

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CAMPUS DE CHAPADÃO DO SUL  
CURSO DE BACHARELADO EM AGRONOMIA

IZABELA CRISTINA DE OLIVEIRA

**CLASSIFICAÇÃO DA VIABILIDADE DE SEMENTES DE SOJA COM USO DE  
INTELIGÊNCIA COMPUTACIONAL**

CHAPADÃO DO SUL – MS

2023

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CAMPUS DE CHAPADÃO DO SUL  
CURSO DE BACHARELADO EM AGRONOMIA

IZABELA CRISTINA DE OLIVEIRA

**CLASSIFICAÇÃO DA VIABILIDADE DE SEMENTES DE SOJA COM USO DE  
INTELIGÊNCIA COMPUTACIONAL**

Trabalho de Conclusão de Curso  
apresentado à Universidade Federal de Mato  
Grosso do Sul, como requisito parcial para a  
obtenção do título de Engenheira Agrônoma.

Orientadora: Profa. Dra. Charline Zaratini  
Alves

CHAPADÃO DO SUL – MS

2023



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



### CERTIFICADO DE APROVAÇÃO

AUTORA: **IZABELA CRISTINA DE OLIVEIRA.**

ORIENTADORA: **Profª. Drª. Charline Zaratín Alves.**

Aprovada pela Banca Examinadora como parte das exigências do Componente Curricular Não Disciplinar TCC, para obtenção do grau de BACHARELA EM AGRONOMIA, pelo curso de Bacharelado em Agronomia da Universidade Federal de Mato Grosso do Sul, Câmpus de Chapadão do Sul.

**Profª. Drª. Charline Zaratín Alves**  
Presidente da Banca Examinadora e Orientadora

**Profª. Drª. Larissa Pereira Ribeiro Teodoro**  
Membro da Banca Examinadora

**Engª. Agrª. Ma. Dthenifer Cordeiro Santana**  
Membro da Banca Examinadora

Chapadão do Sul, 1º de junho de 2023.



Documento assinado eletronicamente por **Charline Zaratín Alves, Professora do Magistério Superior**, em 01/06/2023, às 10:55, 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](#).



Documento assinado eletronicamente por **Larissa Pereira Ribeiro, Professora do Magistério Superior**, em 01/06/2023, às 10:57, 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](#).



Documento assinado eletronicamente por **Dthenifer Cordeiro Santana, Usuário Externo**, em 01/06/2023, às 14:12, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufms.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4106569** e o código CRC **E290A769**.

#### COORDENAÇÃO DE GESTÃO ACADÊMICA DO CÂMPUS DE CHAPADÃO DO SUL

Câmpus de Chapadão do Sul - Rod MS 306, Km 105, Caixa Postal 112

Fone:

CEP 79560-000 - Chapadão do Sul - MS

## DEDICATÓRIA

*Dedico este trabalho às minhas irmãs,  
Ana Paula e Gabriela.*

## AGRADECIMENTOS

À Deus pela coragem de correr atrás dos meus sonhos e por responder as minhas orações não com o que eu quero, mas com o que é melhor para minha vida.

As minhas irmãs Ana Paula de Oliveira e Gabriela Fabricia de Oliveira, e minha avó Anita Jardim de Oliveira, pelo apoio, carinho e amor, independente da distância.

As minhas amigas Dthenifer Cordeiro Santana, Larissa Cardoso Dalbosco e Silvia Elena Navarrete Thomé. E meus amigos da república Amazonas (João Lucas, Gustavo Casadei, Juliano, Yann, Luis Gustavo e Felipe) e do GEMP (Elber, Paulo, Murilo, Guilherme, Gustavo Casalino). Me lembro de orar pedindo a Deus por boas amizades e hoje, não imagino minha vida sem vocês.

A Universidade Federal do Mato Grosso do Sul e Laboratório de Produção e Tecnologia de Sementes, pela formação e crescimento acadêmico e profissional.

A todos os professores que compartilharam seus conhecimentos, mas especialmente, Ana Carina Silva Cândido, Charline Zaratín Alves, Larissa Pereira Ribeiro Teodoro e Paulo Eduardo Teodoro, por ensinar muito mais que os conteúdos disciplinares. Vocês sempre serão lembrados com carinho.

A prof<sup>ª</sup>. Dra. Larissa Pereira Ribeiro Teodoro e a Ma. Dthenifer Cordeiro Santana pelo aceite em participar da minha banca e contribuir para a melhoria deste trabalho.

