

UNIVERSIDADE FEDERAL DO PARANÁ


FELIPE SANTI

MATHEUS PUEHLER

TRABALHO DE CONCLUSÃO DE CURSO

CURITIBA

2025



FELIPE SANTI
MATHEUS PUEHLER

ESTUDO DE PREVISÃO PREDITIVA DE DEMANDA DE PEÇAS DE
REPOSIÇÃO PARA MÁQUINAS DE CONSTRUÇÃO, ATRAVÉS DE SÉRIES
TEMPORAIS

Trabalho de Conclusão de Curso apresentado ao curso de Graduação em Engenharia Mecânica, Setor de Tecnologia, na Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia Mecânica.

Orientador: Pablo Deivid Valle

CURITIBA

2025



UNIVERSIDADE FEDERAL DO PARANÁ

PARECER Nº 3/2025/UFPR/R/TC/DEMEC
PROCESSO Nº 23075.041715/2025-19
INTERESSADO: FELIPE ALBERTO DE SANTI, MATHEUS PUEHLER

TERMO DE APROVAÇÃO

Título: ESTUDO DE PREVISÃO PREDITIVA DE DEMANDA DE PEÇAS DE REPOSIÇÃO PARA MÁQUINAS DE CONSTRUÇÃO, ATRAVÉS DE SÉRIES TEMPORAIS

Autores: FELIPE ALBERTO DE SANTI; MATHEUS PUEHLER

Trabalho de Conclusão de Curso apresentado como requisito parcial para a obtenção do título de bacharel em Engenharia Mecânica. Aprovado pela seguinte banca examinadora:

Prof. Pablo Deivid Valle (UFPR/DEMEC) – Orientador

Prof. João Moraes da Silva Neto (UFPR/DEMEC)

Eng. Gabriel Pontarolo Kopanski (Doutorando/PGMEC)

Curitiba, 14 de julho de 2025



Documento assinado eletronicamente por **PABLO DEIVID VALLE, PROFESSOR DO MAGISTERIO SUPERIOR**, em 18/07/2025, às 09:53, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **GABRIEL PONTAROLO KOPANSKI, Usuário Externo**, em 18/07/2025, às 10:36, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **JOAO MORAIS DA SILVA NETO, CHEFE DO DEPARTAMENTO DE ENGENHARIA MECANICA - TC**, em 06/08/2025, às 15:54, conforme art. 1º, III, "b", da Lei 11.419/2006.



A autenticidade do documento pode ser conferida [aqui](#) informando o código verificador **7953833** e o código CRC **E31B136E**.

SUMÁRIO

1 Introdução	8
2 Metodologia	12
2.1 Definição de modelo para previsão de horímetro	12
2.2 Estudo para alteração de intervalo de troca de manutenção preditiva.....	17
2.3 Construção do Cálculo De Demanda	21
3 Escolha do método	23
4 Resultados e discussão	24
4.1 Impacto na previsão de estoque e receita de injetores.....	24
4.2 Extrapolação do modelo para todo o portfólio de injetores	26
5 Conclusão	27
6 Referências.....	28
7 Responsabilidade pelas informações.....	32

RESUMO

O presente estudo realiza a previsão preditiva de demanda de peças de reposição para máquinas de construção utilizando séries temporais. O objetivo central é melhorar a gestão de manutenção e a disponibilidade de peças, garantindo maior precisão nas previsões de demanda e receita, minimizando interrupções operacionais. Inicialmente, realizou-se o mapeamento de uma frota de máquinas de construção, classificando-as em quartis com base em dados de telemetria, como horas de operação, utilizando a metodologia ARIMA, um modelo estatístico de séries temporais, para prever o horímetro das máquinas nos próximos 12 meses. Após isso, integraram-se essas previsões ao catálogo de peças de reposição do fabricante, considerando a vida útil definida pela engenharia. A identificação do momento exato em que uma peça está prestes a falhar, com base nas horas de uso, é crítica para a precisão das previsões, por isso avaliaram-se também as falhas e trocas de um determinado período para validar as previsões, ajustando os modelos de acordo com o histórico de falhas de determinada peça. Destaca-se no estudo a importância de uma rede robusta de distribuidores para cobrir todas as regiões do Brasil, facilitando a sinergia entre fábrica e distribuidores para proporcionar uma experiência de pós-venda de alta qualidade. A capacidade de atender rapidamente às demandas, minimizar o tempo de inatividade e garantir a disponibilidade de peças em estoque são diferenciais competitivos, que serão beneficiados com o projeto. Por fim, o estudo analisou o desgaste dos componentes a partir do ciclo de vida do produto, exemplificado por um grupo de injetores, ajustando o planejamento de manutenção para maximizar a eficiência e reduzir o tempo de inatividade das máquinas. O estudo teve na metodologia desenvolvida um aumento significativo na precisão das previsões de utilização horária e substituição de componentes, reduzindo os erros de estimativas e melhorando a gestão de estoque e suprimentos. Os resultados obtidos indicam que a aplicação do modelo não apenas melhora a eficiência operacional, mas também reforça a posição competitiva da empresa no mercado de máquinas de construção. O estudo também sugere que a metodologia pode ser expandida para outros componentes, ampliando os benefícios para toda a cadeia de pós-venda.

Palavras-chave: previsão preditiva, peças de reposição, telemetria, ciclo de vida, máquinas de construção.

ABSTRACT

This study carries out predictive demand forecasting for spare parts for construction machinery using time series. The main objective is to improve maintenance management and parts availability, ensuring greater accuracy in demand and revenue forecasts and minimizing operational interruptions. Initially, a fleet of construction machines was mapped, classified into quartiles based on telemetry data, such as operating hours, using the ARIMA methodology, a statistical time series model, to forecast the machines' hour meter over the next 12 months. These forecasts were then integrated with the manufacturer's spare parts catalog, considering the useful life defined by engineering. Identifying the exact moment when a part is about to fail, based on hours of use, is critical to the accuracy of the forecasts, which is why the failures and replacements of a given period were also evaluated to validate the forecasts, adjusting the models according to the failure history of a given part. The study highlights the importance of a robust network of distributors to cover all regions of Brazil, facilitating synergy between the factory and distributors to provide a high-quality after-sales experience. The ability to meet demands quickly, minimize downtime and guarantee the availability of parts in stock are competitive differentials that will benefit from the project. Finally, the study analyzed component wear based on the product's life cycle, exemplified by a group of injectors, adjusting maintenance planning to maximize efficiency and reduce machine downtime. The study found that the methodology developed significantly increased the accuracy of hourly utilization and component replacement forecasts, reducing estimation errors and improving stock and supply management. The results obtained indicate that the application of the model not only improves operational efficiency but also strengthens the company's competitive position in the construction machinery market. The study also suggests that the methodology can be expanded to other components, extending the benefits to the entire after-sales chain.

