

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

MARCIO ALVES FERNANDES

**PREDIÇÃO DA GERMINAÇÃO DE SEMENTES DE SOJA
UTILIZANDO TESTE DE TETRAZÓLIO E INTELIGÊNCIA
COMPUTACIONAL**

CHAPADÃO DO SUL – MS

2024

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

MARCIO ALVES FERNANDES

**PREDIÇÃO DA GERMINAÇÃO DE SEMENTES DE SOJA
UTILIZANDO TESTE DE TETRAZÓLIO E INTELIGÊNCIA
COMPUTACIONAL**

Orientadora: Profa. Dra. Charline Zaratin Alves

Qualificação apresentada à
Universidade Federal de Mato
Grosso do Sul, como requisito para
obtenção do título de Mestre em
Agronomia, área de concentração:
Produção Vegetal.

CHAPADÃO DO SUL – MS

2024



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



PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

CERTIFICADO DE APROVAÇÃO

DISCENTE: Marcio Alves Fernandes

ORIENTADOR: Dra. Charline Zaratín Alves

TÍTULO: Predição da germinação de sementes de soja utilizando teste de tetrazólio e inteligência computacional.

AVALIADORES:

Profa. Dra. Charline Zaratín Alves

Profa. Dra. Dthenifer Cordeiro Santana

Prof. Dr. Márcio Dias Pereira

Chapadão do Sul, 03 de maio de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Charline Zaratín Alves, Professora do Magistério Superior**, em 03/05/2024, às 15:26, 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 **Dthenifer Cordeiro Santana, Usuário Externo**, em 03/05/2024, às 15:27, 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 **Márcio Dias Pereira, Usuário Externo**, em 03/05/2024, às 16:43, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4830892** e o código CRC **B177241C**.

COLEGIADO DE PÓS-GRADUAÇÃO EM AGRONOMIA

Rod MS 306, Km 105, Caixa Postal 112

Fone: (67)3562-6351

CEP 79560-000 - Chapadão do Sul - MS

Referência: Processo nº 23455.000149/2024-21

SEI nº 4830892

AGRADECIMENTOS

A Professora Charline, cuja orientação exemplar e profundo conhecimento foram fundamentais para o meu desenvolvimento durante o programa de mestrado. Sua dedicação não apenas guiou este trabalho, mas também moldaram minha trajetória acadêmica.

A colega Izabela Oliveira, por sua amizade e insights criativos que deram origem à ideia deste artigo. Sua colaboração e apoio foram essenciais para transformar uma ideia inicial em uma pesquisa concreta e significativa.

Ao Professor Job Teixeira de Oliveira, cujo incentivo me motivou a embarcar nesta jornada acadêmica. Sua confiança em minha capacidade foi um dos pilares para a realização deste mestrado e para a concretização deste trabalho.

Agradeço sinceramente a cada um de vocês por seu suporte inestimável e inspiração contínua.

LISTA DE FIGURAS

- FIGURA 1A.** Boxplot para comparação de médias para coeficiente de correlação (r) para os algoritmos testados na predição de germinação de sementes de soja. 6
- FIGURA 1B.** Boxplot para comparação de inputs testados 6
- FIGURA 2A.** Boxplot para comparação de médias para erro médio absoluto (MAE) 7
- FIGURA 2B.** Boxplot para comparação de médias para erro médio absoluto (MAE) para os algoritmos testados na predição de germinação de sementes de soja. 7

LISTA DE TABELAS

Tabela 1. Resumo da análise de variância para as variáveis de acurácia: coeficiente de correlação (r) e erro absoluto médio (MAE) 5

LISTA DE ABREVIACOES

ANN - Redes neurais artificiais

LR - Regresso logstica

M5P - rvore de deciso M5P

MAE - Erro Mdio Absoluto (Mean Absolute Error)

