheu em sua casa, lugar onde aprendi muito sobre um lar e sinto muita saudade.

Nada poderia ter feito os dias melhores do que as amizades que fiz durante esse período. Dthenifer Cordeiro Santana e Izabela Cristina de Oliveira, mesmo os momentos mais difíceis se tornaram mais leves e tranquilos ao estar com vocês. Sou profundamente grato pela amizade e companheirismo de vocês.

Inesquecíveis episódios que passei com meus amigos de república, Juliano Lucas Cardoso Jesus, Alex Henrique Santana, Gustavo Casadei, Helen Nascimento, Gabriel Augusto Teixeira Devolio, Samyra Alves de Oliveira Gonçalves, Camila Angela de Oliveira Coutinho, Yasmim Rocha da Silva, Yann Victor Muniz de Araújo Portugal, Luis Gustavo Martins Santos e Felipe Carrijo de Araújo, todas as festas, todos os passeios, todos vocês sempre estarão em minha memória.

Foram fundamentais para meu desenvolvimento acadêmico, agradeço o corpo docente do campus de Chapadão do Sul, em especial meu orientador Prof. Dr. Job Teixeira de Oliveira, que sempre dispôs do seu tempo a partilhar do seu conhecimento. Sou grato aos professores Dr. Paulo Eduardo Teodoro e Dra. Larissa Teodoro que me acolheram em seu grupo de pesquisa e compartilharam seus ensinamentos acadêmicos e experiências de vida.

Enquanto nos meus melhores pensamentos, nada teria me feito imaginar tudo o que se passou durante minha passagem pela pós-graduação, ressalto alguém que contribui enormemente para meu enriquecimento pessoal e profissional, Prof(a). Dra. Charline

1   Zaratin, depositou sua confiança e me proporcionou uma das grandes experiências da  
2   minha vida.

3           Rogo a Deus pela vida de vocês e espero retribuir tudo o que já me  
4   proporcionaram. Mesmo sonhar com todos esses momentos não seria fácil, mas  
5   concretizar sem vocês, com certeza seria impossível. Cada palavra escrita aqui, ainda não  
6   é capaz de expressar minha gratidão.

7

## ΕΠÍΓΡΑΦΕ

1

2 Bendize o minha alma ao Senhor, e não te esqueças de nenhum dos seus benefícios.

### 3 Salmos 103.2

## RESUMO

No avanço da agricultura vem surgindo métodos de avaliação de fenótipos com o auxílio do sensoriamento e com técnicas de aprendizagem de máquinas. O objetivo do capítulo 1 é classificar híbridos de milho em diferentes manejos de irrigação por meio de imagens multiespectrais buscando o melhor algoritmo de aprendizagem de máquinas para a classificação e o input que melhore o desempenho dos modelos. O objetivo do capítulo 2 é encontrar o algoritmo de aprendizagem de máquinas mais acurado na classificação de híbridos de milho e determinar dados de entrada dos modelos que melhorem a performance dos algoritmos. O experimento foi implementado na área experimental da Universidade Federal de Mato Grosso do Sul no município de Chapadão do Sul, Brasil. Os híbridos de milho utilizados no experimento foram: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3) em dois manejos de irrigação (Irigado e sequeiro). Após 60 dias de emergência da cultura foi utilizado o ARP Sensefly eBee RTK obtendo os comprimentos de onda (SB): Azul (475nm, B\_475), verde (550 nm, G\_550), vermelho (660 nm, R\_660), borda do vermelho (735 nm, RE\_735) e NIR (790 nm, NIR\_790). Após obter os dados de SB foi possível a realização de cálculos de índices de vegetação (VIs). Os dados foram submetidos as análises de aprendizagem de máquina, testando seis algoritmos: Redes neurais artificiais (ANN), Árvores de decisão J48 (J48), REPTree (DT), Floresta aleatória (RF), Máquina de vetor suporte (SVM) e Regressão logística (RL) utilizado como padrão. Três métricas de acurácia foram utilizados buscando averiguar a acurácia dos algoritmos em classificar os híbridos de milho: classificações corretas (CC), coeficiente Kappa e F-Score. Na classificação dos híbridos o algoritmo Redes Neurais Artificiais (ANN) foi o que apresentou melhor resultado. O melhor input foi bandas espectrais (SB) proporcionando melhor acurácia de classificação. Na classificação do manejo irrigado e sequeiro os melhores algoritmos foi ANN e RF, utilizando os inputs IVs e SB+IVs.

**Palavras-chave:** Assinatura espectral; Inteligência computacional; Sensoriamento remoto.



## ABSTRACT

With the advancement of agriculture, methods for evaluating phenotypes have emerged with the aid of sensing and machine learning techniques. The objective of Chapter 1 is to classify maize hybrids in different irrigation managements through multispectral images, searching for the best machine learning algorithm for classification and input that improves the performance of the models. The objective of Chapter 2 is to find the most accurate machine learning algorithm in the classification of maize hybrids and to determine input data from the models that improve the performance of the algorithms. The experiment was implemented in the experimental area of the Federal University of Mato Grosso do Sul in the municipality of Chapadão do Sul, Brazil. The corn hybrids used in the experiment were: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3) in two irrigation managements (Irrigated and rainfed). After 60 days of culture emergence, the ARP Sensefly eBee RTK was used to obtain the wavelengths (SB): Blue (475nm, B\_475), green (550 nm, G\_550), red (660 nm, R\_660), edge of red (735 nm, RE\_735) and NIR (790 nm, NIR\_790). After obtaining the SB data, it was possible to perform calculations of vegetation indices (VIs). The data were subjected to machine learning analysis, testing six algorithms: Artificial Neural Networks (ANN), J48 Decision Trees (J48), REPTree (DT), Random Forest (RF), Support Vector Machine (SVM) and Regression logistics (RL) used as default. Three accuracy metrics were used in order to ascertain the accuracy of the algorithms in classifying corn hybrids: correct classifications (CC), Kappa coefficient and F-Score. In the classification of hybrids, the Artificial Neural Networks (ANN) algorithm was the one that presented the best result. The best input was spectral bands (SB) providing better classification accuracy. In the classification of irrigated and rainfed management, the best algorithms were ANN and RF, using IVs and SB+IVs inputs.

**Keywords:** Spectral signature; Computational intelligence; Remote sensing.

## SUMÁRIO

|    |                                                                       |     |
|----|-----------------------------------------------------------------------|-----|
| 1  |                                                                       |     |
| 2  | RESUMO .....                                                          | vi  |
| 3  | Palavras-chave.....                                                   | vi  |
| 4  | ABSTRACT .....                                                        | vii |
| 5  | Keywords.....                                                         | vii |
| 6  | CAPÍTULO 1 - CLASSIFICAÇÃO DE MANEJO DE IRRIGAÇÃO EM HÍBRIDOS         |     |
| 7  | DE MILHO UTILIZANDO SENSOR MULTIESPECTRAL E APRENDIZAGEM DE           |     |
| 8  | MÁQUINAS.....                                                         | 1   |
| 9  | RESUMO .....                                                          | 1   |
| 10 | Palavras-chave.....                                                   | 1   |
| 11 | ABSTRACT .....                                                        | 2   |
| 12 | Keywords.....                                                         | 2   |
| 13 | 1. INTRODUÇÃO .....                                                   | 3   |
| 14 | 2. MATERIAL E MÉTODOS .....                                           | 4   |
| 15 | 3. RESULTADOS .....                                                   | 7   |
| 16 | 4. DISCUSSÃO.....                                                     | 11  |
| 17 | 5. CONCLUSÃO .....                                                    | 14  |
| 18 | REFERÊNCIAS .....                                                     | 14  |
| 19 | CAPITULO 2: CLASSIFICAÇÃO DE HÍBRIDOS DE MILHO UTILIZANDO             |     |
| 20 | SENSOR MULTIESPECTRAL E APRENDIZAGEM DE MÁQUINA.....                  | 19  |
| 21 | RESUMO .....                                                          | 19  |
| 22 | Palavras-chave.....                                                   | 19  |
| 23 | ABSTRACT .....                                                        | 20  |
| 24 | Keywords.....                                                         | 20  |
| 25 | 1. INTRODUÇÃO .....                                                   | 20  |
| 26 | 2. MATERIAIS E MÉTODO.....                                            | 22  |
| 27 | 2.1. Condução do experimento .....                                    | 22  |
| 28 | 2.2. Aquisição e processamento das imagens multiespectrais.....       | 23  |
| 29 | 2.3. Modelos de Aprendizagem de Máquina e Análises Estatísticas ..... | 23  |
| 30 | 3. RESULTADOS .....                                                   | 24  |
| 31 | 4. DISCUSSÃO.....                                                     | 30  |
| 32 | 5. CONCLUSÃO .....                                                    | 32  |
| 33 | REFERÊNCIAS .....                                                     | 33  |
| 34 |                                                                       |     |

# **CAPÍTULO 1 - CLASSIFICAÇÃO DE MANEJO DE IRRIGAÇÃO EM HÍBRIDOS DE MILHO UTILIZANDO SENSOR MULTIESPECTRAL E APRENDIZAGEM DE MÁQUINAS**

## **RESUMO**

O uso de sensores multiespectrais associados a análises de aprendizagem de máquinas tem se mostrado cada vez mais eficiente na classificação de diferentes características morfofisiológicas. A hipótese deste estudo é que plantas que sejam submetidas a diferentes manejos de irrigação apresentem comportamento espectral diferente, possibilitando sua classificação por meio de modelagens de aprendizagem de máquinas. Assim, o objetivo deste trabalho é classificar híbridos de milho em diferentes manejos de irrigação por meio de imagens multiespectrais buscando o melhor algoritmo de aprendizagem de máquinas para a classificação e o input que melhore o desempenho dos modelos. O experimento foi conduzido na área experimental da Universidade Federal de Mato Grosso do Sul, no município de Chapadão do Sul – MS, onde sete híbridos: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3) foram submetidos a diferentes manejos de irrigação e sem irrigação. Aos 60 dias após a emergência da cultura foram coletadas as bandas azul (475nm, B\_475), verde (550 nm, G\_550), vermelho (660 nm, R\_660), borda do vermelho (735 nm, RE\_735) e NIR (790 nm, NIR\_790) utilizando o Sensefly eBee RTK (Aeronave Remotamente Pilotada) de asa fixa equipada com um sensor multiespectral Parrot Sequoia associado a tecnologia RTK (*Real Time Kinematics*). Através dos dados de bandas coletados, foi utilizado o programa de sistemas de informações geográficas ESRI ArcGIS 10.5. para calcular 41 índices de vegetação (IVs). Os dados foram analisados através de aprendizagem de máquina, testando seis algoritmos: Regressão logística (RL), REPTree (DT), Árvores de decisão J48 (J48), Floresta aleatória (RF), Redes neurais artificiais (ANN) e Máquina de vetor suporte (SVM). Três métricas de acurácia foram utilizados buscando avaliar os algoritmos na classificação dos manejos de irrigação: classificações corretas (CC), coeficiente Kappa e F-Score. Os algoritmos ANN e RF apresentaram melhor acurácia na classificação dos híbridos de milho quando ao manejo de irrigação. IVs e SB+IVs proporcionaram melhor desempenho aos algoritmos.