Keywords: predictive forecasting, spare parts, telemetry, life cycle, construction machinery.

1 INTRODUÇÃO

Ingressar no mercado de máquinas de construção, conhecido como mercado de máquinas de linha amarela, requer um entendimento profundo de sua complexidade e importância estratégica para a economia. Este setor desempenha um papel significativo na geração de empregos diretos e indiretos, além de estar intimamente ligado ao desenvolvimento de infraestrutura, mineração, transporte de matérias-primas e construção civil, conforme apresentado pela Associação Brasileira De Tecnologia Para Construção E Mineração (2023). Dentro desse cenário, fabricantes líderes oferecem um portfólio diversificado de equipamentos pesados, incluindo escavadeiras, carregadeiras de rodas, exemplificada pela Fig. 1, apresentando uma pá carregadeira de rodas modelo 955T da montadora Sinomach, e caminhões articulados, projetados para atender a diversas aplicações e segmentos industriais, conforme apresentado por Rakshitha e Mallika (2018), ao analisar uma das líderes de mercado do segmento, a Volvo CE. A dinâmica desse mercado é amplificada pela estrutura de distribuição, predominantemente baseada em um modelo B2B. Nesse arranjo, a montadora é responsável pela fabricação dos equipamentos e seus componentes, enquanto distribuidores locais assumem a missão de conectar a fábrica aos clientes finais, ficando evidente que os serviços ganham importância em mercados altamente competitivos, onde o fabricante tem poucos revendedores, de acordo com o estudo realizado por Golar et al. (2021). Esses distribuidores desempenham um papel estratégico em áreas como logística, manutenção, suporte técnico e disponibilidade de peças, garantindo não apenas a entrega eficiente dos equipamentos, mas também a continuidade de suas operações.

Figura 1 - Exemplo de uma carregadeira de rodas, máquina muito utilizada no Brasil.



Fonte: SINOMACH (2024)

No Brasil, país de dimensões continentais, a complexidade desse mercado é acentuada pela necessidade de uma rede robusta e ampla de distribuidores para cobrir todas as regiões. Essa estrutura exige uma colaboração estreita entre fábrica e distribuidores, onde o nível dos serviços afeta as vendas de produtos e a reputação da marca, conforme abordado por Golar et al. (2021), visando proporcionar uma experiência de pós-venda que atenda às necessidades específicas dos clientes, com alta qualidade e agilidade. Essa sinergia é essencial para alcançar os objetivos de negócios, especialmente em um ambiente competitivo que valoriza a fidelização e o suporte técnico eficaz.

O mercado de linha amarela apresenta características peculiares, onde presume-se que, se não houver no portfólio da montadora um equipamento para executar um tipo de serviço pesado, ele poderá ser projetado e construído, e os fabricantes tem uma grande dependência do feedback dos usuários, particularidades apresentadas no livro “Construction Equipment Management for Engineers, Estimators, and Owners” de Gransberg et al. (2006).

Sobretudo no que diz respeito ao desgaste acentuado dos equipamentos devido às condições adversas e às aplicações intensivas, esses fatores tornam a manutenção e o suporte no pós-venda fatores cruciais para o sucesso operacional. Para os clientes, questões como o tempo necessário para reparo, os custos envolvidos e a durabilidade das intervenções são determinantes para avaliar a qualidade do serviço recebido, e segundo Granskog et al. (2016), os serviços e ofertas no mercado de pós-venda surgem como alternativas sustentáveis para capturar valor e penetração do mercado. Nesse contexto, a capacidade de atender rapidamente às demandas, minimizar o tempo de inatividade e garantir a disponibilidade de peças em estoque são diferenciais competitivos, de acordo com Gransberg et al. (2006). A gestão de peças de reposição baseia-se, em grande parte, na Bill of Materials (BOM), que detalha todos os componentes necessários para a operação, manutenção e reparo das máquinas. Os itens de manutenção frequente, como filtros, lubrificantes e outros consumíveis, possuem alta demanda e exigem uma gestão criteriosa do estoque, até pela necessidade do suporte de garantia, fornecido pela fábrica e evidenciado por Kirkizoğlu e Karaer (2022), tornando crucial sua disponibilidade.

A reposição desses componentes segue intervalos programados, definidos pelo fabricante com base em catálogos de engenharia e telemetria compartilhada pelas máquinas, e, além disso, é comum que um contrato de serviços seja firmado com a compra da máquina, como destaca Bergstrand e Jönsson (2017). Essa previsibilidade é

fundamental para o planejamento logístico e financeiro, garantindo que os distribuidores consigam atender prontamente às demandas dos clientes. Entretanto, embora as práticas de manutenção sejam bem estabelecidas, inúmeros fatores externos influenciam a precisão das previsões de estoque e receita, exemplificado por Apipattanavis et al. (2010) ao apresentar o contexto de construção de rodovias, onde são altamente dependentes do clima e como poderia ser previsto em contrato a influência dos atrasos relacionados a isso, como por exemplo, a temperatura e nível de chuvas.

Além disso, o tipo de aplicação e das práticas operacionais dos operadores, afeta diretamente o desgaste dos componentes, conforme evidenciado por Wang et al (2004) em “Mixed reality technology applications in construction equipment operator training”, onde os autores apresentam uma nova metodologia de treinamento para os operadores e sua importância durante a operação. Adicionalmente, variáveis macroeconômicas, como inflação e taxas cambiais, podem impactar o uso das máquinas e a frequência de manutenção, fato apresentado pela Globe Newswire (2021) usando a pandemia do Covid-19 como grande exemplo, tornando assim o planejamento de estoque e receita um desafio dinâmico e complexo.

O mercado de máquinas de construção também enfrenta desafios relacionados à competitividade global. A rapidez no avanço tecnológico, a eficiência do transporte internacional, o acesso facilitado a equipamentos de outros mercados e até a produção por manufatura aditiva (Volvo CE, 2018) tornam essencial a adoção de estratégias inovadoras. Nesse cenário, a fidelização de clientes por meio de um serviço de pós-venda eficiente é tão importante quanto a conquista de novos clientes (Bergstrand e Jönsson, 2017). Com o objetivo de superar essas dificuldades e otimizar a cadeia de suprimentos, este estudo propõe a aplicação de um modelo estatístico ARIMA, baseado em séries temporais, definido como um conjunto de modelos que explicam uma série temporal com base em seus valores passados, ou seja, seus erros de previsão de defasagem e atraso, de modo que essa equação possa ser usada para prever valores futuros (Hussein, 2023), para prever a utilização horária de máquinas em operação no Brasil. Integram-se nesse modelo os dados históricos de telemetria, estudos de resistência de materiais e informações fornecidas por distribuidores, permitindo uma previsão mais precisa da demanda por peças de reposição.

