

RESSALVA

Atendendo solicitação do(a)
autor(a), o texto completo desta tese
será disponibilizado somente a partir
de 13/03/2026.

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**Fenotipagem de Alto Rendimento, *Machine Learning* e
Deep Learning: Aplicação de Métodos de Inteligência
Artificial no Melhoramento Genético de Plantas
Autógamas**

**Jardel da Silva Souza
Mestre em Agronomia**

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**Fenotipagem de Alto Rendimento, *Machine Learning* e
Deep Learning: Aplicação de Métodos de Inteligência
Artificial no Melhoramento Genético de Plantas
Autógamas**

Discente: Jardel da Silva

Orientadora: Profa. Dra. Sandra Helena Unêda-Trevisoli

**Tese apresentada à Faculdade de
Ciências Agrárias e Veterinárias –
Unesp, Câmpus de Jaboticabal, como
parte das exigências para a obtenção do
título de Doutor em Agronomia
(Genética e Melhoramento de Plantas).**

S729f Souza, Jardel da Silva
Fenotipagem de alto rendimento, machine learning e deep learning: aplicação de métodos de inteligência artificial no melhoramento genético de plantas autógamas / Jardel da Silva Souza. -- Jaboticabal, 2025
103 p.

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientadora: Sandra Helena Unêda-Treviseli

1. Fenotipagem de Alto-Rendimento. 2. Inteligência Artificial. 3. Arroz. 4. Soja. 5. Redes Neurais. I. Título.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: FENOTIPAGEM DE ALTO RENDIMENTO, *Machine Learning* E *Deep Learning*: APLICAÇÃO DE MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NO MELHORAMENTO GENÉTICO DE PLANTAS AUTÓGAMAS

AUTOR: JARDEL DA SILVA SOUZA

ORIENTADORA: SANDRA HELENA UNÊDA TREVISOLI

Aprovado como parte das exigências para obtenção do Título de Doutor em Agronomia (Genética e Melhoramento de Plantas), pela Comissão Examinadora:

Documento assinado digitalmente
 **SANDRA HELENA UNEDA TREVISOLI**
Data: 21/03/2025 17:18:00-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. SANDRA HELENA UNÊDA TREVISOLI (Participação Presencial)
Departamento de Produção Vegetal / FCAV UNESP Jaboticabal

Documento assinado digitalmente
 **CLAUDENIR FACINCANI FRANCO**
Data: 17/03/2025 09:13:45-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. CLAUDENIR FACINCANI FRANCO (Participação Virtual)
Departamento Biocombustíveis / FATEC

Documento assinado digitalmente
 **PABLO FORLAN VARGAS**
Data: 16/03/2025 10:25:18-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. PABLO FORLAN VARGAS (Participação Presencial)
Agronomia / FCAVR UNESP Registro

Documento assinado digitalmente
 **LÍGIA DE OLIVEIRA AMARAL**
Data: 20/03/2025 17:17:16-0300
Verifique em <https://validar.iti.gov.br>

Dra. LÍGIA DE OLIVEIRA AMARAL (Participação Virtual)
BASF S/A / Porto Nacional/TO



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal



Documento assinado digitalmente

ROUVERSON PEREIRA DA SILVA

Data: 15/03/2025 14:55:42-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. ROUVERSON PEREIRA DA SILVA (Participação Presencial)
Departamento de Engenharia / FCAV UNESP Jaboticabal

