

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

FRANCISCO AILTON RODRIGUES FERREIRA

**DADOS HIPERSPECTRAIS E APRENDIZADO DE MÁQUINA NA
AVALIAÇÃO DO CRESCIMENTO E QUALIDADE DE MUDAS DE
EUCALIPTO**

CHAPADÃO DO SUL – MS

2024

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

FRANCISCO AILTON RODRIGUES FERREIRA

**DADOS HIPERSPECTRAIS E APRENDIZADO DE MÁQUINA NA
AVALIAÇÃO DO CRESCIMENTO E QUALIDADE DE MUDAS DE
EUCALIPTO**

Orientador: Prof. Dr. Gileno Brito de Azevedo
Coorientadora: Dra. Dthenifer Cordeiro Santana

Dissertação 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



PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

CERTIFICADO DE APROVAÇÃO

DISCENTE: Francisco Ailton Rodrigues Ferreira

ORIENTADOR: Dr. Gileno Brito de Azevedo

TÍTULO: Dados hiperspectrais e aprendizado de máquina na avaliação do crescimento e qualidade de mudas de eucalipto.

AVALIADORES:

Prof. Dr. Gileno Brito de Azevedo

Prof. Dr. Paulo Eduardo Teodoro

Prof. Dra. Glauce Tais de Oliveira Sousa Azevedo

Chapadão do Sul, 05 de dezembro de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Gileno Brito de Azevedo, Professor do Magisterio Superior**, em 05/12/2024, às 15:06, 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 **Glauce Tais de Oliveira Sousa Azevedo, Professora do Magistério Superior**, em 05/12/2024, às 15:08, 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 **Paulo Eduardo Teodoro, Professor do Magisterio Superior**, em 05/12/2024, às 15:17, 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 **5294266** e o código CRC **1D300582**.

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

AGRADECIMENTOS

Agradeço primeiramente a Deus pela vida, e pela oportunidade que me deu em realizar um curso de pós-graduação.

Em agradecimentos ao meu paciente Orientador: Prof. Dr. Gileno Brito de Azevedo, sua esposa Prof. Dra. Glauce Azevedo e a minha coorientadora Dra. Dthenifer Cordeiro Santana.

SUMÁRIO

RESUMO	04
INTRODUÇÃO.....	06
MATERIAL E MÉTODOS	07
RESULTADOS	10
DISCUSSÃO.....	13
CONCLUSÕES.....	14
REFERÊNCIA.....	14

DADOS HIPERSPECTRAIS E APRENDIZADO DE MÁQUINA NA AVALIAÇÃO DO CRESCIMENTO E QUALIDADE DE MUDAS DE EUCALIPTO

RESUMO: A combinação de aprendizado de máquina com dados hiperespectrais pode apresentar um avanço significativo na obtenção das variáveis morfológicas e de qualidade das mudas florestais, o que representa uma abordagem inovadora e eficiente, superando as limitações dos métodos tradicionais. Portanto, o objetivo deste estudo foi avaliar a eficácia dos algoritmos de aprendizado de máquina associado a dados hiperespectrais na predição de variáveis morfológicas e a qualidade das mudas de *Eucalyptus deglupta* Blume. Em 90 mudas foram mensuradas: variáveis espectrais (350 a 2500 nm), com auxílio do sensor hiperespectral espectrorradiômetro; e variáveis morfológicas como altura, diâmetro, massas secas e relações entre essas variáveis. Para estimar as variáveis morfológicas foram treinados algoritmos de aprendizado de máquina: redes neurais artificiais (ANN), árvore de decisão (DT), regressão linear (LR), algoritmo M5P e floresta aleatória (RF). No treinamento foram avaliados duas combinações de *inputs*: toda faixa espectral fornecida pelo sensor (WL) e agrupado em 24 bandas espectrais (SB). Foi adotado o procedimento de validação cruzada, com *k-fold* igual a 10. Nas avaliações do desempenho dos algoritmos de predição testados foram utilizadas as métricas de coeficiente de correlação, erro absoluto médio e raiz quadrada do erro médio. A combinação de algoritmos de aprendizado de máquina com dados hiperespectrais se mostrou eficiente para a predição de variáveis morfológicas e de qualidade de mudas de *Eucalyptus deglupta*. O desempenho dos algoritmos de aprendizado de máquina depende do *input* utilizado e vice-versa. O algoritmo SVM, utilizando como *input* WL como variáveis de entrada, foi o mais eficiente na predição das variáveis.