O foco inicial do estudo encontra-se no grupo de injetores, um componente crítico no funcionamento dos equipamentos, que tem sido muito estudado para prever as falhas de máquinas, como através da metodologia PCA (Análise do Componentes

Principal), apresentada por Le et al. (2020). Além de prever a demanda, o modelo busca ajustar os intervalos de manutenção considerando as condições específicas de operação, como segmento de aplicação e intensidade de uso. A abordagem apresentada procura melhorar a precisão das previsões, e também reduzir os custos operacionais e os riscos de ruptura de estoque, que, segundo Teixeira e Figueiredo (2017), contribui para uma gestão de suprimentos mais eficiente e, conseqüentemente, um aumento de produtividade.

2 METODOLOGIA

2.1 DEFINIÇÃO DE MODELO PARA PREVISÃO DE HORÍMETRO


Inicialmente, buscou-se o refinamento da variável que servirá como base para todo o estudo de previsão de demanda para o ano seguinte: quantas horas de utilização da frota de máquinas serão consumidas durante os próximos 12 meses.

A fabricante em questão utilizava uma média aritmética simples, representada pela Eq. (1), onde se extrapolava a utilização total dos últimos 90 dias para cada máquina, sendo h_i a utilização de cada dia, assumindo que se manteria igual de maneira linear para os próximos 365 dias. Porém, ao entender a variação dos dados, o estudo buscou avaliar um modelo estatístico que traria uma maior precisão nessa previsão de utilização. Para isso, foi utilizada a metodologia CRISP-DM (Cross Industry Standard Process for Data Mining) como processo de abordagem para solucionar esse problema.

$$Utilização\ total\ prevista\ [h] = \left(\frac{\sum_{i=1}^{n=90} h_i}{90} \right) \times 365 \quad (1)$$

A metodologia, representada pela Fig. 2, conforme o “Modeler CRISP-BM Guide” desenvolvido pela IBM (International Business Machines Corporation), consiste em seis fases de contextualização e atuação, onde sua abordagem estruturada proporciona um melhor planejamento e gerenciamento de projetos de mineração de dados (Martínez-Plumed, et al., 2021), com objetivo de avaliar qual solução utilizar para determinado cenário. Essas fases são: entender o contexto do negócio, entender os dados disponíveis, fazer a preparação e modelagem dos dados, avaliar o modelo desenvolvido e implementar.

Figura 2 - Representação da metodologia CRISP-DM.




Fonte: IBM (2021)

Ao fazer a análise do volume e frequência de envio dos dados de telemetria de cada máquina, verificou-se um comportamento comum para a utilização de séries temporais, como em cotações na bolsa de valores ou vibrações de um sensor estrutural, onde se tem observações registradas em intervalos de tempo regulares (Brockwell e Davis, 2002), com uma notável sazonalidade, tendência e ruído. Essas componentes estatísticas são definidas por Guarnaccia et al. (2014), sendo sazonalidade o padrão regular na série temporal que se repete em intervalos fixos de tempo, como diários ou semanais, tendência é o critério que representa a direção geral dos dados em função do tempo, sendo que uma vez calculada, é removida dos dados originais para isolar a sazonalidade e ruído uma variação aleatória fora da explicabilidade sazonal e de tendência.

Na Fig. 3, tem-se a representação gráfico de cada uma dessas observações e suas combinações simultâneas, conforme apresentado por Wild e Saber (2004) no livro “Encontros com o acaso”:

Figura 3 - Combinações de tendência, sazonalidade (ciclo) e ruído.



Fonte: Wild e Saber (2004)


A análise de séries temporais é uma eficiente técnica de prever padrões, muito utilizada em diversos mercados, dessa forma, definiu-se junto ao time de negócios do fabricante, que um modelo de previsões por séries temporais seria desenvolvido para a previsão de horímetro das máquinas, buscando prever a tendência para períodos futuros, mantendo o padrão de sazonalidade e utilizando a probabilidade para prever o ruído total.

Existem diversos métodos para essa análise, e, ao avaliar qual deles seria o mais adequado para o tipo de dados utilizados, optou-se pelo modelo ARIMA (AutoRegressive Integrated Moving Average) para realizar as previsões, também pelo fato de time de negócios do fabricante já ter alguns desenvolvimentos utilizando essa técnica. Esse modelo combina componentes autorregressivos, médias móveis e diferenciação, sendo apropriado para uma ampla variedade de séries temporais, incluindo aquelas que apresentam tendências, sazonalidade e comportamentos complexos (Khan e Alghulaiakh, 2020).

Na Fig. 4, é possível analisar o comportamento dos casos de dengue e o resultado de uma previsão, a partir de séries temporais, desenvolvida por Ho e Yee (2015), e embora seja computacionalmente exigente, ele oferece maior precisão ao capturar padrões

complexos, como a utilização diária de máquinas, sendo indicado para análises de dados temporais com padrão forte de sazonalidade (Borsato e Corso, 2019).

Figura 4 - Forecast realizado com modelo ARIMA.



Fonte: Ho e Yee (2015).

Após definir o uso de ARIMA para as previsões de utilização de horímetro, o fabricante envolveu o time de tecnologia e desenvolvimento técnico local para aplicar essa metodologia no sistema da empresa, onde foram criadas tabelas em um modelo semântico no sistema da empresa. Isso foi feito devido à segurança e privacidade dos dados, onde a empresa exige que qualquer aplicação técnica e estatística com suas informações sejam feitas internamente, de acordo com sua política de segurança.

Feito esse processo, a validação pode ser feita através da construção do código, sendo baseado na forma generalizada descrita pela Eq. (2), apresentada por Khan e Alghulaiakh (2020):

$$Y(t) = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q} + \epsilon_t \quad (2)$$

Nela, $Y(t)$ é o valor da série temporal no instante t , ou seja, a função de horas de utilização diária de uma máquina, c representa a média da série temporal, ϕ são os coeficientes autorregressivos, onde se define a linearidade entre o valor de um ponto em uma série temporal e seus valores anteriores, sendo p o número de valores anteriores considerados para a previsão. θ são os coeficientes de média móvel, que determina a relação entre o valor de um ponto em uma série temporal e os erros anteriores da previsão realizada, onde q representa o número de valores anteriores considerados para a previsão e ϵ são os termos de ruído, ou seja, os erros medidos entre o valor observado e o valor previsto para uma determinada defasagem (Khan e Alghulaiakh, 2020).

Assim, aplicada essa técnica estatística, considerando os fatores como estacionariedade, erro médio absoluto e de que maneira o código seria atualizado, processo realizado pelo time técnico do fabricante, aplicou-se a metodologia de IQR (Inter-Quartile Range), para separar as informações que o modelo trouxe.