REPTree - Reduced-Error Pruning Tree

RF - Floresta aleatria

SVM - Mquina de vetor suporte

Viab - Viabilidade

RESUMO

A qualidade das sementes é crucial para a produtividade agrícola, e os testes convencionais podem ser demorados e subjetivos. Portanto, a utilização de aprendizagem de máquina oferece uma abordagem eficiente para a predição da germinação. O objetivo deste trabalho é encontrar algoritmo que juntamente com dados de teste de tetrazólio resultem em predição eficiente da germinação de semente de soja. Foram testados: algoritmos de aprendizado de máquina: REPTree, Árvore de Decisão M5P, Floresta Aleatória, Regressão Logística, Redes Neurais Artificiais e Máquina de Vetor de Suporte. A análise dos dados utilizou como parâmetro de acurácia dos algoritmos coeficiente de correlação (r) e erro absoluto médio (MAE). Os inputs testados foram dados de viabilidade, vigor e vigor + viabilidade. Os resultados destacaram o SVM como o algoritmo mais eficaz na predição da germinação, com os inputs de viabilidade e vigor + viabilidade mostrando os melhores resultados. Este estudo sugere que a integração de técnicas de inteligência computacional com o teste de tetrazólio pode tornar mais eficiente a avaliação da qualidade das sementes de soja, contribuindo para a tomada de decisões rápidas e precisas na agricultura.

Palavras-chave: Aprendizagem de máquina. Máquina de vetor suporte. Viabilidade de sementes.

ABSTRACT

The quality of seeds is crucial for agricultural productivity, and conventional testing methods can be time-consuming and subjective. Therefore, the use of machine learning offers an efficient approach to predicting germination. The objective of this study is to find an algorithm that, together with tetrazolium test data, results in an efficient prediction of soybean seed germination. The following machine learning algorithms were tested: REPTree, M5P Decision Tree, Random Forest, Logistic Regression, Artificial Neural Networks, and Support Vector Machine. The data analysis used correlation coefficient (r) and mean absolute error (MAE) as parameters for algorithm accuracy. The inputs tested were viability data, vigor data, and vigor + viability data. The results highlighted SVM as the most effective algorithm in predicting germination, with the inputs of viability and vigor + viability showing the best results. This study suggests that integrating computational intelligence techniques with the tetrazolium test can make the evaluation of soybean seed quality more efficient, contributing to quick and accurate decision-making in agriculture.

Keywords: Machine learning. Support vector machine. Seed viability.

SUMÁRIO

ABSTRACT	1
INTRODUÇÃO	3
MATERIAL E MÉTODOS	4
Condução do experimento	4
Análises de sementes	4
Análises estatísticas	5
RESULTADOS E DISCUSSÃO	6
CONCLUSÃO	10
REFERÊNCIAS	11

PREDIÇÃO DA GERMINAÇÃO DE SEMENTES DE SOJA UTILIZANDO TESTE DE TETRAZÓLIO E INTELIGÊNCIA COMPUTACIONAL

INTRODUÇÃO

A soja (*Glycine max* [L.] Merrill) é um dos principais produtos agrícolas do mundo, além de ser fonte essencial de proteína e óleo vegetal, utilizado na alimentação humana e animal (LIN et al., 2023). A propagação de plantas de soja é realizada por meio de sementes, que devem apresentar padrões mínimos de qualidade comprovados a partir de testes laboratoriais. A qualidade fisiológica de sementes é um dos pilares para obtenção de altas produtividade a campo, uma vez que são responsáveis pelo estabelecimento, crescimento e desenvolvimento da cultura (MARCOS FILHO, 2015).

A semente necessita apresentar atributos que comprovem sua qualidade genética, física, fisiológica e sanitária, como pureza varietal, grau de umidade, germinação, e ausência de patógenos, respectivamente (KRZYZANOWSKI; FRANÇA-NETO; HENNING, 2018). Para atender os padrões mínimos exigidos para produção e comercialização no Brasil, as sementes de soja devem apresentar pureza física de 99% e germinação de 80% (BRASIL, 2009).

O teste de germinação é frequentemente realizado para comprovar a qualidade de sementes (MARCOS FILHO, 2015). Todavia, os resultados apresentados por esse teste podem ser decorrentes do suprimento das exigências das sementes, uma vez que são realizados sob condições controladas e favoráveis. Dessa forma, a semente que apresenta boa porcentagem de germinação em laboratório, pode apresentar resultados divergentes à campo, sendo necessário o emprego dos testes de vigor para prever o desempenho das sementes em condições não controladas (WENDT et al., 2017).