Palavras-chave: *Eucalyptus deglupta*, Inteligência artificial, Sensoriamento remoto, Silvicultura, Viveiros florestais

HYPERSPECTRAL DATA AND MACHINE LEARNING IN THE EVALUATION OF GROWTH AND QUALITY OF EUCALYPTUS SEEDLINGS

ABSTRACT: The combination of machine learning with hyperspectral data can represent a significant advancement in obtaining morphological and quality variables of forest seedlings, providing an innovative and efficient approach that surpasses the limitations of traditional methods. Therefore, the objective of this study was to evaluate the effectiveness of machine learning algorithms combined with hyperspectral data in predicting morphological variables and the quality of *Eucalyptus deglupta* Blume seedlings. In 90 seedlings, the following were measured: spectral variables (350 to 2500 nm), using a hyperspectral spectroradiometer sensor; and morphological variables such as height, diameter, dry masses, and relationships between these variables. To estimate the morphological variables, machine learning algorithms were trained: artificial neural networks (ANN), decision tree (DT), linear regression (LR), M5P algorithm, and random forest (RF). Two input combinations were evaluated in the training: the entire spectral range provided by the sensor (WL) and grouped into 24 spectral bands (SB). A cross-validation procedure was adopted, with k-fold equal to 10. To assess the performance of the tested prediction algorithms, metrics such as correlation coefficient, mean absolute error, and root mean square error were used. The combination of machine learning algorithms with hyperspectral data proved to be efficient in predicting morphological variables and the quality of *Eucalyptus deglupta* seedlings. The performance of machine learning algorithms depends on the input used and vice-versa. The SVM algorithm, using WL as input variables, was the most efficient in predicting the variables.

Keywords: *Eucalyptus deglupta*, Artificial intelligence, Remote sensing, Silviculture, Forest nurseries

INTRODUÇÃO

O eucalipto é uma das espécies florestais mais cultivadas no mundo, conhecida por seu rápido crescimento e ampla aplicação em vários setores, como papel, celulose, energia, entre outros (Gonçalves *et al.*, 2013). Para garantir o sucesso do cultivo, é essencial o plantio de mudas com crescimento vigoroso e qualidade satisfatória. Durante o processo produtivo, o manejo adotado no viveiro pode influenciar no crescimento e qualidade final das mudas.

Tradicionalmente, a avaliação da qualidade das mudas é realizada com base em características morfológicas, como altura, diâmetro do coleto e biomassa (Gomes *et al.*, 2002; Neres *et al.*, 2019; Lima *et al.*, 2023). No entanto, a obtenção dessas variáveis demanda tempo, mão de obra especializada e, em muitos casos, a utilização de técnicas invasivas ou destrutivas, como a análise do sistema radicular, que pode comprometer o crescimento das mudas ou até inviabilizar seu plantio posterior. Assim, a implementação de técnicas que permitam uma avaliação rápida, precisa e não destrutiva é essencial para otimizar o manejo e tomada de decisão nos viveiros florestais.

Nesse contexto, sensores hiperespectrais destacam-se como uma ferramenta poderosa para identificar características biofísicas e fisiológicas das plantas (Silva Junior *et al.*, 2018; Strabelli *et al.*, 2020; 2023; Santana *et al.*, 2023 a; Silva *et al.*, 2024). A análise hiperespectral baseia-se na capacidade de registrar informações detalhadas da refletância em diversas faixas do espectro eletromagnético, capturando a "assinatura espectral" de cada planta (Silva Junior *et al.*, 2018; Silva *et al.*, 2024). Essa tecnologia permite uma caracterização precisa das mudas sem a necessidade de métodos destrutivos.

Paralelamente, o aprendizado de máquina tem revolucionado o processamento de grandes volumes de dados, incluindo aplicações diversas no setor florestal (Oliveira *et al.*, 2021; Gregori *et al.*, 2023; Lacerda *et al.*, 2023; Santana *et al.*, 2023; Teodoro *et al.*, 2024). Algoritmos avançados possibilitam a previsão de características, como taxas de crescimento, níveis de biomassa e estado de saúde das plantas, com alto grau de precisão (Oliveira *et al.*, 2021; Gregori *et al.*, 2023; Santana *et al.*, 2023b).

Portanto, a combinação de aprendizado de máquina com dados hiperespectrais pode apresentar um avanço significativo na obtenção das variáveis morfológicas e de qualidade das mudas florestais. Isso representa uma abordagem inovadora e eficiente para essa temática, o que pode superar as limitações dos métodos tradicionais. Sensores hiperespectrais fornecem

dados detalhados sobre cada planta, enquanto os algoritmos de aprendizado de máquina processam essas informações e identificam padrões e fazem previsões de forma automatizada e confiável (Silva Junior *et al.*, 2018).

Embora estudos anteriores já tenham explorado essas tecnologias de forma isolada, a integração de aprendizado de máquina e sensoriamento hiperespectral consiste em uma abordagem inovadora para a avaliação das características morfológicas e de qualidade de mudas nos viveiros florestais, contribuindo para o aprimoramento das práticas adotadas e o sucesso de projetos de reflorestamento em larga escala. Assim, este estudo teve como objetivo avaliar a eficácia dos algoritmos de aprendizado de máquina associado a dados hiperespectrais na predição de variáveis morfológicas e a qualidade das mudas de *Eucalyptus deglupta* Blume.

MATERIAL E MÉTODOS

Condução do experimento

O experimento foi conduzido na Universidade Federal de Mato Grosso do Sul, Câmpus de Chapadão do Sul/MS. De acordo com a classificação climática de Köppen-Geiger, o clima local é do tipo tropical de monção (Am) (Alvares *et al.*, 2013), com precipitação média anual em torno de 1860 mm por ano e temperaturas variando entre 13°C e 28°C. A altitude da área experimental é de cerca de 820 m.