Jaboticabal, 13 de março de 2025

DADOS CURRICULARES DO AUTOR

JARDEL DA SILVA SOUZA nasceu em 2 de setembro de 1994, na cidade de Colônia Leopoldina, Alagoas, é Engenheiro Agrônomo, formado pela Universidade Federal da Paraíba (UFPB) em 2018. Durante a graduação, foi bolsista de iniciação científica de 2015 a 2016, no Departamento de Fitotecnia e Ciências Ambientais, e de 2016 a 2017, no Departamento de Solos e Engenharia Rural. Além disso, atuou como monitor da disciplina de Química Orgânica 2014 a 2015 e da disciplina de Melhoramento de Plantas (2017). Em 2017, foi premiado com o Prêmio Jovem Cientista da UFPB e com o Prêmio de Iniciação à Docência pela monitoria na disciplina de Melhoramento de Plantas. Em março de 2018, ingressou no curso de Mestrado em Agronomia pela UFPB, na área de concentração em Biotecnologia e Melhoramento Genético de Plantas. Durante o mestrado, foi bolsista CAPES sob a orientação da Profa. Dra. Elizanilda Ramalho do Rêgo, obtendo o título de Mestre em fevereiro de 2020. Em março de 2021, iniciou o Doutorado em Agronomia (Genética e Melhoramento de Plantas) na Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Câmpus de Jaboticabal, sob a orientação da Profa. Dra. Sandra Helena Unêda-Trevisoli, como bolsista CAPES. Em 2024, realizou um período de treinamento como doutorado sanduíche na Louisiana State University, nos Estados Unidos, sob a orientação do Prof. Dr. Roberto Fritsche-Neto.

Dedico esta tese à memória dos meus pais, Maurício e Maria Marlene, e do meu tio Amauri. Eles me viram crescer, sonhar e percorrer este caminho, mas não tiveram a chance de me ver alcançar o título de Doutor.

AGRADECIMENTOS

A Universidade Estadual Paulista, em especial, ao programa de Pós-Graduação em Agronomia/Genética e Melhoramento de Plantas pela oportunidade de realização do curso, e à CAPES pela concessão da bolsa de estudos.

À minha orientadora na Universidade Estadual Paulista, Professora Dra. Sandra Helena Unêda-Trevisoli, pela amizade, conselhos, ensinamentos e orientações nos trabalhos acadêmicos.

Ao Professor Dr. Roberto Fritsche-Neto, pela amizade, conselhos, ensinamentos e orientações, na Louisiana State University.

Aos colegas do Laboratório Biotecnologia e Melhoramento da UNESP/FCAV Jaboticabal: Alice, Alyce, Ana Beatriz, Ana Clara, Claudenir, Dardânia, Davi, Ery Bonifácio, Flávio, Gabriela Cordeiro, Gustavo Perle, Hortência, José Augusto, Laura Rodrigues, Larissa, Lucas Caruzo, Lucas Zovadelli, Márcio Mandrá, Matheus, Nattan, Nayara, Thainá Moura, Thyaná Garcia. E aos funcionários da FEPE: Colovate, Canoa, Ferrari, Fran e Sr. João.

Aos colegas da Louisiana State University - AgCenter: Adam Famoso, Alisson, Anderson, Felipe Dalla Lana, Gustavo, Jomar Punzalan, Kajal, Kashish, Melina, Valerie, Mr. Dean, Miss Donna.

Aos colegas da República TOca fogo e agregados: Armando, Breno, Eduardo, Fernanda, Francisco, Igor, Jarlyson, Jefferson, Lorena, Luís Alberto, Marcelo, Samira, Hilário, Theodora e Prof. Rouverson.

Aos amigos: Adjair, Eduardo Felipe, Fabiano, Flaviano, Gemerson, Ingrid, Isadora Gouveia, Isadora Le Campion, Jackson, Julia Mercês, Kaline, Karla, Lais, Maiara Marques, Maria de Fátima, Matheus Ayres, Michelle, Nardiele, Raylson (*in memoriam*), Renata, Robério e Thalia.

À minha família: meus pais (*in memoriam*) Maurício e Maria Marlene, meus avós Antonio e Creuza, minha tia Rizomar e meus tios: Amauri (*in memoriam*), Joaquim, José, Renildo. A todos pelas palavras de motivação,

amizade e pelos momentos de descontração ao longo dessa caminhada em busca de crescimento pessoal e profissional. Muito obrigado!

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Impacto Esperado da Tese

Esta tese contribui para o avanço da agricultura digital ao integrar inteligência artificial e fenotipagem de alto rendimento, acelerando o desenvolvimento de cultivares mais produtivas e resilientes às mudanças climáticas.

