



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

APLICAÇÃO DE MÉTODOS DE PREVISÃO: ANÁLISE DAS PARADAS DE MÁQUINAS EM UMA EMPRESA NO LITORAL DO PARANÁ

Gabriel Corrêa Campos Graces de Oliveira

Ciências Sociais Aplicadas - Universidade Estadual do Paraná, Endereço, 83203-560, Paranaguá, Paraná

Issamy Kuriyama da Costa

Ciências Sociais Aplicadas - Universidade Estadual do Paraná, Endereço, 83203-560, Paranaguá, Paraná

Maria Cecília Ferrari de Carvalho Teixeira

Ciências Sociais Aplicadas - Universidade Estadual do Paraná, Endereço, 83203-560, Paranaguá, Paraná

Resumo: Este estudo teve como objetivo prever o comportamento dos dados de paradas de máquina de uma empresa do litoral do Paraná. Para isso foram utilizados modelos de previsão ARIMA e Redes Neurais, a fim de identificar algum padrão de sazonalidade e tendência nas variações desses dados. Como base de dados, tem-se 17 mil informações sobre as falhas de equipamentos, incluindo variáveis que podem influenciar no acontecimento desses eventos. Como resultado, viu-se que fatores como setor de ocorrência e tipo de veículo possuem uma maior incidência e precisam de uma investigação mais detalhada. Como contribuições práticas, o artigo utiliza técnicas de previsão a benefício da gestão de manutenção, prevendo falhas e gerando oportunidades para tomadas de decisão estratégicas com base nesses dados, e de forma teórica, o estudo contribui com a ampliação da aplicação dessas técnicas em um setor de manutenção, visto que o tema é inexplorado na literatura atual.

Palavras-chave: Modelos de previsão, Séries Temporais, Manutenção.

Application of Prediction Methods: Analysis of Machine Stoppages in a Company on the Paraná Coast

Abstract: This study aimed to predict the behavior of the machine downtime data of a company on the coast of Paraná. For this, ARIMA and Neural Network forecasting models were used to identify any seasonal pattern and trend in the variations of these data. The database has 17 thousand

pieces of information about equipment failures, including variables that may influence the occurrence of these events. As a result, it was seen that factors such as the occurrence sector and vehicle type have a higher incidence and need further investigation. As practical contributions, the article uses forecasting techniques for the benefit of maintenance management, predicting failures and generating opportunities for strategic decision-making based on these data. In a theoretical way, the study contributes to the expansion of the application of these techniques in a maintenance sector, as the theme is unexplored in the current literature.

Keywords: Forecast models, Time Series, Maintenance.

1. Introdução

O crescimento das empresas e aumento dos concorrentes vem trazendo a necessidade de se ter mais qualidade e rapidez nos processos, visando alcançar a eficiência máxima nos resultados com uma visão estratégica. Como resultado, as organizações vêm buscando incessantemente novas ferramentas de gerenciamento, que as direcionam para uma maior competitividade através da qualidade e produtividade de seus produtos, processos e serviços (KARDEC, 2004). De modo a se tornarem mais competitivas, as empresas necessitam que as funções básicas representadas pelos diversos departamentos de sua estrutura apresentem resultados excelentes na busca de status de excelência (MIRSHAWKA, 1993).

A manutenção, como função estratégica das organizações, é responsável direta pela disponibilidade dos ativos, tem importância capital nos resultados da empresa. Esses resultados serão tanto melhores quanto mais eficaz for a gestão da manutenção (OTANI, 2008). A gestão de manutenção é uma abordagem chave para garantir o funcionamento adequado dos processos, pois a falha de máquinas afeta a produção de diversos setores, o que impacta no resultado final do negócio. Segundo Sellito (2005), a função manutenção industrial tem incorporado às suas estratégias usuais de gerenciamento alguns conceitos originados na confiabilidade. Para Moubray (1996), a manutenção tem procurado novos modos de pensar, técnicos e administrativos, já que as novas exigências de mercado tornaram visíveis as limitações dos atuais sistemas de gestão.