Para a realização do estudo, foram produzidas mudas de *Eucalyptus deglupta* Blume. Para promover uma maior variabilidade das variáveis morfológicas que expressam a qualidade das mudas a serem analisadas, foram produzidas mudas em tubetes plásticos com três capacidades volumétricas: pequeno (55 cm³), médio (110 cm³) e grande (290 cm³). Estas foram avaliadas ao longo do seu processo produtivo: 66, 79 e 94 dias após a semeadura (DAS). As diferentes combinações entre volumes dos tubetes e idades de avaliação resultaram em variações no padrão de qualidade das mudas. Essa variabilidade é fundamental para a obtenção de dados para o treinamento de modelos mais generalistas, capazes de estimar as variáveis morfológicas em mudas com diferentes padrões de qualidade.

As mudas foram produzidas em tubetes preenchidos com o substrato comercial Carolina Soil (turfa + vermiculita), enriquecido com adubação de base NPK 4-14-8, na proporção de 2,25 g para cada litro de substrato, antes do enchimento dos tubetes. As bandejas com os tubetes foram então dispostas em uma bancada suspensa de forma casualizada. A irrigação, por microaspersão automatizada, foi realizada quatro vezes ao dia, nos horários das 7h, 10h, 13h e 16h. A primeira e a quarta irrigações tiveram duração de 10 minutos, enquanto a segunda e a

terceira tiveram duração de 15 minutos, garantindo assim um adequado suprimento de água para as plantas.

Em cada tubete foram semeadas aproximadamente 5 sementes. Aos 39 DAS foi retirado o sombrite e realizado o raleio em cada tubete, selecionando-se a muda mais central e de melhor desempenho para prosseguir no experimento. Após o raleio, semanalmente, foi realizada adubação de cobertura nas mudas, intercalando-se doses de ureia e ureia + cloreto de potássio. As doses foram de 30 gramas de ureia dissolvida em 6 litros de água em uma semana, seguidas por 30 gramas de ureia e 18 gramas de cloreto de potássio (KCl) dissolvidos em 6 litros de água, aplicadas em cada muda na proporção de 10 ml.

Coleta de dados

A medição de variáveis hiperespectrais e morfológicas foi realizada em 10 mudas para cada volume de recipiente e idade, totalizando a avaliação de 30 mudas por idade e 90 mudas para o total do experimento. Para a realização das avaliações, as mudas foram deslocadas até o laboratório de Espectroscopia, onde foram realizadas as leituras hiperespectrais. A leitura hiperespectral ocorreu nas três primeiras folhas totalmente expandidas de cada muda, sendo posteriormente obtida a média espectral. As leituras foram realizadas com auxílio do sensor hiperespectral espectrorradiômetro (FieldSpec 3 Jr, Analytical Spectral Devices, Boulder, CO, EUA), que fornece informações espectrais na faixa de 350 a 2500 nm.

Em seguida, para a obtenção das variáveis morfológicas foram mensuradas a altura da parte aérea (H, em centímetros) e o diâmetro do coleto (D, em milímetros), com auxílio de uma régua graduada e um paquímetro digital, respectivamente. Posteriormente, as raízes das mudas foram lavadas em água para a retirada do substrato e em seguida foram submetidas à secagem em estufa em temperatura de ± 65 °C, pelo período de 72 horas para obtenção das variáveis: massa seca da parte aérea e massa seca da raiz (MSA e MSR, respectivamente, em gramas), com auxílio de balança analítica, com precisão de $\pm 0,001$ gramas. Com base nestas variáveis, foram calculadas a massa seca total ($MST = MSA + MSR$) e o índice de qualidade de Dickson ($IQD = MST/(H/D+MSA/MSR)$) (Dickson *et al.*, 1960).

Análise dos dados

As variáveis morfológicas foram avaliadas quanto a sua normalidade, pelo teste de normalidade de Shapiro-Wilk ($\alpha = 0,05$). A variabilidade dessas variáveis foi analisada por meio de estatística descritiva e representada por boxplots.

As variáveis hiperespectrais foram agrupadas em 24 bandas espectrais, conforme

metodologia adotada por Silva Junior *et al.* (2018). Isso reduz a dimensionalidade e melhora a qualidade dos dados, facilita sua interpretação e otimiza a eficiência computacional, focando em informações mais representativas. A associação entre as variáveis morfológicas e hiperespectrais foi analisada através da correlação de Pearson.

Para avaliar a capacidade de predição das variáveis morfológicas das mudas a partir dos dados hiperespectrais foram gerados dois bancos de dados: o primeiro com toda a informação espectral fornecida pelo sensor, na faixa de 350 a 2500 nm (WL) e o segundo com as 24 bandas espectrais (SB). A partir de cada banco de dados foram treinados diferentes algoritmos de aprendizado de máquina com o objetivo de verificar quais deles apresentam maior acurácia para a predição das variáveis morfológicas nas mudas de *Eucalyptus deglupta* em diferentes épocas de avaliação e produzidas em diferentes volumes de recipientes. Os algoritmos testados foram: redes neurais artificiais (ANN), árvore de decisão (DT), regressão linear (LR), algoritmo M5P e floresta aleatória (RF), algoritmos esses também utilizados por Teodoro *et al.* (2023) e Santana *et al.* (2023).