Dentro de um conjunto de dados, algumas amostras recebidas podem se afastar totalmente do padrão da maioria dos pontos, os chamados outliers, segundo Barnett e Lewis (1994). Eles podem surgir por diversas razões, como erros de medição ou eventos incomuns dentro da amostra, e assim causar distorções em toda a análise desenvolvida e prejudicar a tomada de decisão.

O IQR é uma metodologia estatística usada para filtrar esses outliers, no caso desse estudo, para as comunicações de telemetria recebidas, buscando uma maior acurácia na previsão do horímetro. Segundo Dash et al. (2023), ele é calculado como a diferença entre o terceiro e o primeiro quartil dos dados abordados, conforme Eq. (3), onde a amostra é dividida igualmente entre quatro quartis, onde cada um possui 25% dos dados.

$$IQR = Q3 - Q1 \quad (3)$$

Define-se então, um limite inferior a partir do primeiro quartil, ou seja, abaixo de 25%, onde normalmente se subtrai um valor 1,5 vezes maior que o IQR, conforme Eq. (4):

$$Limite inferior = Q1 - 1,5 \times IQR \quad (4)$$

Da mesma forma, o limite superior será definido a partir de 1,5 vezes o valor do IQR, somado ao terceiro quartil, ou seja, acima do limite de 75% dos dados:

$$Limite superior = Q3 + 1,5 \times IQR \quad (5)$$

Dessa forma, qualquer ponto acima do limite superior ou abaixo do limite inferior será considerado um outlier, ou seja, considerando apenas dados entre 25% e 75% da amostra como não sendo um outlier, e assim, utilizados para o modelo de previsão, conforme Dash et al. (2023). Feita essa modelagem dos dados de horas trabalhadas, melhorando a previsão de utilização de máquinas futura, e também, o cálculo de previsão de demanda, já havia ferramentas suficientes para uma melhoria na acurácia do estudo.

2.2 ESTUDO PARA ALTERAÇÃO DE INTERVALO DE TROCA DE MANUTENÇÃO PREDITIVA

Já na outra frente do modelo, foi trabalhada a melhoria na predição da utilização de um determinado componente e o momento ideal a ser substituído na iminência da falha, com um grau de confiança alto para o cliente, ou seja, ao projetar um modelo de previsão de demanda, se faz necessário um intervalo de troca mais preciso, conforme discutido por Jihao et al. (2018). Nesse caso, um projeto foi desenvolvido dentro do fornecedor genuíno do fabricante, onde critérios de desgaste do material possibilitaram aumentar ou reduzir a necessidade de troca do item. Para esse estudo, utilizou-se o grupo de injetores para demonstrar a metodologia aplicada, podendo ser extrapolada para todos os grupos de produto onde exista uma melhoria semelhante.

Dentro do portfólio utilizado nas máquinas do fabricante, os injetores compõem uma parcela importante no volume de vendas e penetração de mercado, informação interna obtida durante o desenvolvimento do projeto. No estudo desenvolvido, buscou-se um foco no grupo de injetores de alta pressão para motores de combustão interna a diesel, conhecidos como injetores do tipo common rail, sistema que tem sido utilizado desde meados dos anos 90, garantindo precisão elevada na inserção do combustível na câmara de combustão.

O diferencial desses injetores é a precisão no tempo de injeção, tendo em vista trabalho esclarecedor elaborado por Silva (2015), contribuindo para menores níveis de emissão, redução na taxa de consumo de combustível e capacidade de operar em pressões mais altas do que os sistemas convencionais de injeção de diesel, aspectos também detalhadamente analisados por Tzanetakis et. al (2023), que discute como estes sistemas suportam o uso de combustível aditivado e os avanços em durabilidade simultaneamente com a tecnologia de injeção.

Esta etapa do trabalho integra dados do fornecedor de injetores do fabricante de equipamentos de construção analisado, com informações específicas que possibilitaram a criação de uma base de dados ampla, contendo desde informações técnicas do produto a detalhes particulares de cada aplicação, sendo conectados às informações de estimativas de utilização das máquinas, apresentada anteriormente. Com essas informações, é possível refletir as condições reais de desgaste desse item, e quando eles deverão ser


trocados de maneira preditiva, trazendo uma análise precisa para o fabricante de equipamentos.

Inicialmente, é necessário entender o conceito teórico do projeto mecânico da peça, com o objetivo de ter melhor precisão no resultado do estudo de falha. O funcionamento desse injetor, descrito anteriormente, é extremamente complexo quando comparados a antigos sistemas mecânicos de alta pressão ou injeção eletrônica a diesel, conforme Rahman et al. (2022), onde o que gera a explosão é a alta pressão e sua pulverização é controlada ao longo da câmara de combustão, sendo necessários os ciclos de seringaço, onde o mesmo realiza em torno de 4 ciclos em menos de 1 segundo, para assim, atingir os quatros estágios do ciclo diesel, conforme amplamente discutido por Heywood (2018).

Sendo assim, há necessidade de ter um projeto extremamente robusto, com espessura elevada e presença de ligas metálicas específicas, além de uma ponteira que irá pulverizar o bico com a quantidade certa de furos requisitados para cada aplicação. Sabendo disso, conclui-se que o injetor funciona ciclicamente, recebendo pressão máxima média de 1600 bar, a cada 250 μ s, que é o equivalente a ter 14.400 ciclos em média por hora continuamente, conforme abordado por Kegl (2012) e levantado a partir de dados do fabricante. Isso ocorre até que o injetor comece a apresentar pequenos sinais de fadiga e em algum momento seja necessária sua troca, seja por sofrer fadiga ou por outro componente interno da peça apresentar um desgaste que leve a falha do sistema.

Abaixo, um exemplo fictício para representar o comportamento de erro do produto é descrito na Fig. 5, onde o eixo das abscissas representa o número de ciclos aplicados na escala logarítmica, enquanto as ordenadas expressam a amplitude de tensão máxima que o corpo poderá resistir, reduzindo gradativamente em função do desgaste, e se tornando crítico abaixo de aproximadamente 75 MN/m e 275 MN/m², como é extremamente abordado em conhecimentos de mecânicas da fratura e elementos de máquinas.

Figura 5 - Representação da Amplitude de tensão ($\frac{MN}{m^2}$) vs Número de Ciclos (N_f)



Fonte: O autor (2024).

Segundo Budynas e Nisbett (2016), um projeto mecânico envolve diversas áreas do conhecimento, com a parte mecânica interligada à mecânica da fratura e à fadiga dos materiais, sendo essencial para o desenvolvimento de geometrias ideais que atendam aos requisitos de projetos maiores. A mecânica da fratura e fadiga foca na previsibilidade de peças e estruturas, considerando fatores como parâmetros de design, propriedades dos materiais, processos de fabricação e confiabilidade da aplicação, podendo assim calcular a fratura linear elástica, que prevê a propagação de trincas e descontinuidade no material, e a fratura elasto-plástica, que leva em conta a formação de zonas plásticas ao redor de trincas, considerando o comportamento interno do material sob cargas extremas. Esse tipo de análise avalia como materiais resistem a cargas cíclicas e repetidas, antecipando falhas devido à propagação de trincas microscópicas, essencial para a segurança e durabilidade de componentes mecânicos.

