


**DESENVOLVIMENTO DE UMA FERRAMENTA EM PYTHON PARA ANÁLISE DE
DADOS DE TEMPO DE FALHA COM APLICAÇÕES EM ENGENHARIA DE
MANUTENÇÃO**

**DEVELOPMENT OF A PYTHON TOOL FOR ANALYZING FAILURE TIME DATA WITH
APPLICATIONS IN MAINTENANCE ENGINEERING**

**DESARROLLO DE UNA HERRAMIENTA PYTHON PARA EL ANÁLISIS DE DATOS DE
TIEMPO DE FALLO CON APLICACIONES EN INGENIERÍA DE MANTENIMIENTO**

 <https://doi.org/10.56238/arev7n7-175>

Data de submissão: 15/06/2025

Data de publicação: 15/07/2025

João Vitor Paiva Luz

Graduando em Engenharia de Produção
UFRN, Natal, Brasil

Herbert Ricardo Garcia Viana

Doutor em Engenharia de Produção
UFRN, Natal, Brasil

RESUMO

Este trabalho propõe o desenvolvimento de uma aplicação em Python com interface via Streamlit, capaz de realizar análises básicas de confiabilidade de forma acessível e interativa. A metodologia utilizada caracteriza-se como uma pesquisa aplicada e exploratória, com construção e validação da ferramenta por meio de um experimento computacional. A aplicação permite a importação de arquivos CSV ou Excel contendo dados de falha, além de oferecer um conjunto de dados de exemplo. São calculadas funções clássicas da engenharia da confiabilidade: densidade de probabilidade, falha acumulada, confiabilidade e taxa de falha. O ajuste das curvas é realizado por regressão polinomial, sendo o coeficiente de determinação (R^2) utilizado como métrica de avaliação do modelo. A ferramenta foi validada com dados reais extraídos dos estudos de Aguiar (2019) e Viana et al. (2018), apresentando resultados coerentes com os trabalhos de referência. Contudo, reconhece-se como limitação o uso da regressão polinomial, que, embora útil para visualização, pode comprometer a precisão em análises probabilísticas mais rigorosas. Como sugestão para trabalhos futuros, destaca-se a inclusão de distribuições como Weibull e Exponencial, além da incorporação de testes de aderência estatística.

Palavras-chave: Confiabilidade. LDA. Python. Tempo de Falha. Regressão Polinomial.

ABSTRACT

This work proposes the development of a Python application with a Streamlit interface, capable of performing basic reliability analyses in an accessible and interactive manner. The methodology used is characterized as applied and exploratory research, with the tool being built and validated through a computational experiment. The application allows the import of CSV or Excel files containing failure data, in addition to providing a sample dataset. Classic reliability engineering functions are calculated: probability density, cumulative failure, reliability, and failure rate. Curve fitting is performed using polynomial regression, with the coefficient of determination (R^2) used as the model evaluation metric. The tool was validated with real data extracted from the studies by Aguiar (2019) and Viana et al. (2018), presenting results consistent with the reference works. However, the use of polynomial

regression is recognized as a limitation, which, while useful for visualization, can compromise accuracy in more rigorous probabilistic analyses. Suggestions for future work include the inclusion of distributions such as Weibull and Exponential, as well as the incorporation of statistical goodness-of-fit tests.

Keywords: Reliability. LDA. Python. Failure Time. Polynomial Regression.

RESUMEN

Este trabajo propone el desarrollo de una aplicación Python con una interfaz Streamlit, capaz de realizar análisis básicos de confiabilidad de manera accesible e interactiva. La metodología utilizada se caracteriza por ser una investigación aplicada y exploratoria, y la herramienta se construye y valida mediante un experimento computacional. La aplicación permite la importación de archivos CSV o Excel que contienen datos de fallas, además de proporcionar un conjunto de datos de muestra. Se calculan funciones clásicas de ingeniería de confiabilidad: densidad de probabilidad, falla acumulada, confiabilidad y tasa de fallas. El ajuste de curvas se realiza mediante regresión polinomial, con el coeficiente de determinación (R^2) utilizado como métrica de evaluación del modelo. La herramienta se validó con datos reales extraídos de los estudios de Aguiar (2019) y Viana et al. (2018), presentando resultados consistentes con las obras de referencia. Sin embargo, el uso de la regresión polinomial se reconoce como una limitación, que, si bien es útil para la visualización, puede comprometer la precisión en análisis probabilísticos más rigurosos. Se sugieren trabajos futuros como la inclusión de distribuciones como Weibull y Exponencial, así como la incorporación de pruebas estadísticas de bondad de ajuste.

Palabras clave: Confiabilidad. LDA. Python. Tiempo de Fallo. Regresión Polinómica.

1 INTRODUÇÃO

A busca pela excelência operacional e pela vantagem competitiva tem levado organizações de diversos setores a se concentrarem na confiabilidade como um fator estratégico. Esse movimento é impulsionado, principalmente, pela pressão do mercado por redução de custos e pela exigência de maior qualidade em produtos e sistemas. Nesse cenário, a redução da probabilidade de falhas tornou-se uma prioridade, seja pelos custos associados à manutenção corretiva, seja pela necessidade de assegurar a prestação segura de serviços essenciais, como na aviação, em que falhas podem comprometer a segurança pública.

Assim, a confiabilidade de um sistema é a probabilidade de que este desempenhe as funções requeridas por um determinado período e sob condições especificadas (Lewis, 1994). Neste contexto, o autor esclarece que o termo “sistema” é empregado de forma abrangente, podendo referir-se a componentes, subsistemas, entre outros.

Compreendida essa definição, é possível entender por que a confiabilidade tem ganhado tanto destaque nas organizações. O crescente foco na confiabilidade pode ser explicado, principalmente, por dois fatores. O primeiro é que as organizações lidam com uma quantidade cada vez maior de ativos, como instalações, equipamentos e sistemas, que, além de numerosos, também se tornam mais complexos. O segundo ponto é que boa parte do trabalho da engenharia tem sido voltado para melhorar o desempenho desses produtos e sistemas. No entanto, esse foco em performance muitas vezes acaba resultando em projetos menos confiáveis do que aqueles mais antigos e simples. Isso mostra um dos principais desafios da engenharia atual: como alcançar altos níveis de desempenho sem comprometer a confiabilidade (Lewis, 1994; Moubray, 1997; Viana, 2024).

É interessante observar como o aumento de performance pode reduzir a confiabilidade dos equipamentos. Lewis (1994) exemplifica essa relação ao analisar carros de corrida, especificamente no caso das 500 Milhas de Indianápolis. Ao longo dos anos, os tempos médios para completar o percurso foram diminuindo continuamente, indicando um avanço significativo em desempenho. No entanto, a confiabilidade, medida como a probabilidade de os carros completarem a corrida, permaneceu de forma constante abaixo de 50%.

Apesar da crescente ênfase na confiabilidade, muitos sistemas de gerenciamento de manutenção disponíveis no mercado não acompanharam essa evolução. Diversas plataformas apresentam-se obsoletas ou inadequadas para as demandas atuais, revelando limitações que comprometem a aplicação eficaz de estratégias de manutenção preditiva e proativa.