Todos os algoritmos treinados estão disponíveis no software Waikato Environment for Knowledge Analysis (WEKA), versão 3.8.6 (Frank; Hall; Witten, 2016). Foi adotado o procedimento de validação cruzada, com *k-fold* igual a 10. Na validação cruzada de *k-fold*, os dados de entrada foram divididos em subconjuntos de dados chamados de *k-folds*. Cada modelo foi treinado em todos os *folds*, exceto um ($k-1$), e a avaliação do mesmo foi realizada no conjunto de dados não utilizado no treinamento, totalizando 10 repetições aleatórias para cada modelo. Os hiperparâmetros dos algoritmos foram configurados conforme *default* do Weka, exceto para a RNA, que foi utilizado 10 neurônios na primeira e 10 na segunda camada.

Nas avaliações do desempenho dos algoritmos de predição testados foram utilizadas as métricas de coeficiente de correlação (r), erro absoluto médio (MAE), raiz quadrada do erro médio (RMSE). Para verificar a significância dos *inputs*, dos algoritmos testados e a interação entre ambos, foi realizado uma análise de variância, considerando os tratamentos em esquema fatorial 5x2 (cinco algoritmos x dois *inputs*), com delineamento inteiramente casualizado e dez repetições (*k-folds*). Havendo a presença da significância, foram gerados boxplots com as médias de r , MAE e RMSE, agrupados pelo teste de Scott-Knott (Scott; Knott, 1974) ao nível de 5% de probabilidade. O agrupamento das médias e os boxplots foram gerados usando os pacotes *ggplot2* e *ExpDes.pt* do *software* R (R Core Team, 2023).

RESULTADOS

As variáveis morfológicas das mudas de *Eucalyptus deglupta*, de acordo o teste de normalidade de Shapiro-Wilk, não apresentam distribuição normal ($p\text{-valor} < 0,0001$). As mesmas apresentaram ampla variabilidade e as distribuições revelaram a predominância de valores centrais, porém com a presença de outliers, especialmente em valores superiores, o que sugere assimetria positiva (Figura 1). Esse comportamento indica a ocorrência de indivíduos com crescimento e acúmulo de biomassa diferenciados e acima do padrão predominante.

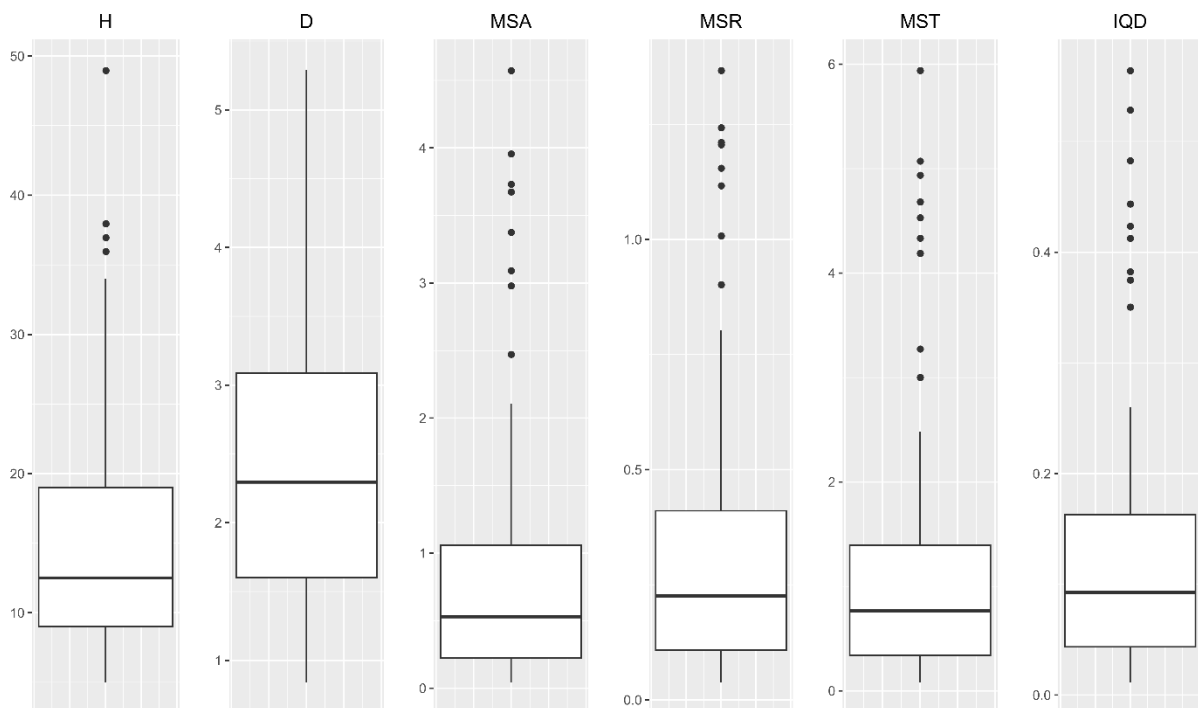


Figura 1. Variabilidade das variáveis morfológicas de mudas de *Eucalyptus deglupta*. Em que: H = altura (cm); D = diâmetro do coleto (mm); MSA = massa seca da parte aérea (g); MSR = massa seca das raízes (g); MST = massa seca total (g); IQD = índice de qualidade de dickson (IQD).