A todas aquelas pessoas que mesmo não citadas, contribuíram para minha formação.

## EPÍGRAFE

*“Para o homem é impossível, mas para  
Deus, todas as coisas são possíveis”*

*Mateus 19:26*

**SUMÁRIO**

|                              |    |
|------------------------------|----|
| RESUMO .....                 | 8  |
| ABSTRACT .....               | 9  |
| INTRODUÇÃO.....              | 10 |
| MATERIAL E MÉTODOS.....      | 11 |
| RESULTADOS E DISCUSSÃO ..... | 14 |
| CONCLUSÃO.....               | 21 |
| REFERÊNCIAS .....            | 21 |

## CLASSIFICAÇÃO DA VIABILIDADE DE SEMENTES DE SOJA COM USO DE INTELIGENCIA COMPUTACIONAL

**RESUMO:** A classificação de lotes de sementes de soja possibilita a obtenção de informações sobre qual lote de sementes apresenta maior potencial de germinar e gerar plântulas normais rapidamente em condições ambientais adversas. A utilização de ferramentas como inteligência computacional contribuem para a diferenciação de lotes de sementes de soja de forma rápida, precisa e acurada. Assim, a hipótese deste trabalho se baseia na possibilidade de classificar sementes de soja oriundas de quatro anos de análise em relação a qualidade fisiológica apresentada. Diante disso, o objetivo deste trabalho é avaliar a classificação da viabilidade de sementes de soja através de inteligência computacional. Os dados utilizados para aprendizagem de máquina foram obtidos no Laboratório de Produção e Tecnologia de Sementes da Universidade Federal de Mato Grosso Do Sul – CPCS/UFMS, por meio do levantamento dos resultados de quatro anos de análises de sementes de soja. Os resultados se encontravam em fichas, contendo informações sobre a primeira contagem de germinação (PCG), germinação, tetrazólio vigor (vigor) e tetrazólio viabilidade (viabilidade). Após a obtenção dos dados referentes as análises realizadas em sementes, estes foram tabelados e submetidos a análises estatísticas. Os dados foram submetidos à análise de componentes principais (PCA) associada ao algoritmo k-means, formando quatro clusters. Posteriormente os dados foram submetidos as análises de aprendizagem de máquina, onde os clusters formados foram utilizados como variáveis de saída (output) e as análises realizadas para avaliar a qualidade fisiológica de sementes de soja foram utilizadas como entrada (input). O desempenho dos modelos de classificação utilizados foi avaliado pelas métricas de porcentagem de classificações corretas (CC), Kappa e F-score. De acordo com o agrupamento, foram utilizados boxplots com as médias dos modelos de acurácia, com médias comparadas pelo teste de Scott-Knott a 5% de significância. A classificação da qualidade de sementes de soja ao longo de quatro anos de avaliação foi realizada de forma eficiente pelos algoritmos RL, RNA e SVM. Tais algoritmos obtiveram métricas de acurácia acima de 70%.

**Palavras-chave:** *Glycine max*. Regressão linear. Redes neurais artificiais. Sementes. Máquina de vetor suporte.



## VIABILITY CLASSIFICATION OF SOYBEAN SEEDS USING COMPUTATIONAL INTELLIGENCE

**ABSTRACT:** The classification of soybean seed lots makes it possible to obtain information about which seed lot has the greatest potential to germinate and quickly generate normal seedlings under adverse environmental conditions. The use of tools such as computational intelligence contributes to the differentiation of soybean seed lots quickly, precisely and accurately. Thus, the hypothesis of this work is based on the possibility of classifying soybean seeds from four years of analysis in relation to the physiological quality presented. Therefore, the objective of this work is to evaluate the viability classification of soybean seeds through computational intelligence. The data used for machine learning were obtained at the Seed Production and Technology Laboratory at the Federal University of Mato Grosso Do Sul – CPCS/UFMS, through a survey of the results of four years of soybean seed analysis. The results were on cards, containing information about the first germination count (PCG), germination, tetrazolium vigor (vigor) and tetrazolium viability (viability). After obtaining the data referring to the analyzes carried out in seeds, these were tabulated and submitted to statistical analysis. The data were subjected to principal component analysis (PCA) associated with the k-means algorithm, forming four clusters. Subsequently, the data were submitted to machine learning analysis, where the formed clusters were used as output variables and the analyzes carried out to evaluate the physiological quality of soybean seeds were used as input (input). The performance of the classification models used was evaluated by the percentage of correct classifications (CC), Kappa and F-score metrics. According to the grouping, boxplots were used with the means of the accuracy models, with means compared by the Scott-Knott test at 5% significance. The classification of soybean seed quality over four years of evaluation was performed efficiently by the RL, RNA and SVM algorithms. Such algorithms obtained accuracy metrics above 70%.