Além disso, esse cenário é agravado pelo fato de que as ferramentas profissionais para realizar uma Life Data Analysis (LDA)¹, uma das técnicas da engenharia da confiabilidade, costumam ter alto custo de aquisição e uma curva de aprendizado elevada. Essa combinação cria uma barreira significativa, dificultando o acesso de estudantes, pesquisadores e entusiastas da área, o que limita a experimentação e a aplicação prática dos conceitos teóricos em problemas reais.

Partindo dessa perspectiva, em ambientes competitivos onde a qualidade da informação é essencial, os dados se consolidam como um pilar estratégico para as organizações. Ferramentas de visualização e análise de dados vêm sendo amplamente utilizadas por diversos agentes das cadeias produtivas, desde produtores até órgãos governamentais. Nesse cenário, soluções de Business Intelligence (BI) têm sido adotadas tanto por pequenas quanto por grandes empresas. Além disso, ferramentas analíticas com foco em funções específicas também vêm ganhando espaço. Um exemplo é a ferramenta desenvolvida neste trabalho, cuja principal vantagem está no fato de permitir a aplicação direta da LDA, sem a necessidade de implementar uma solução completa de BI baseada em *data warehouse*, um tipo de banco de dados voltado à organização e ao tratamento de grandes volumes de informação (Turban et al., 2009).

Diante desse contexto, evidencia-se a necessidade de soluções mais acessíveis, que possibilitem a aplicação prática da Life Data Analysis sem os custos e a complexidade associados às plataformas tradicionais de Business Intelligence. A ferramenta desenvolvida neste trabalho surge como uma resposta a essa demanda, ao oferecer uma alternativa de fácil implementação, voltada tanto ao meio acadêmico quanto às pequenas e médias organizações. Com base nisso, a presente pesquisa propõe-se a responder à seguinte questão: **como desenvolver e validar uma solução em Python, de baixo custo e alta acessibilidade, para realizar uma LDA em formato de dashboard, que possa ser aplicada em contextos acadêmicos e empresariais?**

Diante deste contexto, o objetivo geral deste trabalho é desenvolver e validar uma ferramenta em linguagem Python para a análise estatística de dados de falhas, visando facilitar o estudo e a aplicação de conceitos de Life Data Analysis (LDA). Para atingir esse objetivo, foram definidos os seguintes objetivos específicos: realizar uma revisão bibliográfica sobre os fundamentos da engenharia de confiabilidade e Business Intelligence, desenvolver um script em Python utilizando bibliotecas de código aberto para a modelagem e visualização de dados de tempos até a falha, aplicar a ferramenta desenvolvida em um estudo de caso, utilizando um conjunto de dados públicos para validar sua

¹ *Life Data Analysis* (LDA) é uma metodologia da engenharia da confiabilidade aplicada à modelagem estatística de tempos de falha.

funcionalidade e analisar e discutir os resultados gerados pela ferramenta, demonstrando seu potencial para a tomada de decisão.

Este artigo está estruturado da seguinte forma: a seção 2 descreve a metodologia utilizada para o desenvolvimento e aplicação da ferramenta de BI. A seção 3 apresenta a revisão bibliográfica que fundamenta o trabalho. A seção 4 expõe e analisa os resultados práticos obtidos, seguida pelas considerações finais na seção 5.

2 METODOLOGIA DA PESQUISA

Segundo Turrioni e Mello (2012), autores que escreveram sobre metodologia de pesquisa em engenharia de produção, não há necessariamente um consenso quanto à classificação das pesquisas científicas. No entanto, uma abordagem clássica propõe a divisão em natureza, objetivos e abordagens, sendo que cada uma dessas categorias possui definições específicas ou, em alguns casos, combinações entre si.

Com base no exposto, este estudo é caracterizado como uma pesquisa de natureza aplicada, pois visa desenvolver uma ferramenta que auxilie na análise de tempos de falha, destinada a qualquer pessoa ou organização que tenha interesse em sua utilização. Tal classificação se alinha com a definição de Prodanov e Freitas (2013), para os quais a pesquisa aplicada busca gerar conhecimentos para a resolução de problemas específicos, frequentemente com interesses locais.

Considerando seus objetivos, este estudo caracteriza-se como de natureza exploratória, uma vez que, conforme Prodanov e Freitas (2013) e Turrioni e Mello (2012), abrange uma etapa inicial destinada a fornecer subsídios sobre o tema por meio de revisão bibliográfica e análise de casos exemplares que irão facilitar a compreensão do tema exposto.

Quanto ao método, este trabalho configura-se como um experimento, voltado ao desenvolvimento e aperfeiçoamento de uma ferramenta para análise de dados de falhas. A ferramenta foi construída com base em conjuntos de dados reais obtidos por meio de pesquisas bibliográficas, sendo validada de forma qualitativa para verificar sua capacidade de processar os dados, gerar corretamente os indicadores e facilitar uma análise que antes era considerada complexa.

Para essa abordagem, adotou-se uma combinação de elementos qualitativos, por meio da aplicação de técnicas estatísticas no tratamento e na apresentação dos dados de tempo de falha, gerados como *output* da ferramenta, e quantitativos, expressos na validação empírica da funcionalidade e aplicabilidade do sistema desenvolvido. Nessa perspectiva, conforme destaca Gil (2007), no experimento, o autor atua para que alguma coisa ocorra, a fim de se observar o que se segue, proporcionando um conhecimento amplo e detalhado sobre o fenômeno analisado.

Dessa forma, a metodologia do trabalho foi estruturada em etapas. Primeiramente, realizou-se uma pesquisa teórica por meio de revisão bibliográfica. Em seguida, foi selecionada uma base de dados para o desenvolvimento e implementação da ferramenta em ambiente de programação Python. Por fim, foram analisados estudos que aplicaram a metodologia LDA, com o objetivo de comparar os resultados obtidos e validar a aplicação da ferramenta proposta.

Para a aplicação e desenvolvimento da ferramenta, identificou-se uma biblioteca em Python voltada especificamente para engenharia de confiabilidade, desenvolvida por Reid, M. (2022). Essa biblioteca inclui alguns datasets com dados de tempos de falha. Um desses conjuntos, denominado mileage, com 100 registros de falhas, foi utilizado para elaborar um esboço da aplicação em um ambiente Jupyter Notebook. Embora não haja muitos detalhes sobre a natureza dos dados, a tabela a seguir apresenta uma adaptação dos tempos de falha.

Figura 1 - Dataset Mileage

Tempos de falhas									
32797	37603	16768	15261	38071	39485	26713	45283	25754	41064
47119	26830	43154	20269	35589	25056	35390	16651	32677	27812
33532	25210	22418	14318	44264	28127	40902	27300	29180	28433
55627	16946	14525	19938	20588	29015	22456	36837	28185	36531
11538	30368	52448	32231	25746	10539	35138	21075	22374	45554
34107	24571	28968	44404	28109	41821	27837	27836	41267	8734
26704	43665	32628	32176	29807	49436	28219	47590	33703	32914
9979	55269	31388	42911	16735	37752	21293	21248	36258	28172
10014	29760	26252	18318	28688	43939	31084	21757	30935	26208
22159	17438	31565	37623	22532	27322	27037	17861	49432	24993

Fonte: Adaptado de Reid, M. (2022)

Com a base teórica estabelecida, iniciou-se o desenvolvimento da ferramenta no VSCode, com a criação de um ambiente virtual e instalação das bibliotecas necessárias. A aplicação foi construída em Python utilizando bibliotecas como Streamlit, para o frontend interativo, Pandas e NumPy, para manipulação e cálculo com os dados, Matplotlib, para visualização gráfica, SymPy, para exibição simbólica das equações, Scikit-learn, para validação do modelo de regressão, Reliability, que forneceu dados de exemplo, e Math, para operações matemáticas básicas.