Todas variáveis morfológicas das mudas apresentaram forte correlação negativa com as bandas espectrais (Figura 2), o que mostra uma forte associação entre esses conjuntos de variáveis. Por outro lado, as variáveis morfológicas apresentam correlação positiva entre si e as bandas espectrais também apresentam correlação positiva entre si.

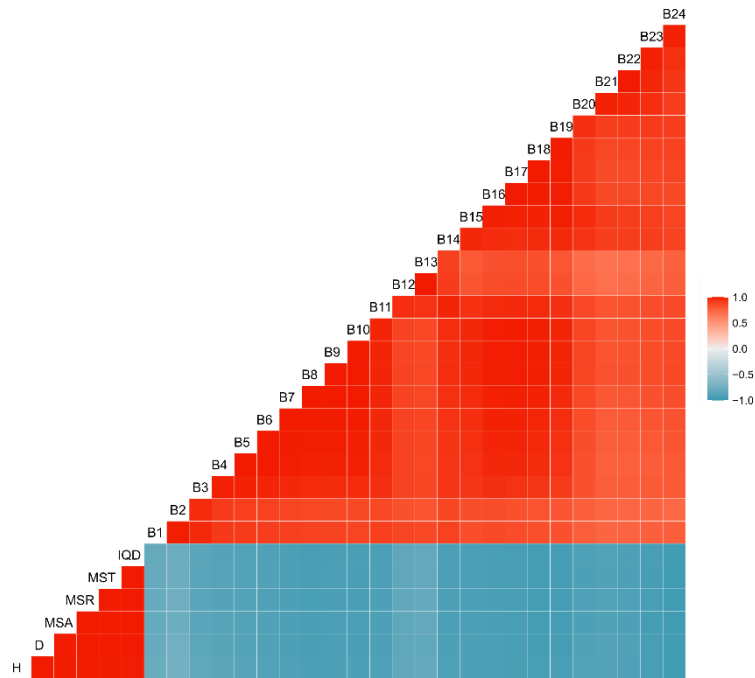


Figura 2. Correlação de Pearson para as variáveis altura (H, cm), diâmetro do coleto (D, mm), massa seca da parte aérea (MSA, g), massa seca do sistema radicular (MSR, g), massa seca total (MST, g), índice de qualidade de dickson (IQD) e as 24 bandas espectrais das mudas de eucalipto (B1 a B24).

O desempenho das estimativas das variáveis morfológicas das mudas foi influenciado pelos algoritmos e *inputs* analisados (Figura 3). De forma geral, as métricas de precisão mais desejáveis (maior valor de r e menores valores de MAE e RMSE) apresentaram comportamento semelhante para todas as variáveis morfológicas.

A utilização das bandas espectrais como *inputs* dos algoritmos (SB) para estimativa das variáveis morfológicas proporcionaram o maior valor de r para o algoritmo de RNA, os menores valores de MAE para os algoritmos RF e SVM e os menores valores de RMSE para os algoritmos M5P, RF, RNA e SVM. Já quando as variáveis morfológicas foram estimadas utilizando toda a faixa espectral como *input* dos algoritmos (WL), os maiores valores de r foram obtidos para os algoritmos M5P e SVM, o menor valor de MAE para o modelo SVM e os menores valores de RMSE para os algoritmos M5P e SVM. O desempenho dos algoritmos de aprendizado de máquina variou em função dos *inputs* utilizados em seu treinamento. O melhor desempenho das estimativas a partir dos algoritmos M5P, REPTree, RF e SVP foram obtidos ao utilizar o *input* WL, enquanto para o modelo de RNA foi obtido melhor desempenho ao utilizar o *input* SB. Para o modelo ZeroR não houve diferenças entre os *inputs*. O melhor desempenho geral das estimativas das variáveis morfológicas foi obtido a partir da combinação

do modelo SVM com o *input* WL.