Sumário

RESUMO	vii
Capítulo 1 – Considerações Gerais.....	9
1. Melhoramento Genético e Inteligência Artificial (IA).....	9
1.1. Limitações dos métodos convencionais e a necessidade de novas tecnologias.....	10
1.2. O papel da Inteligência Artificial no avanço da agricultura digital	11
2. Fenotipagem de Alto Rendimento (HTP) e sua Importância no Melhoramento Genético	12
2.1. Fenotipagem de Alto Rendimento e Inteligência Artificial: como o <i>Machine Learning</i> e <i>Deep Learning</i> auxiliam na análise automática de imagens e sensores para a caracterização fenotípica	13
3. Aplicações do <i>Machine Learning</i> e <i>Deep Learning</i> no Melhoramento Genético e na Agricultura.....	16
4. Modelos Híbridos de <i>Machine Learning</i> e <i>Deep Learning</i> no Melhoramento de Plantas.....	19
5. Espécies autógamias	21
5.1. Cultura da Soja	21
5.2. Cultura do Arroz	22
6. Desafios e Perspectivas Futuras	23
Referências Bibliográficas	26
Capítulo 2: Otimização da Avaliação da Qualidade de Grãos de Arroz Por Meio de Fenotipagem de Alto Rendimento.....	43
Introdução.....	44
Material e Métodos.....	46
Utilização de Software e Processamento de Imagens.....	46
Leitura e Processamento de Imagens	47
Detecção de Contornos e Análise Morfológica.....	47
Análise Quantitativa.....	48
Análise de Grãos Gessados.....	48
Validação	49
Resultados e Discussão	49
Conclusão.....	55

Referências.....	55
Capítulo 3: Uso Integrado de <i>Machine Learning</i> e <i>Deep Learning</i> no Melhoramento Genético de Soja: Classificação de Genótipos e Estimativa de Valor Agrônomico	61
Resumo	61
Introdução.....	62
Material e Métodos.....	64
Caracteres Avaliados	64
Avaliação do teor de óleo e proteína	65
Base de Dados para Random Forest (<i>Machine Learning</i>)	66
Seleção e Pré-Processamento dos Dados	66
Treinamento e Validação do Modelo.....	67
Ambiente de Desenvolvimento	68
Base de Dados para <i>Deep Learning</i>	69
Divisão dos Dados	70
Construção do Modelo de Rede Neural.....	71
Resultados e Discussão	74
<i>Machine Learning</i> na classificação dos genótipos de soja	74
<i>Deep Learning</i> na estimativa do Valor Agrônomico em soja	80
Referências Bibliográficas.....	95

Lista de Figuras

Capítulo I:

- Figura 1.** Processamento Das Imagens Da Câmera Hiperespectral.....47
- Figura 2.** Processamento das imagens da câmera RGB.48
- Figura 3.** correlações entre dados do *seedcount* e os dados da câmera hiperespectral. (a) correlação entre gessamento antigo e gessamento novo (92%); (b) correlação entre largura antiga e largura nova (68%); (c) correlação entre comprimento antigo e comprimento novo (89%).51
- Figura 4.** Correlações entre dados do *Seedcount* e câmera RGB. (A) correlação entre gessamento antigo e gessamento novo (68%); (B) correlação entre largura antiga e largura nova (83%); (C) correlação entre comprimento antigo e comprimento novo (89%)......51
- Figura 1.** Representação gráfica da arquitetura da rede neural artificial, evidenciando as camadas de entrada, ocultas e de saída. A camada de entrada possui 6 neurônios, correspondendo às variáveis preditoras do modelo. A rede conta com duas camadas ocultas, contendo 64 e 32 neurônios, respectivamente, responsáveis pelo aprendizado das representações dos dados. A camada de saída possui 1 neurônio, indicando que o modelo realiza uma tarefa de regressão ou classificação binária.72
- Figura 2.** Agrupamento de genótipos por classificação de desempenho, com destaque para os genótipos classificados como Excelentes (25 amostras).75
- Figura 3.** Comparação das curvas de perda de treinamento e perda de validação, A: safra 2021/2022; B: safra 2022/2023; C: Média dos dois anos. ..80
- Figura 4.** Contribuição relativa das características fenotípicas utilizadas no modelo de classificação para a diferenciação dos genótipos de soja. Jaboticabal, SP.82
- Figura 5.** Correlação entre valores agronômicos reais e valores criados pelo algoritmo para os dados avaliados no ano agrícola 2021/2022. Jaboticabal, SP.85
- Figura 6.** Correlação entre valores agronômicos reais e valores criados por algoritmo para os dados avaliados no ano agrícola 2022/2023. Jaboticabal, SP.86