Os testes de vigor, dentre eles, o de tetrazólio, são responsáveis por caracterizar sementes em lotes de alto, médio e baixo vigor, baseados na capacidade das sementes em resistir a diferentes tipos de estresses sem alterar sua velocidade de germinação, integridade da membrana e desempenho de plântulas no campo (HAO et al., 2020). A utilização do teste de tetrazólio permite a obtenção de resultados em menor tempo, quando comparado ao teste de germinação, além de representar o comportamento das sementes de forma proporcional, com o que aconteceria se as sementes se encontrassem no campo sob condições adversas (KRZYZANOWSKI; FRANÇA-NETO; HENNING, 2018).

Todavia, os testes usuais utilizados para determinação da qualidade das sementes são onerosos e demorados, levando dias até a obtenção de informações e necessidade de experiência do avaliador. Diante disso, é notória a necessidade de métodos que possibilitem a obtenção de informações de forma não destrutiva, precisa e acurada, como o emprego de técnicas de inteligência computacional.

A utilização de técnicas de inteligência computacional, como aprendizagem de máquina, permite a mensuração de diferentes características de forma rápida e não destrutiva, a partir do processamento de dados (GUO et al., 2023), como no presente estudo, a técnicas de inteligência computacional aliadas ao teste de tetrazólio, podem resultar na mesma resposta de teste de germinação. A predição é uma das funcionalidades dos algoritmos de aprendizagem de máquina, onde o algoritmo aprende sobre o comportamento de determinado conjunto de dados durante o treinamento e posteriormente é capaz de prever como um novo conjunto de dados irá se comportar (KARAKATIČ; PODGORELEC, 2016; SANTANA et al., 2022). Porém, cada algoritmo apresenta um desempenho distinto, sendo necessário testar diferentes modelos para encontrar qual o melhor na predição (SANTANA et al., 2023).

A hipótese desta pesquisa se baseou na possibilidade de prever a germinação de sementes de soja por meio de dados do teste de tetrazólio utilizados como input em modelos de aprendizagem de máquina. Assim, o objetivo do trabalho foi verificar encontrar o melhor algoritmo para a predição da germinação, e obter o melhor input para a predição da germinação de sementes de soja.

MATERIAL E MÉTODOS

Condução do experimento

O experimento foi realizado no Laboratório de Produção e Tecnologia de Sementes da Universidade Federal de Mato Grosso do Sul, Campus de Chapadão do Sul. O experimento se baseou no levantamento e transcrição de um banco de dados contendo mil amostras de análise de sementes de soja realizadas no laboratório, as amostras são oriundas do município de Chapadão do Sul – MS e região. Os dados apresentavam informações referentes aos testes de germinação e tetrazólio (vigor e viabilidade).

Análises de sementes

O teste de germinação foi realizado utilizando quatro subamostras de 50 sementes de cada amostra de sementes, distribuídas sobre papel germitest, previamente

umedecido em 2,5 vezes o seu peso e posteriormente mantidas em germinador à 25 °C (BRASIL, 2009). A avaliação foi realizada aos oito dias, onde for constatado plântulas normais e anormais, com resultados expressos em porcentagem de plântulas normais.

O teste de tetrazólio foi realizado em duas subamostras de 50 sementes que inicialmente foram submetidas a uma pré-embebição em papel germitest umedecido 2,5 vezes seu peso mantido em formato de rolo, permanecendo no germinador à 25 °C por 24 horas. Após esse período, as sementes foram embebidas em solução 2,3,5-cloreto de trifeniltetrazólio à concentração de 0,075% e acondicionadas em estufa de demanda bioquímica de oxigênio no escuro, à temperatura de 40 °C durante três horas. Posteriormente as sementes foram seccionadas cuidadosamente para expor o embrião, avaliadas observando a coloração do embrião, onde as células vivas foram coradas em tons de vermelho ou rosa, enquanto as células mortas permanecerão incolores ou com coloração esbranquiçada, posteriormente foram avaliadas a intensidade e a extensão da coloração em cada embrião, sementes com embriões totalmente corados e vigorosos são consideradas viáveis e com alto vigor, sementes com coloração fraca ou áreas incolores indicam baixo vigor ou viabilidade reduzida, assim, obtendo resultados referentes ao vigor e viabilidade (FRANÇA-NETO; KRZYZANOWSKI; DA COSTA, 1998).