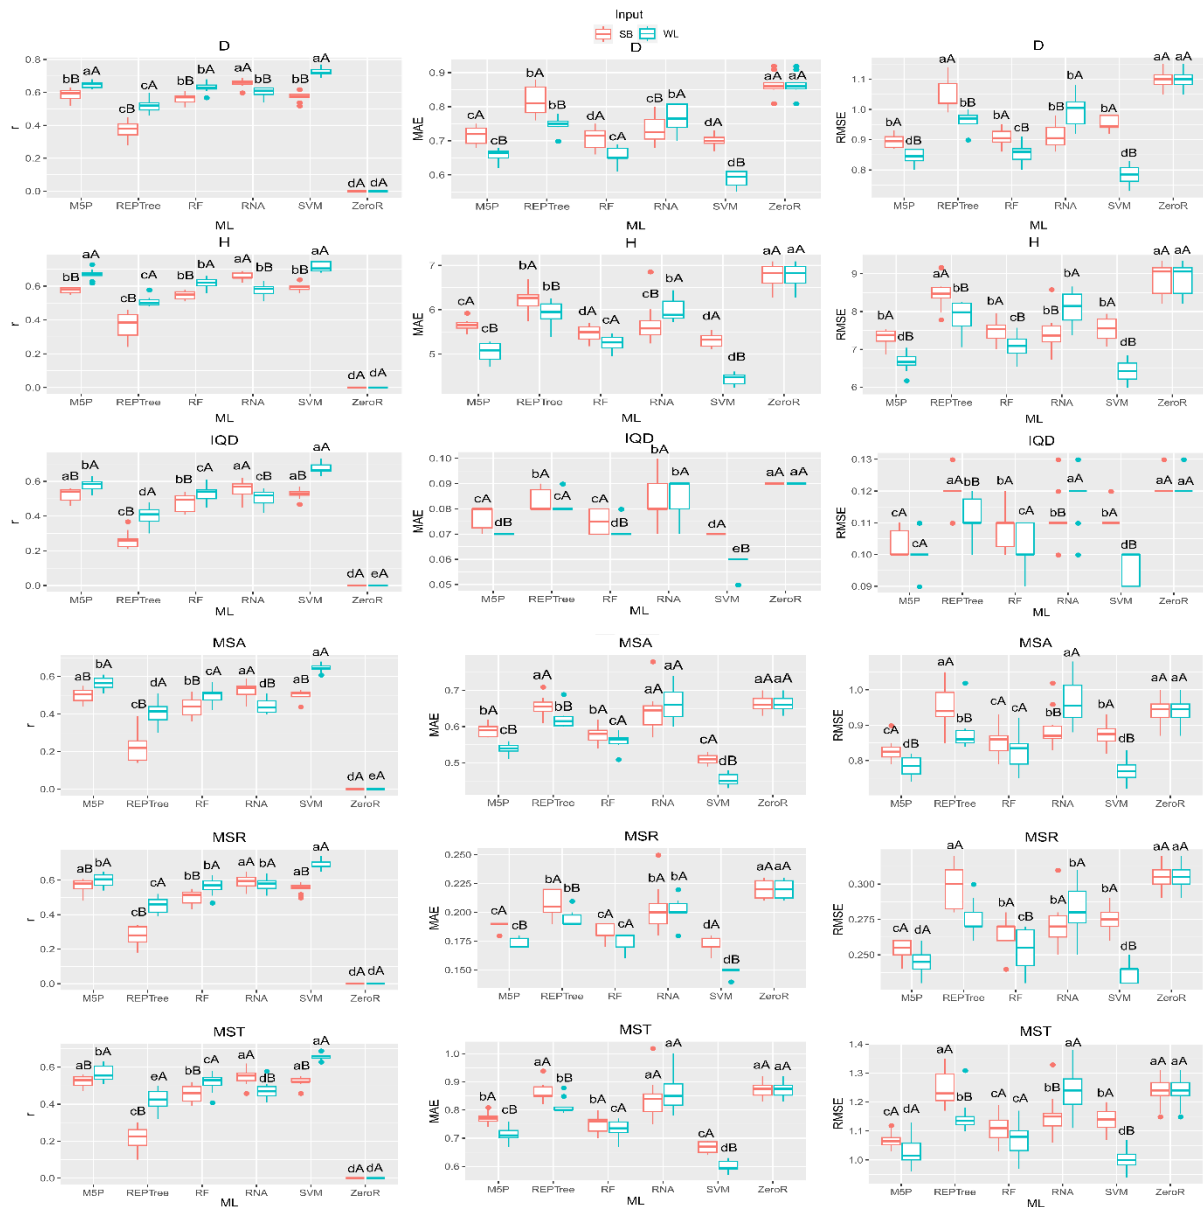


Figura 3. Boxplot para coeficiente de correlação (r), erro médio absoluto (MAE), raiz quadrada do erro-médio (RMSE). Em que: H = altura (cm); D = diâmetro do coleto (mm); MSA = massa seca da parte aérea (g); MSR = massa seca das raízes (g); MST = massa seca total (g); IQD = índice de qualidade de dickson (IQD).

DISCUSSÃO

Os resultados observados revelam padrões importantes na relação entre as variáveis morfológicas das mudas e sua resposta espectral. A forte correlação negativa entre as variáveis morfológicas e as bandas espectrais indica que mudanças nas características físicas das mudas, como altura, diâmetro ou biomassa, impactam diretamente na refletância registrada pelos sensores hiperespectrais. Esse comportamento pode ser explicado pela interação entre a estrutura das mudas e a energia refletida (Ahamed *et al.*, 2011; Silva Júnior *et al.*, 2018; Strabelli *et al.*, 2020; 2023, Silva *et al.*, 2024). Por outro lado, a correlação positiva entre as variáveis morfológicas reflete a tendência de crescimento integrado das mudas. Por exemplo, mudas mais altas frequentemente apresentam maiores diâmetros e maior biomassa, evidenciando o sincronismo entre os fatores de desenvolvimento (Neres *et al.*, 2019).