Figura 7. Correlação entre valores agronômicos reais e valores criados pelo algoritmo para os dados médios dos dois anos agrícolas (2021/2022 e 2022/2023). Jaboticabal, SP.87

Capítulo II:

Figura 1. Processamento das imagens da câmera hiperespectral.....47

Figura 2. Processamento das imagens da câmera RGB.48

Figura 3. correlações entre dados do *seedcount* e os dados da câmera hiperespectral. (a) correlação entre gessamento antigo e gessamento novo (92%); (b) correlação entre largura antiga e largura nova (68%); (c) correlação entre comprimento antigo e comprimento novo (89%).51

Figura 4. Correlações entre dados do *Seedcount* e câmera RGB. (A) correlação entre gessamento antigo e gessamento novo (68%); (B) correlação entre largura antiga e largura nova (83%); (C) correlação entre comprimento antigo e comprimento novo (89%).51

Figura 1. Representação gráfica da arquitetura da rede neural artificial, evidenciando as camadas de entrada, ocultas e de saída. A camada de entrada possui 6 neurônios, correspondendo às variáveis preditoras do modelo. A rede conta com duas camadas ocultas, contendo 64 e 32 neurônios, respectivamente, responsáveis pelo aprendizado das representações dos dados. A camada de saída possui 1 neurônio, indicando que o modelo realiza uma tarefa de regressão ou classificação binária.72

Figura 2. Agrupamento de genótipos por classificação de desempenho, com destaque para os genótipos classificados como Excelentes (25 amostras).75

Figura 3. Comparação das curvas de perda de treinamento e perda de validação, A: safra 2021/2022; B: safra 2022/2023; C: Média dos dois anos. ...80

Figura 4. Contribuição relativa das características fenotípicas utilizadas no modelo de classificação para a diferenciação dos genótipos de soja. Jaboticabal, SP.82

Figura 5. Correlação entre valores agronômicos reais e valores criados pelo algoritmo para os dados avaliados no ano agrícola 2021/2022. Jaboticabal, SP.85

Figura 6. Correlação entre valores agronômicos reais e valores criados por algoritmo para os dados avaliados no ano agrícola 2022/2023. Jaboticabal, SP.86

Figura 7. Correlação entre valores agronômicos reais e valores criados pelo algoritmo para os dados médios dos dois anos agrícolas (2021/2022 e 2022/2023). Jaboticabal, SP.87

Lista de Tabelas

Tabela 1. Métricas de Avaliação do Desempenho do Modelo de Classificação para os genótipos de soja. Jaboticabal, SP.75

Tabela 2. A matriz de confusão, desempenho do modelo na classificação dos genótipos de soja em três categorias: "Excelentes", "Intermediários" e "Menos Promissores".....78

Tabela 3. Estimativas de Herdabilidade (h^2) para caracteres agronômicos em genótipos de soja, em três anos agrícolas (2021/2022, 2022/2023) e a média dos valores combinados dos dois anos agrícolas. Jaboticabal, SP.89

Tabela 4. Estatísticas descritivas das características fenotípicas avaliadas em três anos agrícolas (2021/2022, 2022/2023) e na média geral do período.89

Fenotipagem de Alto Rendimento, *Machine Learning* e *Deep Learning*: Aplicação de Métodos de Inteligência Artificial no Melhoramento Genético de Plantas Autógamas