Após a conclusão da etapa de desenvolvimento da ferramenta, foi necessário realizar a busca por estudos que disponibilizassem conjuntos de dados de falhas e que abordassem a análise de confiabilidade para a realização desta pesquisa. A plataforma Google Acadêmico foi escolhida como fonte principal para essa pesquisa. Dessa forma, para garantir a precisão e padronização dos estudos selecionados, decidiu-se adotar os seguintes parâmetros:

- i. Período de Publicação: Trabalhos publicados entre os anos de 2014 e 2024.

- ii. Critério de Seleção: Estudos que apresentassem dados de falhas e tivessem como foco a análise de confiabilidade.
- iii. Palavras-chave Utilizadas: As buscas foram realizadas utilizando os seguintes termos:
 - a) Confiabilidade;
 - b) Manutenção Centrada em Confiabilidade (RCM);
 - c) Análise de dados de vida (*life data analysis*);
 - d) Taxa de falha;
 - e) Dados de falha.

Dentre os trabalhos encontrados, foram utilizados os dados apresentados por Aguiar (2019), que investigou as métricas de confiabilidade e o custo do ciclo de vida do sistema de oscilação de uma máquina de lingotamento contínuo de placas; por Viana et al. (2018), que realizaram um estudo de confiabilidade em motoredutores de transportadores de correia em uma refinaria de alumina. Esses estudos forneceram dados reais de falhas, essenciais para testar e validar a aplicação da ferramenta desenvolvida neste trabalho.

3 FUNDAMENTO DA ENGENHARIA DA CONFIABILIDADE E BUSINESS INTELLIGENCE

Para a continuidade do estudo, foi necessário pesquisar e compreender alguns conceitos, de forma a viabilizar o desenvolvimento de uma ferramenta alinhada aos objetivos deste trabalho. Com isso, foram explorados os principais fundamentos de Business Intelligence e de Engenharia da Confiabilidade.

Dessa forma, verificou-se que os conceitos de confiabilidade e qualidade estão interligados, mas a definição de qualidade também envolve a otimização do desempenho e a redução de custos. Por isso, é importante definir alguns termos para compreender melhor a relação entre qualidade, confiabilidade, segurança e disponibilidade (Lewis, 1994).

A qualidade, primeiramente, pode ser entendida como um objetivo que surge já na definição do projeto. Ela engloba todos os aspectos e características de um produto ou serviço que atendem às necessidades explícitas e implícitas do projeto, além de assegurar baixa variabilidade no desempenho. Qualquer desvio em relação às características ideais, seja por imperfeições no processo de fabricação, variações no ambiente operacional ou deterioração pelo uso, é considerado uma perda de qualidade (Fogliatto; Ribeiro, 2011).

Já a confiabilidade surge como um subconjunto da qualidade, em que a variabilidade de desempenho do produto ou serviço é tão grande que acaba gerando uma falha, ou seja, ele deixa de conseguir executar suas funções requeridas. Com esse conceito, é possível perceber que um produto com baixa variabilidade tende a ser mais confiável. No entanto, a recíproca não é verdadeira, já que um produto pode ter uma alta variabilidade e, por consequência, uma baixa qualidade, mas isso não significa que ele terá, necessariamente, uma baixa confiabilidade (Lewis, 1994).

A disponibilidade, que também é um conceito importante dentro da engenharia da confiabilidade, diz respeito à capacidade de um ativo desempenhar suas funções requeridas, considerando um período de tempo e condições específicas de operação. Esse conceito tem uma ligação direta com a segurança, já que, em muitos casos, uma das principais funções dos equipamentos é justamente garantir a segurança. E segurança, por sua vez, pode ser entendida como a condição em que o risco de causar morte, lesões, doenças ocupacionais, danos a equipamentos ou perdas materiais está controlado dentro de um nível aceitável (Fogliatto; ribeiro, 2011).

Com os principais conceitos já apresentados, foi possível identificar as funções mais relevantes para a realização de uma LDA, além de alguns outros fundamentos, como o tempo até a falha. Esse tempo representa o intervalo em que um equipamento permanece em operação até ocorrer sua primeira falha, sendo considerado que marca o início da operação. O tempo até a falha é tratado como uma variável aleatória, chamada de T , pois está sujeito a variações que não podem ser previstas. O estado da unidade em um tempo t pode ser representado por uma variável de estado, $X(t)$, que assume dois valores: $X(t) = 1$ quando o equipamento está funcionando no tempo t , e $X(t) = 0$ quando ele não está operacional nesse mesmo instante.

Para a definição das funções, considera-se o tempo até a falha como uma variável contínua. Além disso, tomando como base o terceiro postulado da probabilidade, que afirma que, se dois eventos são mutuamente excludentes, a probabilidade de ocorrência de um ou de outro é igual à soma de suas probabilidades, é possível estabelecer a função de confiabilidade. Supondo n_0 como o número de itens idênticos submetidos a testes, e considerando o intervalo de tempo $(t - \Delta t, t)$, sendo $n_f(t)$ o total de itens que falharam e $n_s(t)$ o número de itens que sobreviveram, a função confiabilidade é definida conforme a equação 1:

$$R(t) = \frac{n_s(t)}{n_s(t) + n_f(t)} = \frac{n_s(t)}{n_0} \quad (1)$$

Essa relação representa a probabilidade acumulada de sucesso até o tempo t , ou seja, a chance de a unidade ainda estar funcionando nesse instante (Fogliatto; Ribeiro, 2011; Viana, 2024).

Já a Função de Distribuição Acumulada de Falha (também chamada de função de falha acumulada), que expressa a probabilidade de que uma unidade falhe durante uma operação de duração menor ou igual a t , é representada matematicamente pela equação 2:

$$F(t) = P(T \leq t) = \int_0^t f(u) du, \quad t > 0 \quad (2)$$

Essa equação descreve a chance acumulada de falha ao longo do tempo t , com base na função densidade $f(t)$ que indica como essas falhas estão distribuídas ao longo do tempo (Modarres; Kaminskiy; Krivtsov, 2017; Viana, 2024).

Para se obter a função densidade de probabilidade $f(t)$, basta derivar a função de distribuição acumulada $F(t)$, como mostrado na equação 3 (Fogliatto; Ribeiro, 2011).

$$f(t) = F'(t) = \frac{d}{dt} F(t) \quad (3)$$

Considerando o terceiro postulado da probabilidade e o fato de que a área total sob a curva da função densidade é igual a 1, é possível expressar a função de confiabilidade também por meio da integral complementar da função densidade conforme a equação 4:

$$R(t) = 1 - F(t) = 1 - \int_0^t f(u) du = \int_t^\infty f(u) du \quad (4)$$

Essa forma alternativa reforça a interpretação da confiabilidade como a probabilidade de sucesso da unidade até o tempo t , ou seja, a probabilidade de a unidade ainda estar em operação nesse instante. Por essa razão, $R(t)$ também é conhecida como função de sobrevivência (Modarres; Kaminskiy; Krivtsov, 2017).