Os modelos de previsão desempenham um papel-chave em diversas áreas na gestão de organizações (PELLEFRINI, 2000), e por isso tem se mostrado cada vez mais presentes e essenciais na análise dos processos e nas tomadas de decisão. De acordo com Santos (2017), a previsão de demanda é extremamente importante no sistema produtivo, visto que as informações obtidas por essa previsão permitem que os responsáveis deste setor prevejam o futuro para que assim consigam planejar suas ações apropriadamente.

O presente estudo tem como objetivo utilizar os modelos de previsão, explorando diferentes abordagens e metodologias, a fim de identificar as causas e fatores que influenciam as paradas de máquina da empresa analisada. Por meio da análise de dados históricos coletados, buscamos desenvolver modelos que antecipem essas paradas, trazendo comparações dos mesmos para maior precisão e identificação das variáveis que estão relacionadas com essas falhas no processo, a fim de proporcionar uma visão das causas e possíveis estratégias para a tomada de decisão na gestão de manutenção dessas máquinas.

2. Procedimento Metodológico

Os métodos utilizados de abordagem foram quantitativos, com os dados de parada de máquina da empresa localizada no litoral do Paraná. A estratégia de pesquisa foi o estudo de caso e com técnicas de coleta de dados, fez-se o uso da análise qualitativa dos dados obtidos, com o intuito de descrever questões relacionadas a previsão de demanda e

fatores de influência.

2.1 Técnicas de Previsão

As técnicas de previsão de demanda classificam-se em três categorias gerais: qualitativa, análise de séries temporais e modelos causais. Séries temporais foram definidas como 'sequências de dados quantitativos relativos a momentos específicos e estudados segundo sua distribuição no tempo' (WIENER, 1966). Já para Tubino (2009), esse é o método mais simples e usual de previsão e pode gerar bons resultados quando elaborado corretamente. Os modelos de séries temporais: Arima e Redes Neurais são o foco deste estudo.

O método ARIMA oferece ótima flexibilidade na identificação de modelos de séries temporais univariadas, estimativa de parâmetros e previsão (BOX, 1975). É uma abordagem estatística amplamente utilizada para previsão de séries temporais. Ele é baseado em dois componentes principais: a parte auto regressiva (AR) e a parte de média móvel (MA). Além disso, o ARIMA também incorpora uma diferenciação para tornar a série temporal estacionária, permitindo a aplicação dos componentes AR e MA. A equação do modelo ARIMA é dado pela fórmula da Figura 1 abaixo.

Figura 1 – Equação ARIMA

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

Onde:

- Y_t é o valor da série temporal no momento t .
- c é a constante do modelo.
- $\phi_1, \phi_2, \dots, \phi_p$ são os parâmetros autoregressivos.
- $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ são os valores passados da série.
- $\theta_1, \theta_2, \dots, \theta_q$ são os parâmetros de média móvel.
- ε_t é o erro no momento t .

Fonte: Elaborado pelos Autores

Outro método que será realizada a análise é a Redes Neurais, em que o processo envolve alimentar entradas para que haja treinamento destes dados, a medida que passa por exemplos destes treinamentos, tem-se o ajuste e busca encontrar possíveis padrões e relações para estes dados. O aprendizado das redes neurais tem capacidade de adaptarem os seus parâmetros como consequência da sua interação. (MEIRELES, 2011). Neste estudo, baseado em a arquitetura da Rede Neural em Recorrentes (RNNs), possuem conexões que permitem que as informações sejam passadas de um determinado tempo para uma próxima sequência. Deste modo, as RNNs capturam padrões temporais e dependências ao longo dos dados sequenciais. A equação do modelo de Redes Neurais é dado pela fórmula da Figura 2 abaixo.