**Keywords:** *Glycine max.* Linear regression. Artificial neural networks. Seeds. Support vector machine.

## INTRODUÇÃO

A soja (*Glycine max* (L.) Merrill) apresenta importância mundial por sua utilização como fonte de nutrientes, decorrente de sua constituição proteica (SHI et al., 2022). A cultura é propagada por sementes, que são as responsáveis pela expansão da cultura e produtividade alcançada (CHEN et al., 2022).

A qualidade das sementes é resultado da interação entre seus atributos fisiológicos, sanitários, físicos e genéticos (MENEGUZZO et al., 2021). A mensuração dessas características é realizada através de testes, que são responsáveis por evidenciar o potencial das sementes em germinar e gerar plântulas normais rapidamente (MARCOS FILHO, 2015).

Os testes de germinação e tetrazólio são alguns dos testes utilizados para analisar a qualidade de sementes de soja. A germinação é uma etapa crítica para o estabelecimento, crescimento e desenvolvimento das plantas a campo, enquanto o teste de tetrazólio refere-se ao comportamento das sementes em condições desfavoráveis (MANGUENA, 2021; MARCOS FILHO, 2015).

Os avanços tecnológicos dos últimos anos possibilitam maior rapidez na tomada de decisão sobre lotes de sementes, pela utilização de técnicas de inteligência computacional como aprendizagem de máquina para processamento dos dados (SANTANA et al., 2022). A classificação é uma das funcionalidades dos algoritmos de aprendizagem de máquina, em que o algoritmo aprende um modelo de classificação em determinado conjunto de dados (KARAKATIC; PODGORELEC, 2016). A aprendizagem de máquina de cada algoritmo apresenta um desempenho distinto em cada conjunto de dados testado, sendo necessário testar diferentes algoritmo para apontar o melhor classificador (SANTANA et al., 2023). Nos estudos de classificação nas ciências agrárias, os algoritmos Redes Neurais Artificiais (RNA), Árvores, Floresta Aleatória

(FA) e Máquina de Vetor Suporte (MVS) tem sido os mais utilizados na discriminação de cultivares (Silva Júnior et al., 2017), na previsão da produtividade (Silva et al., 2020), no monitoramento do estado nutricional das plantas (Santana et al., 2021), e na seleção de genótipos com características de interesse (Andrade et al., 2021).

A classificação por meio de algoritmos apresenta maior tendência a acurácia quando se aumenta o tamanho do conjunto de dados. Logo, a hipótese deste trabalho se baseia na possibilidade de classificar sementes de soja oriundas de quatro anos de análise em relação à qualidade fisiológica. Assim, o objetivo deste trabalho é avaliar a acurácia de classificação da viabilidade de sementes de soja através de inteligência computacional.

## **MATERIAL E MÉTODOS**

### **Obtenção dos dados**

Os dados utilizados para aprendizagem de máquina foram obtidos no Laboratório de Produção e Tecnologia de Sementes da Universidade Federal de Mato Grosso Do Sul, localizado no município de Chapadão do Sul, Mato Grosso do Sul, Brasil, por meio do levantamento dos resultados de quatro anos de análises de sementes de soja, totalizando 350 amostras. Os resultados se encontravam em fichas, contendo informações sobre a primeira contagem de germinação (PCG), germinação, tetrazólio vigor (vigor) e tetrazólio viabilidade (viabilidade).

### **Análises de Sementes**

As análises realizadas nas sementes de soja apresentavam delineamento inteiramente casualizado, com quatro repetições por amostra de sementes. Inicialmente as sementes foram submetidas ao teste de umidade e, na ocasião de umidade adequada, prosseguia-se com a realização dos testes de PCG, germinação, vigor e viabilidade.

