

### GESTÃO DA MANUTENÇÃO FLORESTAL: MODELO DE PREDIÇÃO DE PARADAS DE FORWARDER POR MACHINE LEARNING

Autores: Rafael Mantovani de Souza; Raiane Ribeiro Machado Gomes

ODS: Indústria, Inovação e Infraestrutura

Categoria: Pesquisa

#### Introdução

A gestão da manutenção no setor florestal brasileiro, um pilar da economia nacional que responde por 25,5% do PIB (CNI, 2024), representa um desafio crítico devido aos altos custos operacionais de suas máquinas. Com um consumo de madeira de 182,2 milhões de m<sup>3</sup> em 2022 (IBÁ, 2023), equipamentos como os forwarders, essenciais para transportar a madeira (Malinovski et al., 2006), têm na manutenção a principal fonte de despesas, correspondendo a 57,77% de seus custos totais (Santos et al., 2016). Nesse contexto, a manutenção preditiva, baseada em técnicas de machine learning para prever falhas (Carlos et al., 2023), emerge como uma solução estratégica para otimizar os recursos operacionais (Maktoubian et al., 2021).

#### Objetivos

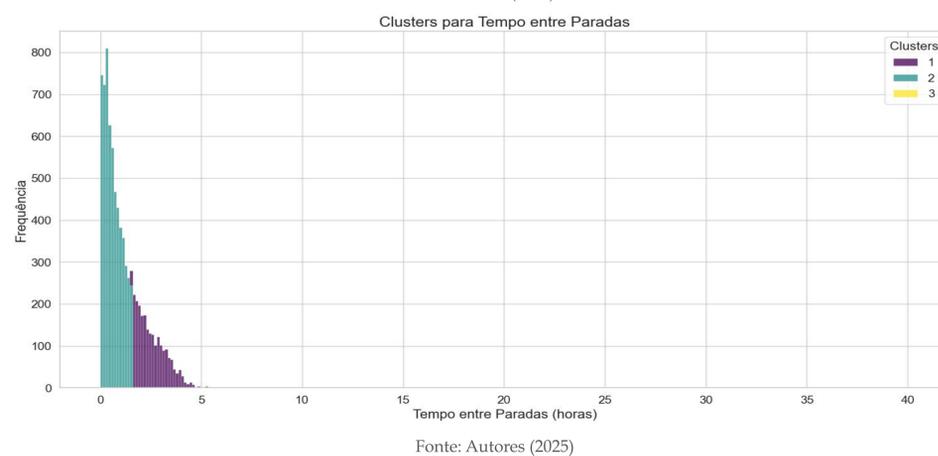
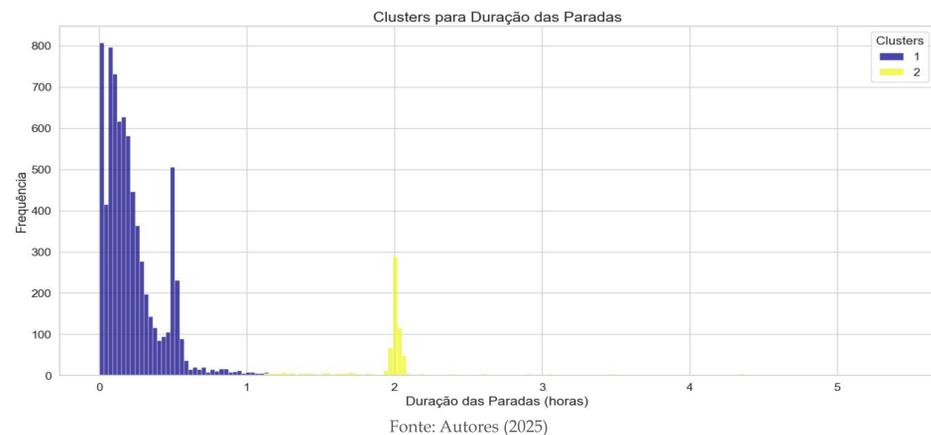
Este trabalho tem como objetivo geral desenvolver um modelo de predição de paradas de máquina florestal, forwarder, através do machine learning como ferramenta de gestão da manutenção de máquinas que possa apoiar o planejamento e gestão das operações florestais. O trabalho tem como objetivos específicos: realizar uma revisão de literatura sobre gestão da manutenção, colheita florestal, machine learning e modelos de predição; analisar e tratar dados reais para quantificação da base de treinamento; gerar dados empíricos a partir desses registros para compor uma base final extensa e adequada à acurácia do modelo; avaliar, com base na literatura, modelos de predição já existentes ou propor adaptações; aplicar aprendizado de máquina e avaliar os resultados, realizando ajustes até a versão final. Ressalta-se que o estudo encontra-se em desenvolvimento, apresentando resultados parciais.