RESUMO – A aplicação de tecnologias emergentes, como fenotipagem de alto rendimento associados à inteligência artificial, tem revolucionado o melhoramento genético, tornando os processos de seleção mais ágeis, precisos e acessíveis. Neste estudo, foram investigadas duas abordagens inovadoras: a fenotipagem de alto rendimento para avaliação da qualidade dos grãos de arroz, além do uso de *Machine Learning* para classificação de genótipos e *Deep Learning* para a estimar do valor agrônomo em soja, sendo, portanto, explorados dois métodos de inteligência artificial para esta cultura. A fenotipagem de alto rendimento mostrou-se uma ferramenta eficaz para a análise da qualidade dos grãos de arroz, substituindo métodos tradicionais demorados e manuais. Utilizando imagens RGB e hiperespectrais, foi possível quantificar a presença de grãos gessados com alta correlação em relação aos dados obtidos pelo método tradicional *seedcount*. A técnica baseada em câmeras RGB apresentou uma precisão de 92%, reduzindo drasticamente o tempo necessário para análise, de três meses para apenas nove dias. Além da eficiência, essa abordagem se mostrou economicamente viável, garantindo resultados confiáveis com um custo muito inferior ao de equipamentos especializados, enquanto um custa em torno de 2 mil dólares o outro custa 40 mil dólares. Por outro lado, no melhoramento genético da soja, a inteligência artificial foi aplicada para otimizar a seleção de genótipos. Algoritmos de *ML* foram empregados para classificar genótipos em grupos de desempenho agrônomo, atingindo uma acurácia de 95%. Paralelamente, modelos de *DL* foram utilizados para prever o valor agrônomo, alcançando um coeficiente de determinação (R^2) de até 86,35%, demonstrando grande precisão na estimativa de características fenotípicas. Essa abordagem integrada possibilitou uma avaliação mais robusta dos genótipos, reduzindo o viés humano e aumentando a eficiência da seleção. Os resultados deste estudo evidenciam o potencial da automação na agricultura, permitindo maior precisão e velocidade nos programas de melhoramento genético. A combinação de fenotipagem de alto rendimento com a inteligência artificial não apenas otimiza o processo de

seleção de cultivares superiores, mas também contribui para a adaptação das culturas às novas demandas climáticas e produtivas. O avanço dessas tecnologias representa um passo essencial para uma agricultura mais sustentável e eficiente, garantindo maior produtividade e qualidade na produção agrícola.

Palavras-chave: Algoritmos de Redes Neurais, Arroz, Classificação de Genótipos, Estimativa Agronômica, Fenotipagem de Alto Rendimento, Inteligência Artificial, *Machine Learning* (ML), Melhoramento Genético, Soja.

High-Throughput Phenotyping, *Machine Learning*, and *Deep Learning*: Application of Artificial Intelligence Methods in the Genetic Improvement of Self-Pollinating Plants

ABSTRACT – The application of emerging technologies, such as high-throughput phenotyping combined with artificial intelligence, has revolutionized plant breeding by making selection processes faster, more accurate, and more accessible. This study investigated two innovative approaches: high-throughput phenotyping for evaluating rice grain quality, and the use of Machine Learning for genotype classification and Deep Learning to estimate agronomic value in soybean—thus exploring two artificial intelligence strategies for this crop. High-throughput phenotyping proved to be an effective tool for analyzing rice grain quality, replacing time-consuming and manual traditional methods. Using RGB and hyperspectral imaging, it was possible to quantify the presence of chalky grains with a high correlation to the data obtained through the traditional SeedCount method. The RGB-based technique achieved 92% accuracy, drastically reducing the analysis time from three months to just nine days. In addition to its efficiency, this approach proved to be economically viable, providing reliable results at a much lower cost than specialized equipment, with one costing around 2,000 USD compared to 40,000 USD. In soybean breeding, artificial intelligence was applied to optimize genotype selection. ML algorithms were used to classify genotypes based on agronomic performance, reaching 95% accuracy. Concurrently, DL models were employed to predict agronomic value, achieving a coefficient of determination (R^2) of up to 86.35%, demonstrating high precision in estimating phenotypic traits. This integrated approach enabled a more robust evaluation of genotypes, reducing human bias and increasing selection efficiency. The results of this study highlight the potential of automation in agriculture, enabling greater precision and speed in plant breeding programs. The combination of high-throughput phenotyping with artificial intelligence not only optimizes the selection of superior cultivars but also contributes to adapting crops to new climatic and productive demands. The advancement of these technologies represents a key step toward more sustainable and efficient agriculture, ensuring higher productivity and quality in food production.

Keywords: Agronomic Prediction, Artificial Intelligence, Genotype Classification, Genetic Improvement, High-throughput Phenotyping, Machine Learning, Neural Networks, Rice, Soybean.

Capítulo 1 – Considerações Gerais

1. Melhoramento Genético e Inteligência Artificial (IA)

O melhoramento genético de plantas constitui um pilar fundamental da agricultura moderna, voltado ao desenvolvimento de cultivares superiores, com maior produtividade, estabilidade fenotípica e resiliência frente a estresses bióticos e abióticos. De acordo com Borém et al. (2017) e Aswini et al. (2023), essa área do conhecimento utiliza as leis da genética, estatística, biotecnologia e fisiologia vegetal, além de outros campos correlacionados, para modificar geneticamente as plantas e atender às exigências da agricultura moderna. Os métodos empregados no melhoramento genético dependem das metas estabelecidas pelos programas de pesquisa e das características específicas de cada espécie vegetal.