E quando discutido para elementos de máquina como engrenagens, porcas ou molas, é comum o estudo realizado com diversos parâmetros para atingir o resultado mais eficiente possível, em termos de custo e desempenho para a aplicação. Semelhantemente ocorre para componentes de motor, necessitando desse cálculo para evitar falhas prematuras que podem levar a graves falhas, como travamento do motor e trinca em câmaras de combustão. A partir do valor limite da amplitude de tensão permissível para esse injetor exemplificado, levando em consideração a pressão do diesel necessária para

o funcionamento adequado do motor, determina-se o limite de tensão admissível, o qual, após aplicar o coeficiente de segurança, é ajustado para atender às exigências do projeto.

Para concluir o cálculo, é analisada a probabilidade de falha por milhão de ciclos, levando em conta os fatores de desgaste, falhas em outros componentes internos e as condições de uso, especialmente em aplicações finais do motor, como em equipamentos de construção. Nesse contexto, o motor e os componentes metálicos relacionados funcionam de maneira similar ao mecanismo de um clipe de escritório: ao ser aberto, esticado e fechado repetidamente, o clipe tende a falhar após um número determinado de ciclos. Assim, máquinas de construção a diesel operam, forçando o motor até que ele pare, e então reiniciam o funcionamento, acionando várias vezes a amplitude de tensão durante esse processo, conforme Costa Júnior (2018).

Nessa metodologia de falha, o fornecedor determina que a vida útil do injetor seja de, aproximadamente, 115 milhões de ciclos, apesar da recomendação direta seja conforme a do catálogo, o que pode ser representada por F , após isso, a probabilidade de falha passa de 1 por milhão. Conforme Eq. (7), pode-se calcular na mesma métrica do fabricante quantas horas serão necessárias para um injetor falhar, onde N são quantos ciclos por segundo o injetor realiza.

$$I = N \times 60s \times 60 \text{ min} \tag{6}$$

$$H = \frac{F}{I} = \frac{115.000.000}{4 \times 60 \times 60} = 7896h \sim 8000h \tag{7}$$

Verificando assim, que o fabricante utiliza uma estimativa de aproximadamente 85 milhões de ciclos até que o componente chegue a falha, ou em termos de horas trabalhadas, aproximadamente 6000h, conforme Tab. 1:

TABELA 1 - Comparação entre o catálogo padrão do fabricante e o resultado do estudo de Ciclo de Vida realizado, em relação à previsão de falha do componente.

Critérios	Desenvolvimento intelectual	Manejo de linguagem funcional
Ciclos até a falha [ciclos]	85.000.000	115.000.000
Utilização até a falha para 4 ciclos/s [h]	5.903	7.986

Fonte: O autor (2024).

Dessa maneira, o estudo trouxe uma variável mais assertiva e confiável em relação à troca de um injetor, podendo assim ser aplicada ao novo método de cálculo de demanda do fabricante, conforme será descrito adiante.

2.3 CONSTRUÇÃO DO CÁLCULO DE DEMANDA

Ao definir uma nova metodologia de forecast, entender quais as variáveis e o que as afeta é essencial, fato evidenciado por Ho e Yee (2015) . Após melhorar a acurácia tanto da previsão do horímetro ao qual cada máquina trabalhará, e também qual será o intervalo de troca ideal para substituir um componente, nesse caso um injetor na iminência de uma falha, o estudo propõe realizar a sequência de cálculo de impacto dessas novas variáveis dentro do negócio do fabricante.

Para isso, foram utilizados números genéricos baseados em um período específico de uma região específica, onde o fabricante tem uma grande operação. Inicialmente, foi levantada a demanda para o injetor 2024XXX, presente em 2634 equipamentos selecionados, com até 10 anos de entrega ao cliente, em diferentes clientes da mesma região:

TABELA 2 - Dados utilizados para validar a previsão.

Dados	Quantidade
Demanda no período avaliado [unidades]	574
Máquinas utilizando a peça [unidades]	2634
Tempo medido [meses]	12

Fonte: O autor (2024).

Com essa informação, pode-se definir o número ao qual o forecast de 12 meses deveria se aproximar, caso existisse uma precisão máxima: 574 unidades. Da mesma forma, verificaram-se as horas absolutas de todos os 2634 equipamentos nesse período:

TABELA 3 - Dados de utilização de máquinas, onde o injetor estudado é aplicado, no período de 12 meses avaliados.

Dados	Escavadeira	Carregadeira	Motoniveladora
Horas trabalhadas no período [h]	1.708.329	2.373.002	254.712
Número de equipamentos [unidades]	1.293	993	348
Média diária de utilização [h/dia]	4,02	7,26	2,22

Fonte: O autor (2024).

Portanto, para esse injetor 2024XXX, a previsão de demanda deveria ser com base em 4.336.043 horas totais para os próximos 12 meses. Dessa maneira, encontra-se o intervalo de troca médio realizado para o item, a partir da divisão de horas absolutas pela demanda realizada, apresentada na Eq. (8).

$$Intervalo\ de\ troca\ média\ [h] = \frac{Horas\ totais\ trabalhadas}{Demanda\ no\ mesmo\ período} \tag{8}$$

TABELA 4 - Intervalo de troca médio do injetor 2024XXX no período de 12 meses avaliado.

Dados	
Horas trabalhadas no período [h]	4.336.043
Demanda no período avaliado [unidades]	574
Intervalo de troca médio [h]	7554

Fonte: O autor (2024).

Chegando assim, às três variáveis principais dentro desse estudo de previsão de demanda, sendo possível a comparação da previsão realizada antes do estudo, e a nova metodologia. A partir da Eq. (9) percebe-se um aumento da precisão e redução no erro na nova metodologia aplicada.

$$Erro\ [%] = \left| \frac{Valor\ real - Valor\ previsto}{Valor\ previsto} \times 100 \right| \tag{9}$$

TABELA 5 - Impacto na previsão do intervalo de troca do injetor 2024XXX.

Dados	Catálogo do fabricante	Estudo de Ciclo de Vida
-------	------------------------	-------------------------

Intervalo de troca previsto [h]	6000	8000
Erro em relação à média realizada [%]	25,9	5,6

Fonte: O autor (2024).