**Palavras-chave:** Floresta Aleatória, Índices de Vegetação, Redes Neurais Artificiais.

# CLASSIFICATION OF IRRIGATION MANAGEMENT IN CORN HYBRIDS USING MULTISPECTRAL SENSOR AND MACHINE LEARNING

## ABSTRACT

The use of multispectral sensors associated with machine learning analysis has proven to be increasingly efficient in classifying different morphophysiological characteristics. The hypothesis of this work is that plants that are submitted to different irrigation managements present different spectral behavior, allowing their classification through machine learning modeling. Thus, the objective of this work is to classify maize hybrids in different irrigation managements using multispectral images, seeking the best machine learning algorithm for classification and input that improves the performance of the models. The experiment was carried out in the experimental area of the Federal University of Mato Grosso do Sul, in the municipality of Chapadão do Sul - MS, where seven hybrids: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3) were subjected to irrigation and non-irrigation management. At 60 days after emergence of the culture, the blue (475nm, B\_475), green (550 nm, G\_550), red (660 nm, R\_660), red border (735 nm, RE\_735) and NIR (790 nm, NIR\_790) using the Sensefly eBee RTK (Remotely Piloted Aircraft) fixed wing equipped with a Parrot Sequoia multispectral sensor associated with RTK (Real Time Kinematics) technology. Through the collected band data, the ESRI ArcGIS 10.5 geographic information system program was used to calculate 41 vegetation indices (VIs). Data were analyzed using machine learning, testing six algorithms: Logistic Regression (RL), REPTree (DT), J48 Decision Trees (J48), Random Forest (RF), Artificial Neural Networks (ANN) and Support Vector Machine (SVM). Three accuracy metrics were used seeking to evaluate the algorithms in the classification of irrigation management: correct classifications (CC), Kappa coefficient and F-Score. The ANN and RF algorithms showed better accuracy in the classification of corn hybrids in terms of irrigation management. IVs and SB+IVs provided better performance to the algorithms.

**Keywords:** Random Forest, Vegetation Indices, Artificial Neural Networks.

## 1. INTRODUÇÃO

As técnicas mais usadas na fenotipagem apresentam falhas devido ao alto custo, grande dependência de mão de obra e demora nos processos de avaliação (AMPATZIDIS; PARTEL, 2019). Desta forma, utilizar plataformas de mensuração de resposta imediata sobre o estado da cultura pode auxiliar a coleta de informações sobre o fenótipo, contribuindo com melhoramento de plantas (BANERJEE et al., 2020). As folhas são as principais vias sinalizadoras de alterações bioquímicas, apresentando rápidas respostas sobre o estado fisiológico e sanitário das plantas (ZHANG et al., 2023).

O sensoriamento remoto possibilita por meio da refletância das folhas, fornecer informações que podem ser relacionadas com a composição química, estrutura celular e propriedades metabólicas das plantas por meio de diagnósticos prévios e de forma não destrutiva (KOVAR et al., 2019; WU et al., 2019). A adoção de sensores multiespectrais na coleta de tais informações, possibilita que haja maior frequência nas avaliações, viabilizando a obtenção de dados durante todo o ciclo da cultura (XIE; YANG, 2020).

A condição hídrica das plantas causa diversas alterações morfofisiológicas no milho (*Zea mays* L.), interferindo na eficiência fotossintética e nos seus parâmetros produtivos (SAH et al., 2020). Bandas espectrais e modelos matemáticos baseado em tais bandas, denominados índices de vegetação (IVs), são sensíveis em detectar informações relacionáveis a mudanças celulares que são dependentes da água, como o ajuste osmótico celular, podendo fornecer informações da condição hídrica celular em diferentes níveis de irrigação (LI et al., 2022; JAVORNIK et al., 2023).

As abordagens por meio de análises de dados tradicionais não se apresentam eficientes em comparação aos modelos proporcionados pela aprendizagem de máquina (ML) onde diversos trabalhos demonstram sua alta capacidade em combinar características numéricas e extrair as informações sobre os fenótipos (SPIŠIĆ et al., 2022). Desta forma, tais algoritmos como as redes neurais estão sendo aplicados para a classificação de genótipos e fenótipos (MAXWELL et al., 2018).

A hipótese desse trabalho é que plantas que sejam submetidas a diferentes manejos de irrigação apresentem comportamento espectral diferente, possibilitando sua classificação por meio de modelagens de aprendizagem de máquinas. Assim, o objetivo deste trabalho é classificar híbridos de milho em diferentes manejos de irrigação por meio de imagens multiespectrais buscando o melhor algoritmo de aprendizagem de máquinas para a classificação e o input que melhore o desempenho dos modelos.

## 2. MATERIAL E MÉTODOS

O experimento foi conduzido na área experimental da Universidade Federal de Mato Grosso do Sul, no município de Chapadão do Sul - MS, sob as coordenadas geográficas, 18°41'33'' de latitude Sul; 52°40'45'' de longitude Oeste e altitude média de 810 m. O solo da área foi caracterizado como Latossolo Vermelho Distrófico (SANTOS et al., 2018) argiloso (48% de argila). Texturas e características químicas do solo apresentadas na tabela 1.

Tabela 1. Características químicas e físico-hídricas do solo da área experimental.

| Camada     | pH <sup>1</sup> | Al <sup>3+</sup> | Ca <sup>2</sup> |                 | P          | K <sup>2</sup> | SB <sup>2</sup> | CTC <sup>3</sup> | CC <sup>4</sup> | MO <sup>5</sup>    | V <sup>6</sup> | Areia | Silte | Argila |
|------------|-----------------|------------------|-----------------|-----------------|------------|----------------|-----------------|------------------|-----------------|--------------------|----------------|-------|-------|--------|
|            |                 |                  | +               | Mg <sup>2</sup> |            |                |                 |                  |                 |                    |                |       |       |        |
| m          |                 |                  |                 |                 | cmolc dm-3 |                |                 |                  |                 | g dm <sup>-3</sup> | %              |       | g kg  |        |
| 0,0 – 0,20 | 6,2             | 0,0              | 4,31            |                 | 41,3       | 0,2            | 2,3             | 5,1              | 0,413           | 19,7               | 45,0           | 515   | 25    | 460    |

<sup>1</sup>pH = potencial hidrogeniônico em água; <sup>2</sup>SB= soma de bases; <sup>3</sup>CTC= Capacidade de Troca Catiônica; <sup>4</sup>CC = Umidade na capacidade de campo ao potencial mátrico; <sup>5</sup>MO = Matéria orgânica; <sup>6</sup>V= Saturação por bases.

O clima da região é definido Tropical Savana (Aw), segundo a classificação de Koppen. Para o bom desenvolvimento do milho é preciso uma precipitação próxima de 500 mm (MONFREDA et al., 2008) que não foi atingida durante o período de cultivo como demonstrado na Figura 1 (373.5 mm). Dessa forma foi necessária uma complementação com a irrigação, evitando estresse hídrico no período vegetativo e enchimento de grãos (HANJRA & QURESHI, 2010).




Figura 1. Balanço hídrico sequeiro no decorrer da segunda safra 2021/2022.




Figura 2. Balanço hídrico irrigado no decorrer da segunda safra 2021/2022.

O experimento foi conduzido em esquema de faixas com sete híbridos: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3) submetidos a manejos irrigado e sequeiro. Para a irrigação utilizou-se a aspersão convencional, posicionando os aspersores a cada 12 m,

deste modo realizando uma faixa irrigada passando sobre todos os híbridos com largura de 18 m. O método utilizado foi o de Penman-Monteith-FAO, utilizando dados de uma estação meteorológica automática do Instituto Nacional de Meteorologia (INMET), com 100% de reposição da Evapotranspiração da cultura – ET<sub>c</sub>, toda vez que o balanço de água do solo aproximava-se do limite inferior da Capacidade Real de Água do Solo-CRA, conforme Allen et al. (1998).

Foi utilizado o método convencional para o preparo de solo (aração e gradagem niveladora). Os híbridos foram semeados por meio de semeadora-adubadora, com mecanismo sulcador tipo haste para a disposição do fertilizante, e mecanismo sulcador tipo duplo desencontrado para a semente, posicionada a uma profundidade de aproximadamente 3 cm, com espaçamento de 0,45 m, com média de 2,65 plantas por metro, no dia 25/02/2022. Foram diagramadas parcelas de 18,62 m<sup>2</sup> (3,8 m x 4,9 m). A adubação de base foi realizada no sulco aplicando 200 kg ha<sup>-1</sup> de fosfato monoamônico (MAP) do formulado 11-52-00. A adubação de cobertura ocorreu no estágio V4 (milho com quatro folhas totalmente desenvolvidas) com a dose de 150 kg ha<sup>-1</sup> de Ureia 45% de N.

Aos 60 dias após a emergência da cultura, momento de florescimento pleno onde o milho atinge o seu maior pico de absorção de nutrientes e de atividade fotossintética, foi realizado um voo às 09:00 da manhã, com céu limpo de nuvens, a uma altitude de 100 e resolução espacial de 0.10 m utilizando o Sensefly eBee RTK (Aeronave Remotamente Pilotada) de asa fixa. A ARP foi equipada com um sensor multiespectral Parrot Sequoia que associado a tecnologia RTK (*Real Time Kinematics*) permite o posicionamento do sensor no local estipulado para coleta da imagem com uma acurácia de 2,5 cm. O programa Pix4Dmapper foi utilizado para mosaicagem e ortorretificação das imagens.

O Parrot Sequoia contém uma superfície refletiva para calibração radiométrica fornecida pelo fabricante e um sensor de luminosidade para calibração de valores adquiridos. As bandas coletadas pelo sensor são: azul (475nm, B\_475), verde (550 nm, G\_550), vermelho (660 nm, R\_660), borda do vermelho (735 nm, RE\_735) e NIR (790 nm, NIR\_790). Através dos dados de bandas coletados na área, foi utilizado o programa de sistemas de informações geografias ESRI ArcGIS 10.5. para calcular 41 índices de vegetação (IVs) utilizando desde as razões simples entre as bandas até cálculos com diferentes configurações que possibilitam correção de problemas atmosféricos ou suavizar influência do solo (SILVA et al., 2020; RAMOS et al., 2020).



Após a coleta, os dados foram analisados utilizando o programa Weka 3.8.5 que forneceu os algoritmos de aprendizagem de máquina que foram testados (Tabela 2). Foram utilizadas arquiteturas padrões do programa para cada algoritmo. RL foi utilizado como padrão, em que se busca melhores desempenhos dos algoritmos quando comparados a ele. A classificação dos híbridos foi realizada por meio de validação cruzada estratificada com  $k\text{-fold} = 10$  e dez repetições (100 execuções para cada modelo).

Tabela 2. Relação dos modelos de aprendizagem de máquinas utilizados na classificação.

| Sigla | Modelo de aprendizagem de máquinas | Referência                                  |
|-------|------------------------------------|---------------------------------------------|
| RL    | Regressão logística                | (ŠTEPANOVSÝ et al., 2017)                   |
| DT    | REPTree                            | (SNOUSY et al., 2011)                       |
| J48   | Árvores de decisão J48             | (QUINLAN, 1993)                             |
| RF    | Floresta aleatória                 | (BELGIU; DRĂGUȚ, 2016)                      |
| ANN   | Redes neurais artificiais          | (EGMONT-PETERSEN; DE RIDDER; HANDELS, 2002) |
| SVM   | Máquina de vetor suporte           | (NALEPA; KAWULOK, 2019)                     |

Foram utilizados três métricas de acurácia para avaliar o desempenho dos algoritmos em classificar os diferentes manejos de irrigação: classificação correta (CC), coeficiente kappa e F-Score. Foram utilizados os pacotes ggplot2 e ExpDes.pt do software R para elaborar as análises e gráficos (TEAM, 2013).