A germinação foi analisada com a distribuição de 50 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 após a montagem do teste, com resultados expressos em porcentagem de plântulas normais. A primeira contagem de germinação (PCG) foi realizada juntamente com o teste de germinação, computando-se a contagem de plântulas normais aos cinco dias após a realização do teste, sendo os 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, permanecendo no germinador a 25 °C por 24 horas. Após esse período, as sementes foram embebidas em solução 2,3,5-cloreto de trigeniltetrazólio e acondicionadas em B.O.D. no escuro, à temperatura de 40 °C durante três horas. Posteriormente as sementes foram avaliadas e classificadas individualmente em vigorosas (vigor) e viáveis (viabilidade), de acordo com metodologia proposta por França Neto (1998).

### **Análises Estatísticas e Modelos de Aprendizagem de Máquina**

Após a obtenção dos dados referentes às análises realizadas em sementes, estes foram tabelados e submetidos a análises estatísticas. Na divisão das sementes, os dados foram submetidos à análise de componentes principais (PCA) associada ao algoritmo k-means. Foram gerados quatro clusters e um biplot foi construído com os dois primeiros componentes principais devido à fácil interpretação desses resultados. Neste biplot, quatro clusters (C1, C2, C3 e C4) foram definidos com base no desempenho das sementes de acordo com as análises realizadas. O uso do algoritmo k-means agrupa tratamentos

cujos centróides estão mais próximos até que não haja variação significativa em a distância mínima de cada observação a cada um dos centróides.

Posteriormente os dados foram submetidos às análises de aprendizagem de máquina, utilizando Regressão Linear (RL) como controle (Tabela 2), no qual os clusters formados foram utilizados como variáveis de saída (output) dos modelos, enquanto as análises realizadas para avaliar as sementes em relação a PCG, germinação, vigor e viabilidade foram utilizadas como entrada dos modelos. A classificação dos clusters foi realizada por meio de validação cruzada estratificada 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, com exceção das Redes neurais artificiais, as quais foi determinada a utilização de duas camadas com 10 neurônios em cada.

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

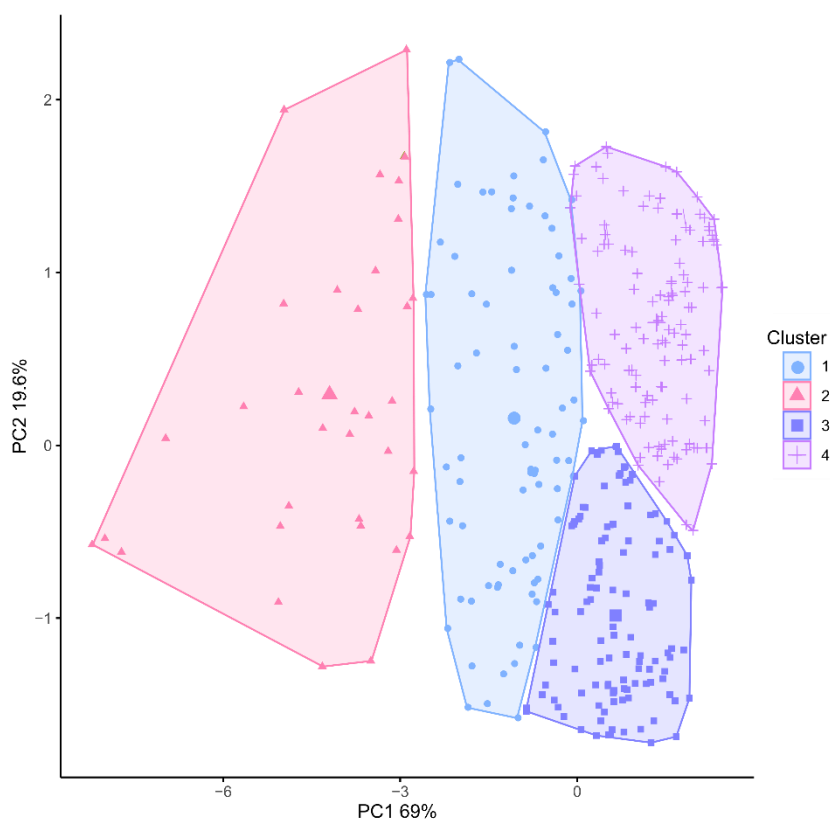
| Sigla | Modelo de aprendizagem de máquinas | Referência                     |
|-------|------------------------------------|--------------------------------|
| ANN   | Redes neurais artificiais          | (Egmont-Petersen et al., 2002) |
| J48   | Árvore de decisão J48              | (Quinlan, 1993)                |
| RL    | Regressão logística                | (Štepanovský et al., 2017)     |
| DT    | Árvore de Decisão                  | (Snousy et al., 2011)          |
| RF    | Floresta aleatória                 | (Belgiu & Drăguț, 2016)        |
| SVM   | Máquina de vetor suporte           | (Nalepa & Kawulok, 2019)       |