Por último, a função taxa de falha, onde essa função representa a taxa condicional de ocorrência de falha em um instante de tempo t , dado que o item permaneceu em funcionamento até imediatamente antes desse instante. E é definido conforme a equação 5.

$$[\lambda = \frac{\text{Frequencia de Falha em um periodo de tempo}}{\text{Numero de Falhas Totais}}] \quad (5)$$

Depois de aprofundar nos conceitos fundamentais da confiabilidade, que permitem a quantificação e análise do tempo de vida de sistemas e componentes ao longo do tempo, é necessário explorar como esses fundamentos podem ser integrados a ferramentas gerenciais para aprimorar a tomada de decisões. Nesse contexto, o Business Intelligence (BI) surge como uma solução muito importante que abrange desde a coleta e armazenamento de dados até a análise e compartilhamento das informações de forma rápida e objetiva, visando fornecer bases para gestores e colaboradores tomarem decisões mais assertivas (Turban, 2009).

Dashboards representam uma das principais ferramentas de Business Intelligence (BI) para a visualização e o acompanhamento de indicadores-chave de desempenho (KPIs) (Turban, 2009). No contexto da Análise de Dados de Vida (LDA), eles permitem representar de forma clara e interativa as funções estatísticas associadas ao comportamento de falhas de ativos, como a função densidade de probabilidade, a função de confiabilidade, a função de falha acumulada e a função de taxa de falha. Ao consolidar informações técnicas complexas em painéis visuais acessíveis, os dashboards facilitam a compreensão rápida dos dados, possibilitando que diferentes níveis da organização acompanhem o desempenho dos equipamentos e tomem decisões com base em evidências.

Após a pesquisa teórica realizada sobre os conceitos de Life Data Analysis (LDA) e Business Intelligence (BI), torna-se necessário apresentar o conceito de ajuste de curva por meio de regressão polinomial, já que este foi o método adotado no estudo. Importante ressaltar, que, quando os dados demonstram um comportamento curvilíneo entre as variáveis, os modelos polinomiais se mostram úteis. Eles também são aplicáveis em situações em que há relações não lineares desconhecidas e, possivelmente, bastante complexas (Montgomery; Peck; Vining, 2009).

Assim, como apresentado por Montgomery, Peck e Vining (2009), a expressão que representa, em termos gerais, o modelo polinomial de ordem k em uma variável é dada pela equação 6

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_k x^k + \varepsilon \quad (6)$$

Neste estudo, após a realização dos ajustes por regressão polinomial, avaliou-se a qualidade desses ajustes nas curvas geradas pela ferramenta desenvolvida por meio do coeficiente de determinação R^2 . Conforme apresentado por Montgomery, Peck e Vining (2009), esse coeficiente indica o quão bem o modelo se ajusta aos dados, representando a proporção da variabilidade da variável dependente explicada pelo modelo de regressão em relação à variabilidade total, e é calculado conforme a equação 7.

$$R^2 = 1 - \frac{SS_{\text{Res}}}{SS_T} \quad (7)$$

Diante deste contexto, observa-se que a integração entre Business Intelligence, Life Data Analysis (LDA) e conceitos estatísticos oferece uma ferramenta poderosa para a melhor avaliação das informações de confiabilidade de componentes e sistemas. A utilização de dashboards para a visualização e interpretação dos dados facilita a tomada de decisões estratégicas, reforçando a importância dessas ferramentas no atual contexto industrial e tecnológico.

4 DESENVOLVIMENTO DA FERRAMENTA

Com o ambiente preparado, o código foi estruturado com a importação das bibliotecas essenciais para o funcionamento da ferramenta. O Quadro 1 apresenta as instruções iniciais do script, responsáveis por carregar os pacotes necessários para a manipulação dos dados, geração de gráficos, aplicação de modelos estatísticos e construção da interface interativa.

Quadro 1 – Importação das bibliotecas utilizadas no projeto

```
import streamlit as st      # Interface web interativa
import numpy as np         # Operações numéricas com arrays
import math                # Funções matemáticas básicas
import matplotlib.pyplot as plt # Geração de gráficos
import pandas as pd        # Manipulação de dados
from reliability.Datasets import mileage # Conjunto de dados para estudo de caso
from sklearn.metrics import r2_score # Validação estatística do modelo
import sympy as sp         # Manipulação de matemática simbólica
```

Fonte: Elaborado pelos autores (2025).

Após a definição inicial das bibliotecas utilizadas no desenvolvimento do projeto, foi realizada a etapa de tratamento dos dados de falha, considerados a matéria-prima para a análise. Com a finalidade de atender os objetivos estabelecidos no estudo, foram implementadas duas opções distintas para a entrada de dados. A primeira disponibiliza um conjunto de dados de exemplo (*mileage*), utilizado para fins de demonstração e validação rápida das funcionalidades da ferramenta. A segunda, mais abrangente, permite que o usuário carregue seus próprios dados por meio de arquivos nos formatos CSV ou Excel, oferecendo maior flexibilidade e aplicabilidade ao sistema desenvolvido.

Após o carregamento de um arquivo pelo usuário, a ferramenta interage com o dataset, solicitando a seleção da coluna específica que contém os tempos de falha. Uma vez selecionada, é executado um tratamento automático para garantir a integridade dos dados: os valores da coluna são convertidos para um formato numérico, e qualquer entrada não-numérica (como textos ou células

vazias) é identificada e descartada do conjunto de análise. Este processo de limpeza é importante para prevenir erros e assegurar que os cálculos seguintes, como os da curva de confiabilidade e da taxa de falha, sejam realizados sobre uma base de informações confiável.

Quadro 2 – Tratamento dos dados de tempos de falha

```
if source_option == 'Dataset de Exemplo (Mileage)':
    ... # Carrega dataset padrão e exibe mensagem de sucesso
else:
    ... # Solicita upload de arquivo CSV ou Excel pelo usuário
    uploaded_file = st.sidebar.file_uploader(...)
    if uploaded_file is not None:
        try:
            if uploaded_file.name.endswith('.csv'):
                ... # Lê arquivo CSV
            else:
                ... # Lê arquivo Excel

            ... # Exibe mensagem de sucesso do upload

            coluna_selecionada = st.sidebar.selectbox(...)
            if coluna_selecionada:
                ... # Converte dados da coluna para valores numéricos válidos
        except Exception as e:
            ... # Exibe mensagem de erro se falhar a leitura
```

Fonte: Elaborado pelos autores (2025).

Depois do tratamento dos dados, são feitos os cálculos que servem de base para a análise de confiabilidade. O primeiro passo é a categorização dos dados de falha em certos intervalos, o que permite a construção do histograma de frequência. Para definir de forma estatística o número ideal de classes (ou bins), a ferramenta utiliza a Regra de Sturges, dada por: $k = 1 + 3,3 \cdot \log_{10}(n)$.

Sendo n o número total de falhas. Essa fórmula ajuda a garantir que a distribuição dos dados fique bem representada, de forma clara e sem perda de detalhes importantes.