#### Metodologia

Os dados iniciais foram fornecidos por uma empresa brasileira de papel e celulose, que produz sua própria madeira para abastecimento da indústria. No total, a base contém 20.136 registros, referentes ao período de 01/01/2021 a 05/10/2022, incluindo as horas de início e fim das paradas, juntamente com suas respectivas classificações: "Operacional", "Alimentação" e "Manutenção". A partir dos dados fornecidos foi desenvolvida dois grupos de tempos, o "Tempo entre Paradas" e "Duração das Paradas". Diante disso, a metodologia foi implementada em Python, utilizando bibliotecas como Pandas, Fitter e Scikit-Learn. Foram analisados o conjunto de dados de Tempo entre Paradas e Duração das Paradas da empresa. A análise consistiu em duas etapas: primeiramente, realizou-se um teste de aderência com a biblioteca Fitter, validado pelo teste de Kolmogorov-Smirnov(KS). Em seguida, aplicou-se a clusterização K-Means, sendo o número ótimo de clusters determinado pelo método do cotovelo.

#### Resultados

Os resultados refutaram a hipótese de uma distribuição única ( $p < 0,05$ ), comprovando que um modelo de falha singular seria impreciso. A análise de clusterização revelou a existência de três perfis de parada distintos. O primeiro cluster agrupou eventos com intervalos entre falhas de 0,00 a 1,58 horas e duração de 1,13 a 5,39 horas. O segundo cluster correspondeu a paradas com intervalos de 1,58 a 6,37 horas e duração de 0,00 a 1,13 horas. Já o terceiro cluster caracterizou as paradas menos frequentes, com intervalos entre falhas de 15,73 a 40,07 horas.



#### Conclusões

O rigor no tratamento dos dados que serão empregados no treinamento e validação se faz necessário para obtenção de maior qualidade do modelo de machine learning a ser desenvolvido, buscando contribuir com o avanço da interface entre engenharia florestal e inteligência artificial, fomentando a evolução para a silvicultura. Ressalta-se que este trabalho está em andamento e os próximos passos consistem em encontrar a curva de distribuição de cada cluster. A partir delas, serão simulados dados sintéticos para ampliar a base de dados para o treinamento do modelo de machine learning. Em seguida, o modelo será treinado e validado para gerar dados preditivos que auxiliem no planejamento da manutenção.

#### Bibliografia

Confederação Nacional Da Indústria (CNI). *Portal da Indústria*. Disponível em: <https://cni.portaldaindustria.com.br/pt>. Acesso em: 30 abr. 2025.

Indústria Brasileira De Árvores (IBÁ). *Relatório anual 2023*. Brasília: IBA, 2023. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2023-r.pdf>. Acesso em: 30 abr. 2025.

Malinovski, R. A.; Malinovski, R. A.; Malinovski, J. R. Análise das variáveis de influência na produtividade das máquinas de colheita de madeira em função das características físicas do terreno, do povoamento e do planejamento operacional florestal. *Floresta*, v. 36, n. 2, 18 out. 2006.

Maktoubian, J.; Taskhiri, M. S.; Turner, P. Intelligent Predictive Maintenance (IPdM) in Forestry: A Review of Challenges and Opportunities. *Forests*, v. 12, n. 11, p. 1495, 29 out. 2021.