### 3. RESULTADOS

Na Figura 3 é apresentada a refletância dos híbridos em seus diferentes manejos, sob os diferentes comprimentos de onda. Os híbridos cultivados em sequeiro obtiveram maior refletância nos comprimentos de onda R\_660 e NIR\_790. Nos comprimentos de ondas B\_475, G\_550 e RE\_735 não houve diferença entre os manejos.




Figura 3. Boxplot para as médias de reflectância nos comprimentos de onda azul (B, 475 nm), verde (G, 550 nm), vermelho (R, 660 nm), borda do vermelho (RE, 735 nm) e NIR (790 nm) em milho sob manejo de irrigação e sequeiro.

As médias seguidas pelas mesmas letras para as diferentes entradas de manejos de irrigação não diferem pelo teste t a 5% de probabilidade.

Houve interação significativa entre os algoritmos de aprendizagem de máquina (ML) e os inputs testados. Através da métrica de acurácia classificação correta (CC) é observado que os melhores algoritmos foram ANN nos diferentes inputs e RF ao utilizar IVs e SB+IVs (Figura 4). Não houve diferença estatística entre os inputs para RL. Os demais algoritmos apresentaram melhor desempenho com os inputs IVs e SB+IVs.




Figura 4. Boxplot para porcentagem de classificação correta (CC) considerando a interação significativa entre os algoritmos de ML e as entradas testadas.

Médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.

Observando a métrica F-Score, o algoritmo que melhor classificou entre os inputs foi ANN (Figura 5). RF se igualou estatisticamente ao se utilizar os inputs IVs e SB+IVs. Para o algoritmo RL todos os inputs proporcionaram a mesma acurácia. Para os outros modelos os melhores inputs para a classificação foram IVs e SB+IVs. Para o algoritmo RL não houve diferença entre os inputs.




Figura 5. Boxplot para F-Score considerando a interação significativa entre os algoritmos de ML e as entradas testadas.

Médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.

Ao avaliar os modelos de aprendizagem de máquina através da métrica de acurácia Kappa, foi possível averiguar que o melhor algoritmo de classificação foi ANN, indiferente os inputs (Figura 6). Não houve diferença entre ANN e RF quando utilizado IVs e SB+IVs. Não houve diferença estatística entre os inputs para RL. IVs e SB+IVs foram os melhores inputs para os demais algoritmos.




Figura 6. Boxplot para coeficiente Kappa considerando a interação significativa entre os algoritmos de ML e as entradas testadas.

Médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste Scott-Knott a 5% de probabilidade.

É possível verificar que as métricas utilizadas para avaliar os algoritmos obtiveram os mesmos resultados estatisticamente, reafirmando que os melhores modelos para classificação foram ANN e RF, e os melhores inputs foram IVs e SB+IVs.

#### 4. DISCUSSÃO

A falta de água submete as plantas a estresse abiótico tanto pelo déficit hídrico quanto pelo estresse térmico que afeta negativamente o crescimento e a produtividade das culturas, especialmente o milho (BHEEMANAHALLI et al., 2022). Utilizar o

1 sensoriamento remoto na detecção de problemas hídricos enfrentados pelo milho permite  
2 obter informações precisas sobre a condição da cultura com ela ainda a campo  
3 (DEVARAJ NAIK; UDAYAKUMAR, 2021). A principal diferença espectral entre os  
4 híbridos de milho submetidos a irrigação e condições de sequeiro está no comprimento  
5 de onda 660 nm e 790 nm, em que apresentaram menor fator de reflectância quando  
6 irrigado. Essa faixa do espectro fornece informações associáveis com plantas saudáveis  
7 ou estressadas (SUN et al., 2021).

8 Ao analisarmos a Figura 1 que representa o balanço hídrico de sequeiro da cultura  
9 do milho, percebemos claramente que houve um período de veranico intenso  
10 compreendidos entre os dias 56 e 105 após plantio. Nesse período, a cultura sofreu  
11 estresse por falta de água severo e essa condição reflete na fisiologia da cultura  
12 (BHEEMANAHALLI et al., 2022). Ao compararmos o balanço hídrico das culturas de  
13 sequeiro (Figura 1) e irrigado (Figura 2), percebemos que há uma diferença na condição  
14 hídrica da cultura, principalmente no período entre 50 e 105 dias após plantio. Neste  
15 estágio de desenvolvimento da cultura, o milho irrigado estava com condição hídrica  
16 ótima, enquanto que as plantas de sequeiro apresentavam condição totalmente inversa.

17 Embora a região do VIS não forneça informações diretamente relacionáveis com  
18 a condição hídrica das plantas, os comprimentos de onda desta região podem de forma  
19 indireta fornecer informações sobre o estado hídrico da planta por meio da atividade  
20 irregular dos pigmentos foliares causado pela desidratação (EL-HENDAWY et al., 2019  
21 VESCOVO et al., 2012). Plantas saudáveis possuem alta absorção no comprimento de  
22 onda vermelho pela clorofila indicando alta atividade fotossintética influenciada pela  
23 adequada quantidade de água fornecida para a planta (WASONGA et al., 2021).

24 A reflectância da região de 790 nm correspondente ao NIR pode ser fortemente  
25 relacionada a estrutura interna da folha como os espaços aéreos intracelulares, cutícula,  
26 mesofilo que estão altamente conexos com o estado hídrico em que a planta se encontra.  
27 A condição hídrica em que a planta é submetida influencia em alterações bioquímicas e  
28 biofísicas das plantas, podendo ser detectada por alterações sofridas na clorofila medidas  
29 por comprimentos de onda do espectro VIS/NIR (400-790 nm) (EL-HENDAWY et al.,  
30 2019).

31 É observável também a distinção da assinatura espectral dos híbridos irrigados e  
32 não irrigados. Observando que a maior distinção ocorre no comprimento de onda 660 nm  
33 e uma maior diferença em 790 nm. As condições ambientais e de manejo em que as  
34 plantas são submetidas influencia na expressão de seu fenótipo. O comportamento

espectral está estreitamente relacionado com as diferentes características apresentadas pela planta permitindo a exploração indireta de diferentes parâmetros fisiológicos e agronômicos expressados por plantas saudáveis ou estressadas (EL-HENDAWY et al., 2019).

Em busca de amenizar efeitos negativos causados pelo pouco fornecimento de água a planta, o milho desenvolve mecanismos fisiológicos para mitigação ao estresse, gerando alterações fenotípicas como mudança na cor e na textura das folhas (ZHUANG et al., 2017). Dessa forma pode-se afirmar que alterações fenotípicas no milho são causadas devido a problemas hídricos enfrentados pela planta que por meio dos dados espectrais aplicados a técnicas de aprendizagem de máquinas possibilita classificar híbridos de milho (AN et al., 2019). O aprendizado de máquina aliado a técnicas de obtenção de dados espectrais vem sendo amplamente utilizadas em pesquisas de alterações fenotípicas advindas de estresse abiótico de culturas (CHEMURA et al., 2018; NAIK et al., 2017). Dentre os algoritmos de aprendizagem de máquinas, ANN e RF apresentaram melhores acurácias na classificação dos híbridos quanto ao manejo de irrigação. A ANN é um tipo de técnica robusta para descomplicar relações não lineares entre os caracteres submetidos de entrada e de saída das modelagens (SAFA et al., 2019) contornando problemas com diferentes parâmetros sobre a produtividade do milho forrageiro apresentando eficácia em prever tal parâmetro (SEPEHRI; ABBASI; NAKHJAVANIMOGHADDAM, 2019). O RF possui eficiência em lidar com quantidade elevada de dados que não se ajustam a distribuição normal (LÓPEZ-CALDERÓN et al., 2020), apresentando eficiência em modelagens de aprendizagem de máquinas utilizando predição de produtividade de milho sob manejos de irrigação (BAIO et al., 2022).

Buscando melhorar a performance dos algoritmos, distintos inputs espectrais foram testados. IVs e SB+IVs proporcionaram melhores acurácias para ANN e RF. Ramos et al. (2020), comprovaram melhoria no desempenho de RF em prever a produtividade do milho utilizando IVs. Os VIs são cálculos matemáticos utilizados no sensoriamento remoto relacionado com processos fisiológicos de híbridos de milho baseado nos comprimentos de onda que são refletidos (ADAK et al., 2021). Como já mencionado, plantas de milho que sofrem com estresse hídrico passam por alterações biológicas e fisiológicas afetando a refletância espectral podendo ser mais perceptível quando utilizado IVs (NIU et al., 2021).

A utilização de dados espectrais associados a modelos de aprendizagem e máquinas com o objetivo de classificação de culturas quanto a condição hídrica é recente,

em que nas condições em que o estudo foi desenvolvido, os algoritmos ANN e RF apresentaram melhor desempenho especialmente quando IVs constituíram os inputs utilizados. A utilização de dados hiperespectrais e níveis de diferentes de irrigação pode proporcionar informações mais detalhadas sobre o comportamento espectral dos híbridos de milho.

## 5. CONCLUSÃO

Os diferentes manejos de irrigação apresentaram comportamentos diferentes em suas informações espectrais. Em que os algoritmos ANN e RF apresentaram melhor acurácia na classificação dos híbridos de milho quando ao manejo de irrigação. IVs e SB+IVs proporcionaram melhor desempenho aos algoritmos.

## REFERÊNCIAS

- ADAK, A.; MURRAY, S. C.; BOŽINOVIĆ, S.; LINDSEY, R.; NAKASAGGA, S.; CHATTERJEE, S.; WILDE, S. Temporal vegetation indices and plant height from remotely sensed imagery can predict grain yield and flowering time breeding value in maize via machine learning regression. **Remote Sensing**, v. 13, n. 11, 1 jun. 2021. <https://doi.org/10.3390/rs13112141>
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. **Fao, Rome**, v. 300, n.9, p.05109.
- AMPATZIDIS, Y.; PARTEL, V. UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. **Remote Sensing**, v. 11, n. 4, 2019. <https://doi.org/10.3390/rs11040410>
- AN, J.; LI, W.; LI, M.; CUI, S.; YUE, H. Identification and classification of maize drought stress using deep convolutional neural network. **Symmetry**, v. 11, n. 2, p. 256, 2019. <https://doi.org/10.3390/sym11020256>
- BAIO, F. H. R.; SANTANA, D. C.; TEODORO, L. P. R.; OLIVEIRA, I. C. D.; GAVA, R.; OLIVEIRA, J. L. G.; SHIRATSUCHI, L. S. Maize Yield Prediction with Machine Learning, Spectral Variables and Irrigation Management. **Remote Sensing**, v. 15, n. 1, p. 79, 2022. <https://doi.org/10.3390/rs15010079>
- BANERJEE, B. P.; JOSHI, S.; THODAY-KENNEDY, E.; PASAM, R. K.; TIBBITS, J.;