Com os intervalos dos histogramas definidos, utiliza-se a biblioteca NumPy para calcular a frequência de falhas em cada classe, gerando assim a função densidade de probabilidade (PDF). A partir dessa densidade, determina-se a probabilidade de falha em cada intervalo e, em seguida, a probabilidade acumulada de falha, representada por $F(t)$, por meio da soma cumulativa desses valores. A curva de confiabilidade, $R(t)$, é obtida diretamente pela equação $R(t) = 1 - F(t)$.

Para o cálculo da taxa de falha, $\lambda(t)$, que dá origem à conhecida "Curva da Banheira", é necessário um processamento mais detalhado. Em cada intervalo, além do número de falhas, deve-se conhecer quantos itens ainda estavam operando no início daquele intervalo, ou seja, os sobreviventes. Esse valor é obtido subtraindo-se do total da população as falhas acumuladas até o início do intervalo.

Assim, a taxa de falha é calculada dividindo-se o número de falhas no intervalo pelo número de sobreviventes naquele ponto, permitindo analisar como o comportamento do componente evolui ao longo do tempo de operação.

Quadro 3 - Cálculos para análise da confiabilidade

```
n = len(dados) # Total de falhas
classes = int(1 + 3.3 * math.log10(n)) # Número de classes (Regra de Sturges)
st.sidebar.info(f"Número de classes (bins): **{classes}**") # Exibe na interface

counts, bin_edges = np.histogram(dados, bins=classes, density=True) # Histograma normalizado
incremento = np.diff(bin_edges) # Largura de cada intervalo (bin)
probabilidades = counts * incremento * 100 # Probabilidade de falha por intervalo (%)
falha_acumulada = np.cumsum(probabilidades) # F(t): falha acumulada
confiabilidade = 100.0 - falha_acumulada # R(t): confiabilidade

frequencia = (counts * incremento) * n # Número absoluto de falhas por intervalo
falha_acumulada_ate = np.concatenate(([0], np.cumsum(frequencia[:-1]))) # Falhas acumuladas até início do intervalo
survivors_at_start_of_bin = n - falha_acumulada_ate # Sobreviventes no início de cada bin

taxa_falhas = np.zeros_like(frequencia, dtype=float) # Inicializa vetor de  $\lambda(t)$ 
for i in range(len(frequencia)):
    ... # Calcula taxa de falha  $\lambda(t)$  por intervalo ou define como NaN
```

Fonte: Elaborado pelos autores (2025).

Após o tratamento dos dados, foi desenvolvido um dashboard com quatro painéis de visualização, para a apresentação dos resultados da análise de confiabilidade. Em cada painel, os dados de falhas são plotados e sobrepostos por suas respectivas curvas de ajuste polinomial, acompanhadas do coeficiente de determinação (R^2), que indica o grau de aderência do modelo aos dados observados. Essa estrutura foi pensada para demonstrar o funcionamento da ferramenta e sua aplicabilidade na representação gráfica das principais funções utilizadas na engenharia da confiabilidade.

Após definida a forma de apresentação das informações no painel, foi estabelecida a disposição de cada métrica em seu respectivo quadrante. No primeiro, ficou a função densidade de probabilidade, por fornecer uma visão inicial do comportamento dos dados. No segundo, foi posicionada a função de falha acumulada ao longo do tempo. O terceiro quadrante ficou reservado para a função de confiabilidade acumulada, que representa a probabilidade de um item continuar operando até determinado instante. Por fim, no último quadrante, foi inserida a função da taxa de falha, permitindo uma análise mais detalhada da variação das falhas ao longo do tempo.

Quadro 4 - Definição do Layout Dashboard

```
# --- Definição do Layout do Dashboard ---
col1, col2 = st.columns(2)
col3, col4 = st.columns(2)

# --- Coluna 1: Função Densidade de Probabilidade ---
with col1:
    ...

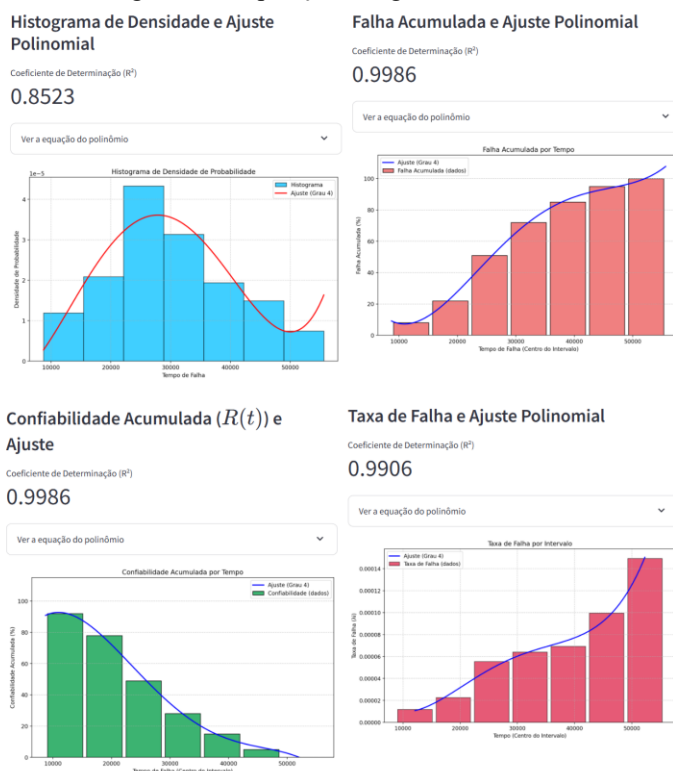
# --- Coluna 2: Função de Falha Acumulada ---
with col2:
    ...

# --- Coluna 3: Função de Confiabilidade Acumulada ---
with col3:
    ...

# --- Coluna 4: Função da Taxa de Falha ---
with col4:
    ...
```

Fonte: Elaborado pelos autores (2025).

Figura 2 - Disposição dos gráficos na tela



Fonte: Elaborado pelos autores (2025).

Além disso, na parte final do código, para facilitar a visualização e permitir a conferência dos resultados por parte do usuário, a ferramenta também exibe uma tabela com as seguintes informações: intervalos de tempo (bin), frequência absoluta de falhas em cada classe (n_i), tamanho de cada classe (h_i), número de sobreviventes no início do intervalo (N_s) e a taxa de falha correspondente (λ_i). Esses

dados permitem uma análise mais detalhada do comportamento do sistema ao longo do tempo, contribuindo para uma interpretação mais precisa da confiabilidade dos componentes analisados.

Figura 3 - Tabela de Cálculo da Taxa de Falha
Tabela de Cálculo da Taxa de Falha

	Intervalo (Bin)	Freq. Abs. (ni)	Tam. Classe (hi)	Sobrev. Início (Ns)	Taxa de Falha (λ_i)
0	8734-15433	8	6699.00	100	0.00001194
1	15433-22132	14	6699.00	92	0.00002272
2	22132-28831	29	6699.00	78	0.00005550
3	28831-35530	21	6699.00	49	0.00006398
4	35530-42229	13	6699.00	28	0.00006931
5	42229-48928	10	6699.00	15	0.00009952
6	48928-55627	5	6699.00	5	0.00014928

Fonte: Elaborado pelos autores (2025).