Inicialmente o erro foi de aproximadamente 25,9%, comparando o intervalo padrão utilizado pelo fabricante e a média realizada pelas máquinas no período de 12 meses, de 7554 horas. Quando utilizado o novo intervalo de troca definido pelo estudo de ciclo de vida desenvolvido, obteve-se um erro de aproximadamente 5,6% se comparado ao realizado pelas máquinas, uma mudança na previsão que vai melhorar significativamente o cálculo final de demanda.

Já na outra frente principal do projeto, a estimativa de horímetro das mesmas máquinas que utilizam o determinado injetor, foi feita a mesma comparação em relação ao método inicial do fabricante, utilizando uma média aritmética dos últimos 90 dias de comunicação das máquinas, e o novo modelo de séries temporais desenvolvido no estudo.

TABELA 6 - Impacto na previsão de horímetro dos 2634 equipamentos.

Dados	Modelo do fabricante	Modelo do estudo de ciclo de vida
Previsão de horímetro [h]	6.057.072	4.904.096
Erro em relação à utilização registrada [%]	28,4	11,5

Fonte: Fonte: O autor (2024).

Com a nova maneira de prever o horímetro das máquinas, o erro diminuiu significativamente, assim como na variável de intervalo de troca, partindo de 28,4% de imprecisão, para 11,5%, se comparado às horas absolutas de 4.336.043 horas. O impacto dessa redução de erro será evidenciado na próxima seção, onde será desenvolvido o cálculo de demanda para o injetor 2024XXX.

3 ESCOLHA DO MÉTODO

O método escolhido para resolução do problema é o TIR (Taxa interna de retorno), o qual traz o valor de uma taxa hipotética de retorno baseado em um fluxo de caixa livre, considerando o valor presente líquido igual a zero. No nosso estudo de caso temos três opções de investimento diferentes, que envolvem um fluxo de caixa livre começando negativamente, pois é o valor que teremos de “investimento” no primeiro momento, e

posteriormente a receita tirando os custos operacionais, de manutenção e tributos (ICMS e IPI).

Como o investimento apresenta um cenário unificado de economia, com mesmas taxas de juros, aumentos inflacionários e outros fatores iniciais de maquinário atual, o cálculo de todos os investimentos foi baseado no mesmo valor, já que a receita mensal continuará sendo R\$ 145.000,00 (em valores atuais) independente da linha que se escolher, pois é a quantidade máxima que a empresa consegue faturar, o que nos interessa é olhar o lucro que cada linha irá trazer para saber a que será mais atrativa economicamente. Para isso podemos olhar para dois fatores: qual linha se pagará primeiro e também qual tem a maior taxa interna de retorno no tempo em que a vida útil do equipamento ainda está ativa.

Em relação ao investimento feito para poder comprar as máquinas, como o determinado pelo caso-problema foi o SAF, devemos considerar que será um dinheiro “emprestado”, o qual deve ser pago em até 5 anos, utilizando juros compostos de 10%. Como o modelo é semelhante ao financiamento utilizado por bancos para compra de imóveis e carros, podemos considerar o valor futuro que esses juros resultarão através de função PGTO, que considera o valor do investimento aplicado para pagamento através de 5 parcelas anuais.

4 RESULTADOS E DISCUSSÃO

Esta seção foi separada em duas subseções, onde na primeira é apresentado o impacto que a melhoria de previsão de demanda possibilitou em termos de receita e eficiência de inventário para o injetor apresentado no estudo. Na segunda subseção, uma extrapolação estimada para todo o grupo de injetores utilizados pelo fabricante.

4.1 IMPACTO NA PREVISÃO DE ESTOQUE E RECEITA DE INJETORES

Ao aplicar a nova metodologia de estimativa de horímetro, a partir do intervalo de troca definido por ciclos de vida do produto, estima-se o impacto total de previsão de receita para o fabricante, a partir da Eq. (10):

$$Demanda\ (unidades) = \frac{Horas\ totais\ previstas\ (h)}{Intervalo\ de\ Troca\ (h)}$$

(10)

Dessa forma, resultou nos seguintes resultados:

TABELA 8 - Comparação do novo modelo de previsão de demanda para os injetores 2024XXX.

Dados	Modelo do fabricante	Modelo do estudo de ciclo de vida
Previsão de horímetro [h]	6.057.072	4.904.096
Intervalo de troca previsto [h]	6000	8000
Demanda total prevista [unidades]	1010	613

Fonte: Fonte: O autor (2024).

Quando comparado à quantidade vendida no período, de 574 unidades, que garantiria uma precisão de 100% no modelo, o erro do novo modelo é expressivamente menor que o modelo então utilizado pela empresa, calculado da mesma maneira que foi representado na Tabela 9:

TABELA 9 - Impacto na previsão de demanda dos injetores 2024XXX.

Dados	Modelo do fabricante	Modelo de estudo de ciclo de vida
Erro em relação à demanda [%]	43,2	6,4

Fonte: O autor (2024).

Dessa forma já pode-se medir o grande impacto positivo na gestão de estoque e suprimentos, onde cerca de 436 unidades de injetores seriam disponibilizados e armazenados de maneira desnecessária. Utilizando o novo modelo, esse impacto é reduzido para cerca de 39 unidades, possibilitando uma previsão de cobertura de estoque muito mais assertiva e segura.

Do ponto de vista comercial, utilizando um valor unitário genérico de 3000 reais por injetor, um valor dentro da média geral do mercado de máquinas de construções, o fabricante inicialmente previu cerca de 3.030.000 reais em receita somente para esse item nos 12 meses seguintes, no entanto, a receita convertida de fato, utilizando esse valor base, seria de cerca de 1.722.000 reais, gerando uma conversão aproximadamente 43,2% menor que o previsto, conforme Tab. 10.

TABELA 10 - Previsão de receita em 12 meses, a partir de um valor médio de R\$ 3.000 para o injetor 2024XXX.

Dados	Modelo do fabricante	Modelo de estudo de ciclo de vida
-------	----------------------	-----------------------------------

Estimativa de receita [R\$]	3.030.000	1.839.000
-----------------------------	-----------	-----------

Fonte: O autor (2024).

Já com o novo modelo de previsão de demanda, o forecast de receita seria de 1.839.000 reais, sendo assim 6,4% menor que o previsto, um impacto consideravelmente menor, visto que a previsão de receita é a base para todas as ações realizadas pelo departamento comercial e para o fornecimento de estoque da equipe logística, conforme informação compartilhada pela equipe comercial do fabricante.

Assim, o estudo trouxe um impacto positivo de 1.191.000 reais somente para o injetor 2024XXX, conforme Eq. (11):

$$Receita = 3.030.000 - 1.839.000 = 1.191.000 \quad (11)$$

4.2 EXTRAPOLAÇÃO DO MODELO PARA TODO O PORTFÓLIO DE INJETORES

Dentro do portfólio de pós-vendas do fabricante, o grupo de injetores compõe uma parcela relevante de receita, onde a estimativa tanto do modelo padrão, quanto do novo modelo descrito nesse estudo, são aplicadas da mesma forma para os outros injetores utilizados no portfólio de equipamentos. Assim é possível utilizar esse grupo para estimar a melhoria geral de previsão de estoque e receita de maneira extrapolada.