- HAYDEN, M.; KANT, S. (2020). High-throughput phenotyping using digital and hyperspectral imaging-derived biomarkers for genotypic nitrogen response. **Journal of Experimental Botany**, v. 71, n. 15, p. 4604–4615, 2020.  
<https://doi.org/10.1093/jxb/eraa143>
- BHEEMANAHALLI, R.; RAMAMOORTHY, P.; POUDEL, S.; SAMIAPPAN, S.; WIJEWARDANE, N.; REDDY, K. R. Effects of drought and heat stresses during reproductive stage on pollen germination, yield, and leaf reflectance properties in maize (*Zea mays* L.). **Plant Direct**, v. 6, n. 8, p. e434, 2022. <https://doi.org/10.1002/pld3.434>
- CHEMURA, A.; MUTANGA, O.; SIBANDA, M.; CHIDOKO, P. (2018). Machine learning prediction of coffee rust severity on leaves using spectroradiometer data. **Tropical Plant Pathology**, v. 43, n. 2, p. 117–127, 2018.  
<https://doi.org/10.1007/s40858-017-0187-8>
- DEVARAJ NAIK, B.; UDAYAKUMAR, M. Comparative assessment of response surface methodology and artificial neural networks in forecasting biodiesel yield from waste cooking sunflower oil. **Materials Today: Proceedings**, v. 46, p. 9908–9913, 2021. <https://doi.org/10.1016/j.matpr.2021.02.291>
- EL-HENDAWY, S. E.; ALOTAIBI, M.; AL-SUHAIBANI, N.; AL-GAADI, K.; HASSAN, W.; DEWIR, Y. H.; SCHMIDHALTER, U. Comparative performance of spectral reflectance indices and multivariate modeling for assessing agronomic parameters in advanced spring wheat lines under two contrasting irrigation regimes. **Frontiers in plant science**, v. 10, p. 1537, 2019.  
<https://doi.org/10.3389/fpls.2019.01537>
- HANJRA, M. A.; QURESHI, M. E. Global water crisis and future food security in an era of climate change. **Food policy**, v. 35, n. 5, p. 365–377, 2010.  
<https://doi.org/10.1016/j.foodpol.2010.05.006>
- JAVORNIK, T.; CAROVIĆ-STANKO, K.; GUNJAČA, J.; VIDAČ, M.; LAZAREVIĆ, B. Monitoring Drought Stress in Common Bean Using Chlorophyll Fluorescence and Multispectral Imaging. **Plants**, v. 12, n. 6, 1 mar. 2023.  
<https://doi.org/10.3390/plants12061386>
- KÖPPEN, W. P. Grundriss der klimakunde. **W. de Gruyter**, 1931.
- KOVAR, M.; BRESTIC, M.; SYTAR, O.; BAREK, V.; HAUPTVOGEL, P.; ZIVČAK, M. Evaluation of hyperspectral reflectance parameters to assess the leafwater content in soybean. **Water (Switzerland)**, v. 11, n. 3, 2019. <https://doi.org/10.3390/w11030443>

- LI, X.; BA, Y.; ZHANG, M.; NONG, M.; YANG, C.; ZHANG, S. Sugarcane Nitrogen Concentration and Irrigation Level Prediction Based on UAV Multispectral Imagery. **Sensors**, v. 22, n. 7, 2022. <https://doi.org/10.3390/s22072711>
- LÓPEZ-CALDERÓN, M. J.; ESTRADA-ÁVALOS, J.; RODRÍGUEZ-MORENO, V. M.; MAURICIO-RUVALCABA, J. E.; MARTÍNEZ-SIFUENTES, A. R.; DELGADO-RAMÍREZ, G.; MIGUEL-VALLE, E. Estimation of total nitrogen content in forage maize (*Zea Mays* l.) Using Spectral Indices: Analysis by Random Forest. **Agriculture**, v. 10, n. 10, p. 451, 2020. <https://doi.org/10.3390/agriculture10100451>
- RAMOS, A. P. M.; OSCO, L. P.; FURUYA, D. E. G.; GONÇALVES, W. N.; SANTANA, D. C.; TEODORO, L. P. R.; PISTORI, H. (2020). A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. **Computers and Electronics in Agriculture**, v. 178, p. 105791, 2020. <https://doi.org/10.1016/j.compag.2020.105791>
- MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784–2817, 2018. <https://doi.org/10.1080/01431161.2018.1433343>
- MONFREDA, C.; RAMANKUTTY, N.; FOLEY, J. A. Farming the planet: 2. Geographic distribution of crop areas, yields, physiological types, and net primary production in the year 2000. **Global biogeochemical cycles**, v. 22, n. 1, 2008. <https://doi.org/10.1029/2007GB002947>
- NAIK, H. S.; ZHANG, J.; LOFQUIST, A.; ASSEFA, T.; SARKAR, S.; ACKERMAN, D.; GANAPATHYSUBRAMANIAN, B. A real-time phenotyping framework using machine learning for plant stress severity rating in soybean. **Plant methods**, v. 13, n. 1, p. 1–12, 2017. <https://doi.org/10.1186/s13007-017-0173-7>
- NIU, Y.; HAN, W.; ZHANG, H.; ZHANG, L.; CHEN, H. Estimating fractional vegetation cover of maize under water stress from UAV multispectral imagery using machine learning algorithms. **Computers and Electronics in Agriculture**, v. 189, p. 106414, 2021. <https://doi.org/10.1016/j.compag.2021.106414>
- SAFA, B.; ARKEBAUER, T. J.; ZHU, Q.; SUYKER, A.; IRMAK, S. Net Ecosystem Exchange (NEE) simulation in maize using artificial neural networks. **IFAC Journal of Systems and Control**, v. 7, p. 100036, 2019. <https://doi.org/10.1016/j.ifacsc.2019.100036>

- 1 SAH, R. P.; CHAKRABORTY, M.; PRASAD, K.; PANDIT, M.; TUDU, V. K.;
- 2 CHAKRAVARTY, M. K.; MOHARANA, D. Impact of water deficit stress in maize:
- 3 Phenology and yield components. **Scientific Reports**, v. 10, n. 1, p. 2944, 2020.
- 4 <https://doi.org/10.1038/s41598-020-59689-7>
- 5 SANTOS, H. G. et al. **Sistema brasileiro de classificação de solos**. [s.l.] Brasília, DF:
- 6 Embrapa, 2018., 2018.
- 7 SCOTT, A. J.; KNOTT, M. A cluster analysis method for grouping means in the
- 8 analysis of variance. **Biometrics**, p. 507–512, 1974. <https://doi.org/10.2307/2529204>
- 9 SEPEHRI, S.; ABBASI, F.; NAKHJAVANIMOOGHADDAM, M. M. Prediction of
- 10 Forage Maize Yield and Sensitivity Analysis of Management Parameters using
- 11 Artificial Neural Network Models. **Iranian Journal of Irrigation & Drainage**, v. 13,
- 12 n. 5, p. 1460–1470, 2019. 20.1001.1.20087942.1398.13.5.24.8
- 13 SILVA, E. E.; BAILO, F. H. R.; TEODORO, L. P. R.; SILVA JUNIOR, C. A.;
- 14 BORGES, R. S.; TEODORO, P. E. UAV-multispectral and vegetation indices in
- 15 soybean grain yield prediction based on in situ observation. **Remote Sensing**
- 16 **Applications: Society and Environment**, v. 18, p. 100318, 2020.
- 17 <https://doi.org/10.1016/j.rsase.2020.100318>
- 18 SPIŠIĆ, J.; ŠIMIĆ, D.; BALEN, J.; JAMBROVIĆ, A.; GALIĆ, V. (2022). Machine
- 19 Learning in the Analysis of Multispectral Reads in Maize Canopies Responding to
- 20 Increased Temperatures and Water Deficit. **Remote Sensing**, v. 14, n. 11, 1 jun. 2022.
- 21 <https://doi.org/10.3390/rs14112596>
- 22 SUN, J.; YANG, L.; YANG, X.; WEI, J.; LI, L.; GUO, E.; KONG, Y. Using Spectral
- 23 Reflectance to Estimate the Leaf Chlorophyll Content of Maize Inoculated With
- 24 Arbuscular Mycorrhizal Fungi Under Water Stress. **Frontiers in Plant Science**, v. 12,
- 25 2021. <https://doi.org/10.3389/fpls.2021.646173>
- 26 TEAM, R. C. R: A language and environment for statistical computing. 2013.
- 27 VESCOVO, L.; WOHLFAHRT, G.; BALZAROLO, M.; PILLONI, S.;
- 28 SOTTOCORNOLA, M.; RODEGHIERO, M.; GIANELLE, D. New spectral vegetation
- 29 indices based on the near-infrared shoulder wavelengths for remote detection of
- 30 grassland phytomass. **International journal of remote sensing**, v. 33, n. 7, p. 2178–
- 31 2195, 2012. <https://doi.org/10.1080/01431161.2011.607195>
- 32 WASONGA, D. O.; YAW, A.; KLEEMOLA, J.; ALAKUKKU, L.; MÄKELÄ, P. S.
- 33 Red-green-blue and multispectral imaging as potential tools for estimating growth and

1 nutritional performance of cassava under deficit irrigation and potassium fertigation.  
2 **Remote Sensing**, v. 13, n. 4, p. 1–20, 2021. <https://doi.org/10.3390/rs13040598>  
3 WU, J.; ROGERS, A.; ALBERT, L. P.; ELY, K.; PROHASKA, N.; WOLFE, B. T.;  
4 SERBIN, S. P. Leaf reflectance spectroscopy captures variation in carboxylation  
5 capacity across species, canopy environment and leaf age in lowland moist tropical  
6 forests. **New Phytologist**, v. 224, n. 2, p. 663–674, 1 out. 2019.  
7 <https://doi.org/10.1111/nph.16029>  
8 XIE, C.; YANG, C. A review on plant high-throughput phenotyping traits using UAV-  
9 based sensors. **Computers and Electronics in Agriculture**, v. 178, p. 105731, 2020.  
10 <https://doi.org/10.1016/j.compag.2020.105731>  
11 ZHANG, H.; WANG, L.; JIN, X.; BIAN, L.; GE, Y. High-throughput phenotyping of  
12 plant leaf morphological, physiological, and biochemical traits on multiple scales using  
13 optical sensing. **The Crop Journal**, 2023. <https://doi.org/10.1016/j.cj.2023.04.014>  
14 ZHUANG, S.; WANG, P.; JIANG, B.; LI, M.; GONG, Z. Early detection of water  
15 stress in maize based on digital images. **Computers and Electronics in Agriculture**, v.  
16 140, p. 461–468, 2017. <https://doi.org/10.1016/j.compag.2017.06.022>  
17

## **CAPITULO 2: CLASSIFICAÇÃO DE HÍBRIDOS DE MILHO UTILIZANDO SENSOR MULTIESPECTRAL E APRENDIZAGEM DE MÁQUINA**

### **RESUMO**

Novas técnicas de avaliação de fenótipos em culturas agrícolas vêm sendo desenvolvidas com o auxílio do sensoriamento e com técnicas de aprendizagem de máquinas. O objetivo deste trabalho é encontrar o algoritmo de aprendizagem de máquinas mais acurado na classificação de híbridos de milho e determinar dados de entrada dos modelos que melhorem a performance dos algoritmos. O experimento foi implementado na área experimental da Universidade Federal de Mato Grosso do Sul no município de Chapadão do Sul, Brasil. Os híbridos de milho utilizados no experimento foram: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3). Após 60 dias de emergência da cultura foi utilizado o ARP Sensefly eBee RTK obtendo os comprimentos de onda (SB): Azul (475nm, B\_475), verde (550 nm, G\_550), vermelho (660 nm, R\_660), borda do vermelho (735 nm, RE\_735) e NIR (790 nm, NIR\_790). Após obter os dados de SB foi possível a realização de cálculos de índices de vegetação (VIs). Os dados foram submetidos as análises de aprendizagem de máquina, testando seis algoritmos: Redes neurais artificiais (ANN), Árvores de decisão J48 (J48), REPTree (DT), Floresta aleatória (RF), Máquina de vetor suporte (SVM) e Regressão logística (RL) utilizado como padrão. Três métricas de acurácia foram utilizados buscando averiguar a acurácia dos algoritmos em classificar os híbridos de milho: classificações corretas (CC), coeficiente Kappa e F-Score. O algoritmo Redes Neurais Artificiais (ANN) foi o que apresentou melhor resultado para as três métricas de acurácia testadas. As três configurações de entrada proporcionaram melhor acurácia de classificação para ANN, todavia o ideal seria utilizar apenas as bandas espectrais (SB) como input pelo menor tempo de processamento dos dados e facilidade.