Nas avaliações quanto ao desempenho dos modelos de classificação utilizados foram usadas as métricas de porcentagem de classificações corretas (CC), Kappa e F-score. Na ilustração do desempenho dos modelos de aprendizagem de máquina foram utilizados boxplots com as médias de acurácia dos modelo, segundo o agrupamento de médias do teste de Scott-Knott a 5% de significância. O agrupamento de médias foi

realizado como o auxílio do software R e os boxplots foram gerados utilizando os pacotes ggplot2 e ExpDes.pt, também do software R.

## RESULTADOS E DISCUSSÃO

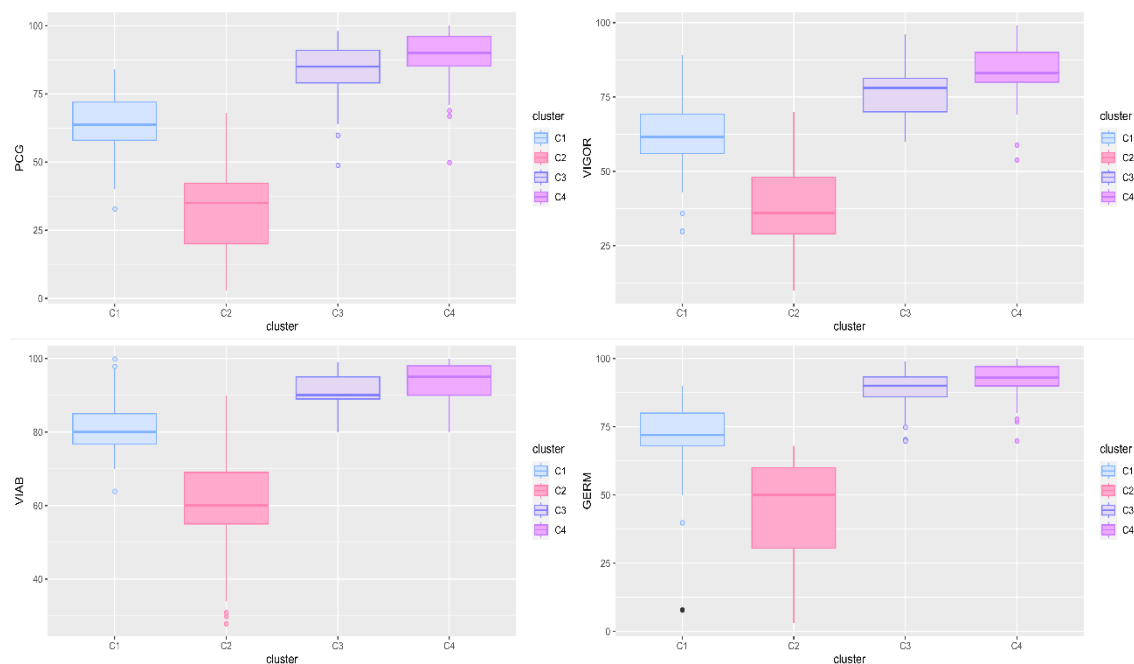
As amostras de sementes avaliadas ao longo de quatro anos foram separadas em quatro clusters de acordo com o vigor e viabilidade que apresentavam (Figura 1). Para a formação desses clusters foi utilizado o algoritmo k-means e plotado em um gráfico de componentes principais permitindo a fácil visualização desses grupos.



**Figura 1.** Análise de Componentes Principais (PCA) para os clusters formados pelo algoritmo k-means de acordo com as variáveis primeira contagem de germinação, vigor, viabilidade e germinação de sementes de soja.

O algoritmo k-means forma grupos que apresentam similaridade entre si e distinção entre os demais clusters. Assim, a divisão dos cluster evidencia a existência de sementes de quatro classes distintas em relação a germinação, viabilidade e vigor das sementes. A divergência entre os lotes de sementes pode ser resultado da qualidade fisiológica na qual se encontravam antes da realização dos testes, uma vez que condições desfavoráveis durante a colheita e armazenamento não são reversíveis e se refletem nos testes de germinação e tetrazólio (XIA et al., 2019; REED et al., 2022).