Esses padrões de correlação destacam o potencial do sensoriamento hiperespectral para capturar, de forma indireta e não destrutiva, informações detalhadas sobre o crescimento e a qualidade das mudas. A aplicação de algoritmos de aprendizado de máquina a dados espectrais permitiu a sua associação com variáveis morfológicas das mudas. Isso demonstra que a combinação dessas técnicas apresenta potencial para estimar de forma rápida e eficiente as variáveis morfológicas, sem a necessidade de medições diretas ou destrutivas. Os sensores hiperespectrais medem em uma ampla faixa de comprimentos de onda, o que facilita a identificação de padrões associados ao crescimento das plantas (Silva Júnior *et al.*, 2018; Santana *et al.*, 2023a). No entanto, como observado no presente estudo, o desempenho dos algoritmos de aprendizado de máquina depende do *input* utilizado e vice-versa.

Nesse contexto, o *input* WL se destacou em relação ao SB em várias métricas, como erro médio absoluto (MAE) e raiz quadrada do erro médio (RMSE), apresentando menor erro e maior precisão preditiva. O *input* WL fornece informações espectrais mais detalhadas, permitindo que os algoritmos capturem padrões mais complexos, o que explica sua superioridade em previsões morfológicas (Silva *et al.*, 2024). A maior riqueza de dados fornecida pelo WL permite uma melhor modelagem das interações entre as variáveis espectrais e as características morfológicas das plantas, resultando em previsões mais assertivas.

Em termos de algoritmos, o SVM provou ser eficaz para lidar com dados espectrais devido à sua capacidade de lidar com grandes volumes de padrões complexos. Esse algoritmo é particularmente eficiente quando se trata de processar dados não lineares e de alta dimensão, como dados hiperespectrais (Silva *et al.*, 2024). O algoritmo SVM forneceu um mapeamento de interação mais profundo entre variáveis, levando-os a previsões de maior precisão. Ao trabalhar com (WL), essas técnicas sofisticadas trazem mais vantagens, pois podem lidar

precisamente com grandes quantidades de características variáveis.

A combinação de sensores hiperespectrais com algoritmos avançados de aprendizado de máquina demonstrou, de forma pioneira, ser eficaz na previsão de variáveis morfológicas das mudas de *Eucalyptus deglupta* sob diferentes manejos. Este estudo destaca-se por abrir novas perspectivas para o monitoramento indireto e não destrutivo das variáveis morfológicas de crescimento e qualidade das mudas de eucalipto, possibilitando sua obtenção em qualquer momento durante o processo produtivo. Além disso, as informações geradas neste trabalho, especialmente quando integradas a outras técnicas de sensoriamento remoto, como o uso de drones, apresentam potencial significativo para otimizar o manejo dos viveiros florestais. Essas tecnologias podem contribuir para tomadas de decisão mais precisas em aspectos como adubação, controle de pragas e doenças, e a determinação do momento ideal para o transplante das mudas ao campo.

CONCLUSÕES

A combinação de algoritmos de aprendizado de máquina com dados hiperespetrais se mostrou eficiente para a predição de variáveis morfológicas e de qualidade de mudas de *Eucalyptus deglupta*.

O desempenho dos algoritmos de aprendizado de máquina depende do *input* utilizado e vice-versa. O algoritmo Support Vector Machine, utilizando como *input* toda faixa espectral (faixa de 350 a 2500 nm) como variáveis de entrada, foi o mais eficiente na predição das variáveis.

REFERÊNCIAS

AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K. C. A review of remote sensing methods for biomass feedstock production. **Biomass and Bioenergy**, v. 35, n. 7, p. 2455-2469, 2011.

ALVARES, C. A.; STAPE, J. L., SENTELHAS, P. C., DE MORAES, G., LEONARDO, J., & SPAROVEK, G., 2013: Köppen's Climate Classification Map for Brazil. **Meteorologische Zeitschrift**, 22 v. 22, n. 6, p. (6), 711-728. , 2013.

DICKSON, A.; LEAF, A. L.; HOSNER, J. F. Quality appraisal of white spruce and white pine seedling stock in nurseries. **Forest Chronicle**, v. 36, p. 10-13, 1960

FRANK, E; HALL, A. H.; WITTEN, I. H. The WEKA Workbench. Apêndice on-line para “Data Mining: Practical Machine Learning Tools and Techniques”, **Morgan Kaufmann**, Quarta edição, 2016.

GOMES, J. M.; COUTO, L.; LEITE, H. G.; XAVIER, A.; GARCIA, S. L. R. Parâmetros morfológicos na avaliação da qualidade de mudas de *Eucalyptus grandis*. **Revista Árvore**, Viçosa, v. 26, p. 655 - 664, 2002.

GONÇALVES, J. L. M.; ALVARES, C. A.; HIGA, A. R.; SILVA, L. D.; ALFENAS, A. C.; STAHL, J.; FERRAZ, S. F. de B.; LIMA, W. de P.; BRANCALION, P. H. S.; HUBNER, A.; BOUILLET, J. P. D.; LACLAU, J. P.; NOUVELLON, Y.; EPRON, D. Integrating genetic and silvicultural strategies to minimize abiotic and biotic constraints in Brazilian eucalypt plantations. **Forest Ecology and Management**, Amsterdam, v. 301, p. 6–27, 2013.