**Palavras-chave:** Redes neurais artificiais; bandas espectrais; assinatura espectral

# CLASSIFICATION OF CORN HYBRIDS USING MULTISPECTRAL SENSOR AND MACHINE LEARNING

## ABSTRACT

New techniques for assessing phenotypes in agricultural crops have been developed with the aid of sensing and machine learning algorithms. The objective of this work is to find the most accurate machine learning algorithm in the classification of maize hybrids and to determine input data of the algorithms that improve the performance of the algorithms. The experiment was implemented in the experimental area of the Federal University of Mato Grosso do Sul in the municipality of Chapadão do Sul, Brazil. The corn hybrids used in the experiment were: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3). After 60 days of crop emergence, the Sensefly eBee RTK was flown to obtain the wavelengths (SB): blue (475nm, B\_475), green (550 nm, G\_550), Red (660 nm, R\_660), Rededge (735 nm, RE\_735) and NIR (790 nm, NIR\_790). After obtaining the SB data, it was possible to perform calculations of vegetation indices (VIs). The data were subjected to machine learning analysis, testing six algorithms: Artificial Neural Networks (ANN), J48 Decision Trees (J48), REPTree (DT), Random Forest (RF), Support Vector Machine (SVM) and Regression logistics (RL) used as default. Three accuracy metrics were used to assess the accuracy of the algorithms in classifying sorghum hybrids: correct classifications (CC), Kappa coefficient and F-Score. The Artificial Neural Networks (ANN) algorithm was the one that presented the best result for the three tested accuracy metrics. The three input configurations provided better classification accuracy for ANN, however, the ideal would be to use only the spectral bands (SB) as input due to the shorter data processing time and facility.

**Keywords:** Artificial neural networks; spectral bands; spectral signature

## 1. INTRODUÇÃO

O milho (*Zea mays* L.) é uma cultura caracterizada por possuir diversas utilizações, representando importante percentual no cultivo dos principais países produtores de grãos (LIU et al., 2023). Sua grande versatilidade é devido a todo o processo de seleção e melhoramento que a planta tem passado, enfrentando desafios

1 mundiais influenciando na produtividade e qualidade nutricional, sendo moldada as  
2 diversas necessidades do homem (SWARUP et al., 2021).

3 Ao longo dos anos técnicas de melhoramento de plantas foram sendo  
4 aperfeiçoadas, especialmente a nível molecular, como o sequenciamento genético de  
5 diversas espécies e a intervenção nos genes possibilitando o desenvolvimento de  
6 populações resistentes a estresses bióticos e abióticos (IQBAL et al., 2021; RIVERO et  
7 al., 2022; ZAFAR et al., 2022). Todavia, as análises que visam avaliar o fenótipo não  
8 evoluíram na mesma proporção passando por problemas como escassez de mão de obra  
9 qualificada capaz de selecionar as características desejáveis de forma rápida e com  
10 precisão, sendo necessário encontrar técnicas mais modernas que possibilitam melhores  
11 avaliações de fenótipos (SANTOS; YASSITEPE, 2014).

12 O aumento tecnológico em área como o sensoriamento remoto somado a busca de  
13 acelerar o melhoramento genético de milho surge novas técnicas para a fenotipagem de  
14 alta precisão (FAP), devido os métodos tradicionais necessitarem um longo período de  
15 avaliações e seleção de materiais (HERZIG et al., 2021). A FAP possui grandes vantagens  
16 em diminuir o tempo de trabalho a campo, mão de obra e custos, utilizando sensores para  
17 caracterização de fenótipos com alta acurácia e menor tempo, de forma não destrutiva  
18 (DOBBELS; LORENZ, 2019; ANDRADE et al., 2021; SANTANA et al., 2023). Por  
19 meio da FAP é possível a relacionar diversos caracteres da planta como a seleção de  
20 genótipos de soja quanto a precocidade e a produtividade de grãos (SANTANA et al.,  
21 2022).

22 O surgimento das aeronaves remotamente pilotadas (ARP) foi de grande valor  
23 para agricultura, capazes de se unir a uma variedade de sensores para capturar diferentes  
24 comprimentos de onda, se tornando importante ferramenta na coleta de informações a  
25 campo, com regularidade ao longo do ciclo da cultura e de forma não destrutiva (DAS  
26 CHOUDHURY et al., 2019). Este método é capaz de coletar dados com extrema rapidez  
27 e com alta resolução espacial (KAR et al., 2021).

28 A quantidade de dados gerados por meio do sensoriamento remoto é ampla, o que  
29 dificulta uso da estatística tradicional para relacionar dados advindos de sensores com  
30 características das plantas devido a não linearidade dos dados de variáveis espectrais com  
31 características fisiológicas e morfológicas de plantas (VAN EEUWIJK et al., 2019).  
32 Dessa forma surge a necessidade de maior e melhor capacidade de processamentos dos  
33 dados, utilizando assim algoritmos de aprendizagem de máquinas (ML).

Através de ML é possível fazer a predição da concentração de nitrogênio foliar e altura de plantas de milho (OSCO et al., 2020). Outra importante utilização do ML é classificação de diferentes cultivares de soja (GAVA et al., 2022), quanto a caracteres nutricionais foliares (SANTANA et al., 2023), classificar com precisão genótipos com base em características industriais de soja (SANTANA et al., 2023).

A hipótese deste trabalho é saber a possibilidade de distinção de híbridos de milho de acordo com as informações espectrais de cada um deles submetidos a modelos de aprendizagem de máquina. O objetivo deste trabalho é encontrar o algoritmo de aprendizagem de máquinas mais acurado na classificação de híbridos de milho e determinar dados de entrada que melhorem a performance dos modelos.

## 2. MATERIAIS E MÉTODO

### 2.1. Condução do experimento

A condução do experimento ocorreu na área experimental da Universidade Federal de Mato Grosso do Sul (18°41'33''S, 52°40'45''W, com 810 m de altitude) no município de Chapadão do Sul, Brasil. Foi adotado o método de preparo do solo convencional (aração e gradagem niveladora). A região possui clima caracterizado como Tropical Savana (Aw) com base na classificação de Koppen. O solo da região é caracterizado como Latossolo Vermelho Distrófico argiloso (SANTOS et al., 2018), possuindo características na camada de 0 - 0,20 m: pH (H<sub>2</sub>O) = 6,2; Al trocável (cmolc dm<sup>-3</sup>) = 0,0; Ca+Mg (cmolc dm<sup>-3</sup>) = 4,31; P (mg dm<sup>-3</sup>) = 41,3; K (cmolc dm<sup>-3</sup>) = 0,2; Matéria orgânica (g dm<sup>-3</sup>) = 19,74; V (%) = 45; m (%) = 0,0; Soma de bases (cmolc dm<sup>-3</sup>) = 2,3; CTC (cmolc dm<sup>-3</sup>) = 5,1.

A semeadura do experimento foi realizada com o auxílio de semeadora alocando as sementes com espaçamento entre fileiras de 0,45 m sulcoaplicando 200 kg ha<sup>-1</sup> de fosfato monoamônico (MAP) do formulado 11-52-00. Foi realizada uma adubação de cobertura com a dose de 150 kg ha<sup>-1</sup> de Ureia 45% de N, no momento em que a planta atingiu estágio V4. O experimento foi implementado a campo em esquema de faixas. As medidas das parcelas foram 3.8 m x 4.9 m (18.62 m<sup>2</sup>). Os híbridos de milho utilizados no experimento foram: H1 (AS 1868), H2 (DKB 360), H3 (FS 615 PWU), H4 (K 7510 VIP3), H5 (NK 520 VIP3), H6 (P 3858 PWU), H7 (SS 182E VIP3). A população de sementes por metro de cada híbrido, respectivamente, foram: 2,67, 2,68, 2,74, 2,65, 2,64, 2,63 e 2,55.



## 2.2. Aquisição e processamento das imagens multiespectrais

Foi realizado um voo após 60 dias de emergência da cultura, quando as variedades de milho se encontravam em florescimento pleno, utilizando o Sensefly eBee RTK, uma aeronave remotamente pilotada (ARP) de asa fixa, que dispõe de decolagem e aterrissagem com controle autônomo. O eBee estava equipado com o sensor multiespectral Parrot Sequoia. A obtenção das imagens foi realizada às 09:00 da manhã, com céu limpo de nuvens, a uma altitude de 100 e resolução espacial de 0.10 m. O levantamento aéreo foi realizado com o uso da tecnologia RTK (*Real Time Kinematics*), o que possibilitou posicionar o sensor para coletar as imagens com acurácia de 2,5 cm. A mosaicagem e a ortorretificação das imagens foram realizadas pelo programa Pix4Dmapper.

A calibração radiométrica foi realizada para toda a cena com base em uma superfície refletiva calibrada fornecida pelo fabricante. O Parrot Sequoia possui um sensor de luminosidade que permite a calibração dos valores adquiridos. Os comprimentos de onda (SB) adquiridos pelo sensor foram: Azul (475nm, B\_475), verde (550 nm, G\_550), vermelho (660 nm, R\_660), borda do vermelho (735 nm, RE\_735) e NIR (790 nm, NIR\_790). Após obter os dados de SB foi possível a realização de cálculos de 41 índices de vegetação (VIs) de razão simples até índices com correção de atmosfera e de solo (RAMOS et al., 2020) utilizando o programa de sistemas de informações geografias ESRI ArcGIS 10.5.

## 2.3. Modelos de Aprendizagem de Máquina e Análises Estatísticas

Os dados foram submetidos as análises de aprendizagem de máquina, em que foram testados seis algoritmos (Tabela 1). RL foi utilizado como padrão, em que se busca melhores desempenhos dos algoritmos quando comparados a ele. A classificação dos híbridos foi realizada por meio de validação cruzada estratificada com  $k\text{-fold} = 10$  e dez repetições (100 execuções para cada modelo). Todos os parâmetros dos algoritmos foram estabelecidos de acordo com a configuração default do software Weka 3.8.5.


Tabela 1. Relação dos modelos de aprendizagem de máquinas utilizados na classificação


| Sigla | Modelo de aprendizagem de máquinas | Referência                                  |
|-------|------------------------------------|---------------------------------------------|
| ANN   | Redes neurais artificiais          | (EGMONT-PETERSEN; DE RIDDER; HANDELS, 2002) |
| J48   | Árvores de decisão J48             | (QUINLAN, 1993)                             |
| RL    | Regressão logística                | (ŠTEPANOVSÝ et al., 2017)                   |
| DT    | REPTree                            | (SNOUSY et al., 2011)                       |
| RF    | Floresta aleatória                 | (BELGIU; DRĂGUȚ, 2016)                      |
| SVM   | Máquina de vetor suporte           | (NALEPA; KAWULOK, 2019)                     |

Três métricas de acurácia foram utilizados buscando averiguar a acurácia dos algoritmos em classificar os híbridos de milho: classificação correta (CC), coeficiente Kappa e F-Score. Uma análise de variância foi construída buscando avaliar significância de ML, input e interação entre elas. Na ilustração do desempenho dos modelos e suas significâncias foram utilizados *boxplots* com as médias de CC, Kappa e F-Score segundo o agrupamento de médias do teste de Scott-Knott (SCOTT; KNOTT, 1974) a 5% de significância. Todas as análises e gráficos foram gerados utilizando os pacotes ggplot2 e ExpDes.pt do software R (TEAM, 2013).