5 APLICAÇÃO E IMPLEMENTAÇÃO

Assim que foi concluído o desenvolvimento da ferramenta e selecionados os dados para a validação qualitativa, realizou-se a sua implementação. A aplicação teve início com o estudo de Aguiar (2019), que forneceu duas tabelas com tempos de falha, sendo a primeira referente ao sistema de oscilação do molde de uma máquina de lingotamento, e a segunda com os tempos de falha do cilindro oscilador, principal equipamento mecânico do sistema de oscilação.

Para realizar a aplicação dos dados na ferramenta, as tabelas foram extraídas do estudo e convertidas para o formato Excel. Com os arquivos organizados, foi possível selecioná-los e inseri-los na ferramenta desenvolvida, permitindo a obtenção dos dados de vida dos dois equipamentos e a comparação com os resultados apresentados no estudo de Aguiar (2019). No entanto, é importante ressaltar que o ajuste de curva adotado neste trabalho foi do tipo polinomial, enquanto no estudo de Aguiar utilizou-se distribuição de Weibull e distribuição exponencial.

Figura 4 - Tempos de falha sistema de oscilação.

Tempo em Horas de operação				
5368,65	1449,1	50,12	432,97	59,67
48,57	3043	24,47	643,9	5089,93
27498,37	3954,3	7748,32	0,32	644,37
7064,98	6516,02	1027,3	7412,88	6177,57
4558,32	73,33	735,52	5737,63	1320
1957,87	357,75	622,85	779,28	1498,1
1266,73	168,33	432,45	342,42	

Fonte: Adaptado de Aguiar (2019).

Figura 5 - Tempos de falha cilindro oscilador.

Tempo em Horas de operação
36144
68376
9792
47208
17208
3864
26256

Fonte: Adaptado de Aguiar (2019).

Com base nesses dados, foram inicialmente obtidas as curvas de densidade de probabilidade e de falha acumulada, ajustadas por polinômios que, visualmente, apresentaram boa aderência aos dados. O coeficiente de determinação (R^2) se mostrou próximo ou igual a 1, indicando um bom desempenho do modelo de regressão polinomial.

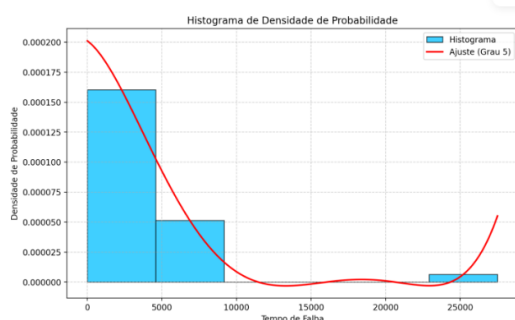
Figura 6 - Curva de densidade de probabilidade e de falha acumulada.

Histograma de Densidade e Ajuste Polinomial

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio




Falha Acumulada e Ajuste Polinomial

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio



Fonte: Elaborado pelos autores (2025).

Na segunda parte, foram geradas as curvas de confiabilidade e taxa de falha, além de uma tabela utilizada para a validação dos dados. Visualmente, as curvas apresentaram boa aderência aos dados, e o coeficiente de determinação (R^2) se mostrou próximo ou igual a 1, evidenciando a qualidade do ajuste polinomial.

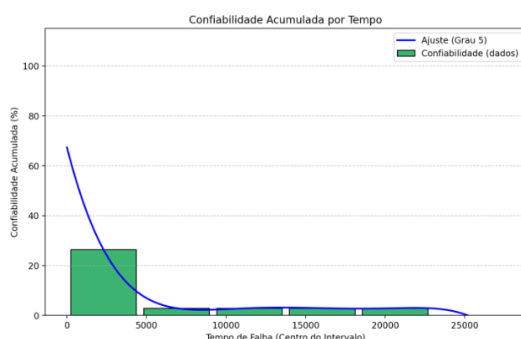
Figura 7 - Curva de confiabilidade e taxa de falha.

Confiabilidade Acumulada ($R(t)$) e Ajuste

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio

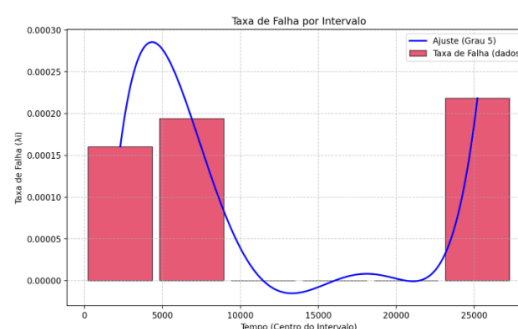


Taxa de Falha e Ajuste Polinomial

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio



Fonte: Elaborado pelos autores (2025).

Por fim, foi construída uma tabela com os dados extraídos das curvas geradas, utilizada para validar as informações obtidas. Nela, são apresentados os intervalos de tempo (bins), a frequência

absoluta de falhas em cada classe, o tamanho da classe, o número de unidades sobreviventes no início do intervalo e a taxa de falha correspondente.

Figura 8 - Tabela de Cálculo da Taxa de Falha.

	Intervalo (Bin)	Freq. Abs. (ni)	Tam. Classe (hi)	Sobrev. Início (Ns)	Taxa de Falha (λ_i)
0	0-4583	25	4583.01	34	0.00016044
1	4583-9166	8	4583.01	9	0.00019395
2	9166-13749	0	4583.01	1	0.00000000
3	13749-18332	0	4583.01	1	0.00000000
4	18332-22915	0	4583.01	1	0.00000000
5	22915-27498	1	4583.01	1	0.00021820

Fonte: Elaborado pelos autores (2025).

Da mesma forma, foi adotado o mesmo procedimento para a segunda tabela, aplicando os mesmos critérios de extração, organização e validação dos dados, o que permitiu a geração das curvas e a análise da taxa de falha associada ao segundo equipamento.

Figura 9 - Curva de densidade de probabilidade e de falha acumulada.


Histograma de Densidade e Ajuste Polinomial

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio

$$f(t) = 7.183 \cdot 10^{-15}t^2 - 6.734 \cdot 10^{-10}t + 2.824 \cdot 10^{-5}$$




Falha Acumulada e Ajuste Polinomial

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio

$$F(t) = -3.979 \cdot 10^{-23}t^2 + 0.001329t + 23.44$$



Fonte: Elaborado pelos autores (2025).

Figura 10 - Curva de confiabilidade e taxa de falha.


Confiabilidade Acumulada ($R(t)$) e Ajuste

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio

$$R(t) = -1.43 \cdot 10^{-23}t^2 - 0.001329t + 76.56$$




Taxa de Falha e Ajuste Polinomial

Coefficiente de Determinação (R^2)

1.0000

Ver a equação do polinômio

$$\lambda(t) = 2.155 \cdot 10^{-14}t^2 - 9.389 \cdot 10^{-10}t + 2.905 \cdot 10^{-5}$$



Fonte: Elaborado pelos autores (2025).

Figura 11 - Tabela de Cálculo da Taxa de Falha.