A Figura 2 apresenta os boxplots representativos de cada cluster formado em relação as variáveis de sementes analisadas. Os clusters 3 e 4 apresentaram superioridades nas médias de primeira contagem de germinação (PCG), vigor, viabilidade e germinação (GERM), contendo também pouca variabilidade dentro desses grupos. O cluster 2 foi o que apresentou menor média para as variáveis de sementes avaliadas e maior variabilidade.




**Figura 2.** Boxplot com as médias dos cluster formados para as variáveis: primeira contagem de germinação (PCG), vigor, viabilidade e germinação (GERM).

A germinação e a viabilidade avaliam as sementes de acordo com sua possibilidade de germinar quando suas exigências são atendidas, avaliando a emissão da raiz mesmo em condições que retardam a germinação (REED et al., 2022). Porém, sementes que não alcançam valor mínimo de 80% de germinação, são comercializadas como grãos, uma vez que a utilização de sementes com alta qualidade fisiológica é um dos pilares para a construção de altas produtividades da cultura (LUDWIG et al., 2021).

Havendo a separação dos clusters quanto a vigor e viabilidades de sementes de soja, os dados foram submetidos a classificação por meio de algoritmos de aprendizagem de máquina. Os dados de qualidade de sementes foram utilizados como informações de entrada (input) dos modelos e as amostras pertencentes a cada cluster formado como informação de saída (output). E na avaliação de acurácia das classificações de cada algoritmo métricas como classificação correta, Kappa e F-score foram utilizadas na avaliação do desempenho dos algoritmos.

Os algoritmos RL, RNA e SVM apresentaram melhor desempenho para a métrica de acurácia classificação correta, alcançando valores de acerto por volta de 70-75% (Figura 3). O pior desempenho foi observado para DT e J48, não conseguindo boas métricas de classificação dos cluster.






**Figura 3.** Boxplot para porcentagem de classificação correta (CC) para a interação significativa dos modelos de aprendizado de máquinas.

As médias seguidas pelas mesmas letras não diferem entre pelo teste de Scott-Knott a 5% de probabilidade.


Os algoritmos RL, RNA e SVM também apresentaram a melhor métrica para o coeficiente de Kappa, mantendo bom índice de acerto para classificação dos clusters (Figura 4). Os algoritmos DT e J48 também apresentaram a pior performance para essa métrica de acurácia.



**Figura 4.** Boxplot para Kappa correta para a interação significativa dos modelos de aprendizado de máquinas.

As médias seguidas pelas mesmas letras não diferem entre pelo teste de Scott-Knott a 5% de probabilidade.

Os algoritmos RL, RNA e SVM permaneceram sendo superior aos demais quando analisado pela métrica F-score (Figura 5). E assim como nas métricas anteriores, os algoritmos DT e J48 tiveram a pior performance.



**Figura 5.** Boxplot para F-score correta para a interação significativa dos modelos de aprendizado de máquinas.

As médias seguidas pelas mesmas letras não diferem entre pelo teste de Scott-Knott a 5% de probabilidade.

Os parâmetros classificação correta (CC), coeficiente kappa e f-score são métricas utilizadas para avaliar os algoritmos de aprendizagem de máquina, apresentando resultados semelhantes, onde RL, RNA e SVM foram os algoritmos que apresentaram os melhores resultados.

O algoritmo RNA é um tipo de aprendizagem rasa, que permite maior capacidade de aprendizado e, conseqüentemente, maior precisão na classificação de forma rápida e precisa (KAMILARIS et al., 2018). Isso porque a inteligência computacional utiliza sua capacidade de aprender sobre os dados disponibilizados para fornecer soluções através da

arquitetura observada nos dados e assim, aprimorando a aprendizagem durante as atividades (ALSHEIKH et al., 2014).

O algoritmo SVM por sua vez, apresenta-se como uma boa opção devido aos poucos parâmetros de ajuste necessários, velocidade de cálculos e aplicabilidade para diversos tamanhos de amostra (HUANG et al., 2022). Além disso, apresenta alta precisão, tolerância ao tamanho da amostra e aumento da precisão conforme aumenta-se o tamanho da amostra (KOK et al., 2021).