### 3. RESULTADOS

Na Figura 1 está apresentada a reflectância de cada híbrido de acordo com cada comprimento de onda específico. Os híbridos H4 e H7 apresentaram os maiores valores de reflectância em todos os comprimentos de onda, se igualando estatisticamente apenas com o híbrido H6 no comprimento de onda B\_475 e o híbrido H1 nos comprimentos de onda RE\_735 e NIR\_790. Os híbridos H3 e H5 tiveram a menor reflectância nos comprimentos de onda B\_475, R\_660 e G\_550. No comprimento de onda RE\_735 os híbridos H5 e H6 tiveram menores reflectâncias. No comprimento NIR\_790 a menor reflectância foi do híbrido H6.








Figura 1. Boxplot da refletância multiespectral dos sete híbridos de milho nos comprimentos de onda azul (B\_475 nm, A), verde (G\_550 nm, B), vermelho (R\_660 nm, C), borda do vermelho (RE\_735 nm, D) e NIR (NIR\_790 nm, E) comparados pelo agrupamento de médias Scott-Knott a 5% de probabilidade. Híbridos seguidos das mesmas letras para cada comprimento de onda não se diferenciam entre si pelo teste de Scott-Knott a 5% de probabilidade.

Foram utilizados três parâmetros na análise de desempenho dos algoritmos de Machine Learning, classificação correta (CC), F-Score e coeficiente Kappa (Tabela 2). Houve significância na interação Input x ML para todas as métricas de acurácia utilizada.


Tabela 2. Resumo da análise de variância para as variáveis Classificação correta (CC), Kappa e F-Score.

| FV       | GL | CC      | Kappa  | F-Score |
|----------|----|---------|--------|---------|
| Input    | 2  | 183.05* | 0.024* | 0.005*  |
| ML       | 5  | 486.34* | 0.066* | 0.034*  |
| Input*ML | 10 | 17.42*  | 0.002* | 0.003*  |
| CV       | -  | 3.5     | 5.1    | 11.16   |

\*significativo a 5% e \*\*significativo a 1% pelo teste F; ML: inteligência computacional; CV: Coeficiente de Variação; GL: Graus de Liberdade.

Por meio da Classificação Correta foi avaliado que o melhor algoritmo usado dentro de todos os inputs foi ANN (Figura 3). Ao observar o algoritmo ANN não houve diferença estatística entre os inputs analisados. Os algoritmos RF, RL, DT e SVM

- 1 apresentaram melhores desempenhos com os inputs IVs e SB+IVs. Para o algoritmo J48
- 2 os melhores inputs foram SB e IVs.



- 3
- 4 Figura 3. Boxplot para porcentagem de classificação correta (CC) para a interação
- 5 significativa entre os modelos de aprendizagem de máquinas e os inputs testados.
- 6 As médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e as mesmas letras
- 7 minúsculas para os diferentes algoritmos de ML não diferem pelo teste de Scott-Knott a 5% de
- 8 probabilidade.
- 9

10 Ao avaliar os algoritmos por meio de F-Score, é averiguado que o melhor

11 algoritmo para classificação dentro de todos inputs foi ANN (Figura 4). Para os

12 algoritmos ANN, RL, J48 e DT não houve diferença estatística entre os diferentes inputs.

13 Para os algoritmos RF e SVM os melhores inputs foram IVs e SB+IVs.




Figura 4. Boxplot para porcentagem de F-Score para a interação significativa entre os modelos de aprendizagem de máquinas e os inputs testados.

As médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e as mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste de Scott-Knott a 5% de probabilidade.

Através da métrica de Kappa, o algoritmo que melhor classifica dentro de todos os inputs foi ANN (Figura 5). Para os algoritmos ANN e J48 não houve diferença estatística entre os inputs. Ao observar os algoritmos RF, RL, DT e SVM os melhores inputs foram IVs SB+IVs.




Figura 5. Boxplot para porcentagem de Kappa para a interação significativa entre os modelos de aprendizagem de máquinas e os inputs testados.

As médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e as mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste de Scott-Knott a 5% de probabilidade.

#### 4. DISCUSSÃO

A assinatura espectral das plantas segue um padrão geral que é a baixa reflectância na região do visível do espectro eletromagnético atribuído ao fato de que os pigmentos realizam a absorção desses comprimentos de onda para realizar a fotossíntese. Enquanto isso na região infravermelho próximo e da borda do vermelho que compreende acima de 700 nm há uma maior reflectância (TAIZ et al., 2017).

A faixa do visível é dividida em bandas espectrais que possuem funções diferentes nas plantas. Por exemplo, O comprimento de onda azul e vermelho que abrange 475 nm e 660 nm, respectivamente, são os mais necessários para a fotossíntese, capazes de acelerar o crescimento e desenvolvimento das plantas (LU et al., 2021; SHI et al., 2019). A expressão de alguns genes da planta que são relacionados à fotossíntese também pode ser regulada positivamente e a taxa de transporte de elétrons se aumentadas de acordo com maior absorção de luz azul em contrapartida a expressão de outros genes pertinentes



1 à fotossíntese são expressos com a submissão maior de luz vermelha (LI et al., 2017; WU  
2 et al., 2014).

3 O comportamento espectral dos híbridos será diferente de acordo com a genética  
4 que cada um deles pertence. Nessa perspectiva os híbridos H3 e H5 apresentaram menores  
5 valores de reflectância nessa faixa, podendo inferir maior aproveitamento dos  
6 comprimentos de onda para a fotossíntese, já que houve menor reflectâncias sendo assim  
7 maior absorção. Especificamente no comprimento de onda de 475 nm região do azul na  
8 assinatura espectral dos híbridos, tiveram pouca diferenciação entre eles.

9 Na região de 550 nm corresponde a região do verde, que possui um pico de reflexão  
10 devido aos cloroplastos que reflete intensamente a luz verde nessa região (NISHIO,  
11 2000). O híbrido H4 teve a maior reflectância na faixa dos 550 nm que os demais. A partir  
12 do 735-790 nm é observado um aumento proeminente na reflectância da região VIS/NIR  
13 atribuída a abundância de clorofila e organização da estrutura interna foliar  
14 (HENNESSY; CLARKE; LEWIS, 2020) sendo indicador de estresse, senescência na  
15 vegetação ou incidência de doenças (ATTA et al., 2023; DAWSON; CURRAN, 1998;  
16 GHOLIZADEH et al., 2016; ZAHIR et al., 2022) Dessa forma observa-se que os híbridos  
17 H1 e H3 teve alta reflectâncias no comprimento de onda de 735 nm e menor nas faixas  
18 de 475 e 660 nm, ou seja, podemos inferir que tais híbridos possuem grande quantidade  
19 de clorofila pela sua maior reflectâncias em 735nm e que essas clorofilas possuem intensa  
20 atividade fotossintética devida a baixa reflectâncias nos comprimentos de onda azul e  
21 vermelho.

22 Conforme as ricas informações fornecidas pelas bandas espectrais sobre a  
23 fisiologia das plantas é possível investigar relações entre as diferentes bandas do espectro  
24 (OLIVEIRA et al., 2023) por meio de modelos matemáticos que relacionam uma ou mais  
25 bandas denominadas índices de vegetação (IVs) (PANTALEÃO et al., 2022; SILVA et  
26 al., 2020). O uso desses IVs pode fornecer informações ainda mais precisas sobre  
27 características fisiológicas das plantas, inclusive relacionar com respostas agronômicas  
28 como produtividade (SANTANA et al., 2022), concentração de nitrogênio foliar e altura  
29 de plantas de milho (OSCO et al., 2020).

30 Havendo a possibilidade de distinção dos híbridos de milho de acordo com os  
31 caracteres espectrais do mesmo torna o processo de seleção dos genótipos menos onerosa.  
32 Todavia a quantidade de dados gerada pode ser grande, dificultando o processamento das  
33 informações. Dessa forma a utilização de algoritmos de aprendizagem de máquina para o  
34 reconhecimento de plantas ou folhas (PUSHPANATHAN et al., 2021) é uma alternativa

1 rápida e precisa no auxílio da distinção de genótipos. O ML advém de treinar algoritmos  
2 no reconhecimento de determinados bancos de dados identificando padrões podendo ser  
3 aplicados em estudos de melhoramento genético de plantas (NIAZIAN; NIEDBAŁA,  
4 2020).

5 Entre os algoritmos de ML utilizado, as redes neurais artificiais são as mais  
6 conhecidas e utilizadas, sendo uma das técnicas mais amplamente utilizadas na resolução  
7 de distintos problemas dentre eles os de classificação (VIDYARTHI; JAIN;  
8 CHOURASIYA, 2020). Dentre as vantagens das redes neurais em relação aos outros  
9 algoritmos de ML está a sua capacidade de modelar dados não lineares complexos, sem  
10 quaisquer suposições anteriores de forma eficiente (QI; ZHANG, 2001).

11 Nas três métricas de acurácia testadas o algoritmo ANN obteve a melhor  
12 performance na classificação dos híbridos de milho, independente das informações de  
13 entrada utilizadas no seu processamento. Dessa forma a utilização das SB pode tornar as  
14 etapas processuais mais simples e rápida por não necessitar de cálculos de modelos  
15 matemáticos como é necessário para os IVS (GAVA et al., 2022). A utilização apenas  
16 dos comprimentos de onda fornece maior acurácia dos algoritmos em diversas tarefas de  
17 análises agrícolas como na previsão de dias para maturidade, altura de planta e  
18 rendimento produtivo em soja (TEODORO et al., 2021).

19 Nossas descobertas demonstram a possibilidade de distinção de híbridos de milho  
20 utilizando dados multiespectrais, que há comportamento espectral distinto entre os  
21 híbridos refletindo em assinatura espectral diferente entre eles. E que a utilização de  
22 algoritmos de aprendizagem de máquinas pode ser importante ferramenta para classificar  
23 esses híbridos. Importante destacar a inovação do trabalho na cultura do milho, em que  
24 há na literatura uso de tais técnicas em outras culturas como a soja, mas poucos trabalhos  
25 utilizando classificação de genótipos sejam eles comerciais ou em processo de  
26 melhoramento na cultura do milho. A utilização de sensores hiperespectrais pode fornecer  
27 respostas mais completas sobre os híbridos, ficando como sugestão para trabalhos futuros.

## 28 29 **5. CONCLUSÃO**

30 O algoritmo Redes Neurais Artificiais foi o que apresentou melhor resultado para  
31 as três métricas de acurácia testadas.

32 As três configurações de entrada proporcionaram melhor acurácia de classificação  
33 para ANN, todavia o ideal seria utilizar apenas as bandas espectrais como input pelo  
34 menor tempo de processamento dos dados e facilidade.