As principais abordagens do melhoramento genético de plantas incluem diversas técnicas que visam aprimorar características desejáveis, como produtividade, resistência a doenças e qualidade nutricional, como os alimentos biofortificados por exemplo. A seleção artificial consiste na escolha de indivíduos com características vantajosas para reprodução, garantindo a transmissão dessas características para as futuras gerações (Borém et al., 2017). A hibridação, envolve o cruzamento de genótipos distintos, permitindo a combinação de atributos favoráveis em uma única cultivar (Novello et al., 2023).

Essas abordagens desempenham um papel fundamental no desenvolvimento de cultivares mais adaptadas às necessidades da agricultura moderna, contribuindo para a sustentabilidade, segurança alimentar e produtividade global (Makrushina & Klitsenko, 2022). O melhoramento genético de plantas tem sido essencial para a segurança alimentar e o desenvolvimento sustentável da agricultura, permitindo, o aumento da produtividade agrícola. Cultivares mais eficientes no uso de recursos garantem maior produção sem a necessidade de expandir as áreas de cultivo, reduzindo impactos ambientais (Esmaeili et al., 2022). Além disso, o desenvolvimento de cultivars resistentes à

pragas e doenças minimiza o uso de defensivos agrícolas, tornando o cultivo mais sustentável (Aziz et al., 2022).

O melhoramento genético também proporciona a adaptação das plantas às condições climáticas extremas, permitindo a produção em regiões afetadas por seca, salinidade e variações de temperatura (Souza et al., 2023). A melhoria nutricional também se destaca como uma das grandes conquistas dessa ciência, possibilitando a obtenção de cultivares biofortificadas, como o arroz dourado, que tem alto potencial na redução da desnutrição mundial (Novello et al., 2023). Apesar dos avanços, o melhoramento genético de plantas ainda enfrenta desafios, como a falta de aceitação social de culturas geneticamente modificadas, regulamentações rigorosas para a liberação de novas cultivares e as mudanças climáticas, que afetam a variabilidade genética existente nas espécies vegetais (Begna, 2022). Diante desse cenário, a integração entre o melhoramento convencional associado à diversas técnicas modernas, podem garantir a produção sustentável de alimentos para atender à crescente demanda global gerada pelo aumento populacional (Saxena, 2022; Hernández et al., 2024).

Conclusão

Este estudo demonstrou o elevado potencial da integração de algoritmos de ML e DL para o melhoramento genético da soja. O modelo Random Forest foi eficiente na classificação de 281 genótipos em três categorias de desempenho, enquanto a Rede Neural Artificial se mostrou precisa na predição do valor agronômico, atingindo médias de 95% para precisão, recall e F1-score.

Características como Valor Agronômico (VA) e Produtividade de Grãos (PRD) apresentaram contribuição intermediária no modelo, evidenciando sua importância na diferenciação dos genótipos. Por outro lado, características como Teor de Óleo (OLEO) e Teor de Proteína (PRO) tiveram menor influência relativa.

A variabilidade observada entre os ciclos agrícolas reforçou a importância da inclusão de variáveis ambientais explícitas no treinamento dos modelos, visando aprimorar a robustez e a precisão das predições frente às interações Genótipo $\times$ Ambiente ($G \times E$).

De forma geral, os resultados obtidos ressaltam o potencial das abordagens de inteligência artificial na otimização dos processos de seleção de genótipos superiores, contribuindo para tornar os programas de melhoramento genético mais eficientes, precisos e resilientes às variabilidades ambientais.

Referências Bibliográficas

Amaral, L. O. et al. Artificial neural network for discrimination and classification of tropical soybean genotypes of different relative maturity groups. **Frontiers in Plant Science**, 2022.

Andrioli, I.; Centurion, J. F. Caracterização de solos com horizontes coesos no Estado de São Paulo. **Revista Brasileira de Ciência do Solo**, v. 23, n. 1, p. 85–91, 1999.