Em trabalho realizado por Santana et al. (2023), os autores avaliaram a classificação de genótipos de soja em relação a características industriais a partir de imagens multiespectrais e aprendizagem de máquina, e obtiveram resultados semelhantes ao encontrado neste trabalho, onde SVM e RNA alcançaram as maiores acurácias de classificação. Em suma, a classificação da qualidade de sementes de soja ao longo de quatro anos de avaliação foi eficientemente classificada pelos algoritmos RL, RNA e SVM. Tais algoritmos obtiveram bons valores para as métricas de acurácia testadas.

Os resultados obtidos neste trabalho demonstram a possibilidade de diferenciar lotes de sementes de forma rápida e acurada utilizando técnicas de inteligência computacional. A possibilidade de utilizar aprendizagem de máquina para avaliar o desempenho de diferentes lotes de sementes é promissor por diminuir o tempo necessário na realização de análises para decidir qual o melhor lote a ser semeado. Dessa forma, perspectivas futuras se baseiam na possibilidade de utilizar técnicas que contribuam para a maior rapidez na avaliação de sementes, diminuindo o tempo de análise e melhorando a precisão a acurária na tomada de decisão sobre os melhores lotes de sementes.

## CONCLUSÕES

As sementes de soja podem ser classificadas através de sua qualidade pelos algoritmos RL, RNA e SVM.

Os algoritmos RL, RNA e SVM apresentaram métricas de acurácia acima de 70% e, portanto, podem ser utilizados para classificar acuradamente grupos de sementes com diferentes qualidades fisiológicas.

## REFERÊNCIAS

ALSHEIKH, M. A. et al. Aprendizado de máquina em redes de sensores sem fio: algoritmos, estratégias e aplicações. **IEEE Communications Surveys & Tutorials**, v. 16, n. 4, p. 1996-2018, 2014.

ANDRADE, S. M. et al. 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.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Regras para Análise de Sementes**. 2009.

CHEN, Z. et al. Soybean seed counting and broken seed recognition based on image sequence of falling seeds. **Computers and Electronics in Agriculture**, v. 196, e106870, 2022.

CONAB. Companhia Nacional de Abastecimento. **Aumento de 20.6% na produção de soja impulsiona safra de grãos, estimada em 309,9 milhões de toneladas**. 2023. Disponível em: < <https://www.conab.gov.br/ultimas-noticias/4937-aumento-de-20-6-na-producao-de-soja-impulsiona-safra-de-graos-estimada-em-309-9-milhoes-de-t>>. Acesso em: 24 mai. 2023.

FRANÇA NETO, J. B.; K. F. C.; C. N. P. **O teste de tetrazólio em sementes de soja**: Vol. Documentos, 116. 1998.

KAMILARIS, A. et al. Aprendizagem profunda na agricultura: uma pesquisa. **Informática e eletrônica na agricultura**, v. 147, p. 70-90, 2018.

KARAKATIČ, S.; PODGORELEC, V. Improved classification with allocation method and multiple classifiers. **Information Fusion**, v. 31, p. 26–42, 2016.

LUDWIG, V. et al. Impact of controlled atmosphere storage on physiological quality of soybean seed. **Journal of Stored Products Research**, v. 90, e101749, 2021.

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

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

MENEGUZZO, M. R. R. et al. Seedling length and soybean seed vigor. **Ciência Rural**, v. 51, 2021.

REED, R. C. et al. Seed germination and vigor: ensuring crop sustainability in a changing climate. **Heredity**, v. 128, n. 6, p. 450–459, 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. 18, e100919, 2023.

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

SANTANA, D. C. et al. UAV-based multispectral sensor to measure variations in corn as a function of nitrogen topdressing. **Remote Sensing Applications: Society and Environment**, v. 23, p. 100534, 2021.

SHI, M. et al. Linkage and association mapping of wild soybean (*Glycine max*) seeds germinating under salt stress. **Journal of Integrative Agriculture**, v. 21, n. 10, p. 2833–2847, 2022.

SILVA JUNIOR, C. A. et al. Vegetation Indices for Discrimination of Soybean Areas: A New Approach. **Agronomy Journal**, v. 109, n. 4, p. 1331–1343, 2017.

SILVA, E. E. et al. UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation. **Remote Sensing Applications: Society and Environment**, v. 18, p. 100318, 2020.

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, 2019.