## REFERÊNCIAS

- ALLEN, R. G.; TASUMI, M.; TREZZA, R.; WATERS, R.; BASTIAANSEN, W. SEBAL (surface energy balance algorithms for land). **Advance training and users manual–Idaho implementation, version**, v. 1, p. 97, 2002.
- ANDRADE, S. M.; TEODORO, L. P. R.; BAIO, F. H. R.; CAMPOS, C. N. S.; ROQUE, C. G.; SILVA JUNIOR, C. A.; CORADI, P. C.; TEODORO, P. E. High-throughput phenotyping of soybean genotypes under base saturation stress conditions. **Journal of Agronomy and Crop Science**, v. 207, n. 5, p. 814–822, 2021.
- ATTA, B. M.; SALEEM, M.; BILAL, M.; REHMAN, A. UL; FAYYAZ, M. Early detection of stripe rust infection in wheat using light-induced fluorescence spectroscopy. **Photochemical & Photobiological Sciences**, v. 22, n. 1, p. 115–134, 2023.
- BELGIU, M.; DRĂGUT, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- DAS CHOUDHURY, S.; SAMAL, A.; AWADA, T. Leveraging image analysis for high-throughput plant phenotyping. **Frontiers in plant science**, v. 10, p. 508, 2019.
- DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B.; MCMURTREY III, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229–239, 2000.
- DAWSON, T. P.; CURRAN, P. J. Technical note A new technique for interpolating the reflectance red edge position. 1998.
- DOBBELS, A. A.; LORENZ, A. J. Soybean iron deficiency chlorosis high-throughput phenotyping using an unmanned aircraft system. **Plant methods**, v. 15, n. 1, p. 1–9, 2019.
- EGMONT-PETERSEN, M.; DE RIDDER, D.; HANDELS, H. Image processing with neural networks—a review. **Pattern Recognition**, v. 35, n. 10, p. 2279–2301, 2002.
- GAVA, R.; SANTANA, D. C.; COTRIM, M. F.; ROSSI, F. S.; TEODORO, L. P. R.; SILVA JUNIOR, C. A.; TEODORO, P. E. Soybean Cultivars Identification Using Remotely Sensed Image and Machine Learning Models. **Sustainability**, v. 14, n. 12, p. 7125, 2022.
- GHOLIZADEH, A.; MIŠUREC, J.; KOPAČKOVÁ, V.; MIELKE, C.; ROGASS, C. Assessment of red-edge position extraction techniques: A case study for norway spruce forests using hymap and simulated sentinel-2 data. **Forests**, v. 7, n. 10, p. 226, 2016.

- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote sensing of Environment**, v. 58, n. 3, p. 289–298, 1996.
- GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Journal of Plant Physiology**, v. 148, n. 3, p. 494–500, 1996.
- HABOUDANE, D.; MILLER, J. R.; PATTEY, E.; ZARCO-TEJADA, P. J.; STRACHAN, I. B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote sensing of environment**, v. 90, n. 3, p. 337–352, 2004.
- HENNESSY, A.; CLARKE, K.; LEWIS, M. Hyperspectral classification of plants: A review of waveband selection generalisability. **Remote Sensing**, v. 12, n. 1, p. 113, 2020.
- HERZIG, P.; BORRMANN, P.; KNAUER, U.; KLÜCK, H.-C.; KILIAS, D.; SEIFFERT, U.; PILLEN, K.; MAURER, A. Evaluation of RGB and multispectral unmanned aerial vehicle (UAV) imagery for high-throughput phenotyping and yield prediction in barley breeding. **Remote Sensing**, v. 13, n. 14, p. 2670, 2021.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295–309, 1988.
- HUETE, A. R.; LIU, H. Q.; BATCHILY, K. V.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote sensing of environment**, v. 59, n. 3, p. 440–451, 1997.
- IQBAL, A.; KHAN, R. S.; KHAN, M. A.; GUL, K.; JALIL, F.; SHAH, D. A.; RAHMAN, H.; AHMED, T. Genetic Engineering Approaches for Enhanced Insect Pest Resistance in Sugarcane. **Molecular Biotechnology**, v. 63, n. 7, p. 557–568, 2021.
- KAR, S.; PURBEY, V. K.; SURADHANIWAR, S.; KORBU, L. B.; KHOLOVÁ, J.; DURBHA, S. S.; ADINARAYANA, J.; VADEZ, V. An ensemble machine learning approach for determination of the optimum sampling time for evapotranspiration assessment from high-throughput phenotyping data. **Computers and Electronics in Agriculture**, v. 182, p. 105992, 2021.
- LI, Y.; XIN, G.; WEI, M.; SHI, Q.; YANG, F.; WANG, X. Carbohydrate accumulation and sucrose metabolism responses in tomato seedling leaves when subjected to different light qualities. **Scientia horticulturae**, v. 225, p. 490–497, 2017.

- 1 LIU, G.; YANG, Y.; GUO, X.; LIU, W.; XIE, R.; MING, B.; XUE, J.; WANG, K., LI,  
2 S.; HOU, P. A global analysis of dry matter accumulation and allocation for maize yield  
3 breakthrough from 1.0 to 25.0 Mg ha<sup>-1</sup>. **Resources, Conservation and Recycling**, v.  
4 188, p. 106656, 2023.
- 5 LU, Z.; MENG, Y.; FAN, H.; LU, J.; ZHONG, X.; OU, Y.; MO, H.; ZHOU, L.  
6 Luminescent properties of Mn<sup>4+</sup>-doped LaTiSbO<sub>6</sub> deep-red-emitting phosphor for  
7 plant growth LEDs. **Journal of Luminescence**, v. 236, p. 118100, 2021.
- 8 NALEPA, J.; KAWULOK, M. Selecting training sets for support vector machines: a  
9 review. **Artificial Intelligence Review**, v. 52, n. 2, p. 857–900, 2019.
- 10 NIAZIAN, M.; NIEDBAŁA, G. Machine learning for plant breeding and  
11 biotechnology. **Agriculture**, v. 10, n. 10, p. 436, 2020.
- 12 NISHIO, J. N. Why are higher plants green? Evolution of the higher plant  
13 photosynthetic pigment complement. **Plant, Cell & Environment**, v. 23, n. 6, p. 539–  
14 548, 2000.
- 15 OSCO, L. P.; JUNIOR, J. M.; RAMOS, A. P.; FURUYA, D. E.; SANTANA, D. C.;  
16 TEODORO, L. P.; GONÇALVES, W. N.; BAIO, F. H.; PISTORI, H., JUNIOR, C. A.;  
17 TEODORO, P. E. **Leaf Nitrogen Concentration and Plant Height Prediction for**  
18 **Maize Using UAV-Based Multispectral Imagery and Machine Learning**  
19 **Techniques. Remote Sensing**, 2020.
- 20 PANTALEÃO, A. DE A.; TEODORO, L. P. R.; MARTÍNEZ, L. A.; AGUILERA, J.  
21 G.; CAMPOS, C. N. S.; BAIO, F. H. R.; SILVA JÚNIOR, C. A.; TEODORO, P. E.  
22 Soybean base saturation stress: Selecting populations for multiple traits using  
23 multivariate statistics. **Journal of Agronomy and Crop Science**, v. 208, n. 2, p. 168–  
24 177, 1 abr. 2022.
- 25 PUSHPANATHAN, K.; HANAFI, M.; MASHOHOR, S.; FAZLIL ILAHI, W. F.  
26 Machine learning in medicinal plants recognition: a review. **Artificial Intelligence**  
27 **Review**, v. 54, n. 1, p. 305–327, 2021.
- 28 QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN. A modified  
29 soil adjusted vegetation index. **Remote sensing of environment**, v. 48, n. 2, p. 119–  
30 126, 1994a.
- 31 QI, M.; ZHANG, G. P. An investigation of model selection criteria for neural network  
32 time series forecasting. **European journal of operational research**, v. 132, n. 3, p.  
33 666-680, E

- 1 RAMOS, A. P. M.; OSCO, L. P.; FURUYA, D. E. G.; GONÇALVES, W. N.;
- 2 SANTANA, D. C.; TEODORO, L. P. R.; PISTORI, H. (2020). A random forest
- 3 ranking approach to predict yield in maize with uav-based vegetation spectral indices.
- 4 **Computers and Electronics in Agriculture**, v. 178, p. 105791, 2020.
- 5 <https://doi.org/10.1016/j.compag.2020.105791>
- 6 RIVERO, R. M.; MITTLER, R.; BLUMWALD, E.; ZANDALINAS, S. I. Developing
- 7 climate-resilient crops: improving plant tolerance to stress combination. **The Plant**
- 8 **Journal**, v. 109, n. 2, p. 373–389, 1 jan. 2022.
- 9 ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring
- 10 vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351,
- 11 n. 1974, p. 309, 1974.
- 12 SANTANA, D. C.; OLIVEIRA CUNHA, M. P.; SANTOS, R. G.; COTRIM, M. F.;
- 13 TEODORO, L. P. R.; SILVA JUNIOR, C. A.; BAIO, F. H. R.; TEODORO, P. E. High-
- 14 throughput phenotyping allows the selection of soybean genotypes for earliness and
- 15 high grain yield. **Plant Methods**, v. 18, n. 1, p. 13, 2022.
- 16 SANTANA, D. C.; SANTOS, R. G.; TEODORO, L. P. R.; SILVA JUNIOR, C. A.;
- 17 BAIO, F. H. R.; CORADI, P. C.; TEODORO, P. E. Structural equation modelling and
- 18 factor analysis of the relationship between agronomic traits and vegetation indices in
- 19 corn. **Euphytica**, v. 218, n. 4, 1 abr. 2022.
- 20 SANTANA, D. C.; TEIXEIRA FILHO, M. C. M.; SILVA, M. R.; CHAGAS, P. H. M.;
- 21 OLIVEIRA, J. L. G.; BAIO, F. H. R.; CAMPOS, C. N. S.; TEODORO, L. P. R.;
- 22 SILVA JUNIOR, C. A.; TEODORO, P. E. Classification of soybean genotypes for
- 23 industrial traits using UAV multispectral imagery and machine learning. **Remote**
- 24 **Sensing Applications: Society and Environment**, v. 29, p. 100919, 2023.
- 25 SANTANA, D. C. TEODORO, L. P. R.; BAIO, F. H. R.; SANTOS, R. G. CORADI, P.
- 26 C.; BIDUSKI, B.; SILVA JUNIOR, C. A.; TEODORO, P. E.; SHIRATSUCHI, L. S.
- 27 Machine Learning in the Classification of Soybean Genotypes for Primary
- 28 Macronutrients' Content Using UAV–Multispectral Sensor. **Remote Sensing**, v. 15, n.
- 29 5, p. 1457, 2023.
- 30 SANTOS, H. D.; JACOMINE, P.; ANJOS, L.; OLIVEIRA, V.; LUMBRERAS, J.;
- 31 COELHO, M.; OLIVEIRA, J. Embrapa: Sistema brasileiro de classificação de solos. 5ª
- 32 edição. Brasília, DF: Embrapa, 2018. 356 p. ISBN 978-85-7035-800-4.