Azodi, C. B. et al. Benchmarking algorithms for genomic prediction of complex traits. **bioRxiv**, 2019.

Barbedo, J. Deep Learning for soybean monitoring and management. **Seeds**, 2023.

Begna, T. The role of genotype by environmental interaction in plant breeding. **Journal of Natural Sciences Research**, v. 11, p. 9–18, 2020.

Bernardy, R. et al. Identifying soybean genotypes with artificial intelligence and near infrared reflectance. **Ciência e Agrotecnologia**, 2024.

Dash, C. S. K. et al. An outliers detection and elimination framework in classification task of data mining. **Decision Analytics Journal**, 2023. Disponível em: <https://doi.org/10.1016/j.dajour.2023.100164>.

Embrapa. Sistema de produção: milho. 2. ed. Brasília, DF: Embrapa, 2023.

Fathi, M.; Shah-Hosseini, R.; Moghimi, A. 3D-ResNet-BiLSTM model: a Deep Learning model for county-level soybean yield prediction with time-series Sentinel-1, Sentinel-2 imagery, and Daymet data. **Remote Sensing**, 2023.

Fehr, W. R.; Caviness, C. E. Stages of soybean development. Ames: Iowa State University, 1977. (Special Report, 80).

Fernandes, I. K. et al. Using Machine Learning to integrate genetic and environmental data to model genotype-by-environment interactions. **bioRxiv**, 2024.

Flach, P. A.; Kull, M. Precision-Recall-Gain Curves: PR analysis done right. Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems, 2015.

Geng, S. Analysis of the different statistical metrics in Machine Learning. **Highlights in Science, Engineering and Technology**, 2024.

Gulzar, Y. Enhancing soybean classification with modified inception model: a transfer learning approach. **Emirates Journal of Food and Agriculture**, 2024.

Herrero-Huerta, M.; Rodriguez-Gonzalvez, P.; Rainey, K. M. Yield prediction by Machine Learning from UAS-based multi-sensor data fusion in soybean. **Plant Methods**, 2020.

Khaki, S.; Wang, L.; Archontoulis, S. V. A CNN-RNN framework for crop yield prediction. **Frontiers in Plant Science**, v. 10, 2019.

Kumari, M. et al. Object-based Machine Learning approach for soybean mapping using temporal Sentinel-1/Sentinel-2 data. **Geocarto International**, v. 37, p. 6848–6866, 2021.

Leite, W. S. et al. Genetic parameters estimation, correlations and selection indexes for six agronomic traits in soybean lines F8. **Comunicata Scientiae**, v. 7, p. 302-310, 2016.

Li, Y. et al. Genotype by environment interactions in forest tree breeding: review of methodology and perspectives on research and application. **Tree Genetics & Genomes**, v. 13, p. 1–18, 2017.

Liang, M. et al. Improving genomic prediction with Machine Learning incorporating TPE for hyperparameters optimization. **Biology**, v. 11, n. 11, p. 1647, 2022.

Liu, Y. et al. Phenotype prediction and genome-wide association study using deep convolutional neural network of soybean. **Frontiers in Genetics**, v. 10, 2019.

Lu, W. et al. Soybean yield preharvest prediction based on bean pods and leaves image recognition using Deep Learning neural network combined with GRNN. **Frontiers in Plant Science**, v. 12, 2022.

Madhumita, P. S. et al. Drought and salinity stress classification in soybean crops: comparative analysis of Machine Learning models. In: 2024 International Conference on Signal Processing, Computation, Electronics, Power and Telecommunication (IConSCEPT). Anais... p. 1–5, 2024.

Maimaitijiang, M. et al. Soybean yield prediction from UAV using multimodal data fusion and Deep Learning. **Remote Sensing of Environment**, v. 237, p. 111599, 2020.

Miranda, M. C. de C., Aono, A. H., & Pinheiro, J. B. (2022). A novel image-based approach for soybean seed phenotyping using Machine Learning techniques. **bioRxiv**.

Moeinizade, S. et al. An applied Deep Learning approach for estimating soybean relative maturity from UAV imagery to aid plant breeding decisions. **ArXiv**, 2021.

Naik, H. S. et al. A real-time phenotyping framework using Machine Learning for plant stress severity rating in soybean. **Plant Methods**, v. 13, 2017.