Análises estatísticas

Os dados foram submetidos às análises de aprendizagem de máquina (Tabela 1), utilizando como entrada (input) dados de viabilidade (Viab), vigor (Vigor) e vigor + viabilidade (Vigor+Viab) e como variável de saída (output), a germinação. Foi utilizado o método de validação cruzada estratificada que foi utilizada nos modelos com k-fold = 10 e dez repetições (100 execuções para cada modelo). Todos os parâmetros dos modelos foram estabelecidos de acordo com a configuração default do software Weka 3.8.5. os modelos de aprendizagem de máquinas utilizado foram REPTree (SNOUSY et al., 2011), Árvore de decisão M5P (M5P) (BLAIFI et al., 2018), Floresta aleatória (RF) (BELGIU; DRĂGUȚ, 2016), Regressão logística (LR) (ŠTEPANOVSKÝ et al., 2017), Redes neurais artificiais (ANN) (EGMONT-PETERSEN; DE RIDDER; HANDELS, 2002), e Máquina de vetor suporte (SVM) (NALEPA; KAWULOK, 2019), tais modelos são os mais utilizados atualmente.

Avaliando o desempenho dos modelos de predição testados foram usadas métricas de coeficiente de correlação (r) e erro absoluto médio (MAE). O agrupamento das médias e os Boxplots foram gerados usando os pacotes ggplot2 e ExpDes.pt do software R.

RESULTADOS E DISCUSSÃO

A interação entre os algoritmos de aprendizagem de máquina (ML) e os inputs testados não foram significativas (Tabela 1), não se observou uma diferença estatisticamente relevante na performance dos diferentes algoritmos de aprendizado de máquina com os diversos tipos de inputs fornecidos, portanto, a variação nos tipos de dados de entrada (inputs) testados não afetou significativamente o desempenho dos algoritmos de aprendizagem de máquinas. Porém, os inputs testados e os algoritmos de aprendizagem de máquina foram significativos para o coeficiente de correlação (r) e erro absoluto médio (MAE), indicando haver variações no desempenho dos algoritmos em relação aos dados de entrada utilizados.

Tabela 1. Resumo da análise de variância para as variáveis de acurácia: coeficiente de correlação (r) e erro absoluto médio (MAE).

FV	GL	r	MAE
inputs	2	0.129395*	38.072*
ML	5	0.003918*	14.8684*
inputs*ML	10	0.000656 ^{ns}	0.3241 ^{ns}
Resíduo	162	0.000677	0.211012
CV (%)		3.5	5.78

*significativo a 5% pelo teste F; F.V: fonte de variação; G.L: Grau de liberdade; ML: aprendizagem de máquinas

A utilização de aprendizagem de máquina permite uma abordagem eficaz para o processamento de dados, especialmente aqueles com alto nível de complexidade, realizando o processamento de grande número de informações de forma precisa e acurada (XIAO et al., 2023). Todavia, a aplicação de técnicas de inteligência computacional pode acelerar a tomada de decisão em relação a germinação das sementes, uma vez que o teste de germinação de soja pode levar até oito dias para apresentar resultados, enquanto o teste de tetrazólio aliado a aprendizagem de máquina fornece resultados em menos de 48 horas, onde o resultado do teste de tetrazólio é obtido de 5 a 10 horas e seus dados utilizados em algoritmos específicos resulta em resultados em minutos, havendo uma margem de tempo para a logística do laboratório.

Em relação ao coeficiente de correlação (r), os algoritmos de aprendizagem de máquina M5P, RL, RNA e SVM apresentaram os melhores resultados, pois apresentam valores de r consistentemente altos, análise estatística indica que esses algoritmos são superiores e não diferem significativamente entre si (Figura 1A). A utilização dos inputs

Viab e Vigor+Viab apresentaram resultados acima de 0,75 em relação a predição da germinação (Figura 1B).