GREGORI, G. S. de; LOUREIRO, E. de S.; PESSOA, L. G. A.; AZEVEDO, G. B. de; AZEVEDO, G. T. de O. S.; SANTANA, D. C.; OLIVEIRA, I. C. de; OLIVEIRA, J. L. G. de; TEODORO, L. P. R.; BAIIO, F. H. R.; SILVA JÚNIOR, C. A. da; TEODORO, P. E.; SHIRATSUCHI, L. S. Machine learning in the hyperspectral classification of *Glycaspis brimblecombei* (Hemiptera Psyllidae) attack severity in eucalyptus. **Remote Sensing**, Vv.15, pag. 5657, 2023

LACERDA, M.; FRANCA, T.; CALVANI, C.; MARANGONI, B.; TEODORO, P.; CAMPOS, C. N. S.; BAIIO, F. H. R.; AZEVEDO, G. B.; CENA, C. A simple method for *Eucalyptus* species discrimination: FTIR spectroscopy and machine learning. **Results in Chemistry**, v. 7, p. 101233, 2024.

LIMA, G.G., MATOS, M., de Sá, F.P. MAGALHÃES, W. L. E.Rachwal, M. F. G. - Zanatta, J. A.; Supraparticles as slow-release fertiliser in seedling potential growth of *Eucalyptus urograndis* and greenhouse gas flux impacts. **Environmental Science and Pollution Research**. v. 30, pag. . 23047–23059 , 2023.

NERES, Y. X. C.; AZEVEDO, G. T. O. S.; SOUZA A. M.; AZEVEDO G. B.; TEODORO P. E.; Effect of the hydrogel incorporation on different substrates on the rooting and quality of clonal *Eucalyptus* seedlings. **Scientia Forestalis**, Piracicaba, v. 47, n. 122, p. 336-345, jun. 2019.

OLIVEIRA, B. R. de; SILVA, A. A. P. da; TEODORO, L. P. R.; AZEVEDO, G. B. de; AZEVEDO, G. T. de O. S.; BAIIO, F. H. R.; SOBRINHO, R. L.; SILVA JÚNIOR, C. A. da; TEODORO, P. E. *Eucalyptus* growth recognition using machine learning methods and spectral variables. **Ecology and Forest Management**, v. 497, 1, p. 119496. Oct., 2021.

R CORE TEAM. R: **A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2023.

SANTANA, D. C.; TEODORO, L. P. R.; BAIIO, F. H. R.; SANTOS, R. G.; CORADI, P. C.; BIDUSKI, B.; SILVA, C. A.; TEODORO, P. E.; SHIRATSUCHI, L. S. SANTANA, D. C.; TEODORO, L. P. R.; BAIIO, F. H. R.; SANTOS, R. G. D.; CORADI, P. C.; BIDUSKI, B.; SILVA JUNIOR, C. A. D; TEODORO, P. E.; SHIRATSUCHI, L. S.. Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. **Remote Sensing Applications: Society and Environment**, v. 29, p. 10-32, 2023a.

SANTANA, D.C; SANTOS, R.G.D; DA SILVA, P.H.N; PISTORI, H.; TEODORO, L.P.R; POERSCH, N.L; DE AZEVEDO, G.B; DE O. S. AZEVEDO, G.T; DA SILVA JÚNIOR, C.A; TEODORO, P.E.; Machine Learning Methods for Woody Volume Prediction in *Eucalyptus*. **Sustainability**, v. 15, p. 10968, 2023b.

SCOTT, A. J.; KNOTT, M. A cluster analysis method for grouping means in the analysis of variance. **Biometrics**, v. 30, n. 3, p. 507-512. 1974.

SILVA, M, A.; CAMPOS, C, N. S.; PRADO, R, M.; SANTOS, A, R.; CÂNDIDO, A, C, da S.; SANTANA, D, C.; OLIVEIRA, I, C.; BAIIO, F, H, R.; SILVA JÚNIOR, C, A, da; TEODORO, Larissa P, R.; TEODORO, P, E. Prediction of secondary metabolites in maize under different nitrogen input by hyperspectral sensing and machine learning. **Infrared Physics & Technology**, v.142, p. 105524, 2024.

STRABELI, T. F., FIORIO, P. R., ALVARES, C. A., & NAKAI, E. S. Conteúdo relativo de água afeta o comportamento espectral de folhas de *Eucalyptus* spp. **Scientia Forestalis**, v. 48, n. 128, p. e3326, 2020.

STRABELI, T. F., FIORIO, P. R., RÉ, N. C., ALVARES, C. A., LUCIANO, A. C. S., & NAKAI, E. S. Modelos espectrais para a estimativa do conteúdo de água em folhas de *Eucalyptus*. **Scientia Forestalis**, 51, e3941, 2023.

TEODORO, L. P. R.; ESTEVÃO, R.; SANTANA, D. C.; OLIVEIRA, I. C. de; LOPES, M. T. G.; AZEVEDO, G. B. de; BAIIO, F. H. R.; SILVA JÚNIOR, C. A. da; TEODORO, P. E. *Eucalyptus* species discrimination using hyperspectral sensor data and machine learning. **Florestas**, v. 15, p. 39, 2024.