Oikonomidis, A. S.; Catal, C.; Kassahun, A. Hybrid Deep Learning-based models for crop yield prediction. **Applied Artificial Intelligence**, v. 36, 2022.

Parmley, K. A. et al. Machine Learning approach for prescriptive plant breeding. **Scientific Reports**, v. 9, 2019.

Riera, L. G. et al. Deep multiview image fusion for soybean yield estimation in breeding applications. **Plant Phenomics**, 2021.

Saini, A.; Guleria, K.; Sharma, S. A Deep Learning-based fine-tuned ResNet50 model for soybean seeds multiclass classification. In: 2023 Global Conference on Information Technologies and Communications (GCITC). Anais... p. 1–6, 2023.

Santana, D. C. et al. Classification of soybean genotypes as to calcium, magnesium, and sulfur content using Machine Learning models and UAV–multispectral sensor. **AgriEngineering**, 2024.

Schmidt, P. Estimating heritability in plant breeding programs. [Periódico não informado], 2020.

Schmidt, P. et al. Heritability in plant breeding on a genotype-difference basis. **Genetics**, v. 212, n. 4, p. 991–1008, 2019.

Shook, J. M. et al. Integrating genotype and weather variables for soybean yield prediction using Deep Learning. **bioRxiv**, 2018.

Shu, K. Prediction of soybean yield using self-normalizing neural networks. In: Proceedings of the 2020 5th International Conference on Machine Learning Technologies. 2020.

Silva, T. L. et al. Genotype-environment interaction in the genetic variability analysis of reproductive traits in Nellore cattle. **Livestock Science**, v. 230, p. 103825, 2019.

Souza, L. M. et al. Genomic selection in rubber tree breeding: A comparison of models and methods for managing G×E interactions. **Frontiers in Plant Science**, v. 10, 2019.

Sun, J. et al. County-level soybean yield prediction using deep CNN-LSTM model. **Sensors**, v. 19, 2019.

Suryavanshi, A. et al. Synergistic Solutions: Federated Learning Meets CNNs in Soybean Disease Classification. In: 2024 Fourth International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT). Anais... p. 1–6, 2024.

Teodoro, P. et al. Predicting days to maturity, plant height, and grain yield in soybean: A machine and Deep Learning approach using multispectral data. **Remote Sensing**, 2021.

Teressa, T. Misconceptions regarding heritability in plant breeding: An overview article. **Journal of Advanced Agricultural Technologies**, 2024.

Teressa, T.; Semahegn, Z.; Bejiga, T. Multi-environments and genetic-environmental interaction (GxE) in plant breeding and its challenges: A review article. **International Journal of Research Studies in Agricultural Sciences**, 2021.

Uzal, L. C. et al. Seed-per-pod estimation for plant breeding using Deep Learning. **Computers and Electronics in Agriculture**, 2018.

Vats, S. et al. Federated Learning CNN Empowers Precision In Agriculture: A Case Study in Soybean Leaf Disease. In: IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI), 2024. Anais... v. 2, p. 1–6.

Wang, F. et al. Estimating soybean yields using causal inference and Deep Learning approaches with satellite remote sensing data. **IEEE Journal of**

Selected Topics in Applied Earth Observations and Remote Sensing, v. 17, p. 14161–14178, 2024.

Xavier, A. Learning from data: Plant breeding applications of Machine Learning. 2016. Tese (Doutorado) – Purdue University, 2016.

Xing, Y. et al. Traits expansion and storage of soybean phenotypic data in computer vision-based test. **Frontiers in Plant Science**, v. 13, 2022.

Yadesa, L. Review on genetic-environmental interaction (GxE) and its application in crop breeding. **International Journal of Research in Agronomy**, 2022.

Yoosefzadeh-Najafabadi, M. et al. Application of Machine Learning algorithms in plant breeding: Predicting yield from hyperspectral reflectance in soybean. **Frontiers in Plant Science**, v. 11, 2021.

Zhang, J. et al. Computer vision and Machine Learning for robust phenotyping in genome-wide studies. **Scientific Reports**, v. 7, 2017.

Zhang, S. et al. Monitoring of soybean maturity using UAV remote sensing and Deep Learning. **Agriculture**, 2022.