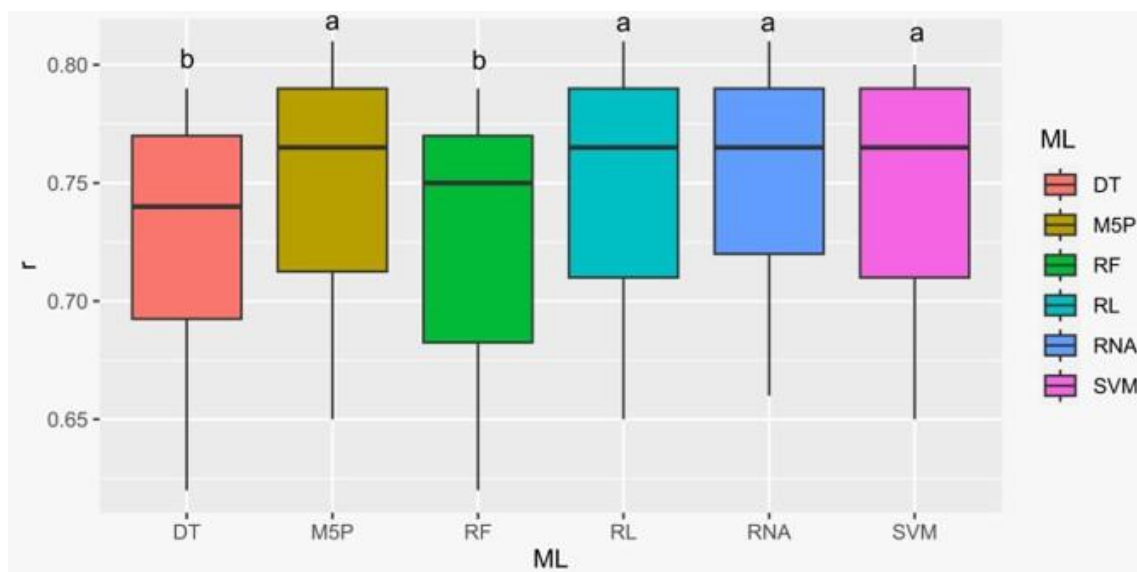


Figura 1A. Boxplot para comparação de médias para coeficiente de correlação (r) para os algoritmos testados na predição de germinação de sementes de soja.




Figura 1B. Boxplot para comparação de inputs testados.

Esse resultado da Figura 1B indica que a predição da germinação pode ser realizada utilizando a viabilidade ou o vigor + viabilidade obtidos através do teste de tetrazólio, uma vez que os algoritmos de aprendizagem de máquina foram eficientes na predição da germinação utilizando estes inputs como entrada.

A utilização de aprendizagem de máquina, especialmente a predição de características como a germinação de sementes, depende do desempenho dos algoritmos testados. Cada algoritmo de aprendizagem de máquina apresenta um desempenho distinto com o conjunto de dados, o que evidencia a necessidade de testar diferentes algoritmos para encontrar o melhor preditor SANTANA et al. (2023). O teste de tetrazólio em sementes de soja depende principalmente da observação e experiência humana, que é subjetiva, diferente da utilização de aprendizagem de máquina, que realiza uma avaliação e forma rápida, acurada e não tendenciosa dos dados apresentados (LIN et al., 2023), a interação de testes convencionais em soja com aprendizagem de máquina ameniza a dependência humana e suas interpretações, as quais podem ser variadas.

O MAE indica que o algoritmo SVM apresentou o melhor resultado na predição da germinação, seguido dos algoritmos M5P e RL (Figura 2A). O algoritmo RNA não é indicado para a predição da germinação utilizando dados obtidos no teste de tetrazólio, por apresentar o maior erro absoluto em relação aos demais algoritmos testados.




Figura 2A. Boxplot para comparação de médias para erro médio absoluto (MAE).




Figura 2B. Boxplot para comparação de médias para erro médio absoluto (MAE) para os algoritmos testados na predição de germinação de sementes de soja.

Os inputs Viab e Vigor+Viab (Figura 2B) apresentaram o melhor desempenho em relação a MAE, evidenciando que ao utilizar a viabilidade e o vigor + viabilidade de sementes de soja como input, houve menor quantidade de erros na predição da germinação. A qualidade das sementes é avaliada por dois parâmetros fundamentais, sendo eles a viabilidade obtida pelo teste de germinação e o vigor, obtido juntamente com a viabilidade pelo teste de tetrazólio, ambos parâmetros que governam a capacidade das sementes de germinar e gerar plântulas normais de forma rápida e uniforme mesmo em condições desfavoráveis (MARCOS FILHO, 2015).