Se comparado ao mesmo período de 12 meses utilizados no estudo, mais de 2500 unidades de injetores foram vendidas, informação também compartilhada pela equipe comercial do da montadora, gerando um impacto em cerca de 3% de toda a receita anual do fabricante. Dessa forma pode-se prever qual seria o impacto do erro apresentado anteriormente, e a nova precisão de forecast de demanda proposta, para toda a categoria desse componente, utilizando também um valor genérico de 3.000 reais por unidade.

$$Receita = 2.500 \text{ unidades} \times 3.000 = 7.500.000 \quad (12)$$

Como foi evidenciado na Tab. 9, aplicando o erro percentual dos dois modelos, é possível identificar a previsão de receita e de demanda para o grupo de injetores para ambos os modelos, e qual o impacto para o fabricante.

Inicialmente pelo modelo padrão do fabricante:

$$Receita \text{ prevista} = \frac{7.500.000}{1 - 43,2\%} = 13.204.225 \quad (13)$$

$$Erro = 13.204.225 - 7.500.000 = 5.704.225 \quad (14)$$

$$Demanda \text{ prevista [unidades]} = \frac{2.500}{1 - 43,2\%} = 4.401 \quad (15)$$

$$Erro [unidades] = 4.401 - 2.500 = 1.901 \quad (16)$$

Da mesma forma, realizando o cálculo a partir do novo modelo de estudo de ciclo de vida do produto:

$$Receita prevista = \frac{7.500.000}{1 - 6,4\%} = 8.012.820 \quad (17)$$

$$Erro = 8.012.820 - 7.500.000 = 512.820 \quad (18)$$

$$Demanda prevista [unidades] = \frac{2.500}{1 - 6,4\%} = 2.671 \quad (19)$$

$$Erro [unidades] = 2.671 - 2.500 = 171 \quad (20)$$

TABELA 11 - Impacto na previsão de receita e demanda em 12 meses, a partir de um valor médio unitário de R\$ 3.000 para todos os injetores utilizados pelo fabricante.

Dados	Modelo do fabricante	Modelo de estudo de ciclo de vida
Erro na estimativa de receita [R\$]	5.702.225	512.820
Erro na estimativa de demanda [unidades]	1.901	171

Fonte: O autor (2024).

Dessa forma, chega-se ao indicador principal que o presente estudo alcançou: uma redução de erro 91% na previsão de receita e demanda, que impacta a saúde financeira e de cadeia de suprimentos em 5.189.405 reais, baseando-se num valor unitário médio de 3.000 reais por injetor, para o fabricante referenciado, conforme Eq. (21):

$$Impacto de receita = 5.702.225 - 512.820 = 5.189.405 \quad (21)$$

Essa melhora na previsão de forecast de demanda e receita também reduz futuros custos de descarte de peças, necessidade de aumento de galpões logísticos para armazenagem e uma melhor disponibilidade de mão de obra para a fábrica, visto que não será atingida uma demanda muito acima do cenário previsto para os próximos 12 meses.

5 CONCLUSÃO

A previsão de demanda de peças para máquinas de construção, utilizando o modelo ARIMA com base em dados de telemetria e um estudo detalhado do ciclo de vida conduzido no fornecedor, revelou-se uma ferramenta valiosa para a otimização da cadeia

de suprimentos e a gestão eficiente do pós-venda do fabricante de máquinas de construção avaliado. O modelo proposto não apenas aprimorou a precisão nas previsões de utilização horária e substituição de componentes, como também reduziu significativamente os erros de forecast, a partir da diminuição da imprecisão na previsão de horímetros de 28,4% para 11,5% e do intervalo de troca de componentes de 25,9% para 5,6%, conforme comprovado pelos resultados de demanda e receita.

Em termos financeiros e comerciais, essa redução equivale a uma diminuição anual de aproximadamente 5,2 milhões de reais em custos logísticos, por conta de uma previsão de demanda mais acertiva. E além da saúde financeira, o modelo trouxe avanços qualitativos na cadeia de suprimentos, com uma diminuição de aproximadamente 1730 injetores no estoque, oferecendo ao setor logístico uma visão mais precisa de forecast, aplicada para o grupo de injetores, com uma redução de 91% no erro de previsão de demanda, otimizando toda a cadeia, desde o fornecimento até o envio das peças. O estudo foi realizado e extrapolado com base no grupo de injetores, mas sugere-se que a nova metodologia seja expandida para outros componentes, como filtros, peças hidráulicas e motores, ampliando ainda mais seus benefícios para toda a cadeia de pós-venda.

Assim, conclui-se que a abordagem proposta não apenas aprimora a eficiência financeira, operacional e a gestão de estoques, mas também fortalece a posição competitiva do fabricante no mercado de máquinas de construção.

6 REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE TECNOLOGIA PARA CONSTRUÇÃO E MINERAÇÃO. Estudo de mercado. 2023. Disponível em: <https://sobratema.org.br/EstudoMercado>. Acesso em: 24 nov. 2024.

JIHAO, Z.; MING, C. After-sale data based common rail injector remanufacturability analysis. 2018. Disponível em: <https://link.springer.com/article/10.1007/s12204-018-1948-3>. Acesso em: 17 fev. 2025.

SILVA, C. L. Avaliação do desgaste triboquímico de agulhas dos bicos injetores em motores diesel operando com biodiesel. 2015. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal do Rio Grande do Norte, Natal, 2015. Disponível em: https://repositorio.ufrn.br/bitstream/123456789/22384/1/LeonardoChagasDaSilva_DISSERT.pdf. Acesso em: 18 fev. 2025.

BERGSTRAND, L.; JÖNSSON, J. Preparing for tomorrow: exploring design adaptations of a wheel loader for a circular business model. Gothenburg, Sweden, 2017.

KEGL, T. Materials for common rail diesel fuel injection systems. *Materials and Manufacturing Processes*, v. 27, n. 4, p. 387–394, 2012. Disponível em: <https://doi.org/10.1080/10426914.2011.610077>. Acesso em: 17 fev. 2025.

COSTA JÚNIOR, E. R. DA. Redução das horas com a manutenção corretiva dos motores diesel a partir de avaliação da confiabilidade. 2018. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Itajubá, Itajubá. Disponível em: <https://repositorio.unifei.edu.br/handle/123456789/2447>. Acesso em: 13 fev. 2025.