- 1 SANTOS, T. T.; YASSITEPE, J. E. DE C. T. Fenotipagem de plantas em larga escala:  
2 um novo campo de aplicação para a visão computacional na agricultura. **Embrapa**  
3 **Informática Agropecuária-Capítulo em livro científico (ALICE)**, 2014.
- 4 SCOTT, A. J.; KNOTT, M. A cluster analysis method for grouping means in the  
5 analysis of variance. **Biometrics**, p. 507–512, 1974.
- 6 SHI, L.; HAN, Y.; WANG, H.; SHI, D. GENG, X.; ZHANG, Z. High-efficiency and  
7 thermally stable far-red emission of Mn<sup>4+</sup> in double cubic perovskite Sr<sub>9</sub>Y<sub>2</sub>W<sub>4</sub>O<sub>24</sub> for  
8 plant cultivation. **Journal of Luminescence**, v. 208, p. 307–312, 2019.
- 9 SILVA, V. S.; SILVA, C. A.; MOHAN, M.; CARDIL, A. REX, F. E.; LOUREIRO, G.  
10 H.; ALMEIDA, D. R.; BROADBENT, E. N.; GORGENS, E. B.; DALLA CORTE, A.  
11 P.; SILVA, E. A.; VALBUENA, R.; KLAUBERG, C. **Combined Impact of Sample**  
12 **Size and Modeling Approaches for Predicting Stem Volume in Eucalyptus spp.**  
13 **Forest Plantations Using Field and LiDAR Data. Remote Sensing**, 2020.
- 14 SNOUSY, M. B. AL; EL-DEEB, H. M.; BADRAN, K.; KHLIL, I. A. al. Suite of  
15 decision tree-based classification algorithms on cancer gene expression data. **Egyptian**  
16 **Informatics Journal**, v. 12, n. 2, p. 73–82, 2011.
- 17 ŠTEPANOVSKÝ, M.; IBROVÁ, A.; BUK, Z.; VELEMÍNSKÁ, J. Novel age  
18 estimation model based on development of permanent teeth compared with classical  
19 approach and other modern data mining methods. **Forensic Science International**, v.  
20 279, p. 72–82, 2017.
- 21 SWARUP, S.; CARGILL, E. J.; CROSBY, K.; FLAGEL, L.; KNISKERN, J.; GLENN,  
22 K. C. Genetic diversity is indispensable for plant breeding to improve crops. **Crop**  
23 **Science**, v. 61, n. 2, p. 839–852, 1 mar. 2021.
- 24 TAIZ, L.; ZEIGER, E.; MØLLER, I. M.; MURPHY, A. **Fisiologia e desenvolvimento**  
25 **vegetal**. [s.l.] Artmed Editora, 2017.
- 26 TEAM, R. C. R: A language and environment for statistical computing. 2013.
- 27 TEODORO, P. E.; TEODORO, L. P. R.; BAIO, F. H. R.; SILVA JUNIOR, C. A.;  
28 SANTOS, R. G.; RAMOS, A. P. M.; PINHEIRO, M. M. F.; OSCO, L. P.;  
29 GONÇALVES, W. N.; CARNEIRO, A. M. Predicting days to maturity, plant height,  
30 and grain yield in soybean: A machine and deep learning approach using multispectral  
31 data. **Remote Sensing**, v. 13, n. 22, p. 4632, 2021.
- 32 VAN EEUWIJK, F. A.; BUSTOS-KORTS, D.; MILLET, E. J.; BOER, M. P.;  
33 KRUIJER, W.; THOMPSON, A., MALOSETTI, M.; IWATA, H., QUIROZ, R.;  
34 KUPPE, C.; MULLER, O.; BLAZAKIS, K. N.; YU, K.; TARDIEU, F.; CHAPMAN, S.

- 1 C. Modelling strategies for assessing and increasing the effectiveness of new  
2 phenotyping techniques in plant breeding. **Plant Science**, v. 282, p. 23–39, 2019.
- 3 VIDYARTHI, V. K.; JAIN, A.; CHOURASIYA, S. Modeling rainfall-runoff process  
4 using artificial neural network with emphasis on parameter sensitivity. **Modeling Earth**  
5 **Systems and Environment**, v. 6, p. 2177–2188, 2020.
- 6 WU, Q.; SU, N.; SHEN, W.; CUI, J. Analyzing photosynthetic activity and growth of  
7 *Solanum lycopersicum* seedlings exposed to different light qualities. **Acta physiologiae**  
8 **plantarum**, v. 36, p. 1411–1420, 2014.
- 9 ZAFAR, M. M.; MUSTAFA, G.; SHOUKAT, F.; IDREES, A.; ALI, A.; SHARIF, F.;  
10 SHAKEEL, A.; MO, H.; YOULU, Y.; ALI, Q.; RAZZAQ, A.; REN, M.; LI, F.  
11 Heterologous expression of cry3Bb1 and cry3 genes for enhanced resistance against  
12 insect pests in cotton. **Scientific Reports**, v. 12, n. 1, p. 10878, 2022.
- 13 ZAHIR, S. A. D. M.; OMAR, A. F.; JAMLOS, M. F.; AZMI, M. A. M.; MUNCAN, J.  
14 A review of visible and near-infrared (Vis-NIR) spectroscopy application in plant stress  
15 detection. **Sensors and Actuators A: Physical**, v. 338, p. 113468, 2022.

16



## APÊNDICES

Tabela 1. Relação dos índices de vegetação.

| Sigla   | Índice de Vegetação (IV)                              | Equação                                                                                                                      |
|---------|-------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------|
| ARVI2   | Índice de vegetação atmosférico resistente 2          | $-0.18 + 1.17 * \left[ \frac{(R_{nir} - R_{red})}{(R_{nir} + R_{red})} \right]$                                              |
| ATSAVI  | Índice de vegetação transformado ajustado ao solo     | $1.22 * \left[ \frac{(R_{nir} - 1.22 * R_{red} - 0.03)}{(1.22 * R_{nir} + R_{red} - 1.22 * 0.03 + 0.0891 + 1.22^2)} \right]$ |
| CCCI    | Índice de conteúdo de clorofila do dossel             | $\frac{(R_{nir} - R_{rededge}) / (R_{nir} + R_{rededge})}{(R_{nir} - R_{red}) / (R_{nir} + R_{red})}$                        |
| CIgreen | Índice de clorofila verde                             | $\frac{NIR}{green} - 1$                                                                                                      |
| CTVI    | Índice de vegetação correto transformado              | $\frac{NDVI + 0.5}{NDVI + 0.5} * \sqrt{NDVI + 0.5}$                                                                          |
| CVI     | índice de vegetação clorofila                         | $NIR \frac{red}{green^2}$                                                                                                    |
| DVI     | Índice de Vegetação Diferenciada                      | $\frac{R_{nir}}{R_{red}}$                                                                                                    |
| EVEI2   | Índice de Vegetação Aprimorado 2                      | $\frac{2.5 * (R_{nir} - R_{red})}{(R_{nir} + 2.4 * R_{red} + 1)}$                                                            |
| EVI     | Índice de vegetação aprimorado                        | $2.5 * \frac{(R_{NIR} - R_{RED})}{((R_{NIR}) + (C1 * R_{NIR}) - (C2 * R_{BLUE}) + L)}$                                       |
| GDVI    | Diferença NIR/Índice de Vegetação por Diferença Verde | $\frac{R_{nir} - R_{green}}{2 * (1 - 0.25 * 2) - ((R_{red} - 0.125))}$                                                       |
| GEMI    | Índice Global de Monitoramento Ambiental              | $\frac{(1 - R_{red})}{(2 * R_{green} - R_{red} - R_{blue})}$                                                                 |
| GLI     | Índice folha verde                                    | $\frac{(2 * R_{green} + R_{red} + R_{blue})}{(R_{nir} - R_{green})}$                                                         |
| GNDVI   | Índice de vegetação normalizada verde                 | $\frac{(R_{nir} + R_{green})}{(1 + L) * (R_{nir} - R_{green})}$                                                              |
| GSAVI   | Índice de Vegetação Ajustado ao Solo Verde            | $\frac{(R_{nir} + R_{green} + L)}{(R_{nir} + R_{green} + L)}$                                                                |

|            |                                                            |                                                                                                      |
|------------|------------------------------------------------------------|------------------------------------------------------------------------------------------------------|
| GTVI       | Índice de Vegetação do Triângulo Verde                     | $\frac{NDVI + 0.5}{NDVI + 0.5} * [(\sqrt{NDVI} + 0.5)]$                                              |
| IAF        | Índice de área foliar                                      | $\frac{\ln(\frac{0.69 - SAVI}{0.59})}{0.91}$                                                         |
| IPVI       | Índice de porcentagem de vegetação infravermelha           | $R_{nir} / \left( \left( R_{nir} + \frac{R_{red}}{2} \right) * (NDVI + 1) \right)$                   |
| LnRE       | Índice de vegetação da borda do vermelho                   | $(\ln R_{NIR} - \ln_{REDGE}) * 100$                                                                  |
| LogR       | Log R                                                      | $\log \frac{R_{nir}}{R_{red}}$                                                                       |
| MCARI      | Índice de reflectância de absorção de clorofila modificado | $R_{700} - R_{670} - 0.2(R_{700} - R_{(550)}) \frac{R_{700}}{R_{670}}$                               |
| MSAVI      | Índice de vegetação modificado ajustado ao solo            | $\frac{2nir + 1 - \sqrt{(2nir + 1)^2 - (8nir - red)}}{2}$                                            |
| MSR        | Proporção de solo modificada                               | $\frac{2 * R_{nir} + 1 - \sqrt{(2 * R_{nir} + 1)^2 - 8 * (R_{NIR} - R_{red})}}{2}$                   |
| MSRNir_Red | Taxa simples modificada NIR/RED                            | $\left( \frac{R_{nir}}{R_{red}} - 1 \right) / \sqrt{\frac{R_{nir}}{R_{red}} + 1}$                    |
| MTVI       | Índice de vegetação triangular modificado                  | $\frac{1.5 [1.2(nir - green) - 2.5(red - green)]}{\sqrt{(2nir + 1)^2 - (6nir - 5\sqrt{red})} - 0.5}$ |
| NDRE       | Índice de vegetação da diferença normalizada pelo rededge  | $\frac{(R_{NIR} - R_{EDGE})}{(R_{NIR} + R_{EDGE})}$                                                  |
| NDVI       | Índice de vegetação da diferença normalizada               | $\frac{(R_{NIR} - R_{RED})}{(R_{NIR} + R_{RED})}$                                                    |
| NGRDI      | Índice de Diferença Verde-Vermelho Normalizado             | $\frac{R_{green} - R_{red}}{R_{green}} / (R_{nir} + R_{red} + R_{green})$                            |
| NIR/G      | Razão simples nir e verde                                  | $\frac{R_{nir}}{R_{green}}$                                                                          |
| NIR/R      | Razão simples nir e vermelho                               | $\frac{R_{nir}}{R_{red}}$                                                                            |
| NIR/RE     | Razão simples nir e rededge                                | $\frac{R_{nir}}{R_{re}}$                                                                             |

|           |                                                |                                                                                                 |
|-----------|------------------------------------------------|-------------------------------------------------------------------------------------------------|
| Norm_R_1  | R normal                                       | $\frac{R_{red}}{(R_{nir} + R_{red} + R_{green})}$                                               |
| OSAVI     | Índice de Vegetação Ajustado ao Solo Otimizado | $\frac{(1 + 0.16) * (R_{nir} - R_{red})}{(R_{nir} + R_{red} + 0.16)}$                           |
| PNDVI     |                                                | $\frac{R_{nir} - (R_{green} + R_{red} + R_{blue})}{R_{nir} + (R_{green} + R_{red} + R_{blue})}$ |
| RDVI      | Índice de vegetação de diferença renormalizada | $\frac{(R_{nir} - R_{red})}{\sqrt{R_{nir} + R_{red}}}$                                          |
| SAVI      | Índice de vegetação ajustada ao solo           | $(1 + 0,5) \frac{nir - red}{nir + red + 0,5}$                                                   |
| SQRT_IR_R |                                                | $\sqrt{\frac{R_{nir}}{R_{red}}}$                                                                |
| TVI       | Índice de vegetação transformado               | $\sqrt{\frac{R_{nir} - R_{red}}{R_{nir} + R_{red}}}$                                            |
| VARI      |                                                | $\frac{R_{green} - R_{red}}{R_{green} + R_{red} - R_{blue}}$                                    |
| WDRVI     | Índice de vegetação de ampla faixa dinâmica    | $\frac{(0.1R_{nir} - R_{red})}{(0.1 * R_{nir} + R_{red})}$                                      |

$R_{NIR}$ : reflectância na faixa do infravermelho próximo;  $R_{GREEN}$ : reflectância na faixa do verde;  $R_{RED}$ : reflectância na faixa do vermelho;  $R_{re}$ : reflectância na faixa de transição do vermelho (Red-edge);  $L$ : fator de correção do efeito do solo.