A viabilidade apresenta a capacidade teórica da semente germinar, enquanto o vigor refere-se à habilidade de germinar quando as condições ambientais, especialmente temperatura e umidade, se encontram desfavoráveis (XIA et al., 2019). Logo, a predição da germinação por meio do teste de tetrazólio é alternativa viável para diminuir o tempo necessário para a obtenção de resultados sobre as sementes.

O algoritmo SVM é um método de aprendizagem de máquina eficiente na previsão de características de plantas, por ser um algoritmo versátil e que pode ser utilizado para tarefas de regressão linear e não linear, uma vez que parte do princípio de encontrar o melhor limite que separa os dados (SARKAR et al., 2023). A utilização de SVM permitiu a classificação de sementes de soja em relação a histogramas de cor (JITANAN; CHIMLEK, 2019) e características físicas de feijão (KOKLU; OZKAN, 2020). Dessa forma, observa-se que o algoritmo SVM já é utilizado para classificar

características de soja e características de leguminosas, apresentando resultado também na predição, como os achados deste trabalho sugerem.

As descobertas encontradas neste trabalho demonstram que a utilização de aprendizagem de máquina pode ser utilizada na predição da germinação de sementes de soja com base nas informações de viabilidade e vigor obtidas pelo teste de tetrazólio. O algoritmo SVM apresentou o maior valor de coeficiente de correlação (r) e menor valor de erro médio absoluto (MAE), evidenciando sua superioridade da predição em relação aos demais algoritmos. A utilização das informações de viabilidade e vigor como entrada nos modelos apresentou os maiores valores de r e menores valores de MAE, sendo indicados para a predição da germinação. Perspectivas futuras se baseiam na possibilidade de criar uma equação que possa ser utilizada para o desenvolvimento de softwares que permitam a entrada de dados de tetrazólio e saída dos dados de germinação, contribuindo para a rapidez na tomada de decisão em relação a lotes de sementes e conseqüentemente, a produtividade no cultivo da soja.

CONCLUSÃO

Este estudo demonstrou que a germinação de sementes de soja pode ser eficazmente predita utilizando o teste de tetrazólio combinado com técnicas de inteligência computacional. Entre os diversos algoritmos testados, o Máquina de Vetor Suporte (SVM) se destacou, especialmente quando os inputs de viabilidade e a combinação de vigor + viabilidade foram utilizados. Esses fatores apresentaram os melhores resultados em termos de acurácia e precisão na predição da germinação, assim, a integração de técnicas de inteligência computacional com o teste de tetrazólio demonstrou ser uma abordagem eficiente para a avaliação rápida e precisa da qualidade das sementes de soja. Estes achados sugerem que a adoção dessas técnicas pode melhorar significativamente a tomada de decisões na agricultura, otimizando a produtividade das culturas de soja.

REFERÊNCIAS

- BELGIU, M.; DRĂGUȚ, 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, abr. 2016.
- BLAIFI, S. et al. M5P model tree based fast fuzzy maximum power point tracker. **Solar Energy**, v. 163, p. 405–424, mar. 2018.
- BRASIL. **Regras para Análise de Sementes**. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Defesa Agropecuária. – Brasília: Mapa/ACS, 2009., 2009. . Acesso em: 18 abr. 2024
- EGMONT-PETERSEN, M.; DE RIDDER, D.; HANDELS, H. Image processing with neural networks—a review. **Pattern Recognition**, v. 35, n. 10, p. 2279–2301, out. 2002.
- FRANÇA-NETO; KRZYŻANOWSKI; DA COSTA. **O teste de tetrazólio em sementes de soja**. EMBRAPA, 1998. Disponível em: <<https://www.agrolink.com.br/downloads/TRETRAZ%C3%93LIO.pdf>>. Acesso em: 12 abr. 2024
- GUO, Z. et al. Application of visible-near-infrared hyperspectral imaging technology coupled with wavelength selection algorithm for rapid determination of moisture content of soybean seeds. **Journal of Food Composition and Analysis**, v. 116, p. 105048, mar. 2023.
- HAO, Q. et al. Evaluation of seed vigor in soybean germplasms from different eco-regions. **Oil Crop Science**, v. 5, n. 1, p. 22–25, mar. 2020.
- JITANAN, S.; CHIMLEK, P. Quality grading of soybean seeds using image analysis. **International Journal of Electrical and Computer Engineering (IJECE)**, v. 9, n. 5, p. 3495, 1 out. 2019.
- KARAKATIČ, S.; PODGORELEC, V. Improved classification with allocation method and multiple classifiers. **Information Fusion**, v. 31, p. 26–42, set. 2016.
- KOKLU, M.; OZKAN, I. A. Multiclass classification of dry beans using computer vision and machine learning techniques. **Computers and Electronics in Agriculture**, v. 174, p. 105507, jul. 2020.