	Intervalo (Bin)	Freq. Abs. (ni)	Tam. Classe (hi)	Sobrev. Início (Ns)	Taxa de Falha (λi)
0	3864-25368	3	21504.00	7	0.00001993
1	25368-46872	2	21504.00	4	0.00002325
2	46872-68376	2	21504.00	2	0.00004650

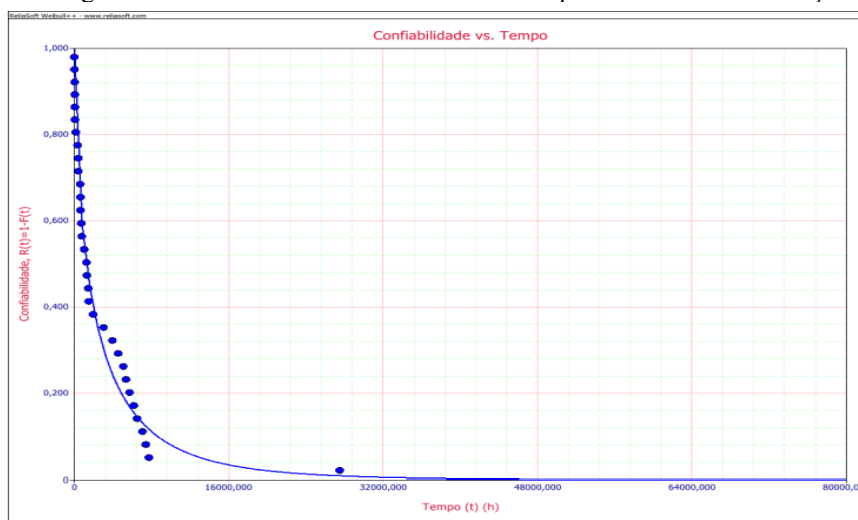
Fonte: Elaborado pelos autores (2025).

O mesmo processo foi aplicado aos dados contidos nos trabalhos de Viana et al. (2018) e Gonçalves (2019). No entanto, os resultados obtidos a partir dessa aplicação serão discutidos na próxima seção, quando será realizada uma comparação com os resultados apresentados nos estudos selecionados.

6 ANÁLISE DOS RESULTADOS

Após a implementação dos primeiros dados na ferramenta, realizou-se a comparação de resultados com os trabalhos selecionados, com o objetivo de demonstrar a capacidade da ferramenta desenvolvida. Como já mencionado, os primeiros tempos de falha foram extraídos do trabalho de Aguiar (2019), no qual os tempos de falha do sistema de oscilação de uma máquina de lingotamento foram ajustados à Distribuição de Weibull e, como resultado, obtiveram-se as seguintes representações gráficas:

Figura 12 - Curva estatística de confiabilidade para o sistema de oscilação.



Fonte: Aguiar (2019).

Neste primeiro gráfico, está representada a curva de confiabilidade do equipamento. Para fins de comparação, a Figura 7 apresenta uma curva semelhante, porém obtida por meio de regressão polinomial com o auxílio da ferramenta desenvolvida neste estudo. A partir da análise visual, é possível observar que, em ambos os gráficos, a confiabilidade do equipamento após 5000 horas é inferior a 20%, indicando comportamentos semelhantes entre as curvas.

No entanto, de acordo com Aguiar (2019), o tempo recomendado para parada preventiva desse equipamento é de 1440 horas, sendo que, para esse intervalo, ele encontrou uma confiabilidade de 0,4703. Já utilizando o cálculo de confiabilidade conforme a Equação 4, com base na função ajustada pela regressão polinomial da curva de distribuição de probabilidade, obteve-se um valor de 0,7243, o que representa uma diferença significativa em relação ao resultado apresentado por Aguiar. Assim, é possível perceber a clara limitação do ajuste polinomial para fins de análise probabilística: a integração da sua PDF ajustada não produz um resultado confiável, como pode-se observar pela operação abaixo.


$$R(t) = 1 - \int_0^{1440} (4,232 \times 10^{-25}t^5 - 2,849 \times 10^{-20}t^4 + 6,556 \times 10^{-16}t^3 - 5,15 \times 10^{-12}t^2 - 9,052 \times 10^{-9}t + 0,0002011) dt$$

Com isso, para validar outra curva, desta vez a da confiabilidade acumulada, foi plotado no gráfico um ponto correspondente a 1440 horas, resultando em uma confiabilidade de 0,419, como pode ser observado na Figura 13. Esse valor se aproxima mais daquele encontrado por Aguiar (2019), que utilizou um ajuste de curva na distribuição de probabilidade Weibull.

Figura 13 - Confiabilidade acumulada.

Coefficiente de Determinação (R^2)

0.9856




Fonte: Elaborado pelos autores (2025).

O segundo conjunto de dados, também contido no trabalho de Aguiar (2019), está representado na Figura 5, agora referente a um cilindro do oscilador. Os resultados das curvas estão plotados nas Figuras 9 e 10. No trabalho selecionado, o ajuste de curva foi feito para uma exponencial. Ele avaliou dois pontos, correspondentes à recomendação de troca do equipamento, que era entre 2,5 anos e 3,5 anos, encontrando valores de confiabilidade iguais a 0,8414 para 2,5 anos e 0,7427 para 3,5 anos. No entanto, os valores encontrados pela ferramenta desenvolvida neste estudo são diferentes, como é possível verificar na Figura 14.

Figura 14 - Confiabilidade acumulada no tempo.

Coefficiente de Determinação (R^2)

1.0000



Fonte: Elaborado pelos autores (2025).

Como já mencionado, as escolhas das curvas de ajuste foram diferentes. Neste estudo, optou-se por utilizar a regressão polinomial, com o objetivo de verificar visualmente qual curva melhor se ajusta aos dados. Para o primeiro equipamento, foi aplicada uma curva de Weibull, enquanto para o segundo utilizou-se uma exponencial. Essa diferença na modelagem ajuda a explicar a variação nos resultados encontrados.

O segundo estudo utilizado como base foi o de Viana et al. (2018), do qual foram extraídos os tempos de falha de um equipamento denominado motoredutor de correias transportadoras, pertencente a uma refinaria de alumínio. Os dados estão apresentados na Figura 15.

Figura 15 - tempos de falha motoredutor

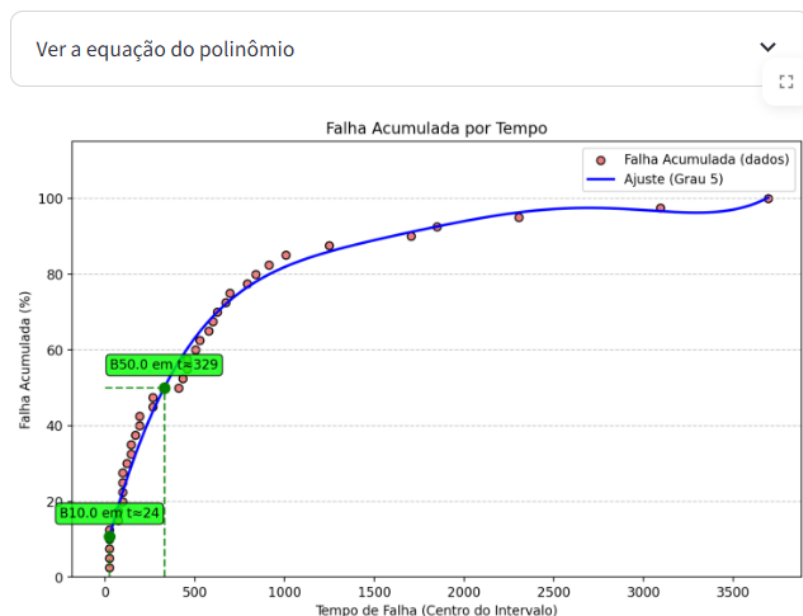
Tempo em horas até a falha do motoredutor									
24	24	24	24	24	72	72	96	96	96
96	120	144	144	168	192	192	264	264	408
432	456	456	504	528	576	600	624	672	696
792	840	912	1008	1248	1704	1848	2304	3096	3696