Figura 2 – Fórmula Redes Neurais

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * \nabla w_t$$
$$v_t = \beta_2 * v_{t-1} + (1 - \beta_2) * (\nabla w_t)^2$$
$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$
$$w_{t+1} = w_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} * \hat{m}_t$$

Fonte: Elaborado pelos Autores

Para avaliar o desempenho desses modelos de previsão utilizados no estudo, serão implementados cálculos dos erros de previsão. O erro de previsão é a diferença entre a previsão e a demanda real (COBRA, 1994). As medidas de erro utilizadas para análise foram o erro médio, erro quadrático e erro absoluto, como visto na tabela 1 abaixo.

Tabela 1 – Medidas de Erros

Medidas de Erro	Descrição	Fórmula
Erro Médio	O erro médio é a média aritmética dos erros de previsão. Ele pode ser positivo ou negativo, dependendo da previsão	$ME = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)$ <p>Onde:</p> <ul style="list-style-type: none"> • n é o número de observações. • Y_i é o valor real observado. • \hat{Y}_i é o valor previsto pelo modelo.
Erro Absoluto	O erro médio absoluto é a média das magnitudes dos erros de previsão, ignorando as direções (positiva ou negativa). Ele é uma medida de quão distantes as previsões estão dos valores reais.	$MAE = \frac{1}{n} \sum_{i=1}^n Y_i - \hat{Y}_i $
Erro Quadrático	O erro médio quadrático é a média dos quadrados dos erros de previsão. Ele amplifica erros maiores e é amplamente utilizado em modelos de regressão e previsão	$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$ <p>Onde:</p> <ul style="list-style-type: none"> • n é o número de observações. • Y_i é o valor real observado. • \hat{Y}_i é o valor previsto pelo modelo.

Fonte: Alura (2021)

O erro médio, erro médio absoluto e erro médio quadrático são usados para avaliar a qualidade das previsões e o desempenho do modelo. O objetivo é minimizar essas medidas, pois valores menores indicam que as previsões estão mais próximas dos valores reais.

3. Referencial Teórico

Para dar início ao estudo da previsão de quebras das máquinas, implementou-se modelos de previsão por meio de linguagem Python, e a partir disso, realizou-se todas as etapas para encontrar os resultados sobre o que ocasionaria as paradas destes equipamentos, e se esses eventos seriam falhas sazonais e se possuíam alguma tendência.


Como primeira etapa, foi preciso realizar um tratamento dos dados para obter maior precisão nos resultados, algumas informações não seriam utilizadas na previsão, como por exemplo, o número da ordem de serviço para manutenção, a data e a hora programada para manutenção, o custo do material, a descrição da falha ocorrida pela operação e o responsável por realizar a avaliação da manutenção na área. Deste modo, retirou-se estas informações e levou-se em consideração os seguintes dados que seriam de suma importância para a análise da previsão: 'Modelo do Maquinário', 'Tipo do Equipamento', 'Data da solicitação da manutenção', 'Tipo de manutenção' à ser realizada, 'Equipe responsável pela manutenção', e o 'Custo de mão de obra'.

Para a análise, foram levados em conta 9 tipos de maquinários que estavam disponíveis na empresa, dos quais sofreram paradas e necessitam de manutenção dos seguintes motivos: Mecânico, Elétrico, Borracharia, Climatização, Hidráulico e/ou Flúidos, Acidente e Caldeiraria. Essas variáveis foram utilizadas para identificar possíveis causas de

problemas em equipamentos específicos.

Após estratificado e tratado os dados que seriam relevantes à pesquisa, iniciou uma análise prévia com gráficos para uma visualização inicial dos dados, como pode ser visto na Figura 3 abaixo.


Figura 3 – Quadro de Quantidade de Quebras das Máquinas



Fonte: Elaborado pelos autores

Com base nisso, evidencia-se que as máquinas 01 e 02 possuíram maior quantidade de falhas com relação às outras máquinas, sendo fundamental para uma análise prévia dos dados de quais equipamentos têm maior parada. Outro aspecto, foi com relação ao Tipo de Serviço em que a Mecânica e Elétrica foram os principais que apresentaram problemas nos equipamentos, como é mostrado na Figura 4 abaixo.