KRZYŻANOWSKI; FRANÇA-NETO; HENNING. **A alta qualidade da semente de soja: fator importante para a produção da cultura.** EMBRAPA, 2018. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/177391/1/CT136-online.pdf>>. Acesso em: 14 abr. 2024

LIN, W. et al. Online classification of soybean seeds based on deep learning. **Engineering Applications of Artificial Intelligence**, v. 123, p. 106434, ago. 2023.

MANGENA, P. Analysis of correlation between seed vigour, germination and multiple shoot induction in soybean (*Glycine max* L. Merr.). **Heliyon**, v. 7, n. 9, p. e07913, set. 2021.

MARCOS FILHO, J. Seed vigor testing: an overview of the past, present and future perspective. **Scientia Agricola**, v. 72, n. 4, p. 363–374, ago. 2015.

NALEPA, J.; KAWULOK, M. Selecting training sets for support vector machines: a review. **Artificial Intelligence Review**, v. 52, n. 2, p. 857–900, ago. 2019.

SANTANA, D. C. et al. High-throughput phenotyping allows the selection of soybean genotypes for earliness and high grain yield. **Plant Methods**, v. 18, n. 1, p. 13, dez. 2022.

SANTANA, D. C. et al. Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. **Remote Sensing Applications: Society and Environment**, v. 29, p. 100919, jan. 2023.

SARKAR, S. et al. Soybean seed composition prediction from standing crops using PlanetScope satellite imagery and machine learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 204, p. 257–274, out. 2023.

SNOUSY, M. B. A. et al. Suite of decision tree-based classification algorithms on cancer gene expression data. **Egyptian Informatics Journal**, v. 12, n. 2, p. 73–82, jul. 2011.

ŠTEPANOVSÝ, M. et al. Novel age estimation model based on development of permanent teeth compared with classical approach and other modern data mining methods. **Forensic Science International**, v. 279, p. 72–82, out. 2017.

WENDT, L. et al. Relação entre testes de vigor com a emergênciaa campo em sementes de soja. **Revista Brasileira de Ciências Agrárias - Brazilian Journal of Agricultural Sciences**, v. 12, n. 2, p. 166–171, 30 mar. 2017.

XIA, Y. et al. Recent advances in emerging techniques for non-destructive detection of seed viability: A review. **Artificial Intelligence in Agriculture**, v. 1, p. 35–47, mar. 2019.

XIAO, J. et al. Enhancing assessment of corn growth performance using unmanned aerial vehicles (UAVs) and deep learning. **Measurement**, v. 214, p. 112764, jun. 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: Marcio Alves Fernandes

ORIENTADOR: Dra. Charline Zaratín Alves

TÍTULO: Predição da germinação de sementes de soja utilizando teste de tetrazólio e inteligência computacional.

AVALIADORES:

Profa. Dra. Charline Zaratín Alves

Profa. Dra. Dthenifer Cordeiro Santana

Prof. Dr. Márcio Dias Pereira

Chapadão do Sul, 03 de maio de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Charline Zaratín Alves, Professora do Magistério Superior**, em 03/05/2024, às 15:26, 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 **Dthenifer Cordeiro Santana, Usuário Externo**, em 03/05/2024, às 15:27, 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 **Márcio Dias Pereira, Usuário Externo**, em 03/05/2024, às 16:43, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4830892** e o código CRC **B177241C**.

COLEGIADO DE PÓS-GRADUAÇÃO EM AGRONOMIA

Rod MS 306, Km 105, Caixa Postal 112

Fone: (67)3562-6351

CEP 79560-000 - Chapadão do Sul - MS

Referência: Processo nº 23455.000149/2024-21

SEI nº 4830892