RAHMAN, M. M. et al. Comparison of diesel engine performance between a mechanical pump and a common rail fuel injection system equipped with real-time non-surfactant emulsion fuel supply system. *Journal of Advanced Research in Fluid Mechanics and Thermal Sciences*, v. 91, n. 2, p. 41–50, 2022. Disponível em: <https://doi.org/10.37934/arfmts.91.2.4150>. Acesso em: 15 fev. 2025.

BARNETT, V.; LEWIS, T. *Outliers in statistical data*. 3rd ed. Chichester: Wiley, 1994. Disponível em: <https://doi.org/10.1002/bimj.4710370219>. Acesso em: 16 fev. 2025.

BROCKWELL, P. J.; DAVIS, R. *Introduction to time series and forecasting*. New York: Springer, 2002.

BUDYNAS, R. G.; NISBETT, J. K. *Shigley's mechanical engineering design*. 10th ed. New York: McGraw-Hill Education, 2016.

GLOBENEWSWIRE. Global \$15.13 billion autonomous construction equipment markets. 2021. Disponível em: <https://www.globenewswire.com/en/news-release/2021/05/24/2234570/28124/en/Global-15-13-Billion-Autonomous-Construction-Equipment-Markets-2015-2020-2020-2025F-2030F-Earth-Moving-Construction-Vehicles-Material-Handling-and-Concrete-Road-Construction.html>. Acesso em: 28 nov. 2024.

GOLARA, S.; DOOLEY, K. J.; MOUSAVI, N. Are dealers still relevant? How dealer service quality impacts manufacturer success. *Production and Operations Management*, 2021. Disponível em: <https://doi.org/10.1111/poms.13450>. Acesso em: 30 nov. 2024.

GRANSKOG, A.; GUTTMAN, B.; SJÖDIN, E. Toward a customer-centric construction-equipment industry. McKinsey & Company, 2016. Disponível em: <https://www.mckinsey.com/industries/automotive-and-assembly/our-insights/toward-a-customer-centric-construction-equipment-industry>. Acesso em: 16 fev. 2025.

HEYWOOD, J. B. *Internal combustion engine fundamentals*. 2nd ed. New York: McGraw-Hill Education, 2018.

HUSSEIN, M. A real-time anomaly detection in satellite telemetry data using artificial intelligence techniques depending on time-series analysis. *ACS Advances in Computer Science*, 2023. Disponível em: https://www.researchgate.net/publication/375970899_A_Real-Time_Anomaly_Detection_in_Satellite_Telemetry_Data_Using_Artificial_Intelligence_Techniques_Depending_on_Time-Series_Analysis. Acesso em: 30 nov. 2024.

IBM. *IBM SPSS Modeler CRISP-DM Guide*. 2013. Disponível em: https://public.dhe.ibm.com/software/analytics/spss/documentation/modeler/16.0/en/modeler_crispdm_book.pdf. Acesso em: 15 nov. 2024.

LE, T.-T. et al. A fault diagnosis method for fuel injectors using machine sound. In: *2020 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, Beijing, China, 2020.

MARTÍNEZ-PLUMED, F. et al. CRISP-DM twenty years later: from data mining processes to data science trajectories. 2021. Disponível em: <https://ieeexplore.ieee.org/document/8943998>. Acesso em: 15 fev. 2025.

KHAN, S.; ALGHULAIKHA, H. ARIMA model for accurate time series stocks forecasting. *International Journal of Advanced Computer Science and Applications*, v. 11, n. 7, 2020. Riyadh, Saudi Arabia.

SINOMACH-HI INTERNATIONAL EQUIPMENT CO., LTD. Carregadeira de rodas 955N. Disponível em: <http://sinomachhiglobal.com.br/1-13-wheel-loader-955n.html>. Acesso em: 15 nov. 2024.

HO, C. C.; YEE, T. Time series analysis and forecasting of dengue using open data. 2015. Disponível em: https://www.researchgate.net/publication/284142511_Time_Series_Analysis_and_Forecasting_of_Dengue_Using_Open_Data. Acesso em: 15 fev. 2025.

TZANETAKIS, T. et al. Durability study of a high-pressure common rail fuel injection system using lubricity additive-dosed gasoline-like fuel. *SAE International Journal of Fuels and Lubricants*, v. 16, p. 237–251, 2023. Disponível em: <https://doi.org/10.4271/04-16-03-0017>. Acesso em: 12 dez. 2024.

VOLVO CONSTRUCTION EQUIPMENT. Volvo CE moves into 3D printing of parts. 2018. Disponível em: <https://www.volvoce.com/global/en/news-and-events/news-and-press-releases/2018/volvo-ce-moves-into-3d-printing-of-parts/>. Acesso em: 26 mar. 2018.

WILD, C. J.; SEBER, G. A. F. *Encontros com o acaso: um primeiro curso de análise de dados e inferência*. Tradução de Cristiana Filizola Carneiro Pessoa e Djalma Galvão Carneiro Pessoa. Rio de Janeiro: LTC, 2004.

RAKSHITHA, S.; MALLIKA, B. K. A study on cost analysis at Volvo construction equipment. Bangalore, India, 2018.

GRANSBERG, D. D.; POPESCU, C. M.; RYAN, R. *Construction equipment management for engineers, estimators, and owners*. 1st ed. Boca Raton: CRC Press, 2006.

KIRKIZOĞLU, Z.; KARAER, Ö. After-sales service and warranty decisions of a durable goods manufacturer. Ankara, Turkey, 2022.

APIPATTANAVIS, S. et al. An integrated framework for quantifying and predicting weather-related highway construction delays. *Journal of Construction Engineering and Management*, 2010. Disponível em: [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000199](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000199). Acesso em: 16 fev. 2025.

WANG, X.; DUNSTON, P. S.; SKINIEWSKI, M. Mixed reality technology applications in construction equipment operator training. In: *21st International Symposium on Automation and Robotics in Construction*, West Lafayette: ISARC, 2004.

TEIXEIRA, C.; LOPES, I.; FIGUEIREDO, M. Multi-criteria classification for spare parts management: a case study. *Procedia Manufacturing*, Modena, Italy, 2017.

GUARNACCIA, C. et al. Acoustical noise analysis and prediction by means of multiple seasonality time series model. *International Journal of Mathematical Models and Methods in Applied Sciences*, Salerno, Italy, 2014.

BORSATO, R.; CORSO, L. L. Aplicação de inteligência artificial e ARIMA na previsão de demanda no setor metal mecânico. *Scientia cum Industria*, 2019. Disponível em: https://www.researchgate.net/publication/337975233_Aplicacao_de_Inteligencia_Artifi

[cial e ARIMA na Previsao de Demanda no setor metal mecanico](#). Acesso em: 16 fev. 2025.

DASH, C. S. K. et al. An outliers detection and elimination framework in classification task of data mining. *Decision Analytics Journal*, Bhubaneswar, India, 2023.

7 RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.