Figura 4 – Quadro de Quantidade de Natureza de Serviços



Fonte: Elaborado pelos autores

Logo em seguida, houve a aplicação dos modelos de previsão para analisar o comportamento dos dados e identificar alguma tendência ou sazonalidade nas falhas das máquinas. Em primeira análise, o método ARIMA foi aplicado para verificar tendência nos dados, a princípio, foram separadas as datas das quebras de forma mensal, e com isso, investigou juntamente a frequência das quebras dos equipamentos. O resultado da previsão de quebras levando em consideração todos os Tipos de Maquinários pôde ser verificado visualmente no gráfico da Figura 5.

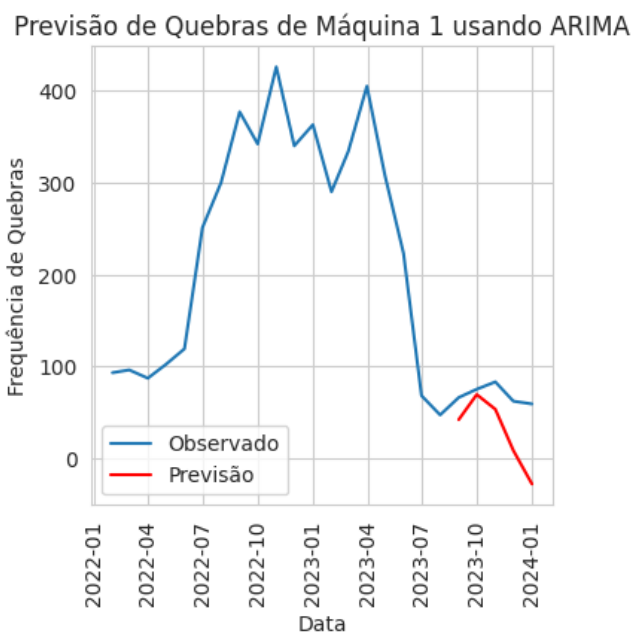
Figura 5 – Gráfico de Previsão Geral de Quebras das Máquinas com o Modelo de Previsão ARIMA



Fonte: Elaborado pelos autores

Para efeitos de estudo, neste artigo foi considerado apenas os dois equipamentos com maiores quebras e as duas naturezas de serviços mais frequentes realizadas, visto que os outros Tipos de Maquinários e outros Tipos de Serviços não tiveram tantos dados para que pudessem garantir maior disponibilidade de variáveis nas previsões. Deste modo, o gráfico de previsão obtido para o maquinário 01 e 02 pode ser visualizado nas Figuras 6 e 7.

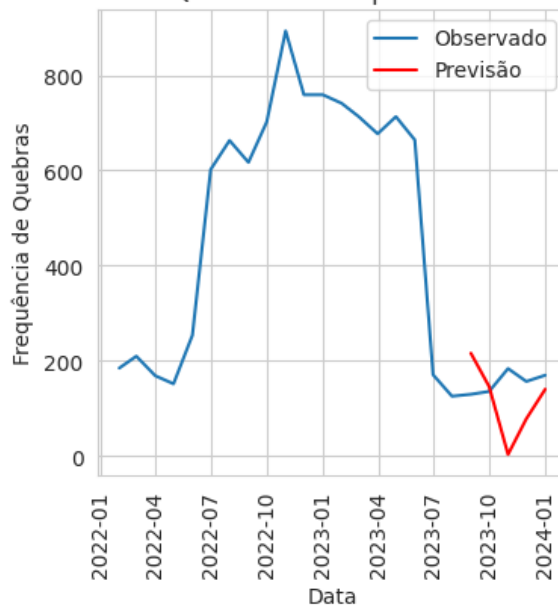
Figura 6 - Gráfico de Previsão de Quebras da Máquina 01 usando o modelo de previsão ARIMA.