Fonte: Adaptado de Viana et al. (2018)

No trabalho de referência, os dados de tempo até a falha do motoredutor foram analisados por meio de testes de aderência, utilizando os métodos Qui-Quadrado (χ^2) e Kolmogorov-Smirnov (KS). A partir desses testes, optou-se por seguir com distribuição de Weibull porque apresentava uma boa aderência aos dados, sendo assim, escolhida para modelar o comportamento das falhas. Com base nesta modelagem, foram identificados dois pontos interessantes: os tempos em que ocorreram 10% e 50% dos reparos, estimados em 31,71 horas e 352,58 horas, respectivamente. Ao aplicar a ferramenta desenvolvida neste estudo aos mesmos dados, os valores estimados foram de aproximadamente 24 horas e 329 horas, como apresentado na Figura 16.

Figura 16 - Confiabilidade acumulada em que 10% e 50% dos reparos ocorreram.
Coeficiente de Determinação (R^2)

0.9843



Fonte: Elaborado pelos autores (2025).

Os resultados deste estudo mostram que os tempos de reparo estimados são compatíveis com os apresentados por Viana et al. (2018), com pequenas variações decorrentes das diferentes abordagens de modelagem. Como já mencionado, ao aplicar a Equação 4 na função polinomial gerada a partir dos dados extraídos do estudo de Aguiar (2019), foi obtido um valor de confiabilidade consideravelmente diferente do relatado originalmente. Essa distorção pode ser explicada, em parte, por uma convenção adotada neste trabalho para a curva densidade de probabilidade: a escolha dos centros de classe dos histogramas como pontos de referência para o ajuste do polinômio. Embora essa abordagem proporcione boa aderência visual, sua aplicação em cálculos de probabilidade, como o da confiabilidade acumulada, pode comprometer a precisão dos resultados, mostrando uma limitação importante da ferramenta e da modelagem por regressão polinomial.

7 CONSIDERAÇÕES FINAIS

Em um mercado industrial cada vez mais competitivo e com diversas ferramentas disponíveis, é fundamental escolher aquelas que realmente auxiliem na gestão da manutenção e na engenharia da confiabilidade. Nesse contexto, a gestão da manutenção vai além do simples reparo, assumindo um papel estratégico, com foco em garantir a confiabilidade e a disponibilidade dos equipamentos, a segurança dos colaboradores e a proteção ambiental, conforme os conceitos discutidos ao longo deste

estudo. Este trabalho alinhou essa visão ao desenvolver uma ferramenta de análise voltada a transformar dados brutos de falhas em informações úteis para a tomada de decisão gerencial.

Com isso, a ferramenta desenvolvida possibilita a análise do comportamento da vida útil dos equipamentos, um passo fundamental para a implementação de um plano de manutenção eficaz e para a manutenção centrada em confiabilidade. A principal contribuição deste estudo está na aplicação prática de técnicas de análise de dados, especialmente a LDA, de forma acessível e de baixo custo. Ao fornecer uma base de dados sólida, o script desenvolvido gera dados assertivos e de qualidade, facilitando o entendimento da vida útil dos equipamentos analisados.

Por fim, este trabalho representa um passo inicial na aplicação de modelos analíticos para a engenharia da confiabilidade. Para trabalhos futuros e visando o aprimoramento da ferramenta, será interessante incluir outras distribuições de probabilidade na modelagem das falhas, como as distribuições Weibull e Exponencial. Além disso, a implementação de testes de aderência, como Anderson-Darling ou Kolmogorov-Smirnov, para validar estatisticamente qual distribuição melhor se ajusta aos dados empíricos, será de suma importância, garantindo assim análises mais robustas e precisas.

REFERÊNCIAS

- AGUIAR, Fernando Milagre de. Estudos das métricas de confiabilidade e do custo do ciclo de vida do sistema de oscilação do molde de uma máquina de lingotamento contínuo de placas. 2019. 60 f. Monografia (Especialização em Engenharia da Confiabilidade) – Universidade Tecnológica Federal do Paraná, Curitiba, 2019.
- BARBIERI, Carlos. BI² Business Intelligence: modelagem e qualidade. 2. ed. Rio de Janeiro: Elsevier, 2012.
- FOGLIATTO, Flávio Sanson; DUARTE, José Luis Ribeiro. Confiabilidade e manutenção industrial. Rio de Janeiro: Elsevier: ABEPRO, 2011.
- GIL, Antonio Carlos. Como elaborar projetos de pesquisa. 4. ed. São Paulo: Atlas, 2007.
- LEWIS, E. E. Introduction to reliability engineering. 2. ed. New York: John Wiley & Sons, 1994.
- MODARRES, M.; KAMINSKIY, M.; KRIVTSOV, V. Reliability engineering and risk analysis: a practical guide. 3. ed. Boca Raton: CRC Press, 2017.
- MONTGOMERY, Douglas C.; PECK, Elizabeth A.; VINING, G. Geoffrey. Introduction to linear regression analysis. 5. ed. Hoboken: John Wiley & Sons, 2012.
- MOUBRAY, J. Reliability-centred maintenance. 2. ed. New York: Industrial Press, 1997.
- PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. Novo Hamburgo: Feevale, 2013.
- REID, M. Reliability – a Python library for reliability engineering (Version 0.8.2). [S.l.]: Zenodo, 2022. Disponível em: <https://doi.org/10.5281/ZENODO.3938000>. Acesso em: 6 jun. 2025.
- TURBAN, Efraim et al. Business intelligence: um enfoque gerencial para a inteligência do negócio. Tradução de Vivaldo Jorge. Porto Alegre: Bookman, 2009.
- TURRIONI, João Batista; MELLO, Carlos Henrique Pereira. Metodologia de pesquisa em engenharia de produção: uma apostila. Itajubá: Universidade Federal de Itajubá, [s.d.].
- VIANA, Herbert Ricardo Garcia; MARQUES, Adolfano; BIRANI, Samir; SENA, Salomão; NOBUMASA, Gilberto Hirbickau. Manutenção centrada em confiabilidade: aplicação em motoredutores de transportadores de correias em uma refinaria de alumina. Revista Gestão Industrial, Ponta Grossa, v. 14, n. 2, p. 186-205, abr./jun. 2018. Disponível em: <https://periodicos.utfpr.edu.br/revistagi>. Acesso em: 6 jun. 2025.
- VIANA, Herbert Ricardo Garcia. Curso de gestão e engenharia da manutenção. 1. ed. Natal: Insigne Acadêmica, 2024.