Fonte: Elaborado pelos autores

Figura 7 - Gráfico de Previsão de Quebras da Máquina 02 usando o modelo de previsão ARIMA.


Previsão de Quebras de Máquina 2 usando ARIMA



Fonte: Elaborado pelos autores


Outro aspecto que foi utilizado para análise no modelo ARIMA, é a frequência de quebras por Tipo de Serviço com relação às datas de quebras mensalmente. Os Tipos de Serviços Mecânico e Elétrico podem ser vistas nos gráficos das Figuras 8 e 9.

Figura 8 - Taxas de quebras por Tipo de Serviço Mecânico usando modelo de previsão ARIMA.



Fonte: Elaborado pelos autores

Figura 9 - Taxas de quebras por Tipo de Serviço Elétrico usando modelo de previsão ARIMA.



Fonte: Elaborado pelos autores


4. Resultados

Em suma, as análises temporais utilizando-se do método ARIMA proporcionaram uma macrovisão sobre as naturezas de manutenção do maquinário, demonstrando que as mesmas não dispuseram de uma sazonalidade específica, mas tiveram as categorias de serviço de Mecânica e de Elétrica como principais responsáveis pelas falhas apresentadas nos veículos. Essa característica se deu principalmente pela quantidade maior dos maquinários 01 e 02. Ainda sobre o método ARIMA, não se achou necessário a aplicação de métricas de desempenho como acurácia, Erro Médio Absoluto e Erro Médio Quadrático pois ficou claro que não houve precisão na previsão do modelo em comparação com o observado.

A título de comparação, foi decidido também a aplicação de um segundo método para análise temporal dos dados, que são as Redes Neurais. O parâmetro optimizer na criação de modelos de redes neurais se refere ao otimizador utilizado durante o treinamento do modelo. O otimizador é um algoritmo que ajusta os pesos das conexões entre as camadas da rede neural de forma a minimizar a função de perda (loss function), o que melhora o desempenho do modelo.

O adam, otimizador utilizado na análise, é um dos otimizadores populares usados em redes neurais e é uma sigla que representa "Adaptive Moment Estimation". O otimizador Adam é uma combinação do método de otimização RMSProp e do algoritmo de gradiente descendente estocástico (SGD). Ele adapta a taxa de aprendizado dos pesos das conexões com base nas médias das primeiras e segundas ordens dos gradientes. O otimizador Adam é frequentemente escolhido por sua eficácia em muitos cenários de treinamento de redes neurais, pois ele tende a convergir mais rápido do que métodos tradicionais como o SGD como mostra a Figura 9 abaixo.

Figura 9 - Previsão de Quebras por Mês usando modelo de Redes Neurais.



Fonte: Elaborado pelos autores

Já com as Redes Neurais, é possível notar que houve uma precisão maior na previsibilidade dos dados, com Erro Médio Quadrado de 2.34, demonstrando ser um modelo melhor do que o ARIMA para conseguir prever as quebras mensais dos veículos.

5. Conclusões

Este estudo teve como objetivo prever o comportamento dos dados de paradas de máquina de uma empresa do litoral do Paraná. Para isso foram utilizados modelos de previsão, a fim de identificar alguma sazonalidade e tendência nas variações desses dados, tendo como resultado prévio a não existência de ambas características, tornando o modelo inadequado para esta análise.

Conclui-se, portanto, que não houve sazonalidade em nenhuma das paradas, apenas houve um aumento expressivo no final de 2022 e começo de 2023. Ao comparar os modelos de previsão ARIMA com Redes Neurais, foi possível constatar que a Rede Neural estabelecida para esse dataset foi capaz de prever com maior exatidão o comportamento dos gráficos. Ainda nota-se, a existência maior de problemas e paradas nas máquinas do tipo 01 e 02 e maior falhas na parte Elétrica e Mecânica desses maquinários. O artigo possui contribuições práticas de como as técnicas de previsão podem ser utilizadas a benefício da gestão de manutenção, prevendo falhas e gerando oportunidades para tomadas de decisão estratégicas com base nesses dados, e de forma teórica, o estudo contribuir com a aplicação em um setor de manutenção, visto que o tema não é muito explorado na literatura atual.

Para futuras pesquisas, o estudo pode ser expandido com o tratamento dos dados pela descrição das causas de quebra dos veículos, a fim de obter maiores detalhes sobre as mesmas, além de ser preciso aumentar a base de dados com outras informações necessárias para esta análise, como: ano e quilometragem do veículo, recomendação do fabricante para manutenção, entre outros fatores que podem interferir nas falhas do maquinário.

Recomenda-se expandir mais a base de dados por alguns anos para verificar se existe sazonalidade anual ao invés de ser mensal.

6. Referências

BOX, George EP, and George C. Tiao. "Intervention analysis with applications to economic and environmental problems." **Journal of the American Statistical Association** 70.349 (1975): 70-79.

COBRA, M. **Administração de Vendas**. S. Paulo: Atlas, 1994

KARDEC, Alan; NASCIF, Julio. **Manutenção Função Estratégica**, 2ª edição, 1ª Reimpressão 2004. **Editora Quality Mark**, Rio de Janeiro, Coleção Manutenção, Abraman.

MEIRELES, Magali Rezende Gouvêa; CENDÓN, Beatriz Valadares. "Categorização e Classificação de documentos a partir de suas citações: uma proposta baseada em Redes Neurais Artificiais". **DataGramZero - Revista de Informação**, 2011.

MIRSHAWKA, V.; OLMEDO, N.L. **Manutenção - Combate aos Custos da Não-Eficácia: A Vez do Brasil**. São Paulo: Makron Books do Brasil Editora Ltda., 1993.

MOUBRAY, J. **Introdução à manutenção centrada na confiabilidade** São Paulo: Aladon, 1996.

OTANI, Mario; MACHADO, Waltair Vieira. A proposta de desenvolvimento de gestão da manutenção industrial na busca da excelência ou classe mundial. **Revista Gestão Industrial**, v. 4, n. 2, 2008.

PELLEGRINI, Fernando Rezende. **Metodologia para implementação de sistemas de previsão de demanda**. Porto Alegre: UFRGS, v. 146, 2000.

PENTEADO, Karoline. Métricas de avaliação para séries temporais. **Alura**. Disponível em: <<https://www.alura.com.br/artigos/metricas-de-avaliacao-para-series-temporais>>. Acesso em: Setembro de 2023

RANGEL, Yasmim Lima et al. ANÁLISIS DEL IMPACTO DE LAS TECNOLOGÍAS DISRUPTIVAS DE LA CUARTA REVOLUCIÓN INDUSTRIAL UTILIZANDO MÉTODOS DE PRONÓSTICO DE LA DEMANDA: UN ESTUDIO DE CASO EN UNA EMPRESA DE ALIMENTOS MINORISTAS. REFAS: **Revista FATEC Zona Sul**, v. 8, n. 4, p. 4, 2022.

SANTOS, Tiago & ALVES, LUCAS. (2017). Aplicação de métodos de previsão de demanda e gestão de estoque em um produto de um supermercado na cidade de Marabá-PA. **ENEGEP**, 10.14488/ENEGEP2017_TN_STP_238_378_31086.

SASSI, Cecilia P. et al. Modelos de regressão linear múltipla utilizando os softwares R e Statistica: uma aplicação a dados de conservação de frutas. **Repositório USP** 2012.

SELLITTO, Miguel Afonso. Formulação estratégica da manutenção industrial com base na confiabilidade dos equipamentos. **Production**, v. 15, p. 44-59, 2005.

VERÍSSIMO, Andrey Jonas et al. Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v